

# Základy biostatistiky

(MS710P09)

ak. rok 2012/2013

Karel Zvára

karel.zvara@mff.cuni.cz

<http://www.karlin.mff.cuni.cz/~zvara>

katedra pravděpodobnosti a matematické statistiky MFF UK

(naposledy upraveno 13. května 2013)



## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika. Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno zapsat se do paralelky prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, interpretace výsledků
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika. Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, interpretace výsledků
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika. Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika, Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, interpretace výsledků
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika, Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, interpretace výsledků
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika, Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika, Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)



## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika, Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika, Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika, Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika, Karolinum 1998, ..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvára>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika. Karolinum 1998, . . . , 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvara>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika. Karolinum 1998,..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvara>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika. Karolinum 1998,..., 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvara>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)

## ▶ cvičení na počítačích v B5

- ▶ od úterý 19. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)

## ▶ zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ▶ literatura

- ▶ K. Zvára: Biostatistika. Karolinum 1998, . . . , 2008
- ▶ internetová stránka <http://www.karlin.mff.cuni.cz/~zvara>

## ▶ konzultace

- po 15:00–15:30 K157, Sokolovská 83 (KPMS MFF UK)
- út 10:00– prac. 209, Albertov 6 (ÚAMVT PŘF UK)
- po dohodě (např. ráno před přednáškou v B7)



# tři části přednášky

odpadne jedna přednáška, také některá cvičení

## ▶ popisná statistika

- ▶ několika čísky vystihnout důležitou vlastnost
- ▶ jednoduchým grafem vyjádřit důležitou vlastnost
- ▶ porovnat soubory dat

## ▶ abstraktní pohled (teorie)

- ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
- ▶ populace a výběr
- ▶ popisné statistiky jako odhady populačních parametrů
- ▶ interval spolehlivosti pro parametr
- ▶ test statistické hypotézy

## ▶ některé metody (modely)

- ▶ testy o jednom, dvou či několika výběrech
- ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků

## ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

# tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ **popisná statistika**
  - ▶ **několika čísla vystihnout důležitou vlastnost**
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ **abstraktní pohled (teorie)**
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ **některé metody (modely)**
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

# tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ **popisná statistika**
  - ▶ **několika čísla vystihnout důležitou vlastnost**
  - ▶ **jednoduchým grafem vyjádřit důležitou vlastnost**
  - ▶ **porovnat soubory dat**
- ▶ **abstraktní pohled (teorie)**
  - ▶ **pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost**
  - ▶ **populace a výběr**
  - ▶ **popisné statistiky jako odhady populačních parametrů**
  - ▶ **interval spolehlivosti pro parametr**
  - ▶ **test statistické hypotézy**
- ▶ **některé metody (modely)**
  - ▶ **testy o jednom, dvou či několika výběrech**
  - ▶ **rozhodování o závislosti kvantitativních či kvalitativních znaků**
- ▶ **cílem jsou principy, pojmy, základní metody, nikoliv vzorečky**

# tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ **popisná statistika**
  - ▶ několika čísla vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ **abstraktní pohled (teorie)**
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ **některé metody (modely)**
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

# tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísky vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

# tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísla vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

# tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísla vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
    - ▶ popisné statistiky jako odhady populačních parametrů
    - ▶ interval spolehlivosti pro parametr
    - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

# tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísla vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
    - ▶ interval spolehlivosti pro parametr
    - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky



## tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísly vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

# tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísly vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

# tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísly vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

## tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísly vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

## tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísly vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

## tři části přednášky

odpadne jedna přednáška, také některá cvičení

- ▶ popisná statistika
  - ▶ několika čísly vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro parametr
  - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé



## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé



## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo, interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména nadstavba Rcmdr
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ volně šiřitelný SW
  - ▶ pracují v něm mnozí další učitelé

# statistika

nejzákladnější dělení, dvojitý pohled

## ▶ statistika

- ▶ **popisná** (deskriptivní):  
data stručně popsat, něco z dat „vydolovat“  
tvrdit něco o daných datech, nezobecňovat
- ▶ **induktivní** (konfirmatorní):  
tvrdit něco nového, zobecnit na větší soubor,  
důležitá je interpretace

## ▶ příklady dat:

- ▶ **výšky**: výška desetiletých chlapců/dívek
- ▶ **děti**: pohlaví, porodní hmotnost a délka, hmotnost a délka v jednom roce, věk otce a matky, počet onemocnění otitidou v prvním roce věku
- ▶ **kojení**: hmotnost a délka porodní a ve 24. týdnu, věk a výška obou rodičů, zda těhotenství plánováno, zda dudlík, porodnice

# statistika

nejzákladnější dělení, dvojitý pohled

## ▶ statistika

- ▶ **popisná** (deskriptivní):  
data stručně popsat, něco z dat „vydolovat“  
tvrdit něco o daných datech, nezobecňovat
- ▶ **induktivní** (konfirmatorní):  
tvrdit něco nového, zobecnit na větší soubor,  
důležitá je interpretace

## ▶ příklady dat:

- ▶ **výšky**: výška desetiletých chlapců/dívek
- ▶ **děti**: pohlaví, porodní hmotnost a délka, hmotnost a délka v jednom roce, věk otce a matky, počet onemocnění otitidou v prvním roce věku
- ▶ **kojení**: hmotnost a délka porodní a ve 24. týdnu, věk a výška obou rodičů, zda těhotenství plánováno, zda dudlík, porodnice

# statistika

nejzákladnější dělení, dvojitý pohled

## ▶ statistika

- ▶ **popisná** (deskriptivní):  
data stručně popsat, něco z dat „vydolovat“  
tvrdit něco o daných datech, nezobecňovat
- ▶ **induktivní** (konfirmatorní):  
tvrdit něco nového, zobecnit na větší soubor,  
důležitá je interpretace

## ▶ příklady dat:

- ▶ výšky: výška desetiletých chlapců/dívek
- ▶ děti: pohlaví, porodní hmotnost a délka, hmotnost a délka v jednom roce, věk otce a matky, počet onemocnění otitidou v prvním roce věku
- ▶ kojení: hmotnost a délka porodní a ve 24. týdnu, věk a výška obou rodičů, zda těhotenství plánováno, zda dudlík, porodnice

# statistika

nejzákladnější dělení, dvojitý pohled

## ▶ statistika

- ▶ **popisná** (deskriptivní):  
data stručně popsat, něco z dat „vydolovat“  
tvrdit něco o daných datech, nezobecňovat
- ▶ **induktivní** (konfirmatorní):  
tvrdit něco nového, zobecnit na větší soubor,  
důležitá je interpretace

## ▶ příklady dat:

- ▶ **výšky**: výška desetiletých chlapců/dívek
- ▶ **děti**: pohlaví, porodní hmotnost a délka, hmotnost a délka v jednom roce, věk otce a matky, počet onemocnění otitidou v prvním roce věku
- ▶ **kojení**: hmotnost a délka porodní a ve 24. týdnu, věk a výška obou rodičů, zda těhotenství plánováno, zda dudlík, porodnice

# statistika

nejzákladnější dělení, dvojitý pohled

## ▶ statistika

- ▶ **popisná** (deskriptivní):  
data stručně popsat, něco z dat „vydolovat“  
tvrdit něco o daných datech, nezobecňovat
- ▶ **induktivní** (konfirmatorní):  
tvrdit něco nového, zobecnit na větší soubor,  
důležitá je interpretace

## ▶ příklady dat:

- ▶ **výšky**: výška desetiletých chlapců/dívek
- ▶ **děti**: pohlaví, porodní hmotnost a délka, hmotnost a délka v jednom roce, věk otce a matky, počet onemocnění otitidou v prvním roce věku
- ▶ **kojení**: hmotnost a délka porodní a ve 24. týdnu, věk a výška obou rodičů, zda těhotenství plánováno, zda dudlík, porodnice

# statistika

nejzákladnější dělení, dvojitý pohled

## ▶ statistika

- ▶ **popisná** (deskriptivní):  
data stručně popsat, něco z dat „vydolovat“  
tvrdit něco o daných datech, nezobecňovat
- ▶ **induktivní** (konfirmatorní):  
tvrdit něco nového, zobecnit na větší soubor,  
důležitá je interpretace

## ▶ příklady dat:

- ▶ **výšky**: výška desetiletých chlapců/dívek
- ▶ **děti**: pohlaví, porodní hmotnost a délka, hmotnost a délka v jednom roce, věk otce a matky, počet onemocnění otitidou v prvním roce věku
- ▶ **kojení**: hmotnost a délka porodní a ve 24. týdnu, věk a výška obou rodičů, zda těhotenství plánováno, zda dudlík, porodnice



# statistika

nejzákladnější dělení, dvojitý pohled

## ▶ statistika

- ▶ **popisná** (deskriptivní):  
data stručně popsat, něco z dat „vydolovat“  
tvrdit něco o daných datech, nezobecňovat
- ▶ **induktivní** (konfirmatorní):  
tvrdit něco nového, zobecnit na větší soubor,  
důležitá je interpretace

## ▶ příklady dat:

- ▶ **výšky**: výška desetiletých chlapců/dívek
- ▶ **děti**: pohlaví, porodní hmotnost a délka, hmotnost a délka v jednom roce, věk otce a matky, počet onemocnění otitidou v prvním roce věku
- ▶ **kojení**: hmotnost a délka porodní a ve 24. týdnu, věk a výška obou rodičů, zda těhotenství plánováno, zda dudlík, porodnice

## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků (umožní to vyšetřování závislosti)
- ▶ měříme na skupinách jednotek – **souborech**
- ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
- ▶ hodnoty znaků zjišťujeme u jedinců, chceme vypovídat celých souborech jedinců
- ▶ kolik procent mužů ve věku 20–25 let kouří?

## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
  - ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
  - ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
  - ▶ na jedné jednotce můžeme měřit několik znaků (umožní to vyšetřování závislosti)
  - ▶ měříme na skupinách jednotek – **souborech**
  - ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
  - ▶ hodnoty znaků zjišťujeme u jedinců, chceme vypovídat celých souborech jedinců
  - ▶ kolik procent mužů ve věku 20–25 let kouří?

## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků (umožní to vyšetřování závislosti)
- ▶ měříme na skupinách jednotek – **souborech**
- ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
- ▶ hodnoty znaků zjišťujeme u jedinců, chceme vypovídat celých souborech jedinců
- ▶ kolik procent mužů ve věku 20–25 let kouří?

## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků (umožní to vyšetřování závislosti)
- ▶ měříme na skupinách jednotek – **souborech**
- ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
- ▶ hodnoty znaků zjišťujeme u jedinců, chceme vypovídat celých souborech jedinců
- ▶ kolik procent mužů ve věku 20–25 let kouří?

## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků (umožní to vyšetřování závislosti)
- ▶ měříme na skupinách jednotek – **souborech**
- ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
- ▶ hodnoty znaků zjišťujeme u jedinců, chceme vypovídat celých souborech jedinců
- ▶ kolik procent mužů ve věku 20–25 let kouří?

## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků (umožní to vyšetřování závislosti)
- ▶ měříme na skupinách jednotek – **souborech**
  - ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
  - ▶ hodnoty znaků zjišťujeme u jedinců, chceme vypovídat celých souborech jedinců
  - ▶ kolik procent mužů ve věku 20–25 let kouří?

## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků (umožní to vyšetřování závislosti)
- ▶ měříme na skupinách jednotek – **souborech**
- ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
- ▶ hodnoty znaků zjišťujeme u jedinců, chceme vypovídat celých souborech jedinců
- ▶ kolik procent mužů ve věku 20–25 let kouří?



## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků (umožní to vyšetřování závislosti)
- ▶ měříme na skupinách jednotek – **souborech**
- ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
- ▶ hodnoty znaků zjišťujeme u jedinců, chceme vypovídat celých souborech jedinců
- ▶ kolik procent mužů ve věku 20–25 let kouří?

## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků (umožní to vyšetřování závislosti)
- ▶ měříme na skupinách jednotek – **souborech**
- ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
- ▶ hodnoty znaků zjišťujeme u jedinců, chceme vypovídat celých souborech jedinců
- ▶ kolik procent mužů ve věku 20–25 let kouří?

# měřítko

- ▶ **nula-jedničkové**  
pouze dvě možné hodnoty (muž/žena, kouří/nekouří)
- ▶ **nominální**  
seznam všech jednoznačně rozlišitelných hodnot,  
**faktor** (porodnice, pohlaví, odrůda)
- ▶ **ordinální**  
hodnoty nominálního měřítka jsou uspořádány,  
**uspořádaný faktor** (vzdělání matky, stupeň bolesti)
- ▶ **intervalové**  
stejně vzdálenosti sousedních hodnot (rok narození)  
„o kolik je x menší než y“ (nikoliv „kolikrát“)
- ▶ **poměrové**  
srovnání se zvolenou jednotkou (hmotnost, výška, věk)  
„kolikrát je x větší, než y“

# měřítko

- ▶ **nula-jedničkové**  
pouze dvě možné hodnoty (muž/žena, kouří/nekouří)
- ▶ **nominální**  
seznam všech jednoznačně rozlišitelných hodnot,  
**faktor** (porodnice, pohlaví, odrůda)
- ▶ **ordinální**  
hodnoty nominálního měřítka jsou uspořádány,  
**uspořádaný faktor** (vzdělání matky, stupeň bolesti)
- ▶ **intervalové**  
stejně vzdálenosti sousedních hodnot (rok narození)  
„o kolik je x menší než y“ (nikoliv „kolikrát“)
- ▶ **poměrové**  
srovnání se zvolenou jednotkou (hmotnost, výška, věk)  
„kolikrát je x větší, než y“

# měřítko

- ▶ **nula-jedničkové**  
pouze dvě možné hodnoty (muž/žena, kouří/nekouří)
- ▶ **nominální**  
seznam všech jednoznačně rozlišitelných hodnot,  
**faktor** (porodnice, pohlaví, odrůda)
- ▶ **ordinální**  
hodnoty nominálního měřítka jsou uspořádány,  
**uspořádaný faktor** (vzdělání matky, stupeň bolesti)
- ▶ **intervalové**  
stejně vzdálenosti sousedních hodnot (rok narození)  
„o kolik je x menší než y“ (nikoliv „kolikrát“)
- ▶ **poměrové**  
srovnání se zvolenou jednotkou (hmotnost, výška, věk)  
„kolikrát je x větší, než y“

# měřítko

- ▶ **nula-jedničkové**  
pouze dvě možné hodnoty (muž/žena, kouří/nekouří)
- ▶ **nominální**  
seznam všech jednoznačně rozlišitelných hodnot,  
**faktor** (porodnice, pohlaví, odrůda)
- ▶ **ordinální**  
hodnoty nominálního měřítka jsou uspořádány,  
**uspořádaný faktor** (vzdělání matky, stupeň bolesti)
- ▶ **intervalové**  
stejně vzdálenosti sousedních hodnot (rok narození)  
„**o kolik** je  $x$  menší než  $y$ “ (nikoliv „kolikrát“)
- ▶ **poměrové**  
srovnání se zvolenou jednotkou (hmotnost, výška, věk)  
„**kolikrát** je  $x$  větší, než  $y$ “

# měřítko

- ▶ **nula-jedničkové**  
pouze dvě možné hodnoty (muž/žena, kouří/nekouří)
- ▶ **nominální**  
seznam všech jednoznačně rozlišitelných hodnot,  
**faktor** (porodnice, pohlaví, odrůda)
- ▶ **ordinální**  
hodnoty nominálního měřítka jsou uspořádány,  
**uspořádaný faktor** (vzdělání matky, stupeň bolesti)
- ▶ **intervalové**  
stejně vzdálenosti sousedních hodnot (rok narození)  
„**o kolik** je  $x$  menší než  $y$ “ (nikoliv „kolikrát“)
- ▶ **poměrové**  
srovnání se zvolenou jednotkou (hmotnost, výška, věk)  
„**kolikrát** je  $x$  větší, než  $y$ “

# hrubší dělení měřítek

(bezprostředně ovlivní volbu metod)

- ▶ **kvalitativní**  
nula-jedničkové, nominální, zpravidla i ordinální
- ▶ u kvalitativních se zpravidla udávají **četnosti** jednotlivých hodnot (kolikrát která hodnota nastala)
- ▶ **kvantitativní** (spojité)  
intervalové, poměrové, někdy ordinální (ale není spojité)
- ▶ hodnoty kvantitativních – čísla
- ▶ pro četnosti hodnot v kvalitativním měřítku se používají zpravidla jiné charakteristiky a metody, než pro hodnoty v kvantitativním měřítku



# hrubší dělení měřítek

(bezprostředně ovlivní volbu metod)

- ▶ **kvalitativní**  
nula-jedničkové, nominální, zpravidla i ordinální
- ▶ u kvalitativních se zpravidla udávají **četnosti** jednotlivých hodnot (kolikrát která hodnota nastala)
- ▶ **kvantitativní** (spojité)  
intervalové, poměrové, někdy ordinální (ale není spojitě)
- ▶ hodnoty kvantitativních – čísla
- ▶ pro četnosti hodnot v kvalitativním měřítku se používají zpravidla jiné charakteristiky a metody, než pro hodnoty v kvantitativním měřítku

# hrubší dělení měřítek

(bezprostředně ovlivní volbu metod)

- ▶ **kvalitativní**  
nula-jedničkové, nominální, zpravidla i ordinální
- ▶ u kvalitativních se zpravidla udávají **četnosti** jednotlivých hodnot (kolikrát která hodnota nastala)
- ▶ **kvantitativní** (spojité)  
intervalové, poměrové, někdy ordinální (ale není spojité)
- ▶ hodnoty kvantitativních – čísla
- ▶ pro četnosti hodnot v kvalitativním měřítku se používají zpravidla jiné charakteristiky a metody, než pro hodnoty v kvantitativním měřítku

# hrubší dělení měřítek

(bezprostředně ovlivní volbu metod)

- ▶ **kvalitativní**  
nula-jedničkové, nominální, zpravidla i ordinální
- ▶ u kvalitativních se zpravidla udávají **četnosti** jednotlivých hodnot (kolikrát která hodnota nastala)
- ▶ **kvantitativní** (spojité)  
intervalové, poměrové, někdy ordinální (ale není spojité)
- ▶ hodnoty kvantitativních – čísla
- ▶ pro četnosti hodnot v kvalitativním měřítku se používají zpravidla jiné charakteristiky a metody, než pro hodnoty v kvantitativním měřítku

# hrubší dělení měřítek

(bezprostředně ovlivní volbu metod)

- ▶ **kvalitativní**  
nula-jedničkové, nominální, zpravidla i ordinální
- ▶ u kvalitativních se zpravidla udávají **četnosti** jednotlivých hodnot (kolikrát která hodnota nastala)
- ▶ **kvantitativní** (spojité)  
intervalové, poměrové, někdy ordinální (ale není spojité)
- ▶ hodnoty kvantitativních – čísla
- ▶ pro četnosti hodnot v kvalitativním měřítku se používají zpravidla jiné charakteristiky a metody, než pro hodnoty v kvantitativním měřítku

# veličina, statistika

- ▶ číselně vyjádřený výsledek měření, pokusu
- ▶ **spojitá veličina**: možné hodnoty znaků v intervalovém nebo poměrovém měřítku jsou hustě rozmístěné
- ▶ **diskrétní veličina**: četnosti hodnot znaků v nula-jedničkovém, nominálním (či ordinálním) měřítku
- ▶ u veličin používáme číselné charakteristiky některých hromadných vlastností (**charakteristiky polohy**, **charakteristiky variability**, charakteristiky tvaru)
- ▶ **statistika** (další význam slova) – funkce pozorovaných hodnot např. průměrná teplota nebo nejvyšší teplota v roce; číselně charakterizuje důležitou vlastnost veličiny (veličin), společná vlastnost skupiny statistických jednotek

# veličina, statistika

- ▶ číselně vyjádřený výsledek měření, pokusu
- ▶ **spojitá veličina**: možné hodnoty znaků v intervalovém nebo poměrovém měřítku jsou hustě rozmístěné
- ▶ **diskrétní veličina**: četnosti hodnot znaků v nula-jedničkovém, nominálním (či ordinálním) měřítku
- ▶ u veličin používáme číselné charakteristiky některých hromadných vlastností (**charakteristiky polohy**, **charakteristiky variability**, charakteristiky tvaru)
- ▶ **statistika** (další význam slova) – funkce pozorovaných hodnot např. průměrná teplota nebo nejvyšší teplota v roce; číselně charakterizuje důležitou vlastnost veličiny (veličin), společná vlastnost skupiny statistických jednotek

## veličina, statistika

- ▶ číselně vyjádřený výsledek měření, pokusu
- ▶ **spojitá veličina**: možné hodnoty znaků v intervalovém nebo poměrovém měřítku jsou hustě rozmístěné
- ▶ **diskrétní veličina**: četnosti hodnot znaků v nula-jedničkovém, nominálním (či ordinálním) měřítku
- ▶ u veličin používáme číselné charakteristiky některých hromadných vlastností (**charakteristiky polohy**, **charakteristiky variability**, charakteristiky tvaru)
- ▶ **statistika** (další význam slova) – funkce pozorovaných hodnot např. průměrná teplota nebo nejvyšší teplota v roce; číselně charakterizuje důležitou vlastnost veličiny (veličin), společná vlastnost skupiny statistických jednotek

## veličina, statistika

- ▶ číselně vyjádřený výsledek měření, pokusu
- ▶ **spojitá veličina**: možné hodnoty znaků v intervalovém nebo poměrovém měřítku jsou hustě rozmístěné
- ▶ **diskrétní veličina**: četnosti hodnot znaků v nula-jedničkovém, nominálním (či ordinálním) měřítku
- ▶ u veličin používáme číselné charakteristiky některých hromadných vlastností (**charakteristiky polohy**, **charakteristiky variability**, charakteristiky tvaru)
- ▶ **statistika** (další význam slova) – funkce pozorovaných hodnot např. průměrná teplota nebo nejvyšší teplota v roce; číselně charakterizuje důležitou vlastnost veličiny (veličin), společná vlastnost skupiny statistických jednotek



## veličina, statistika

- ▶ číselně vyjádřený výsledek měření, pokusu
- ▶ **spojitá veličina**: možné hodnoty znaků v intervalovém nebo poměrovém měřítku jsou hustě rozmístěné
- ▶ **diskrétní veličina**: četnosti hodnot znaků v nula-jedničkovém, nominálním (či ordinálním) měřítku
- ▶ u veličin používáme číselné charakteristiky některých hromadných vlastností (**charakteristiky polohy**, **charakteristiky variability**, charakteristiky tvaru)
- ▶ **statistika** (další význam slova) – funkce pozorovaných hodnot např. průměrná teplota nebo nejvyšší teplota v roce; číselně charakterizuje důležitou vlastnost veličiny (veličin), společná vlastnost skupiny statistických jednotek

## označení

rozlišujte  $n$ ,  $n_i$ ,  $m$ ,  $x_i$ ,  $x_i^*$  (nemusí být čísla)

$x_1,$	$x_2,$	$\dots,$	$x_n$	zjištěné hodnoty
$x_1^*,$	$x_2^*,$	$\dots,$	$x_m^*$	možné hodnoty (různé)
$n_1,$	$n_2,$	$\dots,$	$n_m$	<b>četnosti</b> hodnot

$$n_1 + n_2 + \dots + n_m = \sum_{j=1}^m n_j = n$$

$$\frac{n_1}{n}, \frac{n_2}{n}, \dots, \frac{n_m}{n} \quad - \text{relativní četnosti}$$

$$N_j = \sum_{i=1}^j n_i \quad \text{kumulativní četnosti}$$

pro kumulativní četnosti nutno aspoň ordinální měřítko

# histogram (barplot u kvalitativní veličiny)

- ▶ **histogram**

grafické znázornění intervalových četností spojité veličiny

- ▶ **barplot**

grafické znázornění četností (počtů hodnot) kvalitativního znaku

- ▶ plocha (výška) obdélníku úměrná četnosti

- ▶ relativní četnosti mají jen jiné měřítko svislé osy

- ▶ **výsečový diagram** pro relativní četnosti kvalitativního znaku (podíly nějakého celku)

## histogram (barplot u kvalitativní veličiny)

- ▶ **histogram**

grafické znázornění intervalových četností spojité veličiny

- ▶ **barplot**

grafické znázornění četností (počtů hodnot) kvalitativního znaku

- ▶ plocha (výška) obdélníku úměrná četnosti
- ▶ relativní četnosti mají jen jiné měřítko svislé osy
- ▶ **výsečový diagram** pro relativní četnosti kvalitativního znaku (podíly nějakého celku)

## histogram (barplot u kvalitativní veličiny)

- ▶ **histogram**

grafické znázornění intervalových četností spojité veličiny

- ▶ **barplot**

grafické znázornění četností (počtů hodnot) kvalitativního znaku

- ▶ plocha (výška) obdélníku úměrná četnosti

- ▶ relativní četnosti mají jen jiné měřítko svislé osy

- ▶ **výsečový diagram** pro relativní četnosti kvalitativního znaku (podíly nějakého celku)

## histogram (barplot u kvalitativní veličiny)

- ▶ **histogram**

grafické znázornění intervalových četností spojité veličiny

- ▶ **barplot**

grafické znázornění četností (počtů hodnot) kvalitativního znaku

- ▶ plocha (výška) obdélníku úměrná četnosti

- ▶ relativní četnosti mají jen jiné měřítko svislé osy

- ▶ **výsečový diagram** pro relativní četnosti kvalitativního znaku (podíly nějakého celku)

## histogram (barplot u kvalitativní veličiny)

- ▶ **histogram**

grafické znázornění intervalových četností spojité veličiny

- ▶ **barplot**

grafické znázornění četností (počtů hodnot) kvalitativního znaku

- ▶ plocha (výška) obdélníku úměrná četnosti

- ▶ relativní četnosti mají jen jiné měřítko svislé osy

- ▶ **výsečový diagram** pro relativní četnosti kvalitativního znaku (podíly nějakého celku)

## příklad hod kostkou A – barplot

zpracování četností (kostka A), nominální měřítko s šesti hodnotami

$j$	$n_j$	$f_j = n_j/n$
1	12	0,12
2	21	0,21
3	14	0,14
4	15	0,15
5	21	0,21
6	17	0,17
	<hr/>	
	$n = 100$	1,00



# příklad hod kostkou A – barplot

zpracování četností (kostka A), nominální měřítko s šesti hodnotami

$j$		$n_j$	$f_j = n_j/n$
1	### ### )	12	0,12
2	### ### ### ### )	21	0,21
3	### ###	14	0,14
4	### ### ###	15	0,15
5	### ### ### ### )	21	0,21
6	### ### ###	17	0,17
		<hr/> $n = 100$	<hr/> 1,00

# příklad hod kostkou A – barplot

zpracování četností (kostka A), nominální měřítko s šesti hodnotami

$j$		$n_j$	$f_j = n_j/n$
1	### ### )	12	0,12
2	### ### ### ### )	21	0,21
3	### ###	14	0,14
4	### ### ###	15	0,15
5	### ### ### ### )	21	0,21
6	### ### ###	17	0,17
		<hr/> $n = 100$	<hr/> 1,00

# příklad hod kostkou A – barplot


zpracování četností (kostka A), nominální měřítko s šesti hodnotami

$j$		$n_j$	$f_j = n_j/n$
1	### ### )	12	0,12
2	### ### ### ### )	21	0,21
3	### ###	14	0,14
4	### ### ###	15	0,15
5	### ### ### ### )	21	0,21
6	### ### ###	17	0,17
		<hr/>	
		$n = 100$	<b>1,00</b>

## příklad hod kostkou A – barplot

zpracování četností (kostka A), nominální měřítko s šesti hodnotami

$j$		$n_j$	$f_j = n_j/n$
1	### ### )	12	0,12
2	### ### ### ### )	21	0,21
3	### ###	14	0,14
4	### ### ###	15	0,15
5	### ### ### ### )	21	0,21
6	### ### ###	17	0,17
<hr/>		$n = 100$	<b>1,00</b>



## příklad hod kostkou B – barplot

zpracování četností (kostka B), nominální měřítko s šesti hodnotami

$j$	$n_j$	$f_j = n_j/n$
1	15	0,15
2	16	0,16
3	7	0,07
4	6	0,06
5	15	0,15
6	41	0,41
	<hr/>	
	$n = 100$	

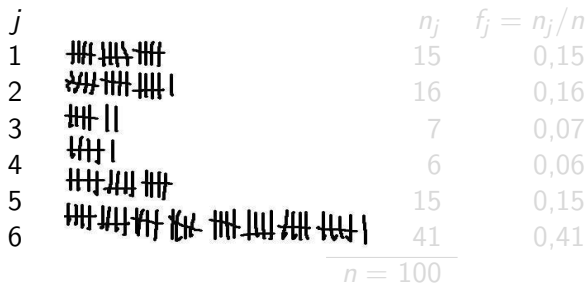
## příklad hod kostkou B – barplot

zpracování četností (kostka B), nominální měřítko s šesti hodnotami

$j$		$n_j$	$f_j = n_j/n$
1	### ### ###	15	0,15
2	### ### ###	16	0,16
3	###	7	0,07
4	###	6	0,06
5	### ### ###	15	0,15
6	### ### ### ### ### ### ### ### ### ###	41	0,41
		$n = 100$	

## příklad hod kostkou B – barplot

zpracování četností (kostka B), nominální měřítko s šesti hodnotami



# příklad hod kostkou B – barplot

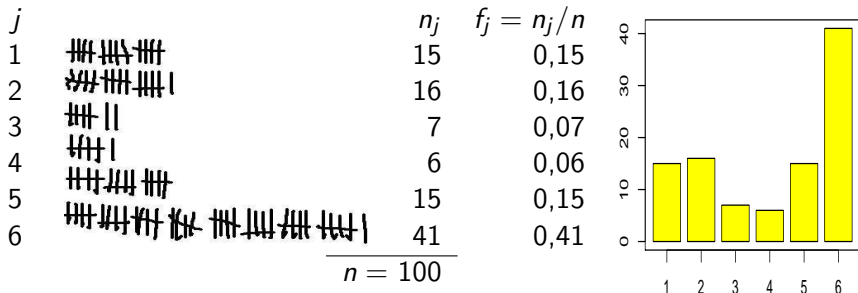
zpracování četností (kostka B), nominální měřítko s šesti hodnotami

$j$		$n_j$	$f_j = n_j/n$
1	### ### ###	15	0,15
2	### ### ###	16	0,16
3	###	7	0,07
4	###	6	0,06
5	### ### ###	15	0,15
6	### ### ### ### ### ### ### ### ###	41	0,41
		<hr/>	
		$n = 100$	



## příklad hod kostkou B – barplot



zpracování četností (kostka B), nominální měřítko s šesti hodnotami



příklad **kojení** (vzdělání 99 matek)

ordinální měřítko se třemi hodnotami

vzděl.	zákl.	maturita	VŠ	celkem	pozn.
$x_j^*$	1	2	3		možné hodnoty
$n_j$	34	47	18	99	absolutní čet.
$n_j/n$	0,343	0,475	0,182	1,000	relativní čet.
$n_j/n$	34,3 %	47,5 %	18,2 %	100 %	relativní čet.
$N_j$	34	81	99		kumulativní čet.



## histogram u spojité veličiny



**třídění:** všechny hodnoty z daného intervalu  $(t_{j-1}, t_j)$  nahradíme prostřední hodnotou  $x_j^* = (t_{j-1} + t_j)/2$

hmotnost dětí ve 12. měsíci (příklad **děti**,  $n = 1633$ )

$j$	$x_j^*$	$t_j$	$n_j$	$n_j/n$	$N_j$	$N_j/n$
1	7750	8000	42	0,026	42	0,026
2	8250	8500	104	0,063	146	0,089
3	8750	9000	173	0,106	319	0,195
4	9250	9500	225	0,138	544	0,333
5	9750	10000	315	0,193	859	0,526
6	10250	10500	257	0,157	1116	0,683
7	10750	11000	210	0,129	1326	0,812
8	11250	11500	133	0,081	1459	0,893
9	11750	12000	88	0,054	1547	0,947
10	12250	12500	47	0,029	1594	0,976
11	12750	13000	28	0,017	1622	0,992
12	13250	$\infty$	11	0,007	1633	1,000

## histogram pro hmotnost v jednom roce

Svislá osa histogramu napravo popsána tak, aby vybarvená plocha byla rovna jedné. Nepřehlédněte, že většina sloupků má šířku rovnou jedné polovině.



## variační řada, pořadí

nutno rozlišovat  $x_i$  a  $x_{(i)}$

- ▶ původní hodnoty spojité veličiny (kvantitativní znak)

$$x_1, x_2, \dots, x_n \quad \text{např. } 7, 4, 5, 4, 2$$

- ▶ variační řada [ $\text{sort}(x)$ ]

$$x_{(1)} \leq x_{(2)} \dots \leq x_{(n)} \quad \text{např. } 2, 4, 4, 5, 7$$

- ▶ pořadí: [ $\text{rank}(x)$ ]

na které místo ve variační řadě se dostane daná hodnota  
nejmenší dostane pořadí 1, druhá nejmenší dostane 2, ...

- ▶ je-li několik hodnot stejných, dostanou průměr z odpovídajících pořadí
- ▶ pořadí hodnot 7, 4, 5, 4, 2 jsou po řadě 5, 2,5, 4, 2,5, 1

## variační řada, pořadí

nutno rozlišovat  $x_i$  a  $x_{(i)}$

- ▶ původní hodnoty spojité veličiny (kvantitativní znak)

$$x_1, x_2, \dots, x_n \quad \text{např. } 7, 4, 5, 4, 2$$

- ▶ **variační řada**  $[\text{sort}(x)]$

$$x_{(1)} \leq x_{(2)} \dots \leq x_{(n)} \quad \text{např. } 2, 4, 4, 5, 7$$

- ▶ **pořadí**:  $[\text{rank}(x)]$

na které místo ve variační řadě se dostane daná hodnota  
nejmenší dostane pořadí 1, druhá nejmenší dostane 2, ...

- ▶ je-li několik hodnot stejných, dostanou průměr z odpovídajících pořadí
- ▶ pořadí hodnot 7, 4, 5, 4, 2 jsou po řadě 5, 2,5, 4, 2,5, 1

## variační řada, pořadí

nutno rozlišovat  $x_i$  a  $x_{(i)}$

- ▶ původní hodnoty spojité veličiny (kvantitativní znak)

$$x_1, x_2, \dots, x_n \quad \text{např. } 7, 4, 5, 4, 2$$

- ▶ **variační řada** [sort(x)]

$$x_{(1)} \leq x_{(2)} \dots \leq x_{(n)} \quad \text{např. } 2, 4, 4, 5, 7$$

- ▶ **pořadí**: [rank(x)]

na které místo ve variační řadě se dostane daná hodnota nejmenší dostane pořadí 1, druhá nejmenší dostane 2, ...

- ▶ je-li několik hodnot stejných, dostanou průměr z odpovídajících pořadí
- ▶ pořadí hodnot 7, 4, 5, 4, 2 jsou po řadě 5, 2,5, 4, 2,5, 1



## variační řada, pořadí

nutno rozlišovat  $x_i$  a  $x_{(i)}$

- ▶ původní hodnoty spojité veličiny (kvantitativní znak)

$$x_1, x_2, \dots, x_n \quad \text{např. } 7, 4, 5, 4, 2$$

- ▶ **variační řada** [sort(x)]

$$x_{(1)} \leq x_{(2)} \dots \leq x_{(n)} \quad \text{např. } 2, 4, 4, 5, 7$$

- ▶ **pořadí**: [rank(x)]

na které místo ve variační řadě se dostane daná hodnota nejmenší dostane pořadí 1, druhá nejmenší dostane 2, ...

- ▶ je-li několik hodnot stejných, dostanou průměr z odpovídajících pořadí
- ▶ pořadí hodnot 7, 4, 5, 4, 2 jsou po řadě 5, 2,5, 4, 2,5, 1

## variační řada, pořadí

nutno rozlišovat  $x_i$  a  $x_{(i)}$

- ▶ původní hodnoty spojité veličiny (kvantitativní znak)

$$x_1, x_2, \dots, x_n \quad \text{např. } 7, 4, 5, 4, 2$$

- ▶ **variační řada** [sort(x)]

$$x_{(1)} \leq x_{(2)} \dots \leq x_{(n)} \quad \text{např. } 2, 4, 4, 5, 7$$

- ▶ **pořadí**: [rank(x)]

na které místo ve variační řadě se dostane daná hodnota nejmenší dostane pořadí 1, druhá nejmenší dostane 2, ...

- ▶ je-li několik hodnot stejných, dostanou průměr z odpovídajících pořadí
- ▶ pořadí hodnot 7, 4, 5, 4, 2 jsou po řadě 5, 2,5, 4, 2,5, 1

# empirická distribuční funkce


[empirical distribution function]

relativní četnost hodnot, které jsou menší nebo rovny  $x$


jaká část dat je **nejvýše**  $x$

naše variační řada: 2, 4, 4, 5, 7

$$F_n(x) = \frac{\#(x_i \leq x)}{n}$$




# empirická distribuční funkce



- ▶ příklad: váha dětí v jednom roce ( $n = 1633$ )
- ▶ připomíná hladkou neklesající funkci

# empirická distribuční funkce



- ▶ příklad: váha dětí v jednom roce ( $n = 1633$ )
- ▶ připomíná hladkou neklesající funkci

## průměry

- ▶ **průměr** [mean(x)]

$$\bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

- ▶ **vážený průměr** s využitím četností ( $n = \sum_j n_j$ )

$$\bar{x} = \frac{1}{n}(n_1 x_1^* + n_2 x_2^* + \dots + n_m x_m^*) = \frac{1}{n} \sum_{j=1}^m n_j x_j^*$$

- ▶ obecněji s nezápornými vahami  $w_j$  hodnot  $x_j^*$

$$\bar{x} = \frac{\sum_j w_j x_j^*}{\sum_j w_j}$$

[weighted.mean(x, w)]

# průměry

- ▶ **průměr** [mean(x)]

$$\bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

- ▶ **vážený průměr** s využitím četností ( $n = \sum_j n_j$ )

$$\bar{x} = \frac{1}{n}(n_1 x_1^* + n_2 x_2^* + \dots + n_m x_m^*) = \frac{1}{n} \sum_{j=1}^m n_j x_j^*$$

- ▶ obecněji s nezápornými vahami  $w_j$  hodnot  $x_j^*$

$$\bar{x} = \frac{\sum_j w_j x_j^*}{\sum_j w_j}$$

[weighted.mean(x, w)]

## průměry

- ▶ **průměr** [mean(x)]

$$\bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

- ▶ **vážený průměr** s využitím četností ( $n = \sum_j n_j$ )

$$\bar{x} = \frac{1}{n}(n_1 x_1^* + n_2 x_2^* + \dots + n_m x_m^*) = \frac{1}{n} \sum_{j=1}^m n_j x_j^*$$

- ▶ obecněji s nezápornými vahami  $w_j$  hodnot  $x_j^*$

$$\bar{x} = \frac{\sum_j w_j x_j^*}{\sum_j w_j}$$

[weighted.mean(x, w)]



## příklad: vážený průměr známek vážený kredity

jaký je nevážený průměr?

známka	kreditů	součin
$x_j^*$	$w_j$	$x_j^* \cdot w_j$
1	6	6
2	4	8
2	2	4
3	4	12
celkem	16	30

$$\bar{x} = \frac{6 \cdot 1 + 4 \cdot 2 + 2 \cdot 2 + 4 \cdot 3}{6 + 4 + 2 + 4} = \frac{30}{16} = 1,875$$

[weighted.mean(x=c(1,2,2,3),w=c(6,4,2,4))]

## další míry polohy

opět jsou důležité závorky kolem indexů

- ▶ **medián** (prostřední hodnota, NIKOLIV *střední hodnota*)

$$\tilde{x} = \begin{cases} x_{(\frac{n+1}{2})} & n \text{ liché} \\ \frac{1}{2} (x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}) & n \text{ sudé} \end{cases} \quad [\text{median}(x)]$$

- ▶ **minimum, maximum**

$$x_{\min} = x_{(1)} \quad [\min(x)]$$

$$x_{\max} = x_{(n)} \quad [\max(x)]$$

$[\text{range}(x)]$  spočítá dvojici  $(x_{\min}, x_{\max})$

- ▶ **variační průměr**  $[\text{mean}(\text{range}(x))]$

$$\frac{1}{2} (x_{(1)} + x_{(n)}) = \frac{1}{2} (x_{\min} + x_{\max})$$

## další míry polohy

opět jsou důležité závorky kolem indexů

- ▶ **medián** (prostřední hodnota, NIKOLIV *střední hodnota*)

$$\tilde{x} = \begin{cases} x_{(\frac{n+1}{2})} & n \text{ liché} \\ \frac{1}{2} (x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}) & n \text{ sudé} \end{cases} \quad [\text{median}(x)]$$

- ▶ **minimum, maximum**

$$x_{\min} = x_{(1)} \quad [\text{min}(x)]$$

$$x_{\max} = x_{(n)} \quad [\text{max}(x)]$$

$[\text{range}(x)]$  spočítá dvojici  $(x_{\min}, x_{\max})$

- ▶ **variační průměr**  $[\text{mean}(\text{range}(x))]$

$$\frac{1}{2} (x_{(1)} + x_{(n)}) = \frac{1}{2} (x_{\min} + x_{\max})$$

## další míry polohy

opět jsou důležité závorky kolem indexů

- ▶ **medián** (prostřední hodnota, NIKOLIV *střední hodnota*)

$$\tilde{x} = \begin{cases} x_{(\frac{n+1}{2})} & n \text{ liché} \\ \frac{1}{2} (x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}) & n \text{ sudé} \end{cases} \quad [\text{median}(x)]$$

- ▶ **minimum, maximum**

$$x_{\min} = x_{(1)} \quad [\text{min}(x)]$$

$$x_{\max} = x_{(n)} \quad [\text{max}(x)]$$

$[\text{range}(x)]$  spočítá dvojici  $(x_{\min}, x_{\max})$

- ▶ **variační průměr**  $[\text{mean}(\text{range}(x))]$

$$\frac{1}{2} (x_{(1)} + x_{(n)}) = \frac{1}{2} (x_{\min} + x_{\max})$$

## kvartily, decily

- ▶ **medián**  $\tilde{x}$  je číslo, které dělí data na dvě poloviny: hodnot menších nebo stejných jako medián – hodnot větších nebo stejných jako medián  $[\text{median}(x)]$   $[\text{quantile}(x, \text{probs}=1/2)]$
- ▶ **dolní kvartil**  $Q_1$  je číslo, které oddělí čtvrtinu hodnot (menších či stejných jako  $Q_1$ ) od tří čtvrtin hodnot (větších či stejných jako  $Q_1$ )  $[\text{quantile}(x, \text{probs}=1/4)]$
- ▶ **horní kvartil**  $Q_3$  je číslo, které oddělí tři čtvrtiny hodnot (menších či stejných jako  $Q_3$ ) od čtvrtiny hodnot (větších či stejných jako  $Q_3$ )  $[\text{quantile}(x, \text{probs}=3/4)]$
- ▶ **první decil** je číslo, které oddělí desetinu nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=1/10)]$
- ▶ **percentil**  $x_p$  je číslo, které oddělí  $100p$  % nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=p)]$
- ▶ několik percentilů současně  $[\text{quantile}(x, \text{probs}=(0:4)/4)]$

## kvartily, decily

- ▶ **medián**  $\tilde{x}$  je číslo, které dělí data na dvě poloviny: hodnot menších nebo stejných jako medián – hodnot větších nebo stejných jako medián  $[\text{median}(x)]$   $[\text{quantile}(x, \text{probs}=1/2)]$
- ▶ **dolní kvartil**  $Q_1$  je číslo, které oddělí čtvrtinu hodnot (menších či stejných jako  $Q_1$ ) od tří čtvrtin hodnot (větších či stejných jako  $Q_1$ )  $[\text{quantile}(x, \text{probs}=1/4)]$
- ▶ **horní kvartil**  $Q_3$  je číslo, které oddělí tři čtvrtiny hodnot (menších či stejných jako  $Q_3$ ) od čtvrtiny hodnot (větších či stejných jako  $Q_3$ )  $[\text{quantile}(x, \text{probs}=3/4)]$
- ▶ **první decil** je číslo, které oddělí desetinu nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=1/10)]$
- ▶ **percentil**  $x_p$  je číslo, které oddělí  $100p$  % nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=p)]$
- ▶ několik percentilů současně  $[\text{quantile}(x, \text{probs}=(0:4)/4)]$

## kvartily, decily

- ▶ **medián**  $\tilde{x}$  je číslo, které dělí data na dvě poloviny: hodnot menších nebo stejných jako medián – hodnot větších nebo stejných jako medián  $[\text{median}(x)]$   $[\text{quantile}(x, \text{probs}=1/2)]$
- ▶ **dolní kvartil**  $Q_1$  je číslo, které oddělí čtvrtinu hodnot (menších či stejných jako  $Q_1$ ) od tří čtvrtin hodnot (větších či stejných jako  $Q_1$ )  $[\text{quantile}(x, \text{probs}=1/4)]$
- ▶ **horní kvartil**  $Q_3$  je číslo, které oddělí tři čtvrtiny hodnot (menších či stejných jako  $Q_3$ ) od čtvrtiny hodnot (větších či stejných jako  $Q_3$ )  $[\text{quantile}(x, \text{probs}=3/4)]$
- ▶ **první decil** je číslo, které oddělí desetinu nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=1/10)]$
- ▶ **percentil**  $x_p$  je číslo, které oddělí  $100p$  % nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=p)]$
- ▶ několik percentilů současně  $[\text{quantile}(x, \text{probs}=(0:4)/4)]$

## kvartily, decily

- ▶ **medián**  $\tilde{x}$  je číslo, které dělí data na dvě poloviny: hodnot menších nebo stejných jako medián – hodnot větších nebo stejných jako medián  $[\text{median}(x)]$   $[\text{quantile}(x, \text{probs}=1/2)]$
- ▶ **dolní kvartil**  $Q_1$  je číslo, které oddělí čtvrtinu hodnot (menších či stejných jako  $Q_1$ ) od tří čtvrtin hodnot (větších či stejných jako  $Q_1$ )  $[\text{quantile}(x, \text{probs}=1/4)]$
- ▶ **horní kvartil**  $Q_3$  je číslo, které oddělí tři čtvrtiny hodnot (menších či stejných jako  $Q_3$ ) od čtvrtiny hodnot (větších či stejných jako  $Q_3$ )  $[\text{quantile}(x, \text{probs}=3/4)]$
- ▶ **první decil** je číslo, které oddělí desetinu nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=1/10)]$
- ▶ **percentil**  $x_p$  je číslo, které oddělí  $100p$  % nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=p)]$
- ▶ několik percentilů současně  $[\text{quantile}(x, \text{probs}=(0:4)/4)]$



## kvartily, decily

- ▶ **medián**  $\tilde{x}$  je číslo, které dělí data na dvě poloviny: hodnot menších nebo stejných jako medián – hodnot větších nebo stejných jako medián `[median(x)] [quantile(x,probs=1/2)]`
- ▶ **dolní kvartil**  $Q_1$  je číslo, které oddělí čtvrtinu hodnot (menších či stejných jako  $Q_1$ ) od tří čtvrtin hodnot (větších či stejných jako  $Q_1$ ) `[quantile(x,probs=1/4)]`
- ▶ **horní kvartil**  $Q_3$  je číslo, které oddělí tři čtvrtiny hodnot (menších či stejných jako  $Q_3$ ) od čtvrtiny hodnot (větších či stejných jako  $Q_3$ ) `[quantile(x,probs=3/4)]`
- ▶ **první decil** je číslo, které oddělí desetinu nejmenších hodnot od ostatních hodnot `[quantile(x,probs=1/10)]`
- ▶ **percentil**  $x_p$  je číslo, které oddělí  $100p$  % nejmenších hodnot od ostatních hodnot `[quantile(x,probs=p)]`
- ▶ několik percentilů současně `[quantile(x,probs=(0:4)/4)]`

## kvartily, decily

- ▶ **medián**  $\tilde{x}$  je číslo, které dělí data na dvě poloviny: hodnot menších nebo stejných jako medián – hodnot větších nebo stejných jako medián  $[\text{median}(x)]$   $[\text{quantile}(x, \text{probs}=1/2)]$
- ▶ **dolní kvartil**  $Q_1$  je číslo, které oddělí čtvrtinu hodnot (menších či stejných jako  $Q_1$ ) od tří čtvrtin hodnot (větších či stejných jako  $Q_1$ )  $[\text{quantile}(x, \text{probs}=1/4)]$
- ▶ **horní kvartil**  $Q_3$  je číslo, které oddělí tři čtvrtiny hodnot (menších či stejných jako  $Q_3$ ) od čtvrtiny hodnot (větších či stejných jako  $Q_3$ )  $[\text{quantile}(x, \text{probs}=3/4)]$
- ▶ **první decil** je číslo, které oddělí desetinu nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=1/10)]$
- ▶ **percentil**  $x_p$  je číslo, které oddělí  $100p$  % nejmenších hodnot od ostatních hodnot  $[\text{quantile}(x, \text{probs}=p)]$
- ▶ několik percentilů současně  $[\text{quantile}(x, \text{probs}=(0:4)/4)]$

## výpočet percentilu $x_p$ (fakultativně)

jedna z nejčastěji užívaných metod výpočtu percentilu, též v R

- ▶ k daným  $n, p$  se najde celé číslo  $k$  splňující

$$\frac{k-1}{n-1} \leq p < \frac{k}{n-1}$$

- ▶ tedy  $k = \lfloor 1 + (n-1) \cdot p \rfloor$   
( $\lfloor x \rfloor$  znamená celou část z  $x$ , zaokrouhlí dolů)
- ▶ provede se lineární interpolace mezi  $x_{(k)}$  a  $x_{(k+1)}$   
( $\{x\}$  znamená zlomkovou část  $x$ , o kolik přesahuje celé číslo)

$$q = \{1 + (n-1) \cdot p\} = (1 + (n-1) \cdot p) - k$$

$$x_p = (1 - q) \cdot x_{(k)} + q \cdot x_{(k+1)}$$

- ▶ např. pro  $n = 99, p = 0,25$  bude

$$k = \lfloor 1 + (99 - 1) \cdot 0,25 \rfloor = \lfloor 25,5 \rfloor = 25, \quad q = 25,5 - 25 = 0,5$$

$$Q_1 = x_{0,25} = (1 - 0,5) \cdot x_{(25)} + 0,5 \cdot x_{(26)}$$

## výpočet percentilu $x_p$ (fakultativně)

jedna z nejčastěji užívaných metod výpočtu percentilu, též v R

- ▶ k daným  $n, p$  se najde celé číslo  $k$  splňující

$$\frac{k-1}{n-1} \leq p < \frac{k}{n-1}$$

- ▶ tedy  $k = \lfloor 1 + (n-1) \cdot p \rfloor$   
( $\lfloor x \rfloor$  znamená celou část z  $x$ , zaokrouhlí dolů)

- ▶ provede se lineární interpolace mezi  $x_{(k)}$  a  $x_{(k+1)}$   
( $\{x\}$  znamená zlomkovou část  $x$ , o kolik přesahuje celé číslo)

$$q = \{1 + (n-1) \cdot p\} = (1 + (n-1) \cdot p) - k$$

$$x_p = (1 - q) \cdot x_{(k)} + q \cdot x_{(k+1)}$$

- ▶ např. pro  $n = 99, p = 0,25$  bude

$$k = \lfloor 1 + (99 - 1) \cdot 0,25 \rfloor = \lfloor 25,5 \rfloor = 25, \quad q = 25,5 - 25 = 0,5$$

$$Q_1 = x_{0,25} = (1 - 0,5) \cdot x_{(25)} + 0,5 \cdot x_{(26)}$$

## výpočet percentilu $x_p$ (fakultativně)

jedna z nejčastěji užívaných metod výpočtu percentilu, též v R

- ▶ k daným  $n, p$  se najde celé číslo  $k$  splňující

$$\frac{k-1}{n-1} \leq p < \frac{k}{n-1}$$

- ▶ tedy  $k = \lfloor 1 + (n-1) \cdot p \rfloor$   
( $\lfloor x \rfloor$  znamená celou část z  $x$ , zaokrouhlí dolů)
- ▶ provede se lineární interpolace mezi  $x_{(k)}$  a  $x_{(k+1)}$   
( $\{x\}$  znamená zlomkovou část  $x$ , o kolik přesahuje celé číslo)

$$q = \{1 + (n-1) \cdot p\} = (1 + (n-1) \cdot p) - k$$

$$x_p = (1 - q) \cdot x_{(k)} + q \cdot x_{(k+1)}$$

- ▶ např. pro  $n = 99, p = 0,25$  bude

$$k = \lfloor 1 + (99 - 1) \cdot 0,25 \rfloor = \lfloor 25,5 \rfloor = 25, \quad q = 25,5 - 25 = 0,5$$

$$Q_1 = x_{0,25} = (1 - 0,5) \cdot x_{(25)} + 0,5 \cdot x_{(26)}$$

## výpočet percentilu $x_p$ (fakultativně)

jedna z nejčastěji užívaných metod výpočtu percentilu, též v R

- ▶ k daným  $n, p$  se najde celé číslo  $k$  splňující

$$\frac{k-1}{n-1} \leq p < \frac{k}{n-1}$$

- ▶ tedy  $k = \lfloor 1 + (n-1) \cdot p \rfloor$   
( $\lfloor x \rfloor$  znamená celou část z  $x$ , zaokrouhlí dolů)
- ▶ provede se lineární interpolace mezi  $x_{(k)}$  a  $x_{(k+1)}$   
( $\{x\}$  znamená zlomkovou část  $x$ , o kolik přesahuje celé číslo)

$$q = \{1 + (n-1) \cdot p\} = (1 + (n-1) \cdot p) - k$$


$$x_p = (1 - q) \cdot x_{(k)} + q \cdot x_{(k+1)}$$

- ▶ např. pro  $n = 99, p = 0,25$  bude

$$k = \lfloor 1 + (99 - 1) \cdot 0,25 \rfloor = \lfloor 25,5 \rfloor = 25, \quad q = 25,5 - 25 = 0,5$$

$$Q_1 = x_{0,25} = (1 - 0,5) \cdot x_{(25)} + 0,5 \cdot x_{(26)}$$

## krabicový diagram




`[boxplot(c(4,5,8,9,10,13,21),horizontal=TRUE,col=7,pch=16)]`

znázorěna řada statistik pro data: 4, 5, 8, 9, 10, 13, 21

- ▶ medián ( $\tilde{x} = 9$ ) – příčka obdélníka
- ▶ kvartily ( $Q_1 = 6,5$ ,  $Q_3 = 11,5$ ) – kratší strany obdélníka
- ▶ tykadla od kvartilu k minimu (maximu), pokud není odlehlé
- ▶ odlehlé pozorování – je dál, než  $3/2 \cdot (Q_3 - Q_1)$  ( $= 7,5$ ) od bližšího kvartilu

## krabicový diagram




`[boxplot(c(4,5,8,9,10,13,21),horizontal=TRUE,col=7,pch=16)]`

znázorěna řada statistik pro data: 4, 5, 8, 9, 10, 13, 21

- ▶ medián ( $\tilde{x} = 9$ ) – příčka obdélníka
- ▶ kvartily ( $Q_1 = 6,5$ ,  $Q_3 = 11,5$ ) – kratší strany obdélníka
- ▶ tykadla od kvartilu k minimu (maximu), pokud není odlehlé
- ▶ odlehlé pozorování – je dál, než  $3/2 \cdot (Q_3 - Q_1)$  ( $= 7,5$ ) od bližšího kvartilu



## krabicový diagram




`[boxplot(c(4,5,8,9,10,13,21),horizontal=TRUE,col=7,pch=16)]`

znázorěna řada statistik pro data: 4, 5, 8, 9, 10, 13, 21

- ▶ medián ( $\tilde{x} = 9$ ) – příčka obdélníka
- ▶ kvartily ( $Q_1 = 6,5$ ,  $Q_3 = 11,5$ ) – kratší strany obdélníka
- ▶ tykadla od kvartilu k minimu (maximu), pokud není odlehlé
- ▶ odlehlé pozorování – je dál, než  $3/2 \cdot (Q_3 - Q_1)$  ( $= 7,5$ ) od bližšího kvartilu

## krabicový diagram



`[boxplot(c(4,5,8,9,10,13,21),horizontal=TRUE,col=7,pch=16)]`

znázorěna řada statistik pro data: 4, 5, 8, 9, 10, 13, 21

- ▶ medián ( $\tilde{x} = 9$ ) – příčka obdélníka
- ▶ kvartily ( $Q_1 = 6,5$ ,  $Q_3 = 11,5$ ) – kratší strany obdélníka
- ▶ tykadla od kvartilu k minimu (maximu), pokud není odlehlé
- ▶ odlehlé pozorování – je dál, než  $3/2 \cdot (Q_3 - Q_1)$  ( $= 7,5$ ) od bližšího kvartilu

## vlastnosti míry polohy

- ▶ přičteme-li ke každé hodnotě  $x$  stejnou konstantu  $a$ , musíme tutéž konstantu  $a$  přičíst k průměru (mediánu, kvartilu, ...)
- ▶ vynásobíme-li každou hodnotu  $x$  stejnou kladnou konstantou  $b$ , musíme průměr (medián, kvartil, ...) vynásobit totéž konstantou  $b$
- ▶ pro dobrou míru polohy  $\mu(X)$  platí:

$$\mu(a + X) = a + \mu(X)$$

$$\mu(b \cdot X) = b \cdot \mu(X) \quad (b > 0)$$

- ▶ dobrá míra polohy je citlivá vůči posunutí (pozná změnu úrovně) i vůči změně měřítka (např. přechod od g ke kg)

## vlastnosti míry polohy

- ▶ přičteme-li ke každé hodnotě  $x$  stejnou konstantu  $a$ , musíme tutéž konstantu  $a$  přičíst k průměru (mediánu, kvartilu, ...)
- ▶ vynásobíme-li každou hodnotu  $x$  stejnou kladnou konstantou  $b$ , musíme průměr (medián, kvartil, ...) vynásobit totéž konstantou  $b$
- ▶ pro dobrou míru polohy  $\mu(X)$  platí:

$$\mu(a + X) = a + \mu(X)$$

$$\mu(b \cdot X) = b \cdot \mu(X) \quad (b > 0)$$

- ▶ dobrá míra polohy je citlivá vůči posunutí (pozná změnu úrovně) i vůči změně měřítka (např. přechod od g ke kg)

## vlastnosti míry polohy

- ▶ přičteme-li ke každé hodnotě  $x$  stejnou konstantu  $a$ , musíme tutéž konstantu  $a$  přičíst k průměru (mediánu, kvartilu, ...)
- ▶ vynásobíme-li každou hodnotu  $x$  stejnou kladnou konstantou  $b$ , musíme průměr (medián, kvartil, ...) vynásobit totéž konstantou  $b$
- ▶ pro dobrou míru polohy  $\mu(X)$  platí:

$$\mu(a + X) = a + \mu(X)$$

$$\mu(b \cdot X) = b \cdot \mu(X) \quad (b > 0)$$

- ▶ dobrá míra polohy je citlivá vůči posunutí (pozná změnu úrovně) i vůči změně měřítka (např. přechod od g ke kg)

## vlastnosti míry polohy

- ▶ přičteme-li ke každé hodnotě  $x$  stejnou konstantu  $a$ , musíme tutéž konstantu  $a$  přičíst k průměru (mediánu, kvartilu, ...)
- ▶ vynásobíme-li každou hodnotu  $x$  stejnou kladnou konstantou  $b$ , musíme průměr (medián, kvartil, ...) vynásobit totéž konstantou  $b$
- ▶ pro dobrou míru polohy  $\mu(X)$  platí:

$$\mu(a + X) = a + \mu(X)$$

$$\mu(b \cdot X) = b \cdot \mu(X) \quad (b > 0)$$

- ▶ dobrá míra polohy je citlivá vůči posunutí (pozná změnu úrovně) i vůči změně měřítka (např. přechod od g ke kg)

## míry variability

- ▶ míra variability  $\sigma(x)$  číselně charakterizuje jinou vlastnost, než míry polohy, proto na poloze **nesmí záviset**
- ▶ ukazuje nakolik jsou zjištěné hodnoty nestejně, velikost jejich kolísání, jejich **variabilitu**
- ▶ pro dobrou míru variability  $\sigma(X)$  platí:

$$\sigma(a + X) = \sigma(X) \quad \text{rozdíl proti míře polohy!!!}$$

$$\sigma(b \cdot X) = b \cdot \sigma(X) \quad b > 0$$

- ▶ přičtení konstanty  $a$  míru variability nezmění, na vynásobení kladnou konstantou  $b$  reaguje

## míry variability

- ▶ míra variability  $\sigma(x)$  číselně charakterizuje jinou vlastnost, než míry polohy, proto na poloze **nesmí záviset**
- ▶ ukazuje nakolik jsou zjištěné hodnoty nestejně, velikost jejich kolísání, jejich **variabilitu**
- ▶ pro dobrou míru variability  $\sigma(X)$  platí:

$$\sigma(a + X) = \sigma(X) \quad \text{rozdíl proti míře polohy!!!}$$

$$\sigma(b \cdot X) = b \cdot \sigma(X) \quad b > 0$$

- ▶ přičtení konstanty  $a$  míru variability nezmění, na vynásobení kladnou konstantou  $b$  reaguje



## míry variability

- ▶ míra variability  $\sigma(x)$  číselně charakterizuje jinou vlastnost, než míry polohy, proto na poloze **nesmí záviset**
- ▶ ukazuje nakolik jsou zjištěné hodnoty nestejně, velikost jejich kolísání, jejich **variabilitu**
- ▶ pro dobrou míru variability  $\sigma(X)$  platí:

$$\begin{array}{ll} \sigma(a + X) = \sigma(X) & \text{rozdíl proti míře polohy!!!} \\ \sigma(b \cdot X) = b \cdot \sigma(X) & b > 0 \end{array}$$

- ▶ přičtení konstanty  $a$  míru variability nezmění, na vynásobení kladnou konstantou  $b$  reaguje

## míry variability

- ▶ míra variability  $\sigma(x)$  číselně charakterizuje jinou vlastnost, než míry polohy, proto na poloze **nesmí záviset**
- ▶ ukazuje nakolik jsou zjištěné hodnoty nestejně, velikost jejich kolísání, jejich **variabilitu**
- ▶ pro dobrou míru variability  $\sigma(X)$  platí:

$$\begin{aligned}\sigma(a + X) &= \sigma(X) && \text{rozdíl proti míře polohy!!!} \\ \sigma(b \cdot X) &= b \cdot \sigma(X) && b > 0\end{aligned}$$

- ▶ přičtení konstanty  $a$  míru variability nezmění, na vynásobení kladnou konstantou  $b$  reaguje

## směrodatná odchylka, rozptyl

[standard deviation, variance]

- ▶ **rozptyl** (variance)

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$s_{b \cdot x}^2 = b^2 s_x^2$$

[var(x)]

- ▶ např. pro data: 4, 5, 8, 9, 10, 13, 21 dostaneme  $\bar{x} = 10$ , tedy

$$s_x^2 = \frac{1}{7-1} ((4-10)^2 + (5-10)^2 + \dots + (21-10)^2) = \frac{196}{6}$$

- ▶ **směrodatná odchylka**

$$s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

[sd(x)]

## směrodatná odchylka, rozptyl

[standard deviation, variance]

- ▶ **rozptyl** (variance)

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$s_{b \cdot x}^2 = b^2 s_x^2$$

[var(x)]

- ▶ např. pro data: 4, 5, 8, 9, 10, 13, 21 dostaneme  $\bar{x} = 10$ , tedy

$$s_x^2 = \frac{1}{7-1} ((4-10)^2 + (5-10)^2 + \dots + (21-10)^2) = \frac{196}{6}$$

- ▶ **směrodatná odchylka**

$$s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

[sd(x)]

## směrodatná odchylka, rozptyl

[standard deviation, variance]

- ▶ **rozptyl** (variance)

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$s_{b \cdot x}^2 = b^2 s_x^2$$

[var(x)]

- ▶ např. pro data: 4, 5, 8, 9, 10, 13, 21 dostaneme  $\bar{x} = 10$ , tedy

$$s_x^2 = \frac{1}{7-1} ((4-10)^2 + (5-10)^2 + \dots + (21-10)^2) = \frac{196}{6}$$

- ▶ **směrodatná odchylka**

$$s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

[sd(x)]

## další míry variability

- ▶ **rozpětí**  $R = x_{\max} - x_{\min}$  [range]
- ▶ **kvartilové rozpětí**  $R_Q = Q_3 - Q_1$  [interquartile range]
- ▶ **variační koeficient** (nesplňuje ani jeden požadavek)  
slouží k porovnání variability při různých úrovních [coefficient of variation]

$$V_x = \frac{s_x}{\bar{x}}$$

- ▶ **entropie** (pro nominální, požadavky nemají smysl, nezávisí na označení hodnot, jen na jejich relativních četnostech) [entropy]

$$H = - \sum_{j=1}^m \frac{n_j}{n} \ln \frac{n_j}{n}$$

## další míry variability

▶ **rozpětí**  $R = x_{\max} - x_{\min}$  [range]

▶ **kvartilové rozpětí**  $R_Q = Q_3 - Q_1$  [interquartile range]

▶ **variační koeficient** (nesplňuje ani jeden požadavek)  
slouží k porovnání variability při různých úrovních [coefficient of variation]

$$V_x = \frac{s_x}{\bar{x}}$$

▶ **entropie** (pro nominální, požadavky nemají smysl, nezávisí na označení hodnot, jen na jejich relativních četnostech) [entropy]

$$H = - \sum_{j=1}^m \frac{n_j}{n} \ln \frac{n_j}{n}$$

## další míry variability

- ▶ **rozpětí**  $R = x_{\max} - x_{\min}$  [range]
- ▶ **kvartilové rozpětí**  $R_Q = Q_3 - Q_1$  [interquartile range]
- ▶ **variační koeficient** (nesplňuje ani jeden požadavek)  
slouží k porovnání variability při různých úrovních [coefficient of variation]

$$V_x = \frac{s_x}{\bar{x}}$$

- ▶ **entropie** (pro nominální, požadavky nemají smysl, nezávisí na označení hodnot, jen na jejich relativních četnostech) [entropy]

$$H = - \sum_{j=1}^m \frac{n_j}{n} \ln \frac{n_j}{n}$$



## další míry variability

- ▶ **rozpětí**  $R = x_{\max} - x_{\min}$  [range]
- ▶ **kvartilové rozpětí**  $R_Q = Q_3 - Q_1$  [interquartile range]
- ▶ **variační koeficient** (nesplňuje ani jeden požadavek)  
slouží k porovnání variability při různých úrovních [coefficient of variation]

$$V_x = \frac{s_x}{\bar{x}}$$

- ▶ **entropie** (pro nominální, požadavky nemají smysl, nezávisí na označení hodnot, jen na jejich relativních četnostech) [entropy]

$$H = - \sum_{j=1}^m \frac{n_j}{n} \ln \frac{n_j}{n}$$

## příklad ICHS: vztah mužů ke kouření

vzděl.	vztah ke kouření						celk.	$H$
	nekuřák/bývalý		střední		silný			
zákl.	25	21,4 %	14	12,0 %	78	66,7 %	117	0,854
odb.	83	28,0 %	24	8,1 %	189	63,9 %	296	0,847
stř.	99	33,2 %	24	8,1 %	175	58,7 %	298	0,882
VŠ	115	48,3 %	17	7,1 %	106	44,5 %	238	0,900

muži se základním vzděláním:

$$H = - \left( \frac{25}{117} \ln \frac{25}{117} + \frac{14}{117} \ln \frac{14}{117} + \frac{78}{117} \ln \frac{78}{117} \right) = 0,854123$$

větší vyrovnanost  $\Rightarrow$  větší entropie

maximum pro  $n_1 = n_2 = n_3$  vyjde  $H = \ln(3) = 1,098612$

## z-skóry

- ▶ **z-skóry** (normovaná veličina)

$$z_i = \frac{x_i - \bar{x}}{s_x}, \quad i = 1, 2, \dots, n \quad [(x - \text{mean}(x)) / \text{sd}(x)]$$

- ▶ hodnoty  $z_1, z_2, \dots, z_n$  „ztratily“ informaci o poloze a variabilitě, vždy platí  $\bar{z} = 0, s_z = 1$
- ▶ přičtení konstanty ani násobení konstantou z-skóry nezmění
- ▶ hodnocení vlastností nezávislých na poloze a variabilitě
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 platí  $\bar{x} = 10, s_x = 5,715$
- ▶ proto dostaneme

$$z_1 = \frac{4 - 10}{5,715} = -1,050, \dots, z_7 = \frac{21 - 10}{5,715} = 1,925$$

## z-skóry

- ▶ **z-skóry** (normovaná veličina)

$$z_i = \frac{x_i - \bar{x}}{s_x}, \quad i = 1, 2, \dots, n \quad [(x - \text{mean}(x)) / \text{sd}(x)]$$

- ▶ hodnoty  $z_1, z_2, \dots, z_n$  „ztratily“ informaci o poloze a variabilitě, vždy platí  $\bar{z} = 0, \quad s_z = 1$
- ▶ přičtení konstanty ani násobení konstantou z-skóry nezmění
- ▶ hodnocení vlastností nezávislých na poloze a variabilitě
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 platí  $\bar{x} = 10, s_x = 5,715$
- ▶ proto dostaneme

$$z_1 = \frac{4 - 10}{5,715} = -1,050, \dots, z_7 = \frac{21 - 10}{5,715} = 1,925$$

## z-skóry

- ▶ **z-skóry** (normovaná veličina)

$$z_i = \frac{x_i - \bar{x}}{s_x}, \quad i = 1, 2, \dots, n \quad [(x - \text{mean}(x)) / \text{sd}(x)]$$

- ▶ hodnoty  $z_1, z_2, \dots, z_n$  „ztratily“ informaci o poloze a variabilitě, vždy platí  $\bar{z} = 0, \quad s_z = 1$
- ▶ přičtení konstanty ani násobení konstantou z-skóry nezmění
- ▶ hodnocení vlastností nezávislých na poloze a variabilitě
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 platí  $\bar{x} = 10, s_x = 5,715$
- ▶ proto dostaneme

$$z_1 = \frac{4 - 10}{5,715} = -1,050, \dots, z_7 = \frac{21 - 10}{5,715} = 1,925$$

## z-skóry

- ▶ **z-skóry** (normovaná veličina)

$$z_i = \frac{x_i - \bar{x}}{s_x}, \quad i = 1, 2, \dots, n \quad [(x - \text{mean}(x)) / \text{sd}(x)]$$

- ▶ hodnoty  $z_1, z_2, \dots, z_n$  „ztratily“ informaci o poloze a variabilitě, vždy platí  $\bar{z} = 0, \quad s_z = 1$
- ▶ přičtení konstanty ani násobení konstantou z-skóry nezmění
- ▶ hodnocení vlastností nezávislých na poloze a variabilitě
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 platí  $\bar{x} = 10, s_x = 5,715$
- ▶ proto dostaneme

$$z_1 = \frac{4 - 10}{5,715} = -1,050, \dots, z_7 = \frac{21 - 10}{5,715} = 1,925$$

## z-skóry

- ▶ **z-skóry** (normovaná veličina)

$$z_i = \frac{x_i - \bar{x}}{s_x}, \quad i = 1, 2, \dots, n \quad [(x - \text{mean}(x)) / \text{sd}(x)]$$

- ▶ hodnoty  $z_1, z_2, \dots, z_n$  „ztratily“ informaci o poloze a variabilitě, vždy platí  $\bar{z} = 0, \quad s_z = 1$
- ▶ přičtení konstanty ani násobení konstantou z-skóry nezmění
- ▶ hodnocení vlastností nezávislých na poloze a variabilitě
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 platí  $\bar{x} = 10, s_x = 5,715$
- ▶ proto dostaneme

$$z_1 = \frac{4 - 10}{5,715} = -1,050, \dots, z_7 = \frac{21 - 10}{5,715} = 1,925$$

## z-skóry

- ▶ **z-skóry** (normovaná veličina)

$$z_i = \frac{x_i - \bar{x}}{s_x}, \quad i = 1, 2, \dots, n \quad [(x - \text{mean}(x)) / \text{sd}(x)]$$

- ▶ hodnoty  $z_1, z_2, \dots, z_n$  „ztratily“ informaci o poloze a variabilitě, vždy platí  $\bar{z} = 0, \quad s_z = 1$
- ▶ přičtení konstanty ani násobení konstantou z-skóry nezmění
- ▶ hodnocení vlastností nezávislých na poloze a variabilitě
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 platí  $\bar{x} = 10, s_x = 5,715$
- ▶ proto dostaneme

$$z_1 = \frac{4 - 10}{5,715} = -1,050, \dots, z_7 = \frac{21 - 10}{5,715} = 1,925$$



## šikmost, špičatost

- ▶ **šikmost** (průměr 3. mocnin z-skórů)

$$g_1 = \frac{1}{n} \sum_{i=1}^n z_i^3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^3 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{s_x^3}$$

[mean(((x-mean(x))/sd(x))^3)]

- ▶ **špičatost** (průměr 4. mocnin z-skórů zmenšený o 3)

$$g_2 = \frac{1}{n} \sum_{i=1}^n z_i^4 - 3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^4 - 3$$

[mean(((x-mean(x))/sd(x))^4)-3]

- ▶  $g_1, g_2$  se používají k posouzení normality
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 dostaneme

$$g_1 = 0,771 \quad g_2 = -0,770$$

## šikmost, špičatost

- ▶ **šikmost** (průměr 3. mocnin z-skórů)

$$g_1 = \frac{1}{n} \sum_{i=1}^n z_i^3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^3 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{s_x^3}$$

[mean(((x-mean(x))/sd(x))^3)]

- ▶ **špičatost** (průměr 4. mocnin z-skórů zmenšený o 3)

$$g_2 = \frac{1}{n} \sum_{i=1}^n z_i^4 - 3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^4 - 3$$

[mean(((x-mean(x))/sd(x))^4)-3]

- ▶  $g_1, g_2$  se používají k posouzení normality
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 dostaneme

$$g_1 = 0,771 \quad g_2 = -0,770$$

## šikmost, špičatost

- ▶ **šikmost** (průměr 3. mocnin z-skórů)

$$g_1 = \frac{1}{n} \sum_{i=1}^n z_i^3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^3 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{s_x^3}$$

[mean(((x-mean(x))/sd(x))^3)]

- ▶ **špičatost** (průměr 4. mocnin z-skórů zmenšený o 3)

$$g_2 = \frac{1}{n} \sum_{i=1}^n z_i^4 - 3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^4 - 3$$

[mean(((x-mean(x))/sd(x))^4)-3]

- ▶  $g_1, g_2$  se používají k posouzení normality
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 dostaneme

$$g_1 = 0,771 \quad g_2 = -0,770$$

## šikmost, špičatost

- ▶ **šikmost** (průměr 3. mocnin z-skórů)

$$g_1 = \frac{1}{n} \sum_{i=1}^n z_i^3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^3 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{s_x^3}$$

[mean(((x-mean(x))/sd(x))^3)]

- ▶ **špičatost** (průměr 4. mocnin z-skórů zmenšený o 3)







$$g_2 = \frac{1}{n} \sum_{i=1}^n z_i^4 - 3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^4 - 3$$

[mean(((x-mean(x))/sd(x))^4)-3]

- ▶  $g_1, g_2$  se používají k posouzení normality
- ▶ pro data: 4, 5, 8, 9, 10, 13, 21 dostaneme

$$g_1 = 0,771 \quad g_2 = -0,770$$

## příklad: věk matky, čísla 1 až 99

věk matek:  $g_1 = 0,741$ ,  $g_2 = 0,220$  čísla 1 až 99:  $g_1 = 0$ ,  $g_2 = -1,236$ 

# normální diagram

[(normal) probability plot], [quantile-comparison plot]

- ▶ k ověřování předpokladu **normálního** rozdělení
- ▶ porovnává skutečnou variační řadu s ideální variační řadou normálního (Gaussova) rozdělení  $N(0, 1)$
- ▶ v ideálním případě body téměř na přímce
- ▶ systematická odchylka ukazuje na rozdělení, které není normální
- ▶ konvexní či konkávní průběh – nesymetrie (nenulová šikmost)
- ▶ esovitý průběh – nenulová špičatost
- ▶ [qqnorm(x)]
- ▶ přímku vloží [qqline(x)]

# normální diagram

[(normal) probability plot], [quantile-comparison plot]

- ▶ k ověřování předpokladu **normálního** rozdělení
- ▶ porovnává skutečnou variační řadu s ideální variační řadou normálního (Gaussova) rozdělení  $N(0, 1)$
- ▶ v ideálním případě body téměř na přímce
- ▶ systematická odchylka ukazuje na rozdělení, které není normální
- ▶ konvexní či konkávní průběh – nesymetrie (nenulová šikmost)
- ▶ esovitý průběh – nenulová špičatost
- ▶ [qqnorm(x)]
- ▶ přímku vloží [qqline(x)]

# normální diagram

[(normal) probability plot], [quantile-comparison plot]

- ▶ k ověření předpokladu **normálního** rozdělení
- ▶ porovnává skutečnou variační řadu s ideální variační řadou normálního (Gaussova) rozdělení  $N(0, 1)$
- ▶ v ideálním případě body téměř na přímce
- ▶ systematická odchylka ukazuje na rozdělení, které není normální
- ▶ konvexní či konkávní průběh – nesymetrie (nenulová šikmost)
- ▶ esovitý průběh – nenulová špičatost
- ▶ [qqnorm(x)]
- ▶ přímku vloží [qqline(x)]



# normální diagram

[(normal) probability plot], [quantile-comparison plot]

- ▶ k ověřování předpokladu **normálního** rozdělení
- ▶ porovnává skutečnou variační řadu s ideální variační řadou normálního (Gaussova) rozdělení  $N(0, 1)$
- ▶ v ideálním případě body téměř na přímce
- ▶ systematická odchylka ukazuje na rozdělení, které není normální
- ▶ konvexní či konkávní průběh – nesymetrie (nenulová šikmost)
- ▶ esovitý průběh – nenulová špičatost
- ▶ [qqnorm(x)]
- ▶ přímku vloží [qqline(x)]

# normální diagram

[(normal) probability plot], [quantile-comparison plot]

- ▶ k ověřování předpokladu **normálního** rozdělení
- ▶ porovnává skutečnou variační řadu s ideální variační řadou normálního (Gaussova) rozdělení  $N(0, 1)$
- ▶ v ideálním případě body téměř na přímce
- ▶ systematická odchylka ukazuje na rozdělení, které není normální
- ▶ konvexní či konkávní průběh – nesymetrie (nenulová šikmost)
- ▶ esovitý průběh – nenulová špičatost
- ▶ [qqnorm(x)]
- ▶ přímku vloží [qqline(x)]

# normální diagram

[(normal) probability plot], [quantile-comparison plot]

- ▶ k ověřování předpokladu **normálního** rozdělení
- ▶ porovnává skutečnou variační řadu s ideální variační řadou normálního (Gaussova) rozdělení  $N(0, 1)$
- ▶ v ideálním případě body téměř na přímce
- ▶ systematická odchylka ukazuje na rozdělení, které není normální
- ▶ konvexní či konkávní průběh – nesymetrie (nenulová šikmost)
- ▶ esovitý průběh – nenulová špičatost
- ▶ [qqnorm(x)]
- ▶ přímku vloží [qqline(x)]

# normální diagram

[(normal) probability plot], [quantile-comparison plot]

- ▶ k ověřování předpokladu **normálního** rozdělení
- ▶ porovnává skutečnou variační řadu s ideální variační řadou normálního (Gaussova) rozdělení  $N(0, 1)$
- ▶ v ideálním případě body téměř na přímce
- ▶ systematická odchylka ukazuje na rozdělení, které není normální
- ▶ konvexní či konkávní průběh – nesymetrie (nenulová šikmost)
- ▶ esovitý průběh – nenulová špičatost
- ▶ [qqnorm(x)]
- ▶ přímku vloží [qqline(x)]

# normální diagram

[(normal) probability plot], [quantile-comparison plot]

- ▶ k ověřování předpokladu **normálního** rozdělení
- ▶ porovnává skutečnou variační řadu s ideální variační řadou normálního (Gaussova) rozdělení  $N(0, 1)$
- ▶ v ideálním případě body téměř na přímce
- ▶ systematická odchylka ukazuje na rozdělení, které není normální
- ▶ konvexní či konkávní průběh – nesymetrie (nenulová šikmost)
- ▶ esovitý průběh – nenulová špičatost
- ▶ [qqnorm(x)]
- ▶ přímku vloží [qqline(x)]

## závislost dvojice znaků

- ▶ možnost zkoumání závislosti dvou znaků
- ▶ způsob znázornění (prokazování) závisí na měřících znacích
- ▶ **kvantitativní – kvantitativní**  
rozptylový (bodový) diagram [scatter plot]  
korelace, regrese [correlation, regression]
- ▶ **kvalitativní - kvalitativní**  
kontingenční tabulka [contingency table]  
chí-kvadrát test, Fisherův exaktní test
- ▶ **kvantitativní - kvalitativní**  
krabicový diagram [box-plot]  
*t*-test, ANOVA

## závislost dvojice znaků

- ▶ možnost zkoumání závislosti dvou znaků
- ▶ způsob znázornění (prokazování) závisí na měřících znacích
- ▶ **kvantitativní – kvantitativní**  
rozptylový (bodový) diagram [scatter plot]  
korelace, regrese [correlation, regression]
- ▶ **kvalitativní - kvalitativní**  
kontingenční tabulka [contingency table]  
chí-kvadrát test, Fisherův exaktní test
- ▶ **kvantitativní - kvalitativní**  
krabicový diagram [box-plot]  
*t*-test, ANOVA

## závislost dvojice znaků

- ▶ možnost zkoumání závislosti dvou znaků
- ▶ způsob znázornění (prokazování) závisí na měřících znacích
- ▶ **kvantitativní – kvantitativní**  
rozptylový (bodový) diagram [scatter plot]  
korelace, regrese [correlation, regression]
- ▶ **kvalitativní - kvalitativní**  
kontingenční tabulka [contingency table]  
chí-kvadrát test, Fisherův exaktní test
- ▶ **kvantitativní - kvalitativní**  
krabicový diagram [box-plot]  
*t*-test, ANOVA



## závislost dvojice znaků

- ▶ možnost zkoumání závislosti dvou znaků
- ▶ způsob znázornění (prokazování) závisí na měřících znacích
- ▶ **kvantitativní – kvantitativní**  
rozptylový (bodový) diagram [scatter plot]  
korelace, regrese [correlation, regression]
- ▶ **kvalitativní - kvalitativní**  
kontingenční tabulka [contingency table]  
chí-kvadrát test, Fisherův exaktní test
- ▶ **kvantitativní - kvalitativní**  
krabicový diagram [box-plot]  
*t*-test, ANOVA

## závislost dvojice znaků

- ▶ možnost zkoumání závislosti dvou znaků
- ▶ způsob znázornění (prokazování) závisí na měřících znacích
- ▶ **kvantitativní – kvantitativní**  
rozptylový (bodový) diagram [scatter plot]  
korelace, regrese [correlation, regression]
- ▶ **kvalitativní - kvalitativní**  
kontingenční tabulka [contingency table]  
chí-kvadrát test, Fisherův exaktní test
- ▶ **kvantitativní - kvalitativní**  
krabicový diagram [box-plot]  
*t*-test, ANOVA

## kvantitativní – kvantitativní

- ▶ pokud záleží na směru závislosti, pak vysvětlovanou (**závisle proměnnou**) veličinu umístíme na svislou osu  $y$
- ▶ **korelační koeficient**: síla a směr **vzájemné lineární** závislosti

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}, \quad \text{kde} \quad s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- ▶  $s_{xy}$  – výběrová **kovariance** [covariance]
- ▶  $[\text{cor}(x,y)]$   $[\text{cor.test}(x,y)]$  [correlation coefficient]
- ▶ pomocí z-skóru ( $\Rightarrow$  nezávislost na poloze a měřítku)

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right) \left( \frac{y_i - \bar{y}}{s_y} \right)$$

- ▶ pro  $r_{xy} > 0$  s rostoucím  $x$  v průměru roste  $y$
- ▶ pro  $r_{xy} < 0$  s rostoucím  $x$  v průměru klesá  $y$
- ▶ nezávislosti odpovídají hodnoty  $r_{xy}$  blízké nule

$$-1 \leq r_{xy} \leq 1$$

## kvantitativní – kvantitativní

- ▶ pokud záleží na směru závislosti, pak vysvětlovanou (**závisle proměnnou**) veličinu umístíme na svislou osu  $y$
- ▶ **korelační koeficient**: síla a směr **vzájemné lineární** závislosti

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}, \quad \text{kde} \quad s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- ▶  $s_{xy}$  – výběrová **kovariance** [covariance]
- ▶  $[\text{cor}(x,y)]$   $[\text{cor.test}(x,y)]$  [correlation coefficient]
- ▶ pomocí z-skórů ( $\Rightarrow$  nezávislost na poloze a měřítku)

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right) \left( \frac{y_i - \bar{y}}{s_y} \right)$$

- ▶ pro  $r_{xy} > 0$  s rostoucím  $x$  v průměru roste  $y$
- ▶ pro  $r_{xy} < 0$  s rostoucím  $x$  v průměru klesá  $y$
- ▶ nezávislosti odpovídají hodnoty  $r_{xy}$  blízké nule

$$-1 \leq r_{xy} \leq 1$$

## kvantitativní – kvantitativní

- ▶ pokud záleží na směru závislosti, pak vysvětlovanou (**závisle proměnnou**) veličinu umístíme na svislou osu  $y$
- ▶ **korelační koeficient**: síla a směr **vzájemné lineární** závislosti

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}, \quad \text{kde} \quad s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- ▶  $s_{xy}$  – výběrová **kovariance** [covariance]
- ▶  $[\text{cor}(x,y)]$   $[\text{cor.test}(x,y)]$  [correlation coefficient]
- ▶ pomocí z-skóru ( $\Rightarrow$  nezávislost na poloze a měřítku)

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right) \left( \frac{y_i - \bar{y}}{s_y} \right)$$

- ▶ pro  $r_{xy} > 0$  s rostoucím  $x$  v průměru roste  $y$
- ▶ pro  $r_{xy} < 0$  s rostoucím  $x$  v průměru klesá  $y$
- ▶ nezávislosti odpovídají hodnoty  $r_{xy}$  blízké nule

$$-1 \leq r_{xy} \leq 1$$

## kvantitativní – kvantitativní

- ▶ pokud záleží na směru závislosti, pak vysvětlovanou (**závisle proměnnou**) veličinu umístíme na svislou osu  $y$
- ▶ **korelační koeficient**: síla a směr **vzájemné lineární** závislosti

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}, \quad \text{kde} \quad s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- ▶  $s_{xy}$  – výběrová **kovariance** [covariance]
- ▶ [cor(x,y)] [cor.test(x,y)] [correlation coefficient]
- ▶ pomocí z-skórů ( $\Rightarrow$  nezávislost na poloze a měřítku)

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right) \left( \frac{y_i - \bar{y}}{s_y} \right)$$

- ▶ pro  $r_{xy} > 0$  s rostoucím  $x$  v průměru roste  $y$
- ▶ pro  $r_{xy} < 0$  s rostoucím  $x$  v průměru klesá  $y$
- ▶ nezávislosti odpovídají hodnoty  $r_{xy}$  blízké nule

$$-1 \leq r_{xy} \leq 1$$

## kvantitativní – kvantitativní

- ▶ pokud záleží na směru závislosti, pak vysvětlovanou (**závisle proměnnou**) veličinu umístíme na svislou osu  $y$
- ▶ **korelační koeficient**: síla a směr **vzájemné lineární** závislosti

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}, \quad \text{kde} \quad s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- ▶  $s_{xy}$  – výběrová **kovariance** [covariance]
- ▶ [cor(x,y)] [cor.test(x,y)] [correlation coefficient]
- ▶ pomocí z-skórů ( $\Rightarrow$  nezávislost na poloze a měřítku)

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right) \left( \frac{y_i - \bar{y}}{s_y} \right)$$

- ▶ pro  $r_{xy} > 0$  s rostoucím  $x$  v průměru roste  $y$
- ▶ pro  $r_{xy} < 0$  s rostoucím  $x$  v průměru klesá  $y$
- ▶ nezávislosti odpovídají hodnoty  $r_{xy}$  blízké nule

$$-1 \leq r_{xy} \leq 1$$

## kvantitativní – kvantitativní

- ▶ pokud záleží na směru závislosti, pak vysvětlovanou (**závisle proměnnou**) veličinu umístíme na svislou osu  $y$
- ▶ **korelační koeficient**: síla a směr **vzájemné lineární** závislosti

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}, \quad \text{kde} \quad s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- ▶  $s_{xy}$  – výběrová **kovariance** [covariance]
- ▶ [cor(x,y)] [cor.test(x,y)] [correlation coefficient]
- ▶ pomocí z-skórů ( $\Rightarrow$  nezávislost na poloze a měřítku)

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right) \left( \frac{y_i - \bar{y}}{s_y} \right)$$

- ▶ pro  $r_{xy} > 0$  s rostoucím  $x$  v průměru roste  $y$   
 pro  $r_{xy} < 0$  s rostoucím  $x$  v průměru klesá  $y$   
 nezávislosti odpovídají hodnoty  $r_{xy}$  blízké nule


$$-1 \leq r_{xy} \leq 1$$




## kvantitativní – kvantitativní, příklady

vlevo – závislost váhy v 24. týdnu na porodní váze s rozlišením pohlaví (data: Kojení)

vpravo – závislost IQ na průměrné známce v 7. třídě (data: Iq3)



$$r = 0,429$$




$$r = -0,689$$

## příklad: kouření u mužů

data: lchs

vzdělání	zákl.	odb.	mat.	VŠ	celk.
nekuřák	14	55	55	73	197
bývalý k.	11	28	44	42	125
kuřák	14	24	24	17	79
silný k.	78	189	175	106	548
celkem	117	296	298	238	949

v grafu znázorněny **absolutní** četnosti  
(**s**družené, **m**arginální četnosti)  
[`barplot(t,beside=TRUE)`]



# kvalitativní – kvalitativní

- ▶ **kontingenční tabulka** [contingency table]  
obsahuje přehledně zapsané úplné údaje
- ▶ **sružené** četnosti jednotlivých kombinací hodnot dvou znaků
- ▶ **marginální** četnosti:
  - ▶ řádkové marginální četnosti: součty sružených četností v jednotlivých řádcích (pro jednotlivé hodnoty řádkového znaku)
  - ▶ sloupcové marginální četnosti: součty sružených četností v jednotlivých sloupcích (pro jednotlivé hodnoty sloupcového znaku)
- ▶ `[table(F,G)]` nebo `[xtabs(~ F + G)]`  
resp. `[xtabs(~ F + G , data=DataFrame)]`  
kde F a G jsou v R faktory, DataFrame je databáze

## kvalitativní – kvalitativní

- ▶ **kontingenční tabulka** [contingency table]  
obsahuje přehledně zapsané úplné údaje
- ▶ **sružené** četnosti jednotlivých kombinací hodnot dvou znaků
- ▶ **marginální** četnosti:
  - ▶ řádkové marginální četnosti: součty sružených četností v jednotlivých řádcích (pro jednotlivé hodnoty řádkového znaku)
  - ▶ sloupcové marginální četnosti: součty sružených četností v jednotlivých sloupcích (pro jednotlivé hodnoty sloupcového znaku)
- ▶ `[table(F,G)]` nebo `[xtabs(~ F + G)]`  
resp. `[xtabs(~ F + G , data=DataFrame)]`  
kde F a G jsou v R faktory, DataFrame je databáze

## kvalitativní – kvalitativní

- ▶ **kontingenční tabulka** [contingency table]  
obsahuje přehledně zapsané úplné údaje
- ▶ **sružené** četnosti jednotlivých kombinací hodnot dvou znaků
- ▶ **marginální** četnosti:
  - ▶ **řádkové** marginální četnosti: součty sružených četností v jednotlivých řádcích (pro jednotlivé hodnoty řádkového znaku)
  - ▶ **sloupcové** marginální četnosti: součty sružených četností v jednotlivých sloupcích (pro jednotlivé hodnoty sloupcového znaku)
- ▶ `[table(F,G)]` nebo `[xtabs(~ F + G)]`  
resp. `[xtabs(~ F + G , data=DataFrame)]`  
kde F a G jsou v R faktory, DataFrame je databáze

## kvalitativní – kvalitativní

- ▶ **kontingenční tabulka** [contingency table]  
obsahuje přehledně zapsané úplné údaje
- ▶ **sružené** četnosti jednotlivých kombinací hodnot dvou znaků
- ▶ **marginální** četnosti:
  - ▶ **řádkové** marginální četnosti: součty sružených četností v jednotlivých řádcích (pro jednotlivé hodnoty řádkového znaku)
  - ▶ **sloupcové** marginální četnosti: součty sružených četností v jednotlivých sloupcích (pro jednotlivé hodnoty sloupcového znaku)
- ▶ `[table(F,G)]` nebo `[xtabs(~ F + G)]`  
resp. `[xtabs(~ F + G , data=DataFrame)]`  
kde F a G jsou v R faktory, DataFrame je databáze

## kvalitativní – kvalitativní

- ▶ **kontingenční tabulka** [contingency table]  
obsahuje přehledně zapsané úplné údaje
- ▶ **sružené** četnosti jednotlivých kombinací hodnot dvou znaků
- ▶ **marginální** četnosti:
  - ▶ **řádkové** marginální četnosti: součty sružených četností v jednotlivých řádcích (pro jednotlivé hodnoty řádkového znaku)
  - ▶ **sloupcové** marginální četnosti: součty sružených četností v jednotlivých sloupcích (pro jednotlivé hodnoty sloupcového znaku)
- ▶ `[table(F,G)]` nebo `[xtabs(~ F + G)]`  
resp. `[xtabs(~ F + G , data=DataFrame)]`  
kde F a G jsou v R faktory, DataFrame je databáze

## kvalitativní – kvalitativní

- ▶ **kontingenční tabulka** [contingency table]  
obsahuje přehledně zapsané úplné údaje
- ▶ **sdužené** četnosti jednotlivých kombinací hodnot dvou znaků
- ▶ **marginální** četnosti:
  - ▶ **řádkové** marginální četnosti: součty sdužených četností v jednotlivých řádcích (pro jednotlivé hodnoty řádkového znaku)
  - ▶ **sloupcové** marginální četnosti: součty sdužených četností v jednotlivých sloupcích (pro jednotlivé hodnoty sloupcového znaku)
- ▶ `[table(F,G)]` nebo `[xtabs(~ F + G)]`  
resp. `[xtabs(~ F + G , data=DataFrame)]`  
kde F a G jsou v R faktory, DataFrame je databáze




## příklad: kouření u mužů

podmínné relativní četnosti

marginální relativní četnosti

vzdělání	zákl.	odb.	mat.	VŠ	celk.
nekuřák	12,0 %	18,6 %	18,5 %	30,7 %	20,8 %
bývalý k.	9,4 %	9,5 %	14,8 %	17,6 %	13,2 %
kuřák	12,0 %	8,1 %	8,1 %	7,1 %	8,3 %
silný k.	66,7 %	63,9 %	58,7 %	44,5 %	57,7 %
celkem	100 %	100 %	100 %	100 %	100 %



## relativní četnosti v kontingenční tabulce

- ▶ **řádková procenta** (relativní četnosti v daném řádku)
  - ▶ podíl jednotlivých hodnot sloupcového znaku pro danou hodnotu řádkového znaku
  - ▶ **podmíněné rozdělení** hodnot sloupcového znaku pro danou hodnotu řádkového znaku
- ▶ **sloupcová procenta** (relativní četnosti v daném sloupci)
  - ▶ podíl jednotlivých hodnot řádkového znaku pro danou hodnotu sloupcového znaku
  - ▶ **podmíněné rozdělení** hodnot řádkového znaku pro danou hodnotu sloupcového znaku
- ▶ **nezávislosti** obou znaků odpovídá situace, kdy jsou např. sloupcová procenta pro všechny hodnoty sloupcového znaku podobné; podobně pro řádková procenta

## relativní četnosti v kontingenční tabulce

- ▶ **řádková procenta** (relativní četnosti v daném řádku)
  - ▶ podíl jednotlivých hodnot sloupcového znaku pro danou hodnotu řádkového znaku
  - ▶ **podmíněné rozdělení** hodnot sloupcového znaku pro danou hodnotu řádkového znaku
- ▶ **sloupcová procenta** (relativní četnosti v daném sloupci)
  - ▶ podíl jednotlivých hodnot řádkového znaku pro danou hodnotu sloupcového znaku
  - ▶ **podmíněné rozdělení** hodnot řádkového znaku pro danou hodnotu sloupcového znaku
- ▶ **nezávislosti** obou znaků odpovídá situace, kdy jsou např. sloupcová procenta pro všechny hodnoty sloupcového znaku podobné; podobně pro řádková procenta

## relativní četnosti v kontingenční tabulce

- ▶ **řádková procenta** (relativní četnosti v daném řádku)
  - ▶ podíl jednotlivých hodnot sloupcového znaku pro danou hodnotu řádkového znaku
  - ▶ **podmíněné rozdělení** hodnot sloupcového znaku pro danou hodnotu řádkového znaku
- ▶ **sloupcová procenta** (relativní četnosti v daném sloupci)
  - ▶ podíl jednotlivých hodnot řádkového znaku pro danou hodnotu sloupcového znaku
  - ▶ **podmíněné rozdělení** hodnot řádkového znaku pro danou hodnotu sloupcového znaku
- ▶ **nezávislosti** obou znaků odpovídá situace, kdy jsou např. sloupcová procenta pro všechny hodnoty sloupcového znaku podobné; podobně pro řádková procenta

## relativní četnosti v kontingenční tabulce

- ▶ **řádková procenta** (relativní četnosti v daném řádku)
  - ▶ podíl jednotlivých hodnot sloupcového znaku pro danou hodnotu řádkového znaku
  - ▶ **podmíněné rozdělení** hodnot sloupcového znaku pro danou hodnotu řádkového znaku
- ▶ **sloupcová procenta** (relativní četnosti v daném sloupci)
  - ▶ podíl jednotlivých hodnot řádkového znaku pro danou hodnotu sloupcového znaku
  - ▶ **podmíněné rozdělení** hodnot řádkového znaku pro danou hodnotu sloupcového znaku
- ▶ **nezávislosti** obou znaků odpovídá situace, kdy jsou např. sloupcová procenta pro všechny hodnoty sloupcového znaku podobné; podobně pro řádková procenta

## relativní četnosti v kontingenční tabulce

- ▶ **řádková procenta** (relativní četnosti v daném řádku)
  - ▶ podíl jednotlivých hodnot sloupcového znaku pro danou hodnotu řádkového znaku
  - ▶ **podmíněné rozdělení** hodnot sloupcového znaku pro danou hodnotu řádkového znaku
- ▶ **sloupcová procenta** (relativní četnosti v daném sloupci)
  - ▶ podíl jednotlivých hodnot řádkového znaku pro danou hodnotu sloupcového znaku
  - ▶ **podmíněné rozdělení** hodnot řádkového znaku pro danou hodnotu sloupcového znaku
- ▶ **nezávislosti** obou znaků odpovídá situace, kdy jsou např. sloupcová procenta pro všechny hodnoty sloupcového znaku podobné; podobně pro řádková procenta

## relativní četnosti v kontingenční tabulce

- ▶ **řádková procenta** (relativní četnosti v daném řádku)
  - ▶ podíl jednotlivých hodnot sloupcového znaku pro danou hodnotu řádkového znaku
  - ▶ **podmíněné rozdělení** hodnot sloupcového znaku pro danou hodnotu řádkového znaku
- ▶ **sloupcová procenta** (relativní četnosti v daném sloupci)
  - ▶ podíl jednotlivých hodnot řádkového znaku pro danou hodnotu sloupcového znaku
  - ▶ **podmíněné rozdělení** hodnot řádkového znaku pro danou hodnotu sloupcového znaku
- ▶ **nezávislosti** obou znaků odpovídá situace, kdy jsou např. sloupcová procenta pro všechny hodnoty sloupcového znaku podobné; podobně pro řádková procenta

## relativní četnosti v kontingenční tabulce



- ▶ **řádková procenta** (relativní četnosti v daném řádku)
  - ▶ podíl jednotlivých hodnot sloupcového znaku pro danou hodnotu řádkového znaku
  - ▶ **podmíněné rozdělení** hodnot sloupcového znaku pro danou hodnotu řádkového znaku
- ▶ **sloupcová procenta** (relativní četnosti v daném sloupci)
  - ▶ podíl jednotlivých hodnot řádkového znaku pro danou hodnotu sloupcového znaku
  - ▶ **podmíněné rozdělení** hodnot řádkového znaku pro danou hodnotu sloupcového znaku
- ▶ **nezávislosti** obou znaků odpovídá situace, kdy jsou např. sloupcová procenta pro všechny hodnoty sloupcového znaku podobné; podobně pro řádková procenta



# kvantitativní – kvalitativní

váha v jednom roce podle pohlaví, data: Deti1633



- ▶ lze chápat jako závislost spojité veličiny na kvalitativní
- ▶ srovnání souborů dat (spojitá veličina)
- ▶ krabicové diagramy resp. empirické distribuční funkce
- ▶ příklad: hmotnost chlapců a dívek v jednom roce
- ▶ **nezávislosti** odpovídá podobné umístění krabic resp. empirických distribučních funkcí



# kvantitativní – kvalitativní

váha v jednom roce podle pohlaví, data: Deti1633



- ▶ lze chápat jako závislost spojitě veličiny na kvalitativní
- ▶ srovnání souborů dat (spojitě veličina)
- ▶ krabicové diagramy resp. empirické distribuční funkce
- ▶ příklad: hmotnost chlapců a dívek v jednom roce
- ▶ **nezávislosti** odpovídá podobné umístění krabic resp. empirických distribučních funkcí



# kvantitativní – kvalitativní

váha v jednom roce podle pohlaví, data: Deti1633



- ▶ lze chápat jako závislost spojité veličiny na kvalitativní
- ▶ srovnání souborů dat (spojitá veličina)
- ▶ krabicové diagramy resp. empirické distribuční funkce
- ▶ příklad: hmotnost chlapců a dívek v jednom roce
- ▶ **nezávislosti** odpovídá podobné umístění krabic resp. empirických distribučních funkcí



# kvantitativní – kvalitativní

váha v jednom roce podle pohlaví, data: Deti1633



- ▶ lze chápat jako závislost spojitě veličiny na kvalitativní
- ▶ srovnání souborů dat (spojitě veličina)
- ▶ krabicové diagramy resp. empirické distribuční funkce
- ▶ příklad: hmotnost chlapců a dívek v jednom roce
- ▶ **nezávislosti** odpovídá podobné umístění krabic resp. empirických distribučních funkcí



# kvantitativní – kvalitativní

váha v jednom roce podle pohlaví, data: Deti1633



- ▶ lze chápat jako závislost spojité veličiny na kvalitativní
- ▶ srovnání souborů dat (spojitá veličina)
- ▶ krabicové diagramy resp. empirické distribuční funkce
- ▶ příklad: hmotnost chlapců a dívek v jednom roce
- ▶ **nezávislosti** odpovídá podobné umístění krabic resp. empirických distribučních funkcí



## příklad: závislost výšky otce na vzdělání matky

data: Kojení



- ▶ porovnáme výšky otců ve skupinách podle vzdělání matky
- ▶ napravo znázorníme průměry a směrodatné odchylky
- ▶ intervaly kolem průměru mívají i jinou interpretaci (jsou jiné)



## příklad: závislost výšky otce na vzdělání matky

data: Kojení



- ▶ porovnáme výšky otců ve skupinách podle vzdělání matky
- ▶ napravo znázorníme průměry a směrodatné odchylky
- ▶ intervaly kolem průměru mívají i jinou interpretaci (jsou jiné)



## příklad: závislost výšky otce na vzdělání matky

data: Kojení

- ▶ porovnáme výšky otců ve skupinách podle vzdělání matky
- ▶ napravo znázorníme průměry a směrodatné odchylky
- ▶ intervaly kolem průměru mívají i jinou interpretaci (jsou jiné)





# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$

# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$

# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$

# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$

# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$

# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$

# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$

# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$



# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$


# Náhodné jevy

- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$


## znázornění pomocí Vennova diagramu

celý obdélník – jev jistý

$$B \subset D \Rightarrow P(B) \leq P(D)$$




$$P(\bar{B}) = 1 - P(B)$$



velikost plochy odpovídá pravděpodobnosti


$$B \cap D = \emptyset \Rightarrow$$

$$P(B \cup D) = P(B) + P(D)$$



obecně platí

$$P(B \cup D) = P(B) + P(D) - P(B \cap D)$$



velikost plochy odpovídá pravděpodobnosti

# pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost ( $pst$ ) by měla mít stejné vlastnosti jako relativní četnost:

- ▶  $0 \leq P(B) \leq 1$

- ▶  $P(\Omega) = 1, P(\emptyset) = 0$

- ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$

(sčítání pravděpodobností)

- ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$

- ▶  $B \subset D \Rightarrow P(B) \leq P(D)$

- ▶  $P(\bar{B}) = 1 - P(B)$

# pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost ( $pst$ ) by měla mít stejné vlastnosti jako relativní četnost:

- ▶  $0 \leq P(B) \leq 1$

- ▶  $P(\Omega) = 1, P(\emptyset) = 0$

- ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$

(sčítání pravděpodobností)

- ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$

- ▶  $B \subset D \Rightarrow P(B) \leq P(D)$

- ▶  $P(\bar{B}) = 1 - P(B)$

# pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost ( $pst$ ) by měla mít stejné vlastnosti jako relativní četnost:

- ▶  $0 \leq P(B) \leq 1$

- ▶  $P(\Omega) = 1, P(\emptyset) = 0$

- ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$

(sčítání pravděpodobností)

- ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$

- ▶  $B \subset D \Rightarrow P(B) \leq P(D)$

- ▶  $P(\bar{B}) = 1 - P(B)$

# pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost (pst) by měla mít stejné vlastnosti jako relativní četnost:

- ▶  $0 \leq P(B) \leq 1$

- ▶  $P(\Omega) = 1, P(\emptyset) = 0$

- ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$

(sčítání pravděpodobností)

- ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$

- ▶  $B \subset D \Rightarrow P(B) \leq P(D)$

- ▶  $P(\bar{B}) = 1 - P(B)$



# pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost (pst) by měla mít stejné vlastnosti jako relativní četnost:
  - ▶  $0 \leq P(B) \leq 1$
  - ▶  $P(\Omega) = 1, P(\emptyset) = 0$
  - ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$   
(sčítání pravděpodobností)
  - ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$
  - ▶  $B \subset D \Rightarrow P(B) \leq P(D)$
  - ▶  $P(\bar{B}) = 1 - P(B)$

# pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost ( $pst$ ) by měla mít stejné vlastnosti jako relativní četnost:

- ▶  $0 \leq P(B) \leq 1$

- ▶  $P(\Omega) = 1, P(\emptyset) = 0$

- ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$

**(sčítání pravděpodobností)**

- ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$

- ▶  $B \subset D \Rightarrow P(B) \leq P(D)$

- ▶  $P(\bar{B}) = 1 - P(B)$

# pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost ( $pst$ ) by měla mít stejné vlastnosti jako relativní četnost:
  - ▶  $0 \leq P(B) \leq 1$
  - ▶  $P(\Omega) = 1, P(\emptyset) = 0$
  - ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$   
(sčítání pravděpodobností)
  - ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$
  - ▶  $B \subset D \Rightarrow P(B) \leq P(D)$
  - ▶  $P(\bar{B}) = 1 - P(B)$

# pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost ( $pst$ ) by měla mít stejné vlastnosti jako relativní četnost:
  - ▶  $0 \leq P(B) \leq 1$
  - ▶  $P(\Omega) = 1, P(\emptyset) = 0$
  - ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$   
(sčítání pravděpodobností)
  - ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$
  - ▶  $B \subset D \Rightarrow P(B) \leq P(D)$
  - ▶  $P(\bar{B}) = 1 - P(B)$

# pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost ( $pst$ ) by měla mít stejné vlastnosti jako relativní četnost:
  - ▶  $0 \leq P(B) \leq 1$
  - ▶  $P(\Omega) = 1, P(\emptyset) = 0$
  - ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$   
(sčítání pravděpodobností)
  - ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$
  - ▶  $B \subset D \Rightarrow P(B) \leq P(D)$
  - ▶  $P(\bar{B}) = 1 - P(B)$

# klasická definice pravděpodobnosti

## ▶ klasická definice psti

- ▶  $m$  **stejně pravděpodobných** elementárních jevů  $\omega_1, \dots, \omega_m$
- ▶ jsou neslučitelné, sjednocení všech je jistý jev
- ▶  $m_B$  elementárních jevů **příznivých jevu**  $B$   
(tj. takových  $\omega_i$ , že  $\omega_i \in B$ , je právě  $m_B$ )

$$P(B) = \frac{m_B}{m}$$

## ▶ příklad

- ▶ hází se dvěma kostkami (modrá, zelená)
- ▶  $B$  – součet aspoň 10

$$m = 6 \cdot 6 = 36; \quad m_B = 6 \quad \Rightarrow \quad P(B) = \frac{6}{36}$$

příznivé možnosti: (6,4), (6,5), (6,6), (5,5), (5,6), (4,6)

# klasická definice pravděpodobnosti

## ▶ klasická definice psti

- ▶  $m$  **stejně pravděpodobných** elementárních jevů  $\omega_1, \dots, \omega_m$
- ▶ jsou neslučitelné, sjednocení všech je jistý jev
- ▶  $m_B$  elementárních jevů **příznivých jevu**  $B$   
(tj. takových  $\omega_i$ , že  $\omega_i \in B$ , je právě  $m_B$ )

$$P(B) = \frac{m_B}{m}$$

## ▶ příklad

- ▶ hází se dvěma kostkami (modrá, zelená)
- ▶  $B$  – součet aspoň 10

$$m = 6 \cdot 6 = 36; \quad m_B = 6 \quad \Rightarrow \quad P(B) = \frac{6}{36}$$

příznivé možnosti: (6,4), (6,5), (6,6), (5,5), (5,6), (4,6)

# klasická definice pravděpodobnosti

## ▶ klasická definice psti

- ▶  $m$  **stejně pravděpodobných** elementárních jevů  $\omega_1, \dots, \omega_m$
- ▶ jsou neslučitelné, sjednocení všech je jistý jev
- ▶  $m_B$  elementárních jevů **příznivých jevu**  $B$   
(tj. takových  $\omega_i$ , že  $\omega_i \in B$ , je právě  $m_B$ )

$$P(B) = \frac{m_B}{m}$$

## ▶ příklad

- ▶ hází se dvěma kostkami (modrá, zelená)
- ▶  $B$  – součet aspoň 10

$$m = 6 \cdot 6 = 36; \quad m_B = 6 \quad \Rightarrow \quad P(B) = \frac{6}{36}$$

příznivé možnosti: (6,4), (6,5), (6,6), (5,5), (5,6), (4,6)



# klasická definice pravděpodobnosti

## ▶ klasická definice psti

- ▶  $m$  **stejně pravděpodobných** elementárních jevů  $\omega_1, \dots, \omega_m$
- ▶ jsou neslučitelné, sjednocení všech je jistý jev
- ▶  $m_B$  elementárních jevů **příznivých jevu  $B$**   
(tj. takových  $\omega_i$ , že  $\omega_i \in B$ , je právě  $m_B$ )

$$P(B) = \frac{m_B}{m}$$

## ▶ příklad

- ▶ hází se dvěma kostkami (modrá, zelená)
- ▶  $B$  – součet aspoň 10

$$m = 6 \cdot 6 = 36; \quad m_B = 6 \quad \Rightarrow \quad P(B) = \frac{6}{36}$$

příznivé možnosti: (6,4), (6,5), (6,6), (5,5), (5,6), (4,6)

# klasická definice pravděpodobnosti

## ▶ klasická definice psti

- ▶  $m$  **stejně pravděpodobných** elementárních jevů  $\omega_1, \dots, \omega_m$
- ▶ jsou neslučitelné, sjednocení všech je jistý jev
- ▶  $m_B$  elementárních jevů **příznivých jevu**  $B$   
(tj. takových  $\omega_i$ , že  $\omega_i \in B$ , je právě  $m_B$ )

$$P(B) = \frac{m_B}{m}$$

## ▶ příklad

- ▶ hází se dvěma kostkami (modrá, zelená)
- ▶  $B$  – součet aspoň 10

$$m = 6 \cdot 6 = 36; \quad m_B = 6 \quad \Rightarrow \quad P(B) = \frac{6}{36}$$

příznivé možnosti: (6,4), (6,5), (6,6), (5,5), (5,6), (4,6)

# klasická definice pravděpodobnosti

## ▶ klasická definice psti

- ▶  $m$  **stejně pravděpodobných** elementárních jevů  $\omega_1, \dots, \omega_m$
- ▶ jsou neslučitelné, sjednocení všech je jistý jev
- ▶  $m_B$  elementárních jevů **příznivých jevu**  $B$   
(tj. takových  $\omega_i$ , že  $\omega_i \in B$ , je právě  $m_B$ )

$$P(B) = \frac{m_B}{m}$$

## ▶ příklad

- ▶ hází se dvěma kostkami (modrá, zelená)
- ▶  $B$  – součet aspoň 10

$$m = 6 \cdot 6 = 36; \quad m_B = 6 \quad \Rightarrow \quad P(B) = \frac{6}{36}$$

příznivé možnosti: (6,4), (6,5), (6,6), (5,5), (5,6), (4,6)

# klasická definice pravděpodobnosti

## ▶ klasická definice psti

- ▶  $m$  **stejně pravděpodobných** elementárních jevů  $\omega_1, \dots, \omega_m$
- ▶ jsou neslučitelné, sjednocení všech je jistý jev
- ▶  $m_B$  elementárních jevů **příznivých jevu**  $B$   
(tj. takových  $\omega_i$ , že  $\omega_i \in B$ , je právě  $m_B$ )

$$P(B) = \frac{m_B}{m}$$

## ▶ příklad

- ▶ hází se dvěma kostkami (modrá, zelená)
- ▶  $B$  – součet aspoň 10

$$m = 6 \cdot 6 = 36; \quad m_B = 6 \quad \Rightarrow \quad P(B) = \frac{6}{36}$$

příznivé možnosti: (6,4), (6,5), (6,6), (5,5), (5,6), (4,6)

## kombinační číslo

- ▶  $\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1)\dots(n-k+1)}{k(k-1)\dots 1}$
- ▶ kolika způsoby lze z  $n$  rozlišitelných objektů vybrat nějakých  $k$  objektů *bez ohledu na pořadí*
- ▶ kolika způsoby lze z 5 studentů vybrat trojici na přezkoušení?

$$\binom{5}{3} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{(3 \cdot 2 \cdot 1) \cdot (2 \cdot 1)} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = \frac{5 \cdot 4}{2 \cdot 1} = 10$$

- ▶ v čitateli je počet možností, kolika způsoby lze postupně (s ohledem na pořadí!) uspořádat všech 5 studentů
- ▶ ve jmenovateli je součin dvou činitelů
- ▶ první udává kolikrát lze uspořádat tři vybrané studenty
- ▶ druhý udává kolikrát lze uspořádat dva nevybrané studenty
- ▶ každá trojice vybraných studentů se kombinuje s každou dvojicí studentů nevybraných

## kombinační číslo

- ▶  $\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1)\dots(n-k+1)}{k(k-1)\dots 1}$
- ▶ kolika způsoby lze z  $n$  rozlišitelných objektů vybrat nějakých  $k$  objektů *bez ohledu na pořadí*
- ▶ kolika způsoby lze z 5 studentů vybrat trojici na přezkoušení?

$$\binom{5}{3} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{(3 \cdot 2 \cdot 1) \cdot (2 \cdot 1)} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = \frac{5 \cdot 4}{2 \cdot 1} = 10$$

- ▶ v čitateli je počet možností, kolika způsoby lze postupně (s ohledem na pořadí!) uspořádat všech 5 studentů
- ▶ ve jmenovateli je součin dvou činitelů
- ▶ první udává kolikrát lze uspořádat tři vybrané studenty
- ▶ druhý udává kolikrát lze uspořádat dva nevybrané studenty
- ▶ každá trojice vybraných studentů se kombinuje s každou dvojicí studentů nevybraných

## kombinační číslo

- ▶  $\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1)\dots(n-k+1)}{k(k-1)\dots 1}$
- ▶ kolika způsoby lze z  $n$  rozlišitelných objektů vybrat nějakých  $k$  objektů *bez ohledu na pořadí*
- ▶ kolika způsoby lze z 5 studentů vybrat trojici na přezkoušení?

$$\binom{5}{3} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{(3 \cdot 2 \cdot 1) \cdot (2 \cdot 1)} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = \frac{5 \cdot 4}{2 \cdot 1} = 10$$

- ▶ v čitateli je počet možností, kolika způsoby lze postupně (s ohledem na pořadí!) uspořádat všech 5 studentů
- ▶ ve jmenovateli je součin dvou činitelů
- ▶ první udává kolikrát lze uspořádat tři vybrané studenty
- ▶ druhý udává kolikrát lze uspořádat dva nevybrané studenty
- ▶ každá trojice vybraných studentů se kombinuje s každou dvojicí studentů nevybraných

## kombinační číslo

- ▶  $\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1)\dots(n-k+1)}{k(k-1)\dots 1}$
- ▶ kolika způsoby lze z  $n$  rozlišitelných objektů vybrat nějakých  $k$  objektů *bez ohledu na pořadí*
- ▶ kolika způsoby lze z 5 studentů vybrat trojici na přezkoušení?

$$\binom{5}{3} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{(3 \cdot 2 \cdot 1) \cdot (2 \cdot 1)} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = \frac{5 \cdot 4}{2 \cdot 1} = 10$$

- ▶ v čitateli je počet možností, kolika způsoby lze postupně (s ohledem na pořadí!) uspořádat všech 5 studentů
- ▶ ve jmenovateli je součin dvou činitelů
- ▶ první udává kolikrát lze uspořádat tři vybrané studenty
- ▶ druhý udává kolikrát lze uspořádat dva nevybrané studenty
- ▶ každá trojice vybraných studentů se kombinuje s každou dvojicí studentů nevybraných



## kombinační číslo

- ▶  $\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1)\dots(n-k+1)}{k(k-1)\dots 1}$
- ▶ kolika způsoby lze z  $n$  rozlišitelných objektů vybrat nějakých  $k$  objektů *bez ohledu na pořadí*
- ▶ kolika způsoby lze z 5 studentů vybrat trojici na přezkoušení?

$$\binom{5}{3} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{(3 \cdot 2 \cdot 1) \cdot (2 \cdot 1)} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = \frac{5 \cdot 4}{2 \cdot 1} = 10$$

- ▶ v čitateli je počet možností, kolika způsoby lze postupně (s ohledem na pořadí!) uspořádat všech 5 studentů
- ▶ ve jmenovateli je součin dvou činitelů
  - ▶ první udává kolikrát lze uspořádat tři vybrané studenty
  - ▶ druhý udává kolikrát lze uspořádat dva nevybrané studenty
  - ▶ každá trojice vybraných studentů se kombinuje s každou dvojicí studentů nevybraných

## kombinační číslo

- ▶  $\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1)\dots(n-k+1)}{k(k-1)\dots 1}$
- ▶ kolika způsoby lze z  $n$  rozlišitelných objektů vybrat nějakých  $k$  objektů *bez ohledu na pořadí*
- ▶ kolika způsoby lze z 5 studentů vybrat trojici na přezkoušení?

$$\binom{5}{3} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{(3 \cdot 2 \cdot 1) \cdot (2 \cdot 1)} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = \frac{5 \cdot 4}{2 \cdot 1} = 10$$

- ▶ v čitateli je počet možností, kolika způsoby lze postupně (s ohledem na pořadí!) uspořádat všech 5 studentů
- ▶ ve jmenovateli je součin dvou činitelů
- ▶ první udává kolikrát lze uspořádat tři vybrané studenty
- ▶ druhý udává kolikrát lze uspořádat dva nevybrané studenty
- ▶ každá trojice vybraných studentů se kombinuje s každou dvojicí studentů nevybraných

## kombinační číslo

- ▶  $\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1)\dots(n-k+1)}{k(k-1)\dots 1}$
- ▶ kolika způsoby lze z  $n$  rozlišitelných objektů vybrat nějakých  $k$  objektů *bez ohledu na pořadí*
- ▶ kolika způsoby lze z 5 studentů vybrat trojici na přezkoušení?

$$\binom{5}{3} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{(3 \cdot 2 \cdot 1) \cdot (2 \cdot 1)} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = \frac{5 \cdot 4}{2 \cdot 1} = 10$$

- ▶ v čitateli je počet možností, kolika způsoby lze postupně (s ohledem na pořadí!) uspořádat všech 5 studentů
- ▶ ve jmenovateli je součin dvou činitelů
- ▶ první udává kolikrát lze uspořádat tři vybrané studenty
- ▶ druhý udává kolikrát lze uspořádat dva nevybrané studenty
- ▶ každá trojice vybraných studentů se kombinuje s každou dvojicí studentů nevybraných

## kombinační číslo


- ▶  $\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1)\dots(n-k+1)}{k(k-1)\dots 1}$
- ▶ kolika způsoby lze z  $n$  rozlišitelných objektů vybrat nějakých  $k$  objektů *bez ohledu na pořadí*
- ▶ kolika způsoby lze z 5 studentů vybrat trojici na přezkoušení?

$$\binom{5}{3} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{(3 \cdot 2 \cdot 1) \cdot (2 \cdot 1)} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = \frac{5 \cdot 4}{2 \cdot 1} = 10$$

- ▶ v čitateli je počet možností, kolika způsoby lze postupně (s ohledem na pořadí!) uspořádat všech 5 studentů
- ▶ ve jmenovateli je součin dvou činitelů
- ▶ první udává kolikrát lze uspořádat tři vybrané studenty
- ▶ druhý udává kolikrát lze uspořádat dva nevybrané studenty
- ▶ každá trojice vybraných studentů se kombinuje s každou dvojicí studentů nevybraných


# Počítání ryb v rybníku

( $m = 20$ )




# Počítání ryb v rybníku

$$(m = 20), a = 7$$



## Počítání ryb v rybníku

$$(m = 20), a = 7, n = 5, Y = 1 \Rightarrow \hat{m} = n \cdot a / Y = 35$$



# hypergeometrické rozdělení

příklad na klasickou pravděpodobnost

- ▶ v rybníku je  $m$  ryb (zpravidla neznámý počet)
  - $a$  ryb vylovíme, označíme a vypustíme zpět
- ▶ po nějaké době vylovíme  $n$  ryb, z nich  $Y$  je označených
- ▶ číslo  $Y$  předem neznáme, je to **náhodná veličina**
- ▶ s jakou pravděpodobností je  $Y = k$ ?
  - ▶ celkem  $\binom{m}{n}$  možných  $n$ -tic vylovených ryb
  - ▶  $k$  označených lze vybrat  $\binom{a}{k}$  způsoby
  - ▶  $n - k$  neoznačených lze vybrat  $\binom{m-a}{n-k}$  způsoby

$$P(Y = k) = \frac{\binom{a}{k} \binom{m-a}{n-k}}{\binom{m}{n}}, \quad \max(0, n + a - m) \leq k \leq \min(a, n)$$

- ▶ např. odhad neznámého  $m$ :  $\hat{m} = \frac{n \cdot a}{Y}$  (neboť  $Y/n \doteq a/m$ )



# hypergeometrické rozdělení

příklad na klasickou pravděpodobnost

- ▶ v rybníku je  $m$  ryb (zpravidla neznámý počet)
  - $a$  ryb vylovíme, označíme a vypustíme zpět
- ▶ po nějaké době vylovíme  $n$  ryb, z nich  $Y$  je označených
- ▶ číslo  $Y$  předem neznáme, je to **náhodná veličina**
- ▶ s jakou pravděpodobností je  $Y = k$ ?
  - ▶ celkem  $\binom{m}{n}$  možných  $n$ -tic vylovených ryb
  - ▶  $k$  označených lze vybrat  $\binom{a}{k}$  způsoby
  - ▶  $n - k$  neoznačených lze vybrat  $\binom{m-a}{n-k}$  způsoby

$$P(Y = k) = \frac{\binom{a}{k} \binom{m-a}{n-k}}{\binom{m}{n}}, \quad \max(0, n+a-m) \leq k \leq \min(a, n)$$

- ▶ např. odhad neznámého  $m$ :  $\hat{m} = \frac{n \cdot a}{Y}$  (neboť  $Y/n \doteq a/m$ )

# hypergeometrické rozdělení

příklad na klasickou pravděpodobnost

- ▶ v rybníku je  $m$  ryb (zpravidla neznámý počet)
  - $a$  ryb vylovíme, označíme a vypustíme zpět
- ▶ po nějaké době vylovíme  $n$  ryb, z nich  $Y$  je označených
- ▶ číslo  $Y$  předem neznáme, je to **náhodná veličina**
- ▶ s jakou pravděpodobností je  $Y = k$ ?
  - ▶ celkem  $\binom{m}{n}$  možných  $n$ -tic vylovených ryb
  - ▶  $k$  označených lze vybrat  $\binom{a}{k}$  způsoby
  - ▶  $n - k$  neoznačených lze vybrat  $\binom{m-a}{n-k}$  způsoby

$$P(Y = k) = \frac{\binom{a}{k} \binom{m-a}{n-k}}{\binom{m}{n}}, \quad \max(0, n+a-m) \leq k \leq \min(a, n)$$

- ▶ např. odhad neznámého  $m$ :  $\hat{m} = \frac{n \cdot a}{Y}$  (neboť  $Y/n \doteq a/m$ )

# hypergeometrické rozdělení

příklad na klasickou pravděpodobnost

- ▶ v rybníku je  $m$  ryb (zpravidla neznámý počet)
  - $a$  ryb vylovíme, označíme a vypustíme zpět
- ▶ po nějaké době vylovíme  $n$  ryb, z nich  $Y$  je označených
- ▶ číslo  $Y$  předem neznáme, je to **náhodná veličina**
- ▶ s jakou pravděpodobností je  $Y = k$ ?
  - ▶ celkem  $\binom{m}{n}$  možných  $n$ -tic vylovených ryb
  - ▶  $k$  označených lze vybrat  $\binom{a}{k}$  způsoby
  - ▶  $n - k$  neoznačených lze vybrat  $\binom{m-a}{n-k}$  způsoby

$$P(Y = k) = \frac{\binom{a}{k} \binom{m-a}{n-k}}{\binom{m}{n}}, \quad \max(0, n + a - m) \leq k \leq \min(a, n)$$

- ▶ např. odhad neznámého  $m$ :  $\hat{m} = \frac{n \cdot a}{Y}$  (neboť  $Y/n \doteq a/m$ )

# hypergeometrické rozdělení

příklad na klasickou pravděpodobnost

- ▶ v rybníku je  $m$  ryb (zpravidla neznámý počet)  
 $a$  ryb vylovíme, označíme a vypustíme zpět
- ▶ po nějaké době vylovíme  $n$  ryb, z nich  $Y$  je označených
- ▶ číslo  $Y$  předem neznáme, je to **náhodná veličina**
- ▶ s jakou pravděpodobností je  $Y = k$ ?
  - ▶ celkem  $\binom{m}{n}$  možných  $n$ -tic vylovených ryb
  - ▶  $k$  označených lze vybrat  $\binom{a}{k}$  způsoby
  - ▶  $n - k$  neoznačených lze vybrat  $\binom{m-a}{n-k}$  způsoby

$$P(Y = k) = \frac{\binom{a}{k} \binom{m-a}{n-k}}{\binom{m}{n}}, \quad \max(0, n + a - m) \leq k \leq \min(a, n)$$

- ▶ např. odhad neznámého  $m$ :  $\hat{m} = \frac{n \cdot a}{Y}$  (neboť  $Y/n \doteq a/m$ )

# hypergeometrické rozdělení

příklad na klasickou pravděpodobnost

- ▶ v rybníku je  $m$  ryb (zpravidla neznámý počet)
  - $a$  ryb vylovíme, označíme a vypustíme zpět
- ▶ po nějaké době vylovíme  $n$  ryb, z nich  $Y$  je označených
- ▶ číslo  $Y$  předem neznáme, je to **náhodná veličina**
- ▶ s jakou pravděpodobností je  $Y = k$ ?
  - ▶ celkem  $\binom{m}{n}$  možných  $n$ -tic vylovených ryb
  - ▶  $k$  označených lze vybrat  $\binom{a}{k}$  způsoby
  - ▶  $n - k$  neoznačených lze vybrat  $\binom{m-a}{n-k}$  způsoby

$$P(Y = k) = \frac{\binom{a}{k} \binom{m-a}{n-k}}{\binom{m}{n}}, \quad \max(0, n + a - m) \leq k \leq \min(a, n)$$

- ▶ např. odhad neznámého  $m$ :  $\hat{m} = \frac{n \cdot a}{Y}$  (neboť  $Y/n \doteq a/m$ )

# hypergeometrické rozdělení

příklad na klasickou pravděpodobnost

- ▶ v rybníku je  $m$  ryb (zpravidla neznámý počet)
  - $a$  ryb vylovíme, označíme a vypustíme zpět
- ▶ po nějaké době vylovíme  $n$  ryb, z nich  $Y$  je označených
- ▶ číslo  $Y$  předem neznáme, je to **náhodná veličina**
- ▶ s jakou pravděpodobností je  $Y = k$ ?
  - ▶ celkem  $\binom{m}{n}$  možných  $n$ -tic vylovených ryb
  - ▶  $k$  označených lze vybrat  $\binom{a}{k}$  způsoby
  - ▶  $n - k$  neoznačených lze vybrat  $\binom{m-a}{n-k}$  způsoby

$$P(Y = k) = \frac{\binom{a}{k} \binom{m-a}{n-k}}{\binom{m}{n}}, \quad \max(0, n + a - m) \leq k \leq \min(a, n)$$

- ▶ např. odhad neznámého  $m$ :  $\hat{m} = \frac{n \cdot a}{Y}$  (neboť  $Y/n \doteq a/m$ )

# hypergeometrické rozdělení

příklad na klasickou pravděpodobnost

- ▶ v rybníku je  $m$  ryb (zpravidla neznámý počet)  
 $a$  ryb vylovíme, označíme a vypustíme zpět
- ▶ po nějaké době vylovíme  $n$  ryb, z nich  $Y$  je označených
- ▶ číslo  $Y$  předem neznáme, je to **náhodná veličina**
- ▶ s jakou pravděpodobností je  $Y = k$ ?
  - ▶ celkem  $\binom{m}{n}$  možných  $n$ -tic vylovených ryb
  - ▶  $k$  označených lze vybrat  $\binom{a}{k}$  způsoby
  - ▶  $n - k$  neoznačených lze vybrat  $\binom{m-a}{n-k}$  způsoby

$$P(Y = k) = \frac{\binom{a}{k} \binom{m-a}{n-k}}{\binom{m}{n}}, \quad \max(0, n + a - m) \leq k \leq \min(a, n)$$

- ▶ např. odhad neznámého  $m$ :  $\hat{m} = \frac{n \cdot a}{Y}$  (neboť  $Y/n \doteq a/m$ )

## příklad ponožky

V noci vzbudili Kubu, že má jít hlídat tábor. Po tmě z pytlíku vytáhl **dvě** ponožky, aniž ověřil jejich barvu. Původně tam byly tři páry ponožek ze stejného materiálu: zelené, modré, šedivé.

Náhodné jevy a veličiny:

- ▶  $A$  obě ponožky jsou stejné barvy
- ▶  $B$  aspoň jedna obutá ponožka je zelená
- ▶  $C$  aspoň jedna obutá ponožka je modrá
- ▶  $D$  na pravé noze je zelená ponožka
- ▶  $X$  počet obutých šedivých ponožek
- ▶  $Y$  počet obutých modrých ponožek



## příklad ponožky

V noci vzbudili Kubu, že má jít hlídat tábor. Po tmě z pytlíku vytáhl **dvě** ponožky, aniž ověřil jejich barvu. Původně tam byly tři páry ponožek ze stejného materiálu: zelené, modré, šedivé.

Náhodné jevy a veličiny:

- ▶  $A$  obě ponožky jsou stejné barvy
- ▶  $B$  aspoň jedna obutá ponožka je zelená
- ▶  $C$  aspoň jedna obutá ponožka je modrá
- ▶  $D$  na pravé noze je zelená ponožka
- ▶  $X$  počet obutých šedivých ponožek
- ▶  $Y$  počet obutých modrých ponožek

## příklad ponožky

V noci vzbudili Kubu, že má jít hlídat tábor. Po tmě z pytlíku vytáhl **dvě** ponožky, aniž ověřil jejich barvu. Původně tam byly tři páry ponožek ze stejného materiálu: zelené, modré, šedivé.

Náhodné jevy a veličiny:

- ▶  $A$  obě ponožky jsou stejné barvy
- ▶  $B$  aspoň jedna obutá ponožka je zelená
- ▶  $C$  aspoň jedna obutá ponožka je modrá
- ▶  $D$  na pravé noze je zelená ponožka
- ▶  $X$  počet obutých šedivých ponožek
- ▶  $Y$  počet obutých modrých ponožek

## příklad ponožky

V noci vzbudili Kubu, že má jít hlídat tábor. Po tmě z pytlíku vytáhl **dvě** ponožky, aniž ověřil jejich barvu. Původně tam byly tři páry ponožek ze stejného materiálu: zelené, modré, šedivé.

Náhodné jevy a veličiny:

- ▶  $A$  obě ponožky jsou stejné barvy
- ▶  $B$  aspoň jedna obutá ponožka je zelená
- ▶  $C$  aspoň jedna obutá ponožka je modrá
- ▶  $D$  na pravé noze je zelená ponožka
- ▶  $X$  počet obutých šedivých ponožek
- ▶  $Y$  počet obutých modrých ponožek

## příklad ponožky

V noci vzbudili Kubu, že má jít hlídat tábor. Po tmě z pytlíku vytáhl **dvě** ponožky, aniž ověřil jejich barvu. Původně tam byly tři páry ponožek ze stejného materiálu: zelené, modré, šedivé.

Náhodné jevy a veličiny:

- ▶  $A$  obě ponožky jsou stejné barvy
- ▶  $B$  aspoň jedna obutá ponožka je zelená
- ▶  $C$  aspoň jedna obutá ponožka je modrá
- ▶  $D$  na pravé noze je zelená ponožka
- ▶  $X$  počet obutých šedivých ponožek
- ▶  $Y$  počet obutých modrých ponožek

## příklad ponožky

V noci vzbudili Kubu, že má jít hlídat tábor. Po tmě z pytlíku vytáhl **dvě** ponožky, aniž ověřil jejich barvu. Původně tam byly tři páry ponožek ze stejného materiálu: zelené, modré, šedivé.

Náhodné jevy a veličiny:

- ▶  $A$  obě ponožky jsou stejné barvy
- ▶  $B$  aspoň jedna obutá ponožka je zelená
- ▶  $C$  aspoň jedna obutá ponožka je modrá
- ▶  $D$  na pravé noze je zelená ponožka
- ▶  $X$  počet obutých šedivých ponožek
- ▶  $Y$  počet obutých modrých ponožek

## příklad ponožky – výpočet pravděpodobností jevů

označení (z,m) znamená barvu postupně na levé a na pravé noze

možnosti vytáhnou **dvojici** ponožek:  $m = 6 \cdot 5 = 30$ možnosti vytáhnout dvě zelené:  $m_{z,z} = 2 \cdot 1 = 2$ možnosti vytáhnout zelenou a modrou:  $m_{z,m} = 2 \cdot 2 = 4$ 


$\omega_i$	$P(\omega_i)$	A	B	C	D	$B \cap C$	$B \cup C$	Y	X
(z,z)	1/15	•	•		•		•	0	0
(z,m)	2/15		•	•		•	•	1	0
(z,š)	2/15		•				•	0	1
(m,z)	2/15		•	•	•	•	•	1	0
(m,m)	1/15	•		•			•	2	0
(m,š)	2/15			•			•	1	1
(š,z)	2/15		•		•		•	0	1
(š,m)	2/15			•			•	1	1
(š,š)	1/15	•						0	2
pravděpodobnost		3/15	9/15	9/15	5/15	4/15	14/15		

$$P(B) + P(C) - P(B \cap C) = \frac{9}{15} + \frac{9}{15} - \frac{4}{15} = \frac{14}{15} = P(B \cup C)$$

## podmíněná pravděpodobnost

Vennův diagram: když víme, že nastalo  $A$  (je to jisté,  $pst A$  za podmínky  $A$  je rovna 1), pak **podmíněná  $pst$  jevu  $B$  za podmínky  $A$  bude rovna relativní velikosti  $B \cap A$  vzhledem k velikosti  $A$**

$$P(B|A) = \frac{P(A \cap B)}{P(A)}$$



## příklad ponožky: s jakou pstí se Kuba obul rozumně?

- ▶ bez další informace:  $P(A) = \frac{3}{15} = \frac{1}{5}$
- ▶ spolubydlící ve stanu Aleš se v noci vzbudil a v pytlíku viděl pár zelených ponožek

$$P(A|\bar{B}) = \frac{P(A \cap \bar{B})}{P(\bar{B})} = \frac{2/15}{6/15} = \frac{1}{3} > \frac{1}{5} = P(A)$$

- ▶ v pytlíku chyběla aspoň jedna modrá nebo aspoň jedna zelená

$$P(A|(B \cup C)) = \frac{P(A \cap (B \cup C))}{P(B \cup C)} = \frac{2/15}{14/15} = \frac{1}{7} < \frac{1}{5} = P(A)$$

- ▶ na pravé noze má Kuba zelenou

$$P(A|D) = \frac{P(A \cap D)}{P(D)} = \frac{1/15}{5/15} = \frac{1}{5} = \frac{1}{5} = P(A)$$



## příklad ponožky: s jakou pstí se Kuba obul rozumně?

- ▶ bez další informace:  $P(A) = \frac{3}{15} = \frac{1}{5}$
- ▶ spolubydlící ve stanu Aleš se v noci vzbudil a v pytlíku viděl pár zelených ponožek

$$P(A|\bar{B}) = \frac{P(A \cap \bar{B})}{P(\bar{B})} = \frac{2/15}{6/15} = \frac{1}{3} > \frac{1}{5} = P(A)$$

- ▶ v pytlíku chyběla aspoň jedna modrá nebo aspoň jedna zelená

$$P(A|(B \cup C)) = \frac{P(A \cap (B \cup C))}{P(B \cup C)} = \frac{2/15}{14/15} = \frac{1}{7} < \frac{1}{5} = P(A)$$

- ▶ na pravé noze má Kuba zelenou

$$P(A|D) = \frac{P(A \cap D)}{P(D)} = \frac{1/15}{5/15} = \frac{1}{5} = \frac{1}{5} = P(A)$$

## příklad ponožky: s jakou pstí se Kuba obul rozumně?

- ▶ bez další informace:  $P(A) = \frac{3}{15} = \frac{1}{5}$
- ▶ spolubydlící ve stanu Aleš se v noci vzbudil a v pytlíku viděl pár zelených ponožek

$$P(A|\bar{B}) = \frac{P(A \cap \bar{B})}{P(\bar{B})} = \frac{2/15}{6/15} = \frac{1}{3} > \frac{1}{5} = P(A)$$

- ▶ v pytlíku chyběla aspoň jedna modrá nebo aspoň jedna zelená

$$P(A|(B \cup C)) = \frac{P(A \cap (B \cup C))}{P(B \cup C)} = \frac{2/15}{14/15} = \frac{1}{7} < \frac{1}{5} = P(A)$$

- ▶ na pravé noze má Kuba zelenou

$$P(A|D) = \frac{P(A \cap D)}{P(D)} = \frac{1/15}{5/15} = \frac{1}{5} = \frac{1}{5} = P(A)$$

## příklad ponožky: s jakou pstí se Kuba obul rozumně?

- ▶ bez další informace:  $P(A) = \frac{3}{15} = \frac{1}{5}$
- ▶ spolubydlící ve stanu Aleš se v noci vzbudil a v pytlíku viděl pár zelených ponožek

$$P(A|\bar{B}) = \frac{P(A \cap \bar{B})}{P(\bar{B})} = \frac{2/15}{6/15} = \frac{1}{3} > \frac{1}{5} = P(A)$$

- ▶ v pytlíku chyběla aspoň jedna modrá nebo aspoň jedna zelená

$$P(A|(B \cup C)) = \frac{P(A \cap (B \cup C))}{P(B \cup C)} = \frac{2/15}{14/15} = \frac{1}{7} < \frac{1}{5} = P(A)$$

- ▶ na pravé noze má Kuba zelenou

$$P(A|D) = \frac{P(A \cap D)}{P(D)} = \frac{1/15}{5/15} = \frac{1}{5} = \frac{1}{5} = P(A)$$

## nezávislost náhodných jevů

informace, že na pravé noze je zelená ponožka (jev  $D$ ) neovlivnila pravděpodobnost jevu  $A$  (stejná barva ponožek)  
jevy  $A$  a  $D$  jsou **nezávislé**

$$P(A|D) = \frac{P(A \cap D)}{P(D)} = P(A)$$

a tedy po odstranění zlomku v druhé rovnosti

$$P(A \cap D) = P(A) \cdot P(D)$$

definuje **nezávislost** náhodných jevů  $A$  a  $D$   
(informace o výskytu  $D$  neovlivnila pravděpodobnost jevu  $A$ )  
vlastnost symetrická, nezávisí na pořadí

## vlastnosti podmíněné pravděpodobnost

- ▶ pravděpodobnost jevu  $D$  za podmínky jevu  $C$

$$P(D|C) = \frac{m_{D \cap C}}{m_C} = \frac{m_{D \cap C}/m}{m_C/m} = \frac{P(D \cap C)}{P(C)}$$

- ▶ pravděpodobnost průniku jevů  $D, C$  obecně

$$P(D \cap C) = P(D|C)P(C)$$

$$P(C \cap D) = P(C|D)P(D)$$

- ▶ ale  $D \cap C = C \cap D$ , proto

$$P(C \cap D) = P(D \cap C)$$

- ▶ odtud shoda pravých stran

$$P(D|C)P(C) = P(C|D)P(D)$$

- ▶ vyděl  $P(C) \Rightarrow$  Bayesův vzorec:

$$P(D|C) = \frac{P(C|D)P(D)}{P(C)}$$

## vlastnosti podmíněné pravděpodobnost

- ▶ pravděpodobnost jevu  $D$  za podmínky jevu  $C$

$$P(D|C) = \frac{m_{D \cap C}}{m_C} = \frac{m_{D \cap C}/m}{m_C/m} = \frac{P(D \cap C)}{P(C)}$$

- ▶ pravděpodobnost průniku jevů  $D, C$  obecně

$$P(D \cap C) = P(D|C)P(C)$$

$$P(C \cap D) = P(C|D)P(D)$$

- ▶ ale  $D \cap C = D \cap C$ , proto

$$P(C \cap D) = P(D \cap C)$$

- ▶ odtud shoda pravých stran

$$P(D|C)P(C) = P(C|D)P(D)$$

- ▶ vyděl  $P(C) \Rightarrow$  Bayesův vzorec:

$$P(D|C) = \frac{P(C|D)P(D)}{P(C)}$$

## vlastnosti podmíněné pravděpodobnost

- ▶ pravděpodobnost jevu  $D$  za podmínky jevu  $C$

$$P(D|C) = \frac{m_{D \cap C}}{m_C} = \frac{m_{D \cap C}/m}{m_C/m} = \frac{P(D \cap C)}{P(C)}$$

- ▶ pravděpodobnost průniku jevů  $D, C$  obecně

$$P(D \cap C) = P(D|C)P(C)$$

$$P(C \cap D) = P(C|D)P(D)$$

- ▶ ale  $D \cap C = D \cap C$ , proto

$$P(C \cap D) = P(D \cap C)$$

- ▶ odtud shoda pravých stran

$$P(D|C)P(C) = P(C|D)P(D)$$

- ▶ vyděl  $P(C) \Rightarrow$  Bayesův vzorec:

$$P(D|C) = \frac{P(C|D)P(D)}{P(C)}$$

## vlastnosti podmíněné pravděpodobnost

- ▶ pravděpodobnost jevu  $D$  za podmínky jevu  $C$

$$P(D|C) = \frac{m_{D \cap C}}{m_C} = \frac{m_{D \cap C}/m}{m_C/m} = \frac{P(D \cap C)}{P(C)}$$

- ▶ pravděpodobnost průniku jevů  $D, C$  obecně

$$P(D \cap C) = P(D|C)P(C)$$

$$P(C \cap D) = P(C|D)P(D)$$

- ▶ ale  $D \cap C = D \cap C$ , proto

$$P(C \cap D) = P(D \cap C)$$

- ▶ odtud shoda pravých stran

$$P(D|C)P(C) = P(C|D)P(D)$$

- ▶ vyděl  $P(C) \Rightarrow$  Bayesův vzorec:

$$P(D|C) = \frac{P(C|D)P(D)}{P(C)}$$



## vlastnosti podmíněné pravděpodobnost

- ▶ pravděpodobnost jevu  $D$  za podmínky jevu  $C$

$$P(D|C) = \frac{m_{D \cap C}}{m_C} = \frac{m_{D \cap C}/m}{m_C/m} = \frac{P(D \cap C)}{P(C)}$$

- ▶ pravděpodobnost průniku jevů  $D, C$  obecně

$$P(D \cap C) = P(D|C)P(C)$$

$$P(C \cap D) = P(C|D)P(D)$$

- ▶ ale  $D \cap C = D \cap C$ , proto

$$P(C \cap D) = P(D \cap C)$$


- ▶ odtud shoda pravých stran

$$P(D|C)P(C) = P(C|D)P(D)$$

- ▶ vyděl  $P(C) \Rightarrow$  Bayesův vzorec:

$$P(D|C) = \frac{P(C|D)P(D)}{P(C)}$$

## vzorec pro úplnou pst, Bayesův vzorec

počítáme  $P(H_1|C)$ , např.  $C$  – správná odpověď,  $H_j$  – správná známka  $j$ 

$$P(H_1) = 0,231$$

$$P(H_2) = 0,375$$

$$P(H_3) = 0,219$$

$$P(H_4) = 0,175$$

$$P(C|H_1) = 0,589$$

$$P(C|H_2) = 0,362 \quad (\text{proč je } P(C|H_2) < P(C|H_1)?)$$

$$P(C \cap H_1) = P(C|H_1)P(H_1), \quad P(C \cap H_2) = P(C|H_2)P(H_2)$$

$$P(C) = P(C \cap H_1) + P(C \cap H_2) = 0,136 + 0,136 = 0,272$$

$$P(H_1 \cap C) = P(H_1|C)P(C)$$

$$P(H_1|C) = \frac{P(H_1 \cap C)}{P(C)} = \frac{P(C|H_1)P(H_1)}{P(C|H_1)P(H_1) + P(C|H_2)P(H_2)} = \frac{1}{2}$$

## obecný vzorec pro úplnou pravděpodobnost

(totéž, ale obecně))

- ▶  $H_1, \dots, H_k$  neslučitelné (tj.  $H_i \cap H_j = \emptyset$  pro  $i \neq j$ )
- ▶ sjednocení  $H_1, \dots, H_k$  dá jev jistý (tj.  $H_1 \cup \dots \cup H_k = \Omega$ )

z definice podmíněné psti plyne  $P(C \cap H_j) = P(C|H_j) \cdot P(H_j)$

$$\begin{aligned} P(C) &= P(C \cap \Omega) = P(C \cap (H_1 \cup H_2 \cup \dots \cup H_k)) \\ &= P((C \cap H_1) \cup (C \cap H_2) \cup \dots \cup (C \cap H_k)) \text{ (neslučitelné jevy)} \\ &= P(C \cap H_1) + P(C \cap H_2) + \dots + P(C \cap H_k) \\ &= P(C|H_1)P(H_1) + P(C|H_2)P(H_2) + \dots + P(C|H_k)P(H_k) \end{aligned}$$

tedy obecně

$$P(C) = \sum_{j=1}^k P(C|H_j) P(H_j)$$

$P(C)$  je **váženým průměrem** podmíněných pstí  $P(C|H_j)$

## Bayesův vzorec [Bayes formula]

stejně předpoklady:  $H_j$  neslučitelné, sjednocení všech jistý jev

$$P(H_i|C) = \frac{P(H_i \cap C)}{P(C)}, \quad P(C|H_i) = \frac{P(C \cap H_i)}{P(H_i)}$$

odtud je pro libovolně zvolené  $i$

$$P(H_i \cap C) = P(C \cap H_i) = P(C|H_i) P(H_i)$$

proto pro každé  $i$ ,  $i = 1, \dots, k$  platí

$$P(H_i|C) = \frac{P(H_i \cap C)}{P(C)} = \frac{P(C|H_i) P(H_i)}{P(C)} = \frac{P(C|H_i) P(H_i)}{\sum_{j=1}^k P(C|H_j) P(H_j)}$$

$H_1, \dots, H_k$  – **hypotézy**,  $P(H_1|C), \dots, P(H_k|C)$  – **aposteriorní** psti  
 $P(H_1), \dots, P(H_k)$  – **apriorní** psti (nutně  $P(H_1) + \dots + P(H_k) = 1$ )

## příklad: zkoušení

$H_j$  – student si zaslouží známku  $j$ , učitel studenta (tedy  $j$ ) nezná

$C$  – student správně odpoví na položenou otázku

$P(H_j)$  – apriorní představa učitele o neznámém studentovi

$P(C|H_j)$  – obtížnost otázky, volí učitel

$H_j$	$P(H_j)$	$P(C H_j)$	$P(C H_j)P(H_j)$	$P(H_j C)$	$P(H_j C_2)$	$P(H_j C_3)$
1	0,20	1,00	0,2000	0,2694	0,3451	0,4230
2	0,35	0,80	0,2800	0,3771	0,3865	0,3790
3	0,25	0,65	0,1625	0,2189	0,1822	0,1452
4	0,20	0,50	0,1000	0,1347	0,0863	0,0529
$\Sigma$	1,00		0,7425	1,0000	1,0000	1,0000

$$P(C) = 0,7425$$

podobně  $C_2, C_3$  správné odpovědi na další stejně obtížné otázky, když použijeme předchozí aposteriorní psti jako apriorní

## senzitivita, specificita, prevalence

- ▶  $D$  – subjekt je nemocen, **prevalence** – podíl nemocných v populaci  $P(D)$ , zvolme  $P(D) = 0,001$
- ▶ nemoc je skrytá, vyhledáváme ji pomocí testu s vlastnostmi:
  - ▶  $P(T|D)$  – pravděpodobnost pozitivního výsledku u nemocného (senzitivita, pokud možno velká, zvolme  $P(T|D) = 0,98$ , na test pozitivně reaguje 98 % nemocných)
  - ▶  $P(\bar{T}|\bar{D})$  – pravděpodobnost negativního výsledku u zdravého (specificita, pokud možno velká, zvolme  $P(\bar{T}|\bar{D}) = 0,99$ , na test pozitivně reaguje jen  $P(T|\bar{D}) = 1 - P(\bar{T}|\bar{D}) = 1$  % zdravých)

## senzitivita, specificita, prevalence

- ▶  $D$  – subjekt je nemocen, **prevalence** – podíl nemocných v populaci  $P(D)$ , zvolme  $P(D) = 0,001$
- ▶ nemoc je skrytá, vyhledáváme ji pomocí testu s vlastnostmi:
  - ▶  $P(T|D)$  – pravděpodobnost pozitivního výsledku u nemocného (**senzitivita**, pokud možno velká, zvolme  $P(T|D) = 0,98$ , na test pozitivně reaguje 98 % nemocných)
  - ▶  $P(\bar{T}|\bar{D})$  – pravděpodobnost negativního výsledku u zdravého (**specificita**, pokud možno velká, zvolme  $P(\bar{T}|\bar{D}) = 0,99$ , na test pozitivně reaguje jen  $P(T|\bar{D}) = 1 - P(\bar{T}|\bar{D}) = 1$  % zdravých)

## senzitivita, specificita, prevalence

- ▶  $D$  – subjekt je nemocen, **prevalence** – podíl nemocných v populaci  $P(D)$ , zvolme  $P(D) = 0,001$
- ▶ nemoc je skrytá, vyhledáváme ji pomocí testu s vlastnostmi:
  - ▶  $P(T|D)$  – pravděpodobnost pozitivního výsledku u nemocného (**senzitivita**, pokud možno velká, zvolme  $P(T|D) = 0,98$ , na test pozitivně reaguje 98 % nemocných)
  - ▶  $P(\bar{T}|\bar{D})$  – pravděpodobnost negativního výsledku u zdravého (**specificita**, pokud možno velká, zvolme  $P(\bar{T}|\bar{D}) = 0,99$ , na test pozitivně reaguje jen  $P(T|\bar{D}) = 1 - P(\bar{T}|\bar{D}) = 1$  % zdravých)



## senzitivita, specificita, prevalence

- ▶  $D$  – subjekt je nemocen, **prevalence** – podíl nemocných v populaci  $P(D)$ , zvolme  $P(D) = 0,001$
- ▶ nemoc je skrytá, vyhledáváme ji pomocí testu s vlastnostmi:
  - ▶  $P(T|D)$  – pravděpodobnost pozitivního výsledku u nemocného (**senzitivita**, pokud možno velká, zvolme  $P(T|D) = 0,98$ , na test pozitivně reaguje 98 % nemocných)
  - ▶  $P(\bar{T}|\bar{D})$  – pravděpodobnost negativního výsledku u zdravého (**specificita**, pokud možno velká, zvolme  $P(\bar{T}|\bar{D}) = 0,99$ , na test pozitivně reaguje jen  $P(T|\bar{D}) = 1 - P(\bar{T}|\bar{D}) = 1$  % zdravých)

## senzitivita, specificita, prevalence

- ▶ jaká je pst, že pozitivně reagující je opravdu nemocný?

$$\begin{aligned}
 P(D|T) &= \frac{P(T|D)P(D)}{P(T|D)P(D) + P(T|\bar{D})P(\bar{D})} \\
 &= \frac{0,98 \cdot 0,001}{0,98 \cdot 0,001 + 0,01 \cdot 0,999} \doteq 0,089
 \end{aligned}$$

- ▶ jaká je pst, že jde o zdravého člověka v případě, že test byl negativní?

$$\begin{aligned}
 P(\bar{D}|\bar{T}) &= \frac{P(\bar{T}|\bar{D})P(\bar{D})}{P(\bar{T}|\bar{D})P(\bar{D}) + P(\bar{T}|D)P(D)} \\
 &= \frac{0,99 \cdot 0,999}{0,99 \cdot 0,999 + 0,02 \cdot 0,001} = 0,99998
 \end{aligned}$$

- ▶ porovnej s apriorními pstmi: 0,001 resp. 0,999

## senzitivita, specificita, prevalence

- ▶ jaká je pst, že pozitivně reagující je opravdu nemocný?

$$\begin{aligned}
 P(D|T) &= \frac{P(T|D)P(D)}{P(T|D)P(D) + P(T|\bar{D})P(\bar{D})} \\
 &= \frac{0,98 \cdot 0,001}{0,98 \cdot 0,001 + 0,01 \cdot 0,999} \doteq 0,089
 \end{aligned}$$

- ▶ jaká je pst, že jde o zdravého člověka v případě, že test byl negativní?

$$\begin{aligned}
 P(\bar{D}|\bar{T}) &= \frac{P(\bar{T}|\bar{D})P(\bar{D})}{P(\bar{T}|\bar{D})P(\bar{D}) + P(\bar{T}|D)P(D)} \\
 &= \frac{0,99 \cdot 0,999}{0,99 \cdot 0,999 + 0,02 \cdot 0,001} = 0,99998
 \end{aligned}$$

- ▶ porovnej s apriorními pstmi: 0,001 resp. 0,999

## senzitivita, specificita, prevalence

- ▶ jaká je pst, že pozitivně reagující je opravdu nemocný?

$$\begin{aligned}
 P(D|T) &= \frac{P(T|D)P(D)}{P(T|D)P(D) + P(T|\bar{D})P(\bar{D})} \\
 &= \frac{0,98 \cdot 0,001}{0,98 \cdot 0,001 + 0,01 \cdot 0,999} \doteq 0,089
 \end{aligned}$$

- ▶ jaká je pst, že jde o zdravého člověka v případě, že test byl negativní?

$$\begin{aligned}
 P(\bar{D}|\bar{T}) &= \frac{P(\bar{T}|\bar{D})P(\bar{D})}{P(\bar{T}|\bar{D})P(\bar{D}) + P(\bar{T}|D)P(D)} \\
 &= \frac{0,99 \cdot 0,999}{0,99 \cdot 0,999 + 0,02 \cdot 0,001} = 0,99998
 \end{aligned}$$

- ▶ porovnej s apriorními pstmi: 0,001 resp. 0,999

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ pstí hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ pstí hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ pstní hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ pstí hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$



# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ pstní hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ psti hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ psti hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ psti hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ psti hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ psti hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ psti hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ psti hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$



# náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ psti hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličiny (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

## příklad: ponožky

 $X$  a  $Y$  mají stejné rozdělenínáhodná veličina  $Y$  – počet modrých ponožekrozdělení  $Y$  dáno hodnotami  $y_j^*$  a pstmí těchto hodnot  $P(Y = y_j^*)$ náhodná veličina  $X$  – počet šedivých ponožekrozdělení  $X$  dáno hodnotami  $x_j^*$  a pstmí těchto hodnot  $P(X = x_j^*)$ 

$\omega_j$	$P(\omega_j)$	$Y$	$X$
(z,z)	1/15	0	0
(z,m)	2/15	1	0
(z,š)	2/15	0	1
(m,z)	2/15	1	0
(m,m)	1/15	2	0
(m,š)	2/15	1	1
(š,z)	2/15	0	1
(š,m)	2/15	1	1
(š,š)	1/15	0	2

$j$	$x_j^*$	$P(X = x_j^*)$
1	<b>0</b>	2/15+4/15= <b>6/15</b>
2	<b>1</b>	0/15+8/15= <b>8/15</b>
3	<b>2</b>	1/15+0/15= <b>1/15</b>

$j$	$y_j^*$	$P(Y = y_j^*)$
1	<b>0</b>	2/15+4/15= <b>6/15</b>
2	<b>1</b>	0/15+8/15= <b>8/15</b>
3	<b>2</b>	1/15+0/15= <b>1/15</b>

# distribuční funkce

protějšek empirické distribuční funkce (str. 19), [(cumulative) distribution function]

- ▶ pst, že  $X$  nepřekročí  $x$

$$F_X(x) = P(X \leq x)$$

- ▶ diskrétní rozdělení:

$$F(x) = \sum_{k \leq x} P(X = k)$$

- ▶ spojité rozdělení:  $F(x) = \int_{-\infty}^x f(t)dt$ , kde  $f(x) = \frac{dF(x)}{dx}$
- ▶ vlastnosti distribuční funkce

$$0 \leq F(x) \leq 1$$

neklesající:  $x_1 < x_2 \Rightarrow F(x_1) \leq F(x_2)$

$$P(x_1 < X \leq x_2) = F(x_2) - F(x_1)$$

# distribuční funkce

protějšek empirické distribuční funkce (str. 19), [(cumulative) distribution function]

- ▶ pst, že  $X$  nepřekročí  $x$

$$F_X(x) = P(X \leq x)$$

- ▶ diskrétní rozdělení:

$$F(x) = \sum_{k \leq x} P(X = k)$$

- ▶ spojité rozdělení:  $F(x) = \int_{-\infty}^x f(t)dt$ , kde  $f(x) = \frac{dF(x)}{dx}$
- ▶ vlastnosti distribuční funkce

$$0 \leq F(x) \leq 1$$

neklesající:  $x_1 < x_2 \Rightarrow F(x_1) \leq F(x_2)$

$$P(x_1 < X \leq x_2) = F(x_2) - F(x_1)$$

## distribuční funkce

protějšek empirické distribuční funkce (str. 19), [(cumulative) distribution function]

- ▶ pst, že  $X$  nepřekročí  $x$

$$F_X(x) = P(X \leq x)$$

- ▶ diskrétní rozdělení:

$$F(x) = \sum_{k \leq x} P(X = k)$$

- ▶ spojité rozdělení:  $F(x) = \int_{-\infty}^x f(t)dt$ , kde  $f(x) = \frac{dF(x)}{dx}$
- ▶ vlastnosti distribuční funkce

$$0 \leq F(x) \leq 1$$

neklesající:  $x_1 < x_2 \Rightarrow F(x_1) \leq F(x_2)$

$$P(x_1 < X \leq x_2) = F(x_2) - F(x_1)$$

## distribuční funkce

protějšek empirické distribuční funkce (str. 19), [(cumulative) distribution function]

- ▶ pst, že  $X$  nepřekročí  $x$

$$F_X(x) = P(X \leq x)$$

- ▶ diskrétní rozdělení:

$$F(x) = \sum_{k \leq x} P(X = k)$$

- ▶ spojité rozdělení:  $F(x) = \int_{-\infty}^x f(t)dt$ , kde  $f(x) = \frac{dF(x)}{dx}$
- ▶ vlastnosti distribuční funkce

$$0 \leq F(x) \leq 1$$


neklesající:  $x_1 < x_2 \Rightarrow F(x_1) \leq F(x_2)$

$$P(x_1 < X \leq x_2) = F(x_2) - F(x_1)$$

# příklad diskrétního rozdělení

rozdělení počtu modrých ponožek  $Y$

$j$	$y_j^*$	$P(Y = y_j^*)$	$F_Y(y_j^*)$
1	0	$6/15$	$6/15=0,400$
2	1	$8/15$	$14/15 \doteq 0,933$
3	2	$1/15$	$15/15=1,000$





# hustota spojitého rozdělení

[density function]

- ▶ necht'  $f(x)$  je hustota náhodné veličiny  $X$
- ▶ hustota je nezáporná, plocha pod celou hustotou je rovna jedné

$$f(x) \geq 0, \quad \int_{-\infty}^{\infty} f(x) dx = 1$$

- ▶ plocha pod hustotou nad intervalem  $x_1, x_2$  je rovna pravděpodobnosti, že  $X$  je mezi  $x_1, x_2$







# hustota spojitého rozdělení

[density function]

- ▶ necht'  $f(x)$  je hustota náhodné veličiny  $X$
- ▶ hustota je nezáporná, plocha pod celou hustotou je rovna jedné

$$f(x) \geq 0, \quad \int_{-\infty}^{\infty} f(x)dx = 1$$

- ▶ plocha pod hustotou nad intervalem  $x_1, x_2$  je rovna pravděpodobnosti, že  $X$  je mezi  $x_1, x_2$





# hustota spojitého rozdělení

[density function]

- ▶ necht'  $f(x)$  je hustota náhodné veličiny  $X$
- ▶ hustota je nezáporná, plocha pod celou hustotou je rovna jedné

$$f(x) \geq 0, \quad \int_{-\infty}^{\infty} f(x)dx = 1$$

- ▶ plocha pod hustotou nad intervalem  $x_1, x_2$  je rovna pravděpodobnosti, že  $X$  je mezi  $x_1, x_2$




## geometrický význam hustoty

$P(x_1 < X, X \leq x_2) = P(x_1 < X \leq x_2)$ , vpravo stručnější, používaný zápis

$$\begin{aligned} F(x_2) &= P(X \leq x_2) = P(X \leq x_1) + P(x_1 < X \leq x_2) \\ &= F(x_1) + P(x_1 < X \leq x_2) \end{aligned}$$

odtud  $\boxed{P(x_1 < X \leq x_2) = F(x_2) - F(x_1)}$   $= \int_{x_1}^{x_2} f_X(x) dx$





## $p$ -kvantil $x_p$

- ▶  $x_p$  je hodnota, pod kterou je  $100p$  procent pravděpodobnosti

$$P(X \leq x_p) = p$$

- ▶ populační protějšek percentilu
- ▶ např. `[qnorm(0.975)]` dá  $1,959964 \doteq 1,96$





## $p$ -kvantil $x_p$

- ▶  $x_p$  je hodnota, pod kterou je  $100p$  procent pravděpodobnosti

$$P(X \leq x_p) = p$$

- ▶ populační protějšek percentilu
- ▶ např. `[qnorm(0.975)]` dá  $1,959964 \doteq 1,96$





## $p$ -kvantil $x_p$

- ▶  $x_p$  je hodnota, pod kterou je  $100p$  procent pravděpodobnosti

$$P(X \leq x_p) = p$$

- ▶ populační protějšek percentilu
- ▶ např. `[qnorm(0.975)]` dá  $1,959964 \doteq 1,96$





## kritická hodnota $x(\alpha)$

kritická hodnota  $x(\alpha)$  je překročena s pstí  $\alpha$

$$P(X \geq x(\alpha)) = \alpha$$

např. `[qnorm(1-0.025)]` dá  $1,959964 \doteq 1,96$



## střední hodnota

pokračujeme v idealizovaných představách

- ▶ míra polohy, **populační průměr**, očekávaná hodnota  
[expected value, mean value]
- ▶ metoda výpočtu se značí  $E X$
- ▶ vypočtená hodnota se značí  $\mu$  nebo úplněji  $\mu_X$
- ▶ **vážený průměr možných hodnot**
- ▶ ideální protějšek výběrového průměru
- ▶ diskrétní rozdělení: vahami jsou pravděpodobnosti

$$\mu_X = E X = \sum_j x_j^* P(X = x_j^*)$$

- ▶ spojitě rozdělení: místo vah je hustota  $f_X(x)$

$$\mu_X = E X = \int_{-\infty}^{\infty} x f_X(x) dx$$



## střední hodnota

pokračujeme v idealizovaných představách

- ▶ míra polohy, **populační průměr**, očekávaná hodnota  
[expected value, mean value]
- ▶ metoda výpočtu se značí  $E X$
- ▶ vypočtená hodnota se značí  $\mu$  nebo úplněji  $\mu_X$
- ▶ **vážený průměr možných hodnot**
- ▶ ideální protějšek výběrového průměru
- ▶ diskrétní rozdělení: vahami jsou pravděpodobnosti

$$\mu_X = E X = \sum_j x_j^* P(X = x_j^*)$$

- ▶ spojitě rozdělení: místo vah je hustota  $f_X(x)$

$$\mu_X = E X = \int_{-\infty}^{\infty} x f_X(x) dx$$

## střední hodnota

pokračujeme v idealizovaných představách

- ▶ míra polohy, **populační průměr**, očekávaná hodnota  
[expected value, mean value]
- ▶ metoda výpočtu se značí  $E X$
- ▶ vypočtená hodnota se značí  $\mu$  nebo úplněji  $\mu_X$
- ▶ vážený průměr možných hodnot
- ▶ ideální protějšek výběrového průměru
- ▶ diskrétní rozdělení: vahami jsou pravděpodobnosti

$$\mu_X = E X = \sum_j x_j^* P(X = x_j^*)$$

- ▶ spojitě rozdělení: místo vah je hustota  $f_X(x)$

$$\mu_X = E X = \int_{-\infty}^{\infty} x f_X(x) dx$$

## střední hodnota

pokračujeme v idealizovaných představách

- ▶ míra polohy, **populační průměr**, očekávaná hodnota  
[expected value, mean value]
- ▶ metoda výpočtu se značí  $E X$
- ▶ vypočtená hodnota se značí  $\mu$  nebo úplněji  $\mu_X$
- ▶ **vážený průměr možných hodnot**
- ▶ ideální protějšek výběrového průměru
- ▶ diskrétní rozdělení: vahami jsou pravděpodobnosti

$$\mu_X = E X = \sum_j x_j^* P(X = x_j^*)$$

- ▶ spojité rozdělení: místo vah je hustota  $f_X(x)$

$$\mu_X = E X = \int_{-\infty}^{\infty} x f_X(x) dx$$

## střední hodnota

pokračujeme v idealizovaných představách

- ▶ míra polohy, **populační průměr**, očekávaná hodnota  
[expected value, mean value]
- ▶ metoda výpočtu se značí  $E X$
- ▶ vypočtená hodnota se značí  $\mu$  nebo úplněji  $\mu_X$
- ▶ **vážený průměr možných hodnot**
- ▶ ideální protějšek výběrového průměru
- ▶ diskrétní rozdělení: vahami jsou pravděpodobnosti

$$\mu_X = E X = \sum_j x_j^* P(X = x_j^*)$$

- ▶ spojité rozdělení: místo vah je hustota  $f_X(x)$

$$\mu_X = E X = \int_{-\infty}^{\infty} x f_X(x) dx$$

## střední hodnota

pokračujeme v idealizovaných představách

- ▶ míra polohy, **populační průměr**, očekávaná hodnota  
[expected value, mean value]
- ▶ metoda výpočtu se značí  $E X$
- ▶ vypočtená hodnota se značí  $\mu$  nebo úplněji  $\mu_X$
- ▶ **vážený průměr možných hodnot**
- ▶ ideální protějšek výběrového průměru
- ▶ diskrétní rozdělení: vahami jsou pravděpodobnosti

$$\mu_X = E X = \sum_j x_j^* P(X = x_j^*)$$

- ▶ spojité rozdělení: místo vah je hustota  $f_X(x)$

$$\mu_X = E X = \int_{-\infty}^{\infty} x f_X(x) dx$$

## střední hodnota

pokračujeme v idealizovaných představách

- ▶ míra polohy, **populační průměr**, očekávaná hodnota  
[expected value, mean value]
- ▶ metoda výpočtu se značí  $E X$
- ▶ vypočtená hodnota se značí  $\mu$  nebo úplněji  $\mu_X$
- ▶ **vážený průměr možných hodnot**
- ▶ ideální protějšek výběrového průměru
- ▶ diskrétní rozdělení: vahami jsou pravděpodobnosti

$$\mu_X = E X = \sum_j x_j^* P(X = x_j^*)$$

- ▶ spojitě rozdělení: místo vah je hustota  $f_X(x)$

$$\mu_X = E X = \int_{-\infty}^{\infty} x f_X(x) dx$$

## příklad ponožky

 $X$  – počet modrých ponožek

$j$	$x_j^*$	$P(X = x_j^*)$	$x_j^* \cdot P(X = x_j^*)$
1	0	6/15	0
2	1	8/15	8/15
3	2	1/15	2/15
součet		15/15	10/15

$$\mu_X = 0 \cdot \frac{6}{15} + 1 \cdot \frac{8}{15} + 2 \cdot \frac{1}{15} = \frac{10}{15} = \frac{2}{3}$$

▶ Náhodná veličina

# (populační) rozptyl $\sigma^2$ , (populační) směrodatná odchylka $\sigma$

[variance, standard deviation]

- ▶ míra variability, **populační rozptyl, popul. směr. odchylka**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylky
- ▶ diskrétní rozdělení

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ spojité rozdělení  $\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$



# (populační) rozptyl $\sigma^2$ , (populační) směrodatná odchylka $\sigma$

[variance, standard deviation]

- ▶ míra variability, **populační rozptyl**, **popul. směr. odchylka**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylky
- ▶ diskrétní rozdělení

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ spojité rozdělení  $\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$

# (populační) rozptyl $\sigma^2$ , (populační) směrodatná odchylka $\sigma$

[variance, standard deviation]

- ▶ míra variability, **populační rozptyl**, **popul. směr. odchylka**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylky
- ▶ diskrétní rozdělení

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ spojité rozdělení  $\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$

# (populační) rozptyl $\sigma^2$ , (populační) směrodatná odchylka $\sigma$

[variance, standard deviation]

- ▶ míra variability, **populační rozptyl**, **popul. směr. odchylka**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylky
- ▶ diskrétní rozdělení

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ spojité rozdělení  $\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$

# (populační) rozptyl $\sigma^2$ , (populační) směrodatná odchylka $\sigma$

[variance, standard deviation]

- ▶ míra variability, **populační rozptyl**, **popul. směr. odchylka**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylky
- ▶ diskrétní rozdělení

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ spojité rozdělení  $\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$

# (populační) rozptyl $\sigma^2$ , (populační) směrodatná odchylna $\sigma$

[variance, standard deviation]

- ▶ míra variability, **populační rozptyl**, **popul. směr. odchylna**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylny
- ▶ diskrétní rozdělení

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ spojité rozdělení  $\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$

# (populační) rozptyl $\sigma^2$ , (populační) směrodatná odchylka $\sigma$

[variance, standard deviation]

- ▶ míra variability, **populační rozptyl**, **popul. směr. odchylka**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylky
- ▶ **diskrétní rozdělení**

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ **spojité rozdělení**  $\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$

# (populační) rozptyl $\sigma^2$ , (populační) směrodatná odchylka $\sigma$

[variance, standard deviation]

- ▶ míra variability, **populační rozptyl**, **popul. směr. odchylka**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylky
- ▶ diskrétní rozdělení

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ spojité rozdělení

$$\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$$

# (populační) rozptyl $\sigma^2$ , (populační) směrodatná odchylka $\sigma$

[variance, standard deviation]

- ▶ míra variability, **populační rozptyl**, **popul. směr. odchylka**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylky
- ▶ diskrétní rozdělení

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ spojité rozdělení  $\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$



## příklad ponožky

 $X$  – počet šedivých ponožek,  $\mu_X = 2/3$ 

$j$	$x_j^*$	$P(X = x_j^*)$	$x_j^* - \mu_X$	$(x_j^* - \mu_X)^2$	$(x_j^* - \mu_X)^2 P(X = x_j^*)$
1	0	6/15	-2/3	4/9	24/135
2	1	8/15	1/3	1/9	8/135
3	2	1/15	4/3	16/9	16/135
$\Sigma$		15/15	???		48/135=16/45

$$\begin{aligned} \sigma_X^2 &= \sum_j (x_j^* - \mu_X)^2 p_j \\ &= (0 - 2/3)^2 \cdot 6/15 + (1 - 2/3)^2 \cdot 8/15 \\ &\quad + (2 - 2/3)^2 \cdot 1/15 = 16/45 \doteq 0,356 \\ \sigma_X &= \sqrt{16/45} \doteq 0,596 \end{aligned}$$

## sdružené rozdělení

- ▶ abychom mohli popsat **závislost** náhodných veličin, zajímáme se o **společné** chování dvojice (trojice, . . . ) náhodných veličin, tedy chování **náhodného vektoru**
- ▶ příklad **ponožky**
  - ▶  $X$  – počet šedivých ponožek
  - ▶  $Y$  – počet modrých
  - ▶  $Z$  – počet jiných než šedivých ponožek
- ▶ zajímá nás rozdělení náhodného vektoru  $(X, Y)$
- ▶ proč nemá smysl vyšetřovat **vektor**  $(X, Z)$ ?
- ▶ (protože  $Z$  je určeno  $X$  jednoznačně:  $Z = 2 - X$ )

## sdružené rozdělení

- ▶ abychom mohli popsat **závislost** náhodných veličin, zajímáme se o **společné** chování dvojice (trojice, . . . ) náhodných veličin, tedy chování **náhodného vektoru**
- ▶ příklad **ponožky**
  - ▶  $X$  – počet šedivých ponožek
  - ▶  $Y$  – počet modrých
  - ▶  $Z$  – počet jiných než šedivých ponožek
- ▶ zajímá nás rozdělení náhodného vektoru  $(X, Y)$
- ▶ proč nemá smysl vyšetřovat **vektor**  $(X, Z)$ ?
- ▶ (protože  $Z$  je určeno  $X$  jednoznačně:  $Z = 2 - X$ )

## sdružené rozdělení

- ▶ abychom mohli popsat **závislost** náhodných veličin, zajímáme se o **společné** chování dvojice (trojice, . . . ) náhodných veličin, tedy chování **náhodného vektoru**
- ▶ příklad **ponožky**
  - ▶  $X$  – počet šedivých ponožek
  - ▶  $Y$  – počet modrých
  - ▶  $Z$  – počet jiných než šedivých ponožek
- ▶ zajímá nás rozdělení náhodného vektoru  $(X, Y)$
- ▶ proč nemá smysl vyšetřovat **vektor**  $(X, Z)$ ?
- ▶ (protože  $Z$  je určeno  $X$  jednoznačně:  $Z = 2 - X$ )

## sdružené rozdělení

- ▶ abychom mohli popsat **závislost** náhodných veličin, zajímáme se o **společné** chování dvojice (trojice, . . . ) náhodných veličin, tedy chování **náhodného vektoru**
- ▶ příklad **ponožky**
  - ▶  $X$  – počet šedivých ponožek
  - ▶  $Y$  – počet modrých
  - ▶  $Z$  – počet jiných než šedivých ponožek
- ▶ zajímá nás rozdělení náhodného vektoru  $(X, Y)$
- ▶ proč nemá smysl vyšetřovat **vektor**  $(X, Z)$ ?
- ▶ (protože  $Z$  je určeno  $X$  jednoznačně:  $Z = 2 - X$ )

## sdružené rozdělení

- ▶ abychom mohli popsat **závislost** náhodných veličin, zajímáme se o **společné** chování dvojice (trojice, ... ) náhodných veličin, tedy chování **náhodného vektoru**
- ▶ příklad **ponožky**
  - ▶  $X$  – počet šedivých ponožek
  - ▶  $Y$  – počet modrých
  - ▶  $Z$  – počet jiných než šedivých ponožek
- ▶ zajímá nás rozdělení náhodného vektoru  $(X, Y)$
- ▶ proč nemá smysl vyšetřovat **vektor**  $(X, Z)$ ?
- ▶ (protože  $Z$  je určeno  $X$  jednoznačně:  $Z = 2 - X$ )

## sdružené rozdělení

- ▶ abychom mohli popsat **závislost** náhodných veličin, zajímáme se o **společné** chování dvojice (trojice, . . . ) náhodných veličin, tedy chování **náhodného vektoru**
- ▶ příklad **ponožky**
  - ▶  $X$  – počet šedivých ponožek
  - ▶  $Y$  – počet modrých
  - ▶  $Z$  – počet jiných než šedivých ponožek
- ▶ zajímá nás rozdělení náhodného vektoru  $(X, Y)$
- ▶ proč nemá smysl vyšetřovat **vektor**  $(X, Z)$ ?
- ▶ (protože  $Z$  je určeno  $X$  jednoznačně:  $Z = 2 - X$ )

## sdružené rozdělení

- ▶ abychom mohli popsat **závislost** náhodných veličin, zajímáme se o **společné** chování dvojice (trojice, . . . ) náhodných veličin, tedy chování **náhodného vektoru**
- ▶ příklad **ponožky**
  - ▶  $X$  – počet šedivých ponožek
  - ▶  $Y$  – počet modrých
  - ▶  $Z$  – počet jiných než šedivých ponožek
- ▶ zajímá nás rozdělení náhodného vektoru  $(X, Y)$
- ▶ proč nemá smysl vyšetřovat **vektor**  $(X, Z)$ ?
- ▶ (protože  $Z$  je určeno  $X$  jednoznačně:  $Z = 2 - X$ )



## sdružené rozdělení

- ▶ abychom mohli popsat **závislost** náhodných veličin, zajímáme se o **společné** chování dvojice (trojice, . . . ) náhodných veličin, tedy chování **náhodného vektoru**
- ▶ příklad **ponožky**
  - ▶  $X$  – počet šedivých ponožek
  - ▶  $Y$  – počet modrých
  - ▶  $Z$  – počet jiných než šedivých ponožek
- ▶ zajímá nás rozdělení náhodného vektoru  $(X, Y)$
- ▶ proč nemá smysl vyšetřovat **vektor**  $(X, Z)$ ?
- ▶ (protože  $Z$  je určeno  $X$  jednoznačně:  $Z = 2 - X$ )

## příklad ponožky

$X$  šedivých ponožek,  $Y$  počet modrých ponožek

sdužené pravděpodobnosti, **marginální** pravděpodobnosti,  
**podmíněné** pravděpodobnosti  $Y$  při daném  $X = x$

$\omega_i$	$P(\omega_i)$	$Y$	$X$
(z,z)	1/15	0	0
(z,m)	2/15	1	0
(z,š)	2/15	0	1
(m,z)	2/15	1	0
(m,m)	1/15	2	0
(m,š)	2/15	1	1
(š,z)	2/15	0	1
(š,m)	2/15	1	1
(š,š)	1/15	0	2

$x_i^*$	$y_j^*$			celkem
	0	1	2	
0	1/15	4/15	1/15	6/15
1	4/15	4/15	0/15	8/15
2	1/15	0/15	0/15	1/15
	6/15	8/15	1/15	15/15

$x_i^*$	$y_j^*$			celkem
	0	1	2	
0	1/6	4/6	1/6	1
1	3/6	3/6	0/6	1
2	6/6	0	0	1

## sdužené, **marginální** a **podmíněné** rozdělení

**sdužené rozdělení** – popisuje **společné chování**  $X, Y$

$$P(X = x_i^*, Y = y_j^*) \text{ resp. } f_{X,Y}(x, y)$$

**marginální rozdělení**: chování jedné bez ohledu na hodnotu druhé

$$P(X = x_i^*) = \sum_j P(X = x_i^*, Y = y_j^*) \quad \forall x_i^*$$

$$P(Y = y_j^*) = \sum_i P(X = x_i^*, Y = y_j^*) \quad \forall y_j^*$$

**podmíněné rozdělení**: chování  $Y$  při **dané** hodnotě  $X$

$$P(Y = y_j^* | X = x_i^*) = \frac{P(X = x_i^*, Y = y_j^*)}{P(X = x_i^*)}$$

## kovariance

protějšek  $s_{xy}$  (str. 37), [covariance]

**kovariance** vyjadřuje vzájemnou závislost náhodných veličin:

$$\sigma_{X,Y} = E(X - \mu_X)(Y - \mu_Y)$$

$$\sigma_{X,Y} = \sum_i \sum_j (x_i^* - \mu_X)(y_j^* - \mu_Y) P(X = x_i^*, Y = y_j^*)$$

označení metody výpočtu:  $\text{cov}(X, Y)$

zřejmě platí  $\text{cov}(X, X) = \text{var } X$  tj.  $\sigma_{X,X} = \sigma_X^2$

náhodné veličiny jsou **nezávislé** právě tehdy, když platí

$$P(X = x_i^*, Y = y_j^*) = P(X = x_i^*) \cdot P(Y = y_j^*), \quad \forall (x_i^*, y_j^*)$$

**(ze znalosti hodnoty jedné veličiny nic nevíme o druhé)**

jsou-li  $X, Y$  – nezávislé  $\Rightarrow \sigma_{X,Y} = 0$  (nikoliv obrácená implikace)

## shrnutí vlastností populačního průměru a rozptylu

srovnej s požadavky na míry polohy a míry variability

$$\mu_{\alpha+X} = \alpha + \mu_X,$$

$$\sigma_{\alpha+X}^2 = \sigma_X^2,$$

$$\sigma_{\alpha+X} = \sigma_X,$$

$$\mu_{\beta X} = \beta \cdot \mu_X,$$

$$\sigma_{\beta X}^2 = \beta^2 \cdot \sigma_X^2,$$

$$\sigma_{\beta X} = |\beta| \cdot \sigma_X,$$

pro součet náhodných veličin  $X + Y$  dále platí

$$\mu_{X+Y} = \mu_X + \mu_Y$$

$$\sigma_{X+Y}^2 = \sigma_X^2 + \sigma_Y^2 + 2\sigma_{XY}$$

$$\sigma_{X,Y} = 0$$

$$\sigma_{X+Y}^2 = \sigma_X^2 + \sigma_Y^2$$

obecně

pro nezávislé  $X, Y$ pro nezávislé  $X, Y$ 

$\mu_X, \sigma_X, \dots$  jsou konstanty, vyjadřují (charakterizují) polohu, variabilitu ... náhodné veličiny  $X$

## ukázka důkazu

$$\begin{aligned}\mu_{\alpha+\beta X} &= E(\alpha + \beta X) \\ &= \sum_i (\alpha + \beta x_i^*) P(X = x_i^*) \\ &= \sum_i \alpha P(X = x_i^*) + \sum_i \beta x_i^* P(X = x_i^*) \\ &= \alpha \sum_i P(X = x_i^*) + \beta \sum_i x_i^* P(X = x_i^*) \\ &= \alpha + \beta \cdot EX = \alpha + \beta \cdot \mu_X\end{aligned}$$

**normování** náhodné veličiny  $X$  (populační obdoba z-skórů)

$$Z = \frac{X - \mu_X}{\sigma_X} \quad (\text{bezrozměrné!})$$

$$\Rightarrow \mu_Z = 0, \quad \sigma_Z = 1$$

## charakteristiky založené na normované verzi

charakteristiky  $X$  nezávislé na  $\mu_X$  a  $\sigma_X$ , protějšky popisných statistik

- ▶ (populační) **korelační koeficient** [correlation coefficient]

$$\rho_{XY} = \text{cov} \left( \frac{X - \mu_X}{\sigma_X}, \frac{Y - \mu_Y}{\sigma_Y} \right) = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

- ▶ (populační) **šikmost** náhodné veličiny  $X$  [skewness]

$$\gamma_1 = E \left( \frac{X - \mu_X}{\sigma_X} \right)^3 = \frac{E(X - \mu_X)^3}{\sigma_X^3}$$

- ▶ (populační) **špičatost** náhodné veličiny  $X$  (někdy bez  $-3$ ) [kurtosis]

$$\gamma_2 = E \left( \frac{X - \mu_X}{\sigma_X} \right)^4 - 3 = \frac{E(X - \mu_X)^4}{\sigma_X^4} - 3$$

## charakteristiky založené na normované verzi

charakteristiky  $X$  nezávislé na  $\mu_X$  a  $\sigma_X$ , protějšky popisných statistik

- ▶ (populační) **korelační koeficient** [correlation coefficient]

$$\rho_{XY} = \text{cov} \left( \frac{X - \mu_X}{\sigma_X}, \frac{Y - \mu_Y}{\sigma_Y} \right) = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

- ▶ (populační) **šikmost** náhodné veličiny  $X$  [skewness]

$$\gamma_1 = E \left( \frac{X - \mu_X}{\sigma_X} \right)^3 = \frac{E(X - \mu_X)^3}{\sigma_X^3}$$

- ▶ (populační) **špičatost** náhodné veličiny  $X$  (někdy bez  $-3$ ) [kurtosis]

$$\gamma_2 = E \left( \frac{X - \mu_X}{\sigma_X} \right)^4 - 3 = \frac{E(X - \mu_X)^4}{\sigma_X^4} - 3$$



## charakteristiky založené na normované verzi

charakteristiky  $X$  nezávislé na  $\mu_X$  a  $\sigma_X$ , protějšky popisných statistik

- ▶ (populační) **korelační koeficient** [correlation coefficient]

$$\rho_{XY} = \text{cov} \left( \frac{X - \mu_X}{\sigma_X}, \frac{Y - \mu_Y}{\sigma_Y} \right) = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

- ▶ (populační) **šikmost** náhodné veličiny  $X$  [skewness]

$$\gamma_1 = E \left( \frac{X - \mu_X}{\sigma_X} \right)^3 = \frac{E(X - \mu_X)^3}{\sigma_X^3}$$

- ▶ (populační) **špičatost** náhodné veličiny  $X$  (někdy bez  $-3$ ) [kurtosis]

$$\gamma_2 = E \left( \frac{X - \mu_X}{\sigma_X} \right)^4 - 3 = \frac{E(X - \mu_X)^4}{\sigma_X^4} - 3$$

## příklad ponožky

$x_i^*$	$y_j^*$			celkem
	0	1	2	
0	1/15	4/15	1/15	6/15
1	4/15	4/15	0/15	8/15
2	1/15	0/15	0/15	1/15
	6/15	8/15	1/15	15/15

$$\mu_X = \mu_Y = 2/3 \quad \sigma_X^2 = \sigma_Y^2 = 48/135 = 16/45$$

$$\begin{aligned} \sigma_{XY} = & (0 - 2/3) \cdot (0 - 2/3) \cdot 1/15 + (0 - 2/3) \cdot (1 - 2/3) \cdot 4/15 \\ & + (0 - 2/3) \cdot (2 - 2/3) \cdot 1/15 + (1 - 2/3) \cdot (0 - 2/3) \cdot 4/15 \\ & + (1 - 2/3) \cdot (1 - 2/3) \cdot 4/15 + (1 - 2/3) \cdot (2 - 2/3) \cdot 0/15 \\ & + (2 - 2/3) \cdot (0 - 2/3) \cdot 1/15 + (2 - 2/3) \cdot (1 - 2/3) \cdot 0/15 \\ & + (2 - 2/3) \cdot (2 - 2/3) \cdot 0/15 = -24/135 \doteq -0,177 \end{aligned}$$

$X, Y$  jsou závislé, neboť např.

$$6/15 \cdot 8/15 \doteq 0,213 < 4/15 \doteq 0,267, \quad \rho_{X,Y} = -1/2$$

# alternativní rozdělení

nula-jedničkové, Bernoulliovo

- ▶  $X$  – **počet zdarů** v jednom pokusu
- ▶ pravděpodobnost zdaru  $\pi$ ,  $0 < \pi < 1$
- ▶  $\pi$  je jediný parametr
- ▶ pouze dvě možné hodnoty: 1 (nastal zdar), 0 (nezdar)
- ▶  $P(X = 1) = \pi$ ,  $P(X = 0) = 1 - \pi$
- ▶  $X \sim \text{alt}(\pi)$
- ▶  $\mu_X = E X = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- ▶  $\sigma_X^2 = \text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$

# alternativní rozdělení

nula-jedničkové, Bernoulliovo

- ▶  $X$  – **počet zdarů** v jednom pokusu
- ▶ pravděpodobnost zdaru  $\pi$ ,  $0 < \pi < 1$
- ▶  $\pi$  je jediný parametr
- ▶ pouze dvě možné hodnoty: 1 (nastal zdar), 0 (nezdar)
- ▶  $P(X = 1) = \pi$ ,  $P(X = 0) = 1 - \pi$
- ▶  $X \sim \text{alt}(\pi)$
- ▶  $\mu_X = E X = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- ▶  $\sigma_X^2 = \text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$

# alternativní rozdělení

nula-jedničkové, Bernoulliovo

- ▶  $X$  – **počet zdarů** v jednom pokusu
- ▶ pravděpodobnost zdaru  $\pi$ ,  $0 < \pi < 1$
- ▶  $\pi$  je jediný parametr
- ▶ pouze dvě možné hodnoty: 1 (nastal zdar), 0 (nezdar)
- ▶  $P(X = 1) = \pi$ ,  $P(X = 0) = 1 - \pi$
- ▶  $X \sim \text{alt}(\pi)$
- ▶  $\mu_X = EX = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- ▶  $\sigma_X^2 = \text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$

# alternativní rozdělení

nula-jedničkové, Bernoulliovo

- ▶  $X$  – **počet zdarů** v jednom pokusu
- ▶ pravděpodobnost zdaru  $\pi$ ,  $0 < \pi < 1$
- ▶  $\pi$  je jediný parametr
- ▶ pouze dvě možné hodnoty: 1 (nastal zdar), 0 (nezdar)
- ▶  $P(X = 1) = \pi$ ,  $P(X = 0) = 1 - \pi$
- ▶  $X \sim \text{alt}(\pi)$
- ▶  $\mu_X = E X = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- ▶  $\sigma_X^2 = \text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$

## alternativní rozdělení

nula-jedničkové, Bernoulliovo

- ▶  $X$  – **počet zdarů** v jednom pokusu
- ▶ pravděpodobnost zdaru  $\pi$ ,  $0 < \pi < 1$
- ▶  $\pi$  je jediný parametr
- ▶ pouze dvě možné hodnoty: 1 (nastal zdar), 0 (nezdar)
- ▶  $P(X = 1) = \pi$ ,  $P(X = 0) = 1 - \pi$
- ▶  $X \sim \text{alt}(\pi)$
- ▶  $\mu_X = EX = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- ▶  $\sigma_X^2 = \text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$

## alternativní rozdělení

nula-jedničkové, Bernoulliovo

- ▶  $X$  – **počet zdarů** v jednom pokusu
- ▶ pravděpodobnost zdaru  $\pi$ ,  $0 < \pi < 1$
- ▶  $\pi$  je jediný parametr
- ▶ pouze dvě možné hodnoty: 1 (nastal zdar), 0 (nezdar)
- ▶  $P(X = 1) = \pi$ ,  $P(X = 0) = 1 - \pi$
- ▶  $X \sim \text{alt}(\pi)$
- ▶  $\mu_X = EX = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- ▶  $\sigma_X^2 = \text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$



## alternativní rozdělení

nula-jedničkové, Bernoulliovo

- ▶  $X$  – **počet zdarů** v jednom pokusu
- ▶ pravděpodobnost zdaru  $\pi$ ,  $0 < \pi < 1$
- ▶  $\pi$  je jediný parametr
- ▶ pouze dvě možné hodnoty: 1 (nastal zdar), 0 (nezdar)
- ▶  $P(X = 1) = \pi$ ,  $P(X = 0) = 1 - \pi$
- ▶  $X \sim \text{alt}(\pi)$
- ▶  $\mu_X = EX = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- ▶  $\sigma_X^2 = \text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$

## alternativní rozdělení

nula-jedničkové, Bernoulliovo

- ▶  $X$  – **počet zdarů** v jednom pokusu
- ▶ pravděpodobnost zdaru  $\pi$ ,  $0 < \pi < 1$
- ▶  $\pi$  je jediný parametr
- ▶ pouze dvě možné hodnoty: 1 (nastal zdar), 0 (nezdar)
- ▶  $P(X = 1) = \pi$ ,  $P(X = 0) = 1 - \pi$
- ▶  $X \sim \text{alt}(\pi)$
- ▶  $\mu_X = EX = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- ▶  $\sigma_X^2 = \text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$

# binomické rozdělení

[binomial distribution]

- ▶  $n$  **nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ , ( $0 < \pi < 1$ )
- ▶  $Y$  je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty:  $0, 1, \dots, n$

$$P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

[dbinom(k,n,prob)]

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne  $Y$  slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo  $Y$  šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale v dlouhodobém průměru je relativní četnost blízká  $1/2$  ( $1/6$ )

# binomické rozdělení

[binomial distribution]

- ▶  $n$  **nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ , ( $0 < \pi < 1$ )
- ▶  $Y$  je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty:  $0, 1, \dots, n$

$$P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

[dbinom(k,n,prob)]

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne  $Y$  slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo  $Y$  šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale v dlouhodobém průměru je relativní četnost blízká  $1/2$  ( $1/6$ )

# binomické rozdělení

[binomial distribution]

- ▶  $n$  **nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ , ( $0 < \pi < 1$ )
- ▶  $Y$  je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty:  $0, 1, \dots, n$

$$P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

[dbinom(k,n,prob)]

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne  $Y$  slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo  $Y$  šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale v dlouhodobém průměru je relativní četnost blízká  $1/2$  ( $1/6$ )

# binomické rozdělení

[binomial distribution]

- ▶  $n$  **nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ , ( $0 < \pi < 1$ )
- ▶  $Y$  je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty:  $0, 1, \dots, n$

$$P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

[dbinom(k,n,prob)]

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne  $Y$  slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo  $Y$  šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale v dlouhodobém průměru je relativní četnost blízká  $1/2$  ( $1/6$ )

# binomické rozdělení

[binomial distribution]

- ▶  $n$  **nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ , ( $0 < \pi < 1$ )
- ▶  $Y$  je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty:  $0, 1, \dots, n$

$$P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

[dbinom(k,n,prob)]

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne  $Y$  slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo  $Y$  šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale v dlouhodobém průměru je relativní četnost blízká  $1/2$  ( $1/6$ )

# binomické rozdělení

[binomial distribution]

- ▶  $n$  **nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ , ( $0 < \pi < 1$ )
- ▶  $Y$  je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty:  $0, 1, \dots, n$

$$P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

[dbinom(k,n,prob)]

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne  $Y$  slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo  $Y$  šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale v dlouhodobém průměru je relativní četnost blízká  $1/2$  ( $1/6$ )



# binomické rozdělení

[binomial distribution]

- ▶  $n$  **nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ , ( $0 < \pi < 1$ )
- ▶  $Y$  je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty:  $0, 1, \dots, n$

$$P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

[dbinom(k,n,prob)]

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne  $Y$  slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo  $Y$  šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale v dlouhodobém průměru je relativní četnost blízká  $1/2$  ( $1/6$ )

# binomické rozdělení

[binomial distribution]

- ▶  $n$  **nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ , ( $0 < \pi < 1$ )
- ▶  $Y$  je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty:  $0, 1, \dots, n$

$$P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

[dbinom(k,n,prob)]

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne  $Y$  slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo  $Y$  šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale v dlouhodobém průměru je relativní četnost blízká  $1/2$  ( $1/6$ )

# binomické rozdělení

[binomial distribution]

- ▶  $n$  **nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ , ( $0 < \pi < 1$ )
- ▶  $Y$  je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty:  $0, 1, \dots, n$

$$P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

[dbinom(k,n,prob)]

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne  $Y$  slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo  $Y$  šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale v dlouhodobém průměru je relativní četnost blízká  $1/2$  ( $1/6$ )

## binomické rozdělení pomocí alternativního rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶  $Y$  je celkový počet zdarů v  $n$  pokusech, tedy
- ▶  $Y = X_1 + X_2 + \dots + X_n = \sum_{i=1}^n X_i$ ,  
kde  $X_i$  je počet zdarů v  $i$ -tém pokusu
- ▶ z vlastností střední hodnoty (očekávaný počet zdarů)

$$\mu_Y = E Y = E \sum_{i=1}^n X_i = \sum_{i=1}^n E X_i = \sum_{i=1}^n \pi = n\pi$$

- ▶ protože jsou pokusy **nezávislé**

$$\sigma_Y^2 = \text{var} \sum_{i=1}^n X_i = \sum_{i=1}^n \text{var} X_i = \sum_{i=1}^n \pi(1 - \pi) = n\pi(1 - \pi)$$

## binomické rozdělení pomocí alternativního rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶  $Y$  je celkový počet zdarů v  $n$  pokusech, tedy
- ▶  $Y = X_1 + X_2 + \dots + X_n = \sum_{i=1}^n X_i$ ,  
kde  $X_i$  je počet zdarů v  $i$ -tém pokusu
- ▶ z vlastností střední hodnoty (očekávaný počet zdarů)

$$\mu_Y = E Y = E \sum_{i=1}^n X_i = \sum_{i=1}^n E X_i = \sum_{i=1}^n \pi = n\pi$$

- ▶ protože jsou pokusy **nezávislé**

$$\sigma_Y^2 = \text{var} \sum_{i=1}^n X_i = \sum_{i=1}^n \text{var} X_i = \sum_{i=1}^n \pi(1 - \pi) = n\pi(1 - \pi)$$

## binomické rozdělení pomocí alternativního rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶  $Y$  je celkový počet zdarů v  $n$  pokusech, tedy
- ▶  $Y = X_1 + X_2 + \dots + X_n = \sum_{i=1}^n X_i$ ,  
kde  $X_i$  je počet zdarů v  $i$ -tém pokusu
- ▶ z vlastností střední hodnoty (očekávaný počet zdarů)

$$\mu_Y = E Y = E \sum_{i=1}^n X_i = \sum_{i=1}^n E X_i = \sum_{i=1}^n \pi = n\pi$$

- ▶ protože jsou pokusy **nezávislé**

$$\sigma_Y^2 = \text{var} \sum_{i=1}^n X_i = \sum_{i=1}^n \text{var} X_i = \sum_{i=1}^n \pi(1 - \pi) = n\pi(1 - \pi)$$

## binomické rozdělení pomocí alternativního rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶  $Y$  je celkový počet zdarů v  $n$  pokusech, tedy
- ▶  $Y = X_1 + X_2 + \dots + X_n = \sum_{i=1}^n X_i$ ,  
kde  $X_i$  je počet zdarů v  $i$ -tém pokusu
- ▶ z vlastností střední hodnoty (očekávaný počet zdarů)

$$\mu_Y = E Y = E \sum_{i=1}^n X_i = \sum_{i=1}^n E X_i = \sum_{i=1}^n \pi = n\pi$$

- ▶ protože jsou pokusy **nezávislé**

$$\sigma_Y^2 = \text{var} \sum_{i=1}^n X_i = \sum_{i=1}^n \text{var} X_i = \sum_{i=1}^n \pi(1 - \pi) = n\pi(1 - \pi)$$

## binomické rozdělení pomocí alternativního rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶  $Y$  je celkový počet zdarů v  $n$  pokusech, tedy
- ▶  $Y = X_1 + X_2 + \dots + X_n = \sum_{i=1}^n X_i$ ,  
kde  $X_i$  je počet zdarů v  $i$ -tém pokusu
- ▶ z vlastností střední hodnoty (očekávaný počet zdarů)

$$\mu_Y = E Y = E \sum_{i=1}^n X_i = \sum_{i=1}^n E X_i = \sum_{i=1}^n \pi = n\pi$$

- ▶ protože jsou pokusy **nezávislé**

$$\sigma_Y^2 = \text{var} \sum_{i=1}^n X_i = \sum_{i=1}^n \text{var} X_i = \sum_{i=1}^n \pi(1 - \pi) = n\pi(1 - \pi)$$



## příklad: kuřáci

- ▶ mezi dvacetiletými muži je (řekněme) 35 % kuřáků ( $\pi = 0,35$ )
- ▶ je-li dvacetiletých 70 tisíc ( $m = 70\,000$ ), pak je kuřáků asi  $m\pi = 70\,000 \cdot 0,35 = 24\,500$ , ale nevíme, kteří to jsou
- ▶ vyberme náhodně  $n = 60$  dvacetiletých mužů, označme jako  $Y$  počet kuřáků mezi nimi, je tedy  $Y \sim \text{bi}(60, 0,35)$
- ▶ střední hodnota (očekávaný počet), rozptyl

$$\mu_Y = 60 \cdot 0,35 = 21 \quad \sigma_Y^2 = 60 \cdot 0,35 \cdot 0,65 = 13,65 \doteq (3,7)^2$$

- ▶ ukázky pravděpodobností možných hodnot

$k$	15	17	19	21	23	25
$P(Y = k)$	0,029	0,062	0,095	0,107	0,091	0,059

- ▶ psti počítány pomocí `[dbinom(0:60,60,0.35)]`

## příklad: kuřáci

- ▶ mezi dvacetiletými muži je (řekněme) 35 % kuřáků ( $\pi = 0,35$ )
- ▶ je-li dvacetiletých 70 tisíc ( $m = 70\,000$ ), pak je kuřáků asi  $m\pi = 70\,000 \cdot 0,35 = 24\,500$ , ale nevíme, kteří to jsou
- ▶ vyberme náhodně  $n = 60$  dvacetiletých mužů, označme jako  $Y$  počet kuřáků mezi nimi, je tedy  $Y \sim \text{bi}(60, 0,35)$
- ▶ střední hodnota (očekávaný počet), rozptyl

$$\mu_Y = 60 \cdot 0,35 = 21 \quad \sigma_Y^2 = 60 \cdot 0,35 \cdot 0,65 = 13,65 \doteq (3,7)^2$$

- ▶ ukázky pravděpodobností možných hodnot

$k$	15	17	19	21	23	25
$P(Y = k)$	0,029	0,062	0,095	0,107	0,091	0,059

- ▶ psti počítány pomocí `[dbinom(0:60,60,0.35)]`

## příklad: kuřáci

- ▶ mezi dvacetiletými muži je (řekněme) 35 % kuřáků ( $\pi = 0,35$ )
- ▶ je-li dvacetiletých 70 tisíc ( $m = 70\,000$ ), pak je kuřáků asi  $m\pi = 70\,000 \cdot 0,35 = 24\,500$ , ale nevíme, kteří to jsou
- ▶ vyberme náhodně  $n = 60$  dvacetiletých mužů, označme jako  $Y$  počet kuřáků mezi nimi, je tedy  $Y \sim \text{bi}(60, 0,35)$
- ▶ střední hodnota (očekávaný počet), rozptyl

$$\mu_Y = 60 \cdot 0,35 = 21 \quad \sigma_Y^2 = 60 \cdot 0,35 \cdot 0,65 = 13,65 \doteq (3,7)^2$$

- ▶ ukázky pravděpodobností možných hodnot

$k$	15	17	19	21	23	25
$P(Y = k)$	0,029	0,062	0,095	0,107	0,091	0,059

- ▶ psti počítány pomocí `[dbinom(0:60,60,0.35)]`

## příklad: kuřáci

- ▶ mezi dvacetiletými muži je (řekněme) 35 % kuřáků ( $\pi = 0,35$ )
- ▶ je-li dvacetiletých 70 tisíc ( $m = 70\,000$ ), pak je kuřáků asi  $m\pi = 70\,000 \cdot 0,35 = 24\,500$ , ale nevíme, kteří to jsou
- ▶ vyberme náhodně  $n = 60$  dvacetiletých mužů, označme jako  $Y$  počet kuřáků mezi nimi, je tedy  $Y \sim \text{bi}(60, 0,35)$
- ▶ střední hodnota (očekávaný počet), rozptyl

$$\mu_Y = 60 \cdot 0,35 = 21 \quad \sigma_Y^2 = 60 \cdot 0,35 \cdot 0,65 = 13,65 \doteq (3,7)^2$$

- ▶ ukázky pravděpodobností možných hodnot

$k$	15	17	19	21	23	25
$P(Y = k)$	0,029	0,062	0,095	0,107	0,091	0,059

- ▶ psti počítány pomocí `[dbinom(0:60,60,0.35)]`

## příklad: kuřáci

- ▶ mezi dvacetiletými muži je (řekněme) 35 % kuřáků ( $\pi = 0,35$ )
- ▶ je-li dvacetiletých 70 tisíc ( $m = 70\,000$ ), pak je kuřáků asi  $m\pi = 70\,000 \cdot 0,35 = 24\,500$ , ale nevíme, kteří to jsou
- ▶ vyberme náhodně  $n = 60$  dvacetiletých mužů, označme jako  $Y$  počet kuřáků mezi nimi, je tedy  $Y \sim \text{bi}(60, 0,35)$
- ▶ střední hodnota (očekávaný počet), rozptyl

$$\mu_Y = 60 \cdot 0,35 = 21 \quad \sigma_Y^2 = 60 \cdot 0,35 \cdot 0,65 = 13,65 \doteq (3,7)^2$$

- ▶ ukázky pravděpodobností možných hodnot

$k$	15	17	19	21	23	25
$P(Y = k)$	0,029	0,062	0,095	0,107	0,091	0,059

- ▶ psti počítány pomocí `[dbinom(0:60,60,0.35)]`

## příklad: kuřáci

- ▶ mezi dvacetiletými muži je (řekněme) 35 % kuřáků ( $\pi = 0,35$ )
- ▶ je-li dvacetiletých 70 tisíc ( $m = 70\,000$ ), pak je kuřáků asi  $m\pi = 70\,000 \cdot 0,35 = 24\,500$ , ale nevíme, kteří to jsou
- ▶ vyberme náhodně  $n = 60$  dvacetiletých mužů, označme jako  $Y$  počet kuřáků mezi nimi, je tedy  $Y \sim \text{bi}(60, 0,35)$
- ▶ střední hodnota (očekávaný počet), rozptyl

$$\mu_Y = 60 \cdot 0,35 = 21 \quad \sigma_Y^2 = 60 \cdot 0,35 \cdot 0,65 = 13,65 \doteq (3,7)^2$$

- ▶ ukázky pravděpodobností možných hodnot

$k$	15	17	19	21	23	25
$P(Y = k)$	0,029	0,062	0,095	0,107	0,091	0,059

- ▶ psti počítány pomocí `[dbinom(0:60,60,0.35)]`

# Poissonovo rozdělení

[Poisson distribution]

- ▶  $X \sim \text{Po}(\lambda)$  ( $\lambda > 0$ )
- ▶ zákon vzácných (řídkých) jevů
- ▶ kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- ▶ předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu
- ▶ 
$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$
- ▶  $\mu_X = \lambda, \sigma_X^2 = \lambda$
- ▶ při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- ▶ pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- ▶ např. počet kolonií na Petriho misce

# Poissonovo rozdělení

[Poisson distribution]

- ▶  $X \sim \text{Po}(\lambda)$  ( $\lambda > 0$ )
- ▶ zákon vzácných (řídkých) jevů
- ▶ kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- ▶ předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu
- ▶ 
$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$
- ▶  $\mu_X = \lambda, \sigma_X^2 = \lambda$
- ▶ při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- ▶ pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- ▶ např. počet kolonií na Petriho misce



# Poissonovo rozdělení

[Poisson distribution]

- ▶  $X \sim \text{Po}(\lambda)$  ( $\lambda > 0$ )
- ▶ zákon vzácných (řídkých) jevů
- ▶ kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- ▶ předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu
- ▶ 
$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$
- ▶  $\mu_X = \lambda, \sigma_X^2 = \lambda$
- ▶ při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- ▶ pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- ▶ např. počet kolonií na Petriho misce

# Poissonovo rozdělení

[Poisson distribution]

- ▶  $X \sim \text{Po}(\lambda)$  ( $\lambda > 0$ )
- ▶ zákon vzácných (řídkých) jevů
- ▶ kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- ▶ předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$

- ▶  $\mu_X = \lambda, \sigma_X^2 = \lambda$
- ▶ při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- ▶ pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- ▶ např. počet kolonií na Petriho misce

# Poissonovo rozdělení

[Poisson distribution]

- ▶  $X \sim \text{Po}(\lambda)$  ( $\lambda > 0$ )
- ▶ zákon vzácných (řídkých) jevů
- ▶ kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- ▶ předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu
- ▶ 
$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$
- ▶  $\mu_X = \lambda, \sigma_X^2 = \lambda$
- ▶ při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- ▶ pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- ▶ např. počet kolonií na Petriho misce

# Poissonovo rozdělení

[Poisson distribution]

- ▶  $X \sim \text{Po}(\lambda)$  ( $\lambda > 0$ )
- ▶ zákon vzácných (řídkých) jevů
- ▶ kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- ▶ předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu
- ▶ 
$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$
- ▶  $\mu_X = \lambda, \sigma_X^2 = \lambda$
- ▶ při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- ▶ pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- ▶ např. počet kolonií na Petriho misce

# Poissonovo rozdělení

[Poisson distribution]

- ▶  $X \sim \text{Po}(\lambda)$  ( $\lambda > 0$ )
- ▶ zákon vzácných (řídkých) jevů
- ▶ kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- ▶ předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu
- ▶ 
$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$
- ▶  $\mu_X = \lambda, \sigma_X^2 = \lambda$
- ▶ při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- ▶ pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- ▶ např. počet kolonií na Petriho misce

# Poissonovo rozdělení

[Poisson distribution]

- ▶  $X \sim \text{Po}(\lambda)$  ( $\lambda > 0$ )
- ▶ zákon vzácných (řídkých) jevů
- ▶ kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- ▶ předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu
- ▶ 
$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$
- ▶  $\mu_X = \lambda, \sigma_X^2 = \lambda$
- ▶ při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- ▶ pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- ▶ např. počet kolonií na Petriho misce

# Poissonovo rozdělení

[Poisson distribution]

- ▶  $X \sim \text{Po}(\lambda)$  ( $\lambda > 0$ )
- ▶ zákon vzácných (řídkých) jevů
- ▶ kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- ▶ předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu
- ▶ 
$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$
- ▶  $\mu_X = \lambda, \sigma_X^2 = \lambda$
- ▶ při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- ▶ pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- ▶ např. počet kolonií na Petriho misce

## příklad

souvislost binomického a Poissonova rozdělení

s jakou pstí udělá 5 z 55 stejně připravených studentů zkoušku na výbornou, je-li pst jedničky 0,08?

- ▶ binomické rozdělení  $Y \sim \text{bi}(55, 0,08)$  [dbinom(5,55,0.08)]

$$P(Y = 5) = \binom{55}{5} \cdot 0,08^5 \cdot 0,92^{50} = 0,176$$

- ▶ aproximace Poissonovým rozdělením (použij  $\lambda = n\pi = 4,4$ )  
 $Y \sim \text{Po}(55 \cdot 0,08) = \text{Po}(4,4)$  [dpois(5, 4.4)]

$$P(Y = 5) = \frac{4,4^5}{5!} e^{-4,4} = 0,169$$



## příklad

souvislost binomického a Poissonova rozdělení

s jakou pstí udělá 5 z 55 stejně připravených studentů zkoušku na výbornou, je-li pst jedničky 0,08?

- ▶ binomické rozdělení  $Y \sim \text{bi}(55, 0,08)$  [dbinom(5,55,0.08)]

$$P(Y = 5) = \binom{55}{5} \cdot 0,08^5 \cdot 0,92^{50} = 0,176$$

- ▶ aproximace Poissonovým rozdělením (použij  $\lambda = n\pi = 4,4$ )  
 $Y \sim \text{Po}(55 \cdot 0,08) = \text{Po}(4,4)$  [dpois(5, 4.4)]

$$P(Y = 5) = \frac{4,4^5}{5!} e^{-4,4} = 0,169$$

# normální (Gaussovo) rozdělení $N(\mu, \sigma^2)$

[normal (Gaussian) distribution]

- ▶  $\mu_X = \mu, \sigma_X^2 = \sigma^2$
- ▶ spojité rozdělení, symetrické okolo střední hodnoty  $\mu$
- ▶ maximální hodnota hustoty přibližně  $0,4/\sigma$
- ▶  $N(0, 1)$  (normované normální rozdělení):  
 $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$  (hustota),  
 $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$  (distr. fce)
- ▶  $X \sim N(\mu, \sigma^2)$ , pak  $Z = \frac{X-\mu}{\sigma} \sim N(0, 1)$

$$P(a < X < b) = \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right)$$

- ▶ model vzniku: součet velkého počtu nepatrných příspěvků
- ▶ velmi často modeluje znaky v poměrovém měřítku

# normální (Gaussovo) rozdělení $N(\mu, \sigma^2)$

[normal (Gaussian) distribution]

- ▶  $\mu_X = \mu, \sigma_X^2 = \sigma^2$
- ▶ spojité rozdělení, symetrické okolo střední hodnoty  $\mu$
- ▶ maximální hodnota hustoty přibližně  $0,4/\sigma$
- ▶  $N(0, 1)$  (normované normální rozdělení):  
 $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$  (hustota),  
 $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$  (distr. fce)
- ▶  $X \sim N(\mu, \sigma^2)$ , pak  $Z = \frac{X-\mu}{\sigma} \sim N(0, 1)$

$$P(a < X < b) = \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right)$$

- ▶ model vzniku: součet velkého počtu nepatrných příspěvků
- ▶ velmi často modeluje znaky v poměrovém měřítku

# normální (Gaussovo) rozdělení $N(\mu, \sigma^2)$

[normal (Gaussian) distribution]

- ▶  $\mu_X = \mu, \sigma_X^2 = \sigma^2$
- ▶ spojité rozdělení, symetrické okolo střední hodnoty  $\mu$
- ▶ maximální hodnota hustoty přibližně  $0,4/\sigma$
- ▶  $N(0, 1)$  (normované normální rozdělení):  
 $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$  (hustota),  
 $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$  (distr. fce)
- ▶  $X \sim N(\mu, \sigma^2)$ , pak  $Z = \frac{X-\mu}{\sigma} \sim N(0, 1)$

$$P(a < X < b) = \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right)$$

- ▶ model vzniku: součet velkého počtu nepatrných příspěvků
- ▶ velmi často modeluje znaky v poměrovém měřítku

# normální (Gaussovo) rozdělení $N(\mu, \sigma^2)$

[normal (Gaussian) distribution]

- ▶  $\mu_X = \mu, \sigma_X^2 = \sigma^2$
- ▶ spojité rozdělení, symetrické okolo střední hodnoty  $\mu$
- ▶ maximální hodnota hustoty přibližně  $0,4/\sigma$
- ▶  $N(0, 1)$  (normované normální rozdělení):  
 $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$  (hustota),  
 $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$  (distr. fce)
- ▶  $X \sim N(\mu, \sigma^2)$ , pak  $Z = \frac{X-\mu}{\sigma} \sim N(0, 1)$

$$P(a < X < b) = \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right)$$

- ▶ model vzniku: součet velkého počtu nepatrných příspěvků
- ▶ velmi často modeluje znaky v poměrovém měřítku

# normální (Gaussovo) rozdělení $N(\mu, \sigma^2)$

[normal (Gaussian) distribution]

- ▶  $\mu_X = \mu, \sigma_X^2 = \sigma^2$
- ▶ spojité rozdělení, symetrické okolo střední hodnoty  $\mu$
- ▶ maximální hodnota hustoty přibližně  $0,4/\sigma$
- ▶  $N(0, 1)$  (normované normální rozdělení):  
 $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$  (hustota),  
 $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$  (distr. fce)
- ▶  $X \sim N(\mu, \sigma^2)$ , pak  $Z = \frac{X-\mu}{\sigma} \sim N(0, 1)$

$$P(a < X < b) = \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right)$$

- ▶ model vzniku: součet velkého počtu nepatrných příspěvků
- ▶ velmi často modeluje znaky v poměrovém měřítku

# normální (Gaussovo) rozdělení $N(\mu, \sigma^2)$

[normal (Gaussian) distribution]

- ▶  $\mu_X = \mu, \sigma_X^2 = \sigma^2$
- ▶ spojité rozdělení, symetrické okolo střední hodnoty  $\mu$
- ▶ maximální hodnota hustoty přibližně  $0,4/\sigma$
- ▶  $N(0, 1)$  (normované normální rozdělení):  
 $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$  (hustota),  
 $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$  (distr. fce)
- ▶  $X \sim N(\mu, \sigma^2)$ , pak  $Z = \frac{X-\mu}{\sigma} \sim N(0, 1)$

$$P(a < X < b) = \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right)$$

- ▶ model vzniku: součet velkého počtu nepatrných příspěvků
- ▶ velmi často modeluje znaky v poměrovém měřítku

# normální (Gaussovo) rozdělení $N(\mu, \sigma^2)$

[normal (Gaussian) distribution]

- ▶  $\mu_X = \mu, \sigma_X^2 = \sigma^2$
- ▶ spojité rozdělení, symetrické okolo střední hodnoty  $\mu$
- ▶ maximální hodnota hustoty přibližně  $0,4/\sigma$
- ▶  $N(0, 1)$  (normované normální rozdělení):  
 $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$  (hustota),  
 $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$  (distr. fce)
- ▶  $X \sim N(\mu, \sigma^2)$ , pak  $Z = \frac{X-\mu}{\sigma} \sim N(0, 1)$


$$P(a < X < b) = \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right)$$

- ▶ model vzniku: součet velkého počtu nepatrných příspěvků
- ▶ velmi často modeluje znaky v poměrovém měřítku




hustota  $N(\mu, \sigma^2)$ 

[dnorm(x,mu,sigma)]



normální (Gaussovo) rozdělení  $N(\mu, \sigma^2)$ 

význam parametrů



výpočet pravděpodobnosti, že  $a < X < b$ použije distribuční funkci  $N(0, 1)$  $P(a < X < b) = F_X(b) - F_X(a)$  platí obecně pro spoj. rozděl.

$$X \sim N(\mu, \sigma^2) \Rightarrow Z = \frac{X - \mu}{\sigma} \sim N(0, 1)$$

$$P(X \leq x) = P\left(\frac{X - \mu}{\sigma} \leq \frac{x - \mu}{\sigma}\right) = P\left(Z \leq \frac{x - \mu}{\sigma}\right) = \Phi\left(\frac{x - \mu}{\sigma}\right)$$

$$P(a < X < b) = \Phi\left(\frac{b - \mu}{\sigma}\right) - \Phi\left(\frac{a - \mu}{\sigma}\right)$$

`[pnorm((b-mu)/sigma)-pnorm((a-mu)/sigma)]`v programu R je distribuční funkce  $N(\mu, \sigma^2)$  s obecnými parametry:`[pnorm(b,mu,sigma)-pnorm(a,mu,sigma)]`

## příklad

- ▶ u jakého dílu populace desetiletých hochů naměříme výšku od 135 do 140 cm, když pro výšku desetiletých platí  $X \sim N(136,1, 6,4^2)$
- ▶ předpokládáme zaokrouhlování na celá čísla při měření, takže hodnoty od 135 cm do 140 cm naměříme, když měřené výšky budou od 134,5 cm do 140,5 cm:

$$\begin{aligned}
 P(134,5 < X < 140,5) &= \Phi\left(\frac{140,5 - 136,1}{6,4}\right) - \Phi\left(\frac{134,5 - 136,1}{6,4}\right) \\
 &= 0,754 - 0,401 = 0,353
 \end{aligned}$$

`[pnorm((140.5-136.1)/6.4)-pnorm((134.5-136.1)/6.4)]`

- ▶ pomocí distribuční fce s obecnými parametry  
`[pnorm(140.5,136.1,6.4)-pnorm(134.5,136.1,6.4)]`

## příklad

- ▶ u jakého dílu populace desetiletých hochů naměříme výšku od 135 do 140 cm, když pro výšku desetiletých platí  $X \sim N(136,1, 6,4^2)$
- ▶ předpokládáme zaokrouhlování na celá čísla při měření, takže hodnoty od 135 cm do 140 cm naměříme, když měřené výšky budou od 134,5 cm do 140,5 cm:

$$\begin{aligned}
 P(134,5 < X < 140,5) &= \Phi\left(\frac{140,5 - 136,1}{6,4}\right) - \Phi\left(\frac{134,5 - 136,1}{6,4}\right) \\
 &= 0,754 - 0,401 = 0,353
 \end{aligned}$$

`[pnorm((140.5-136.1)/6.4)-pnorm((134.5-136.1)/6.4)]`

- ▶ pomocí distribuční fce s obecnými parametry  
`[pnorm(140.5,136.1,6.4)-pnorm(134.5,136.1,6.4)]`

## příklad

- ▶ u jakého dílu populace desetiletých hochů naměříme výšku od 135 do 140 cm, když pro výšku desetiletých platí  $X \sim N(136,1, 6,4^2)$
- ▶ předpokládáme zaokrouhlování na celá čísla při měření, takže hodnoty od 135 cm do 140 cm naměříme, když měřené výšky budou od 134,5 cm do 140,5 cm:

$$\begin{aligned}
 P(134,5 < X < 140,5) &= \Phi\left(\frac{140,5 - 136,1}{6,4}\right) - \Phi\left(\frac{134,5 - 136,1}{6,4}\right) \\
 &= 0,754 - 0,401 = 0,353
 \end{aligned}$$

[pnorm((140.5-136.1)/6.4)-pnorm((134.5-136.1)/6.4)]

- ▶ pomocí distribuční fce s obecnými parametry  
[pnorm(140.5,136.1,6.4)-pnorm(134.5,136.1,6.4)]

kritické hodnoty normálního a Studentova  $t$ -rozdělení

[Student distribution]

- ▶ **normální rozdělení**  $N(0, 1)$  [qnorm(1-alpha)]

$$Z \sim N(0, 1) : P(Z > z(\alpha)) = \alpha$$

ze symetrie platí  $P(|Z| > z(\alpha/2)) = \alpha$ 

- ▶ **Studentovo  $t$ -rozdělení s  $k$  stupni volnosti  $t_k$**   
(podobné normálnímu, protože místo  $\sigma$  používá jeho odhad, má větší rozptyl)

$$T \sim t_k : P(|T| > t_k(\alpha)) = \alpha$$

- ▶ jsou to spíše kritické hodnoty  $|T|$  [qt(1-alpha/2,k)]

kritické hodnoty normálního a Studentova  $t$ -rozdělení

[Student distribution]

- ▶ **normální rozdělení**  $N(0, 1)$  [qnorm(1-alpha)]

$$Z \sim N(0, 1) : P(Z > z(\alpha)) = \alpha$$

ze symetrie platí  $P(|Z| > z(\alpha/2)) = \alpha$

- ▶ **Studentovo  $t$ -rozdělení s  $k$  stupni volnosti  $t_k$**   
(podobné normálnímu, protože místo  $\sigma$  používá jeho odhad, má větší rozptyl)

$$T \sim t_k : P(|T| > t_k(\alpha)) = \alpha$$

- ▶ jsou to spíše kritické hodnoty  $|T|$  [qt(1-alpha/2,k)]



kritické hodnoty normálního a Studentova  $t$ -rozdělení

[Student distribution]

- ▶ **normální rozdělení**  $N(0, 1)$  [qnorm(1-alpha)]

$$Z \sim N(0, 1) : P(Z > z(\alpha)) = \alpha$$

ze symetrie platí  $P(|Z| > z(\alpha/2)) = \alpha$

- ▶ **Studentovo  $t$ -rozdělení s  $k$  stupni volnosti  $t_k$**   
(podobné normálnímu, protože místo  $\sigma$  používá jeho odhad, má větší rozptyl)

$$T \sim t_k : P(|T| > t_k(\alpha)) = \alpha$$

- ▶ jsou to spíše kritické hodnoty  $|T|$  [qt(1-alpha/2,k)]

## některé kritické hodnoty

$\alpha$	0,50	0,25	0,10	<b>0,05</b>	0,01
$z(\alpha/2)$	0,674	1,150	1,645	<b>1,960</b>	2,576
$t_{100}(\alpha)$	0,677	1,157	1,660	<b>1,984</b>	2,626
$t_{20}(\alpha)$	0,687	1,185	1,725	<b>2,086</b>	2,845
$t_5(\alpha)$	0,727	1,301	2,015	<b>2,571</b>	4,032

- ▶  $T \sim t_k$  má jediný parametr  $k$  (počet stupňů volnosti)
- ▶ s rostoucím  $k$  se chování blíží normálnímu rozdělení  $N(0, 1)$
- ▶ pro  $Z \sim N(0, 1)$  je 95 % hodnot v intervalu  $(-1,960; 1,960)$
- ▶ pro  $T \sim t_5$  je 95 % hodnot v intervalu  $(-2,571; 2,571)$
- ▶ pro  $T \sim t_{20}$  je 95 % hodnot v intervalu  $(-2,086; 2,086)$
- ▶ pro  $T \sim t_{100}$  je 95 % hodnot v intervalu  $(-1,984; 1,984)$

## některé kritické hodnoty

$\alpha$	0,50	0,25	0,10	<b>0,05</b>	0,01
$z(\alpha/2)$	0,674	1,150	1,645	<b>1,960</b>	2,576
$t_{100}(\alpha)$	0,677	1,157	1,660	<b>1,984</b>	2,626
$t_{20}(\alpha)$	0,687	1,185	1,725	<b>2,086</b>	2,845
$t_5(\alpha)$	0,727	1,301	2,015	<b>2,571</b>	4,032

- ▶  $T \sim t_k$  má jediný parametr  $k$  (počet stupňů volnosti)
- ▶ s rostoucím  $k$  se chování blíží normálnímu rozdělení  $N(0, 1)$
- ▶ pro  $Z \sim N(0, 1)$  je 95 % hodnot v intervalu  $(-1,960; 1,960)$
- ▶ pro  $T \sim t_5$  je 95 % hodnot v intervalu  $(-2,571; 2,571)$
- ▶ pro  $T \sim t_{20}$  je 95 % hodnot v intervalu  $(-2,086; 2,086)$
- ▶ pro  $T \sim t_{100}$  je 95 % hodnot v intervalu  $(-1,984; 1,984)$

## některé kritické hodnoty

$\alpha$	0,50	0,25	0,10	<b>0,05</b>	0,01
$z(\alpha/2)$	0,674	1,150	1,645	<b>1,960</b>	2,576
$t_{100}(\alpha)$	0,677	1,157	1,660	<b>1,984</b>	2,626
$t_{20}(\alpha)$	0,687	1,185	1,725	<b>2,086</b>	2,845
$t_5(\alpha)$	0,727	1,301	2,015	<b>2,571</b>	4,032

- ▶  $T \sim t_k$  má jediný parametr  $k$  (počet stupňů volnosti)
- ▶ s rostoucím  $k$  se chování blíží normálnímu rozdělení  $N(0, 1)$
- ▶ pro  $Z \sim N(0, 1)$  je 95 % hodnot v intervalu  $(-1,960; 1,960)$
- ▶ pro  $T \sim t_5$  je 95 % hodnot v intervalu  $(-2,571; 2,571)$
- ▶ pro  $T \sim t_{20}$  je 95 % hodnot v intervalu  $(-2,086; 2,086)$
- ▶ pro  $T \sim t_{100}$  je 95 % hodnot v intervalu  $(-1,984; 1,984)$

## některé kritické hodnoty

$\alpha$	0,50	0,25	0,10	<b>0,05</b>	0,01
$z(\alpha/2)$	0,674	1,150	1,645	<b>1,960</b>	2,576
$t_{100}(\alpha)$	0,677	1,157	1,660	<b>1,984</b>	2,626
$t_{20}(\alpha)$	0,687	1,185	1,725	<b>2,086</b>	2,845
$t_5(\alpha)$	0,727	1,301	2,015	<b>2,571</b>	4,032

- ▶  $T \sim t_k$  má jediný parametr  $k$  (počet stupňů volnosti)
- ▶ s rostoucím  $k$  se chování blíží normálnímu rozdělení  $N(0, 1)$
- ▶ pro  $Z \sim N(0, 1)$  je 95 % hodnot v intervalu  $(-1,960; 1,960)$
- ▶ pro  $T \sim t_5$  je 95 % hodnot v intervalu  $(-2,571; 2,571)$
- ▶ pro  $T \sim t_{20}$  je 95 % hodnot v intervalu  $(-2,086; 2,086)$
- ▶ pro  $T \sim t_{100}$  je 95 % hodnot v intervalu  $(-1,984; 1,984)$

## některé kritické hodnoty

$\alpha$	0,50	0,25	0,10	<b>0,05</b>	0,01
$z(\alpha/2)$	0,674	1,150	1,645	<b>1,960</b>	2,576
$t_{100}(\alpha)$	0,677	1,157	1,660	<b>1,984</b>	2,626
$t_{20}(\alpha)$	0,687	1,185	1,725	<b>2,086</b>	2,845
$t_5(\alpha)$	0,727	1,301	2,015	<b>2,571</b>	4,032

- ▶  $T \sim t_k$  má jediný parametr  $k$  (počet stupňů volnosti)
- ▶ s rostoucím  $k$  se chování blíží normálnímu rozdělení  $N(0, 1)$
- ▶ pro  $Z \sim N(0, 1)$  je 95 % hodnot v intervalu  $(-1,960; 1,960)$
- ▶ pro  $T \sim t_5$  je 95 % hodnot v intervalu  $(-2,571; 2,571)$
- ▶ pro  $T \sim t_{20}$  je 95 % hodnot v intervalu  $(-2,086; 2,086)$
- ▶ pro  $T \sim t_{100}$  je 95 % hodnot v intervalu  $(-1,984; 1,984)$

## některé kritické hodnoty


$\alpha$	0,50	0,25	0,10	<b>0,05</b>	0,01
$z(\alpha/2)$	0,674	1,150	1,645	<b>1,960</b>	2,576
$t_{100}(\alpha)$	0,677	1,157	1,660	<b>1,984</b>	2,626
$t_{20}(\alpha)$	0,687	1,185	1,725	<b>2,086</b>	2,845
$t_5(\alpha)$	0,727	1,301	2,015	<b>2,571</b>	4,032

- ▶  $T \sim t_k$  má jediný parametr  $k$  (počet stupňů volnosti)
- ▶ s rostoucím  $k$  se chování blíží normálnímu rozdělení  $N(0, 1)$
- ▶ pro  $Z \sim N(0, 1)$  je 95 % hodnot v intervalu  $(-1,960; 1,960)$
- ▶ pro  $T \sim t_5$  je 95 % hodnot v intervalu  $(-2,571; 2,571)$
- ▶ pro  $T \sim t_{20}$  je 95 % hodnot v intervalu  $(-2,086; 2,086)$
- ▶ pro  $T \sim t_{100}$  je 95 % hodnot v intervalu  $(-1,984; 1,984)$

# aproximace binomického rozdělení normálním

se stejnou střední hodnotou a stejným rozptylem

rozdělení  $bi(n, \pi)$  lze aproximovat pomocí  $N(n\pi, n\pi(1 - \pi))$





## další rozdělení související s normálním

[F-distribution, chi-square distribution]

- ▶  $V$  má rozdělení (musí být  $P(V > 0) = 1$  !!)

**logaritmicko-normální**, platí-li  $\ln V \sim N(\mu, \sigma^2)$

- ▶ **Fisherovo  $F$ -rozdělení**  $F_{k,m}$  [qf(1-alpha,k,m)]

$$F \sim F_{k,m} : P(F > F_{k,m}(\alpha)) = \alpha$$

- ▶ **rozdělení chí-kvadrát**  $\chi_k^2$  [qchisq(1-alpha,k)]

$$X^2 \sim \chi_k^2 : P(X^2 > \chi_k^2(\alpha)) = \alpha$$

- ▶ speciálně platí:

- ▶  $\chi_1^2(0,05) = 3,841 = 1,960^2$

- ▶  $\chi_1^2(\alpha) = z(\alpha/2)^2$

- ▶  $F_{1,m}(\alpha) = (t_m(\alpha))^2$

## další rozdělení související s normálním

[F-distribution, chi-square distribution]

- ▶  $V$  má rozdělení (musí být  $P(V > 0) = 1$  !!)

**logaritmicko-normální**, platí-li  $\ln V \sim N(\mu, \sigma^2)$

- ▶ **Fisherovo  $F$ -rozdělení**  $F_{k,m}$  [qf(1-alpha,k,m)]

$$F \sim F_{k,m} : P(F > F_{k,m}(\alpha)) = \alpha$$

- ▶ **rozdělení chí-kvadrát**  $\chi_k^2$  [qchisq(1-alpha,k)]

$$X^2 \sim \chi_k^2 : P(X^2 > \chi_k^2(\alpha)) = \alpha$$

- ▶ speciálně platí:

- ▶  $\chi_1^2(0,05) = 3,841 = 1,960^2$

- ▶  $\chi_1^2(\alpha) = z(\alpha/2)^2$

- ▶  $F_{1,m}(\alpha) = (t_m(\alpha))^2$

## další rozdělení související s normálním

[F-distribution, chi-square distribution]

- ▶  $V$  má rozdělení (musí být  $P(V > 0) = 1$  !!)

**logaritmicko-normální**, platí-li  $\ln V \sim N(\mu, \sigma^2)$

- ▶ **Fisherovo  $F$ -rozdělení**  $F_{k,m}$  [qf(1-alpha,k,m)]

$$F \sim F_{k,m} : P(F > F_{k,m}(\alpha)) = \alpha$$

- ▶ **rozdělení chí-kvadrát**  $\chi_k^2$  [qchisq(1-alpha,k)]

$$X^2 \sim \chi_k^2 : P(X^2 > \chi_k^2(\alpha)) = \alpha$$

- ▶ speciálně platí:

- ▶  $\chi_1^2(0,05) = 3,841 = 1,960^2$
- ▶  $\chi_1^2(\alpha) = z(\alpha/2)^2$
- ▶  $F_{1,m}(\alpha) = (t_m(\alpha))^2$

## další rozdělení související s normálním

[F-distribution, chi-square distribution]

- ▶  $V$  má rozdělení (musí být  $P(V > 0) = 1$  !!)

**logaritmicko-normální**, platí-li  $\ln V \sim N(\mu, \sigma^2)$

- ▶ **Fisherovo  $F$ -rozdělení**  $F_{k,m}$  [qf(1-alpha,k,m)]

$$F \sim F_{k,m} : P(F > F_{k,m}(\alpha)) = \alpha$$

- ▶ **rozdělení chí-kvadrát**  $\chi_k^2$  [qchisq(1-alpha,k)]

$$X^2 \sim \chi_k^2 : P(X^2 > \chi_k^2(\alpha)) = \alpha$$

- ▶ speciálně platí:

- ▶  $\chi_1^2(0,05) = 3,841 = 1,960^2$
- ▶  $\chi_1^2(\alpha) = z(\alpha/2)^2$
- ▶  $F_{1,m}(\alpha) = (t_m(\alpha))^2$

## další rozdělení související s normálním

[F-distribution, chi-square distribution]

- ▶  $V$  má rozdělení (musí být  $P(V > 0) = 1$  !!)

**logaritmicko-normální**, platí-li  $\ln V \sim N(\mu, \sigma^2)$

- ▶ **Fisherovo  $F$ -rozdělení**  $F_{k,m}$  [qf(1-alpha,k,m)]

$$F \sim F_{k,m} : P(F > F_{k,m}(\alpha)) = \alpha$$

- ▶ **rozdělení chí-kvadrát**  $\chi_k^2$  [qchisq(1-alpha,k)]

$$X^2 \sim \chi_k^2 : P(X^2 > \chi_k^2(\alpha)) = \alpha$$

- ▶ speciálně platí:

- ▶  $\chi_1^2(0,05) = 3,841 = 1,960^2$
- ▶  $\chi_1^2(\alpha) = z(\alpha/2)^2$
- ▶  $F_{1,m}(\alpha) = (t_m(\alpha))^2$

## další rozdělení související s normálním

[F-distribution, chi-square distribution]

- ▶  $V$  má rozdělení (musí být  $P(V > 0) = 1$  !!)

**logaritmicko-normální**, platí-li  $\ln V \sim N(\mu, \sigma^2)$

- ▶ **Fisherovo  $F$ -rozdělení**  $F_{k,m}$  [qf(1-alpha,k,m)]

$$F \sim F_{k,m} : P(F > F_{k,m}(\alpha)) = \alpha$$

- ▶ **rozdělení chí-kvadrát**  $\chi_k^2$  [qchisq(1-alpha,k)]

$$X^2 \sim \chi_k^2 : P(X^2 > \chi_k^2(\alpha)) = \alpha$$

- ▶ speciálně platí:

- ▶  $\chi_1^2(0,05) = 3,841 = 1,960^2$
- ▶  $\chi_1^2(\alpha) = z(\alpha/2)^2$
- ▶  $F_{1,m}(\alpha) = (t_m(\alpha))^2$

## další rozdělení související s normálním

[F-distribution, chi-square distribution]

- ▶  $V$  má rozdělení (musí být  $P(V > 0) = 1$  !!)

**logaritmicko-normální**, platí-li  $\ln V \sim N(\mu, \sigma^2)$

- ▶ **Fisherovo  $F$ -rozdělení**  $F_{k,m}$  [qf(1-alpha,k,m)]

$$F \sim F_{k,m} : P(F > F_{k,m}(\alpha)) = \alpha$$

- ▶ **rozdělení chí-kvadrát**  $\chi_k^2$  [qchisq(1-alpha,k)]

$$X^2 \sim \chi_k^2 : P(X^2 > \chi_k^2(\alpha)) = \alpha$$

- ▶ speciálně platí:

- ▶  $\chi_1^2(0,05) = 3,841 = 1,960^2$
- ▶  $\chi_1^2(\alpha) = z(\alpha/2)^2$
- ▶  $F_{1,m}(\alpha) = (t_m(\alpha))^2$

## příklad: věk matek (motivační příklad)

nepřehlédněte slova **populace**, **populační**

- ▶ velká **populace** dětí (a tedy jejich matek, téměř 11 tisíc)
- ▶ na rozdíl od běžné praxe **známe populační průměr  $\mu$**
- ▶ náhodně vybráno 1000 matek (vlastně průměry výběrů rozsahu  $n = 1$ ), nakreslen histogram
- ▶ 1000 krát náhodně vybráno vždy  $n = 10$  matek, vždy spočítán **výběrový** průměr, nakreslen histogram **výběrových** průměrů
- ▶ 1000 krát náhodně vybráno vždy  $n = 100$  matek, vždy spočítán **výb.** průměr, nakreslen histogram **výb.** průměrů
- ▶ podle teorie by každý další rozptyl ze 1000 **výb.** průměrů měl být desetkrát menší než ten založený na desetkrát menším  $n$
- ▶ skutečné rozptyly (odhady z 1000 realizací): 23,5; 2,20; 0,21



## příklad: věk matek (motivační příklad)

nepřehlédněte slova **populace**, **populační**

- ▶ velká **populace** dětí (a tedy jejich matek, téměř 11 tisíc)
- ▶ na rozdíl od běžné praxe **známe populační průměr  $\mu$**
- ▶ náhodně vybráno 1000 matek (vlastně průměry výběrů rozsahu  $n = 1$ ), nakreslen histogram
- ▶ 1000 krát náhodně vybráno vždy  $n = 10$  matek, vždy spočítán **výběrový** průměr, nakreslen histogram **výběrových** průměrů
- ▶ 1000 krát náhodně vybráno vždy  $n = 100$  matek, vždy spočítán **výb.** průměr, nakreslen histogram **výb.** průměrů
- ▶ podle teorie by každý další rozptyl ze 1000 **výb.** průměrů měl být desetkrát menší než ten založený na desetkrát menším  $n$
- ▶ skutečné rozptyly (odhady z 1000 realizací): 23,5; 2,20; 0,21

## příklad: věk matek (motivační příklad)

nepřehlédněte slova **populace**, **populační**

- ▶ velká **populace** dětí (a tedy jejich matek, téměř 11 tisíc)
- ▶ na rozdíl od běžné praxe **známe populační průměr  $\mu$**
- ▶ náhodně vybráno 1000 matek (vlastně průměry výběrů rozsahu  $n = 1$ ), nakreslen histogram
- ▶ 1000 krát náhodně vybráno vždy  $n = 10$  matek, vždy spočítán **výběrový** průměr, nakreslen histogram **výběrových** průměrů
- ▶ 1000 krát náhodně vybráno vždy  $n = 100$  matek, vždy spočítán **výb.** průměr, nakreslen histogram **výb.** průměrů
- ▶ podle teorie by každý další rozptyl ze 1000 **výb.** průměrů měl být desetkrát menší než ten založený na desetkrát menším  $n$
- ▶ skutečné rozptyly (odhady z 1000 realizací): 23,5; 2,20; 0,21

## příklad: věk matek (motivační příklad)

nepřehlédněte slova **populace**, **populační**

- ▶ velká **populace** dětí (a tedy jejich matek, téměř 11 tisíc)
- ▶ na rozdíl od běžné praxe **známe populační průměr  $\mu$**
- ▶ náhodně vybráno 1000 matek (vlastně průměry výběrů rozsahu  $n = 1$ ), nakreslen histogram
- ▶ 1000 krát náhodně vybráno vždy  $n = 10$  matek, vždy spočítán **výběrový** průměr, nakreslen histogram **výběrových** průměrů
- ▶ 1000 krát náhodně vybráno vždy  $n = 100$  matek, vždy spočítán **výb.** průměr, nakreslen histogram **výb.** průměrů
- ▶ podle teorie by každý další rozptyl ze 1000 **výb.** průměrů měl být desetkrát menší než ten založený na desetkrát menším  $n$
- ▶ skutečné rozptyly (odhady z 1000 realizací): 23,5; 2,20; 0,21

## příklad: věk matek (motivační příklad)

nepřehlédněte slova **populace**, **populační**

- ▶ velká **populace** dětí (a tedy jejich matek, téměř 11 tisíc)
- ▶ na rozdíl od běžné praxe **známe populační průměr  $\mu$**
- ▶ náhodně vybráno 1000 matek (vlastně průměry výběrů rozsahu  $n = 1$ ), nakreslen histogram
- ▶ 1000 krát náhodně vybráno vždy  $n = 10$  matek, vždy spočítán **výběrový** průměr, nakreslen histogram **výběrových** průměrů
- ▶ 1000 krát náhodně vybráno vždy  $n = 100$  matek, vždy spočítán **výb.** průměr, nakreslen histogram **výb.** průměrů
- ▶ podle teorie by každý další rozptyl ze 1000 **výb.** průměrů měl být desetkrát menší než ten založený na desetkrát menším  $n$
- ▶ skutečné rozptyly (odhady z 1000 realizací): 23,5; 2,20; 0,21

## příklad: věk matek (motivační příklad)

nepřehlédněte slova **populace**, **populační**

- ▶ velká **populace** dětí (a tedy jejich matek, téměř 11 tisíc)
- ▶ na rozdíl od běžné praxe **známe populační průměr  $\mu$**
- ▶ náhodně vybráno 1000 matek (vlastně průměry výběrů rozsahu  $n = 1$ ), nakreslen histogram
- ▶ 1000 krát náhodně vybráno vždy  $n = 10$  matek, vždy spočítán **výběrový** průměr, nakreslen histogram **výběrových** průměrů
- ▶ 1000 krát náhodně vybráno vždy  $n = 100$  matek, vždy spočítán **výb.** průměr, nakreslen histogram **výb.** průměrů
- ▶ podle teorie by každý další rozptyl ze 1000 **výb.** průměrů měl být desetkrát menší než ten založený na desetkrát menším  $n$
- ▶ skutečné rozptyly (odhady z 1000 realizací): 23,5; 2,20; 0,21





## příklad: věk matek (motivační příklad)

nepřehlédněte slova **populace**, **populační**

- ▶ velká **populace** dětí (a tedy jejich matek, téměř 11 tisíc)
- ▶ na rozdíl od běžné praxe **známe populační průměr  $\mu$**
- ▶ náhodně vybráno 1000 matek (vlastně průměry výběrů rozsahu  $n = 1$ ), nakreslen histogram
- ▶ 1000 krát náhodně vybráno vždy  $n = 10$  matek, vždy spočítán **výběrový** průměr, nakreslen histogram **výběrových** průměrů
- ▶ 1000 krát náhodně vybráno vždy  $n = 100$  matek, vždy spočítán **výb.** průměr, nakreslen histogram **výb.** průměrů
- ▶ podle teorie by každý další rozptyl ze 1000 **výb.** průměrů měl být desetkrát menší než ten založený na desetkrát menším  $n$
- ▶ skutečné rozptyly (odhady z 1000 realizací): 23,5; 2,20; 0,21

# příklad: věk matek (umělá situace)

populace - 10 916 matek, opakované výběry rozsahu  $n = 1, 10, 100$   
 je patrná variabilita klesající s rostoucím  $n$



## příklad: věk matek

průměrný věk matek v opakovaných výběrech, počet opakování  $B = 1000$   
 (20. března 2012 některé hodnoty opraveny)

rozsah výběru $n$	průměr průměrů	směr. odch. průměrů	rozptyl průměrů	rozptyl průměrů teoreticky
1	25,42	4,625	21,388	24,428
10	25,35	1,544	2,385	2,443
100	25,39	0,480	0,231	0,244
1000	25,40	0,150	0,022	0,024
populace	$\mu = 25,40$	$\sigma = 4,932$	$\sigma^2 = 24,428$	



# průměr z náhodného výběru

nemusí jít o normální rozdělení!

- ▶  $X_1, \dots, X_n$  **nezávislé**, mají stejné rozdělení
  - $\mu_{X_i} = E X_i = \mu$  (stejná střední hodnota)
  - $\sigma_{X_i}^2 = \text{var } X_i = \sigma^2$  (stejný rozptyl)
- ▶  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} (X_1 + X_2 + \dots + X_n)$
- ▶  $\mu_{\bar{X}} = E \bar{X} = \mu$ 
  - ▶ výběrový průměr  $\bar{X}$  je opět náhodná veličina
  - ▶ je **nestranným** odhadem [unbiased estimator] parametru  $\mu$
  - ▶ **nestranným** odhadem populačního průměru (střední hodnoty)
  - ▶ když pořizujeme výběry opakovaně, průměry kolísají kolem skutečné hodnoty populačního průměru
- ▶ z příkladu víme, že rozptyl  $\bar{X}$  závisí na  $n$

**náhodný výběr**  
populační průměr  
populační rozptyl

výběrový průměr

# průměr z náhodného výběru

nemusí jít o normální rozdělení!

- ▶  $X_1, \dots, X_n$  **nezávislé**, mají stejné rozdělení
  - $\mu_{X_i} = E X_i = \mu$  (stejná střední hodnota)
  - $\sigma_{X_i}^2 = \text{var } X_i = \sigma^2$  (stejný rozptyl)
- ▶  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$
- ▶  $\mu_{\bar{X}} = E \bar{X} = \mu$ 
  - ▶ výběrový průměr  $\bar{X}$  je opět náhodná veličina
  - ▶ je **nestranným odhadem** [unbiased estimator] parametru  $\mu$
  - ▶ **nestranným odhadem** populačního průměru (střední hodnoty)
  - ▶ když pořizujeme výběry opakovaně, průměry kolísají kolem skutečné hodnoty populačního průměru
- ▶ z příkladu víme, že rozptyl  $\bar{X}$  závisí na  $n$

**náhodný výběr**  
populační průměr  
populační rozptyl

výběrový průměr

# průměr z náhodného výběru

nemusí jít o normální rozdělení!

- ▶  $X_1, \dots, X_n$  **nezávislé**, mají stejné rozdělení
  - $\mu_{X_i} = E X_i = \mu$  (stejná střední hodnota)
  - $\sigma_{X_i}^2 = \text{var } X_i = \sigma^2$  (stejný rozptyl)
- ▶  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$
- ▶  $\mu_{\bar{X}} = E \bar{X} = \mu$ 
  - ▶ výběrový průměr  $\bar{X}$  je opět náhodná veličina
  - ▶ je **nestranným** odhadem [unbiased estimator] parametru  $\mu$
  - ▶ nestranným odhadem populačního průměru (střední hodnoty)
  - ▶ když pořizujeme výběry opakovaně, průměry kolísají kolem skutečné hodnoty populačního průměru
- ▶ z příkladu víme, že rozptyl  $\bar{X}$  závisí na  $n$

**náhodný výběr**  
populační průměr  
populační rozptyl

výběrový průměr

# průměr z náhodného výběru

nemusí jít o normální rozdělení!

- ▶  $X_1, \dots, X_n$  **nezávislé**, mají stejné rozdělení
  - $\mu_{X_i} = E X_i = \mu$  (stejná střední hodnota)
  - $\sigma_{X_i}^2 = \text{var } X_i = \sigma^2$  (stejný rozptyl)
- ▶  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$
- ▶  $\mu_{\bar{X}} = E \bar{X} = \mu$ 
  - ▶ výběrový průměr  $\bar{X}$  je opět náhodná veličina
  - ▶ je **nestranným** odhadem [unbiased estimator] parametru  $\mu$
  - ▶ nestranným odhadem populačního průměru (střední hodnoty)
  - ▶ když pořizujeme výběry opakovaně, průměry kolísají kolem skutečné hodnoty populačního průměru
- ▶ z příkladu víme, že rozptyl  $\bar{X}$  závisí na  $n$

**náhodný výběr**  
populační průměr  
populační rozptyl

výběrový průměr

# průměr z náhodného výběru

nemusí jít o normální rozdělení!

- ▶  $X_1, \dots, X_n$  **nezávislé**, mají stejné rozdělení
  - $\mu_{X_i} = E X_i = \mu$  (stejná střední hodnota)
  - $\sigma_{X_i}^2 = \text{var } X_i = \sigma^2$  (stejný rozptyl)
- ▶  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$
- ▶  $\mu_{\bar{X}} = E \bar{X} = \mu$ 
  - ▶ výběrový průměr  $\bar{X}$  je opět náhodná veličina
  - ▶ je **nestranným** odhadem [unbiased estimator] parametru  $\mu$
  - ▶ nestranným odhadem populačního průměru (střední hodnoty)
  - ▶ když pořizujeme výběry opakovaně, průměry kolísají kolem skutečné hodnoty populačního průměru
- ▶ z příkladu víme, že rozptyl  $\bar{X}$  závisí na  $n$

**náhodný výběr**  
populační průměr  
populační rozptyl

výběrový průměr

# průměr z náhodného výběru

nemusí jít o normální rozdělení!

- ▶  $X_1, \dots, X_n$  **nezávislé**, mají stejné rozdělení
  - $\mu_{X_i} = E X_i = \mu$  (stejná střední hodnota)
  - $\sigma_{X_i}^2 = \text{var } X_i = \sigma^2$  (stejný rozptyl)
- ▶  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$
- ▶  $\mu_{\bar{X}} = E \bar{X} = \mu$ 
  - ▶ výběrový průměr  $\bar{X}$  je opět náhodná veličina
  - ▶ je **nestranným** odhadem [unbiased estimator] parametru  $\mu$
  - ▶ nestranným odhadem populačního průměru (střední hodnoty)
  - ▶ když pořizujeme výběry opakovaně, průměry kolísají kolem skutečné hodnoty populačního průměru
- ▶ z příkladu víme, že rozptyl  $\bar{X}$  závisí na  $n$

**náhodný výběr**  
populační průměr  
populační rozptyl

výběrový průměr

# průměr z náhodného výběru

nemusí jít o normální rozdělení!

- ▶  $X_1, \dots, X_n$  **nezávislé**, mají stejné rozdělení
  - $\mu_{X_i} = E X_i = \mu$  (stejná střední hodnota)
  - $\sigma_{X_i}^2 = \text{var } X_i = \sigma^2$  (stejný rozptyl)
- ▶  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$
- ▶  $\mu_{\bar{X}} = E \bar{X} = \mu$ 
  - ▶ výběrový průměr  $\bar{X}$  je opět náhodná veličina
  - ▶ je **nestranným** odhadem [unbiased estimator] parametru  $\mu$
  - ▶ nestranným odhadem populačního průměru (střední hodnoty)
  - ▶ když pořizujeme výběry opakovaně, průměry kolísají kolem skutečné hodnoty populačního průměru
- ▶ z příkladu víme, že rozptyl  $\bar{X}$  závisí na  $n$

# průměr z náhodného výběru

nemusí jít o normální rozdělení!

- ▶  $X_1, \dots, X_n$  **nezávislé**, mají stejné rozdělení
  - $\mu_{X_i} = E X_i = \mu$  (stejná střední hodnota)
  - $\sigma_{X_i}^2 = \text{var } X_i = \sigma^2$  (stejný rozptyl)
- ▶  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$
- ▶  $\mu_{\bar{X}} = E \bar{X} = \mu$ 
  - ▶ výběrový průměr  $\bar{X}$  je opět náhodná veličina
  - ▶ je **nestranným** odhadem [unbiased estimator] parametru  $\mu$
  - ▶ nestranným odhadem populačního průměru (střední hodnoty)
  - ▶ když pořizujeme výběry opakovaně, průměry kolísají kolem skutečné hodnoty populačního průměru
- ▶ z příkladu víme, že rozptyl  $\bar{X}$  závisí na  $n$

**náhodný výběr**  
populační průměr  
populační rozptyl

výběrový průměr



## rozptyl průměru z náhodného výběru

$$\sigma_{\bar{X}}^2 = \text{var} \left( \frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n^2} \sum_{i=1}^n \text{var} X_i = \frac{\sigma^2}{n} = \left( \frac{\sigma}{\sqrt{n}} \right)^2 = (\text{S.E.}(\bar{X}))^2$$

- ▶  $\text{S.E.}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$  – **střední chyba průměru**

[standard error of mean]

- ▶ variabilita průměrů (měřená rozptylem) z výběrů rozsahu  $n$  je  $n$ -krát menší, než variabilita jednotlivých pozorování  $\sigma^2$
- ▶ střední chyba průměru je  $\sqrt{n}$ -krát menší než  $\sigma$
- ▶ čím jsou rozsahy výběru větší, tím méně výběrové průměry kolísají (kolem populačního průměru)
- ▶ speciálně pro normální rozdělení  $X_i \sim N(\mu, \sigma^2)$  nezávislé:

$$\bar{X} \sim N(\mu, \sigma^2/n) \Rightarrow Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$$

(všimněte si závislosti na  $n$ )

## rozptyl průměru z náhodného výběru

$$\sigma_{\bar{X}}^2 = \text{var} \left( \frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n^2} \sum_{i=1}^n \text{var} X_i = \frac{\sigma^2}{n} = \left( \frac{\sigma}{\sqrt{n}} \right)^2 = (\text{S.E.}(\bar{X}))^2$$

- ▶  $\text{S.E.}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$  – **střední chyba průměru** [standard error of mean]
- ▶ variabilita průměrů (měřená rozptylem) z výběrů rozsahu  $n$  je  $n$ -krát menší, než variabilita jednotlivých pozorování  $\sigma^2$
- ▶ střední chyba průměru je  $\sqrt{n}$ -krát menší než  $\sigma$
- ▶ čím jsou rozsahy výběru větší, tím méně výběrové průměry kolísají (kolem populačního průměru)
- ▶ speciálně pro normální rozdělení  $X_i \sim N(\mu, \sigma^2)$  nezávislé:

$$\bar{X} \sim N(\mu, \sigma^2/n) \Rightarrow Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$$

(všimněte si závislosti na  $n$ )

## rozptyl průměru z náhodného výběru

$$\sigma_{\bar{X}}^2 = \text{var} \left( \frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n^2} \sum_{i=1}^n \text{var} X_i = \frac{\sigma^2}{n} = \left( \frac{\sigma}{\sqrt{n}} \right)^2 = (\text{S.E.}(\bar{X}))^2$$

- ▶  $\text{S.E.}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$  – **střední chyba průměru** [standard error of mean]
- ▶ variabilita průměrů (měřená rozptylem) z výběrů rozsahu  $n$  je  $n$ -krát menší, než variabilita jednotlivých pozorování  $\sigma^2$
- ▶ střední chyba průměru je  $\sqrt{n}$ -krát menší než  $\sigma$
- ▶ čím jsou rozsahy výběru větší, tím méně výběrové průměry kolísají (kolem populačního průměru)
- ▶ speciálně pro normální rozdělení  $X_i \sim N(\mu, \sigma^2)$  nezávislé:

$$\bar{X} \sim N(\mu, \sigma^2/n) \Rightarrow Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$$

(všimněte si závislosti na  $n$ )

## rozptyl průměru z náhodného výběru

$$\sigma_{\bar{X}}^2 = \text{var} \left( \frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n^2} \sum_{i=1}^n \text{var} X_i = \frac{\sigma^2}{n} = \left( \frac{\sigma}{\sqrt{n}} \right)^2 = (\text{S.E.}(\bar{X}))^2$$

- ▶  $\text{S.E.}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$  – **střední chyba průměru** [standard error of mean]
- ▶ variabilita průměrů (měřená rozptylem) z výběrů rozsahu  $n$  je  $n$ -krát menší, než variabilita jednotlivých pozorování  $\sigma^2$
- ▶ střední chyba průměru je  $\sqrt{n}$ -krát menší než  $\sigma$
- ▶ čím jsou rozsahy výběru větší, tím méně výběrové průměry kolísají (kolem populačního průměru)
- ▶ speciálně pro normální rozdělení  $X_i \sim N(\mu, \sigma^2)$  nezávislé:

$$\bar{X} \sim N(\mu, \sigma^2/n) \Rightarrow Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$$

(všimněte si závislosti na  $n$ )

## rozptyl průměru z náhodného výběru

$$\sigma_{\bar{X}}^2 = \text{var} \left( \frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n^2} \sum_{i=1}^n \text{var} X_i = \frac{\sigma^2}{n} = \left( \frac{\sigma}{\sqrt{n}} \right)^2 = (\text{S.E.}(\bar{X}))^2$$

- ▶  $\text{S.E.}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$  – **střední chyba průměru** [standard error of mean]
- ▶ variabilita průměrů (měřená rozptylem) z výběrů rozsahu  $n$  je  $n$ -krát menší, než variabilita jednotlivých pozorování  $\sigma^2$
- ▶ střední chyba průměru je  $\sqrt{n}$ -krát menší než  $\sigma$
- ▶ čím jsou rozsahy výběru větší, tím méně výběrové průměry kolísají (kolem populačního průměru)
- ▶ speciálně pro normální rozdělení  $X_i \sim N(\mu, \sigma^2)$  nezávislé:





$$\bar{X} \sim N(\mu, \sigma^2/n) \Rightarrow Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$$

(všimněte si závislosti na  $n$ )

## příklad: věk matek (nestejná měřítka!)

populace - 10 916 matek, opakované výběry rozsahu  $n = 1, 10, 100$

je patrné, že s rostoucím  $n$  se histogram blíží histogramu norm. rozdělení



## příklad: věk matek

průměrný věk matek v opakovaných výběrech,

počet opakování  $B = 1000$ 

(20. března 2012 některé hodnoty opraveny)

rozsah výběru $n$	průměr průměrů	směr. odch. průměrů	šikmost průměrů	špičatost průměrů
1	25,42	4,625	0,740	0,287
10	25,35	1,544	0,275	-0,038
100	25,39	0,480	0,081	-0,053
1000	25,40	0,150	0,003	0,037
populace	$\mu = 25,40$	$\sigma = 4,942$	$\gamma_1 = 0,773$	$\gamma_2 = 0,192$

# centrální limitní věta (CLV, CLT)

## [Central Limit Theorem]

- ▶ Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$  (nemusí pocházet z normálního rozdělení). Potom **pro velké**  $n$  má průměr  $\bar{X}$  přibližně rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , součet  $X_1 + \dots + X_n$  pak rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶ prakticky: **průměr** má pro dost velká  $n$  **normální rozdělení** s rozptylem  $n$ -krát menším než jednotlivá pozorování, a to bez ohledu na výchozí rozdělení jednotlivých pozorování
- ▶ CLT je často důvodem předpokladu o normálním rozdělení, výsledná hodnota je ovlivněna součtem velkého počtu nahodilých malých vlivů
- ▶ příklad: průměrný věk matek z velkých výběrů má už (téměř) normální rozdělení



# centrální limitní věta (CLV, CLT)

## [Central Limit Theorem]

- ▶ Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$  (nemusí pocházet z normálního rozdělení). Potom **pro velké**  $n$  má průměr  $\bar{X}$  přibližně rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , součet  $X_1 + \dots + X_n$  pak rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶ prakticky: **průměr** má pro dost velká  $n$  **normální rozdělení** s rozptylem  $n$ -krát menším než jednotlivá pozorování, a to bez ohledu na výchozí rozdělení jednotlivých pozorování
- ▶ CLT je často důvodem předpokladu o normálním rozdělení, výsledná hodnota je ovlivněna součtem velkého počtu nahodilých malých vlivů
- ▶ příklad: průměrný věk matek z velkých výběrů má už (téměř) normální rozdělení

# centrální limitní věta (CLV, CLT)

## [Central Limit Theorem]

- ▶ Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$  (nemusí pocházet z normálního rozdělení). Potom **pro velké**  $n$  má průměr  $\bar{X}$  přibližně rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , součet  $X_1 + \dots + X_n$  pak rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶ prakticky: **průměr** má pro dost velká  $n$  **normální rozdělení** s rozptylem  $n$ -krát menším než jednotlivá pozorování, a to bez ohledu na výchozí rozdělení jednotlivých pozorování
- ▶ CLT je často důvodem předpokladu o normálním rozdělení, výsledná hodnota je ovlivněna součtem velikého počtu nahodilých malých vlivů
- ▶ příklad: průměrný věk matek z velkých výběrů má už (téměř) normální rozdělení

# centrální limitní věta (CLV, CLT)

## [Central Limit Theorem]

- ▶ Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$  (nemusí pocházet z normálního rozdělení). Potom **pro velké**  $n$  má průměr  $\bar{X}$  přibližně rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , součet  $X_1 + \dots + X_n$  pak rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶ prakticky: **průměr** má pro dost velká  $n$  **normální rozdělení** s rozptylem  $n$ -krát menším než jednotlivá pozorování, a to bez ohledu na výchozí rozdělení jednotlivých pozorování
- ▶ CLT je často důvodem předpokladu o normálním rozdělení, výsledná hodnota je ovlivněna součtem velikého počtu nahodilých malých vlivů
- ▶ příklad: průměrný věk matek z velkých výběrů má už (téměř) normální rozdělení

interval spolehlivosti pro  $\mu$  (populační průměr)výběr z  $N(\mu, \sigma^2)$  nebo velké  $n$ 

[confidence interval]

- ▶ víme, že  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$

$$P(|Z| < 1,96) = P\left(\frac{|\bar{X} - \mu|}{\sigma} \sqrt{n} < 1,96\right) = 0,95$$

- ▶ což je totéž, jako ( $\mu$  se od  $\bar{X}$  liší nejvýše ...)

$$P\left(|\bar{X} - \mu| < 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- ▶ tedy (všimněte si zkracování intervalu s rostoucím  $n$ )

$$P\left(\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- ▶ dostali jsme 95% **interval spolehlivosti pro parametr  $\mu$**

interval spolehlivosti pro  $\mu$  (populační průměr)výběr z  $N(\mu, \sigma^2)$  nebo velké  $n$ 

[confidence interval]

- ▶ víme, že  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$

$$P(|Z| < 1,96) = P\left(\frac{|\bar{X} - \mu|}{\sigma} \sqrt{n} < 1,96\right) = 0,95$$

- ▶ což je totéž, jako ( $\mu$  se od  $\bar{X}$  liší nejvýše ...)

$$P\left(|\bar{X} - \mu| < 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- ▶ tedy (všimněte si zkracování intervalu s rostoucím  $n$ )

$$P\left(\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- ▶ dostali jsme 95% **interval spolehlivosti pro parametr  $\mu$**

interval spolehlivosti pro  $\mu$  (populační průměr)výběr z  $N(\mu, \sigma^2)$  nebo velké  $n$ 

[confidence interval]

- ▶ víme, že  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$

$$P(|Z| < 1,96) = P\left(\frac{|\bar{X} - \mu|}{\sigma} \sqrt{n} < 1,96\right) = 0,95$$

- ▶ což je totéž, jako ( $\mu$  se od  $\bar{X}$  liší nejvýše ...)

$$P\left(|\bar{X} - \mu| < 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- ▶ tedy (všimněte si zkracování intervalu s rostoucím  $n$ )

$$P\left(\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- ▶ dostali jsme 95% interval spolehlivosti pro parametr  $\mu$

interval spolehlivosti pro  $\mu$  (populační průměr)výběr z  $N(\mu, \sigma^2)$  nebo velké  $n$ 

[confidence interval]

- ▶ víme, že  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$

$$P(|Z| < 1,96) = P\left(\frac{|\bar{X} - \mu|}{\sigma} \sqrt{n} < 1,96\right) = 0,95$$

- ▶ což je totéž, jako ( $\mu$  se od  $\bar{X}$  liší nejvýše ...)

$$P\left(|\bar{X} - \mu| < 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- ▶ tedy (všimněte si zkracování intervalu s rostoucím  $n$ )

$$P\left(\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- ▶ dostali jsme 95% **interval spolehlivosti pro parametr  $\mu$**

## interpretace intervalu spolehlivosti

- ▶ je to **intervalový** odhad populačního průměru (stř. hodnoty)  $\mu$
- ▶  $\bar{X}$  je **bodový** odhad  $\mu$
- ▶ **základní vlastnost**: 95% interval spolehlivosti **překryje** s pravděpodobností 95 % **neznámé**  $\mu$  (**odhadovaný parametr**)
- ▶ kdybychom postup prováděli opakovaně, pak asi v 95 % případů interval překryje skutečnou hodnotu  $\mu$ , ve zbylých asi 5 % zůstane skutečné  $\mu$  mimo interval spolehlivosti
- ▶ pro obecné  $\alpha$  (spolehlivost  $1 - \alpha$ ):

$$P \left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right) = 1 - \alpha$$

- ▶ POZOR na nesprávné interpretace, vypovídá o neznámé **konstantě**  $\mu$ , nikoliv o **náhodných veličinách**  $X$  nebo  $\bar{X}$



## interpretace intervalu spolehlivosti

- ▶ je to **intervalový** odhad populačního průměru (stř. hodnoty)  $\mu$
- ▶  $\bar{X}$  je **bodový** odhad  $\mu$
- ▶ **základní vlastnost**: 95% interval spolehlivosti **překryje** s pravděpodobností 95 % **neznámé**  $\mu$  (**odhadovaný parametr**)
- ▶ kdybychom postup prováděli opakovaně, pak asi v 95 % případů interval překryje skutečnou hodnotu  $\mu$ , ve zbylých asi 5 % zůstane skutečné  $\mu$  mimo interval spolehlivosti
- ▶ pro obecné  $\alpha$  (spolehlivost  $1 - \alpha$ ):

$$P \left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right) = 1 - \alpha$$

- ▶ POZOR na nesprávné interpretace, vypovídá o neznámé **konstantě**  $\mu$ , nikoliv o **náhodných veličinách**  $X$  nebo  $\bar{X}$

## interpretace intervalu spolehlivosti

- ▶ je to **intervalový** odhad populačního průměru (stř. hodnoty)  $\mu$
- ▶  $\bar{X}$  je **bodový** odhad  $\mu$
- ▶ **základní vlastnost**: 95% interval spolehlivosti **překryje** s pravděpodobností 95 % **neznámé**  $\mu$  (**odhadovaný parametr**)
- ▶ kdybychom postup prováděli opakovaně, pak asi v 95 % případů interval překryje skutečnou hodnotu  $\mu$ , ve zbylých asi 5 % zůstane skutečné  $\mu$  mimo interval spolehlivosti
- ▶ pro obecné  $\alpha$  (spolehlivost  $1 - \alpha$ ):

$$P \left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right) = 1 - \alpha$$

- ▶ POZOR na nesprávné interpretace, vypovídá o neznámé konstantě  $\mu$ , nikoliv o **náhodných veličinách**  $X$  nebo  $\bar{X}$

## interpretace intervalu spolehlivosti

- ▶ je to **intervalový** odhad populačního průměru (stř. hodnoty)  $\mu$
- ▶  $\bar{X}$  je **bodový** odhad  $\mu$
- ▶ **základní vlastnost**: 95% interval spolehlivosti **překryje** s pravděpodobností 95 % **neznámé**  $\mu$  (**odhadovaný parametr**)
- ▶ kdybychom postup prováděli opakovaně, pak asi v 95 % případů interval překryje skutečnou hodnotu  $\mu$ , ve zbylých asi 5 % zůstane skutečné  $\mu$  mimo interval spolehlivosti
- ▶ pro obecné  $\alpha$  (spolehlivost  $1 - \alpha$ ):

$$P \left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right) = 1 - \alpha$$

- ▶ POZOR na nesprávné interpretace, vypovídá o neznámé konstantě  $\mu$ , nikoliv o **náhodných veličinách**  $X$  nebo  $\bar{X}$

## interpretace intervalu spolehlivosti

- ▶ je to **intervalový** odhad populačního průměru (stř. hodnoty)  $\mu$
- ▶  $\bar{X}$  je **bodový** odhad  $\mu$
- ▶ **základní vlastnost**: 95% interval spolehlivosti **překryje** s pravděpodobností 95 % **neznámé**  $\mu$  (**odhadovaný parametr**)
- ▶ kdybychom postup prováděli opakovaně, pak asi v 95 % případů interval překryje skutečnou hodnotu  $\mu$ , ve zbylých asi 5 % zůstane skutečné  $\mu$  mimo interval spolehlivosti
- ▶ pro obecné  $\alpha$  (spolehlivost  $1 - \alpha$ ):

$$P \left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right) = 1 - \alpha$$

- ▶ POZOR na nesprávné interpretace, vypovídá o neznámé konstantě  $\mu$ , nikoliv o **náhodných veličinách**  $X$  nebo  $\bar{X}$

## interpretace intervalu spolehlivosti

- ▶ je to **intervalový** odhad populačního průměru (stř. hodnoty)  $\mu$
- ▶  $\bar{X}$  je **bodový** odhad  $\mu$
- ▶ **základní vlastnost**: 95% interval spolehlivosti **překryje** s pravděpodobností 95 % **neznámé**  $\mu$  (**odhadovaný parametr**)
- ▶ kdybychom postup prováděli opakovaně, pak asi v 95 % případů interval překryje skutečnou hodnotu  $\mu$ , ve zbylých asi 5 % zůstane skutečné  $\mu$  mimo interval spolehlivosti
- ▶ pro obecné  $\alpha$  (spolehlivost  $1 - \alpha$ ):

$$P \left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right) = 1 - \alpha$$

- ▶ POZOR na nesprávné interpretace, vypovídá o neznámé **konstantě**  $\mu$ , nikoliv o **náhodných veličinách**  $X$  nebo  $\bar{X}$

## příklad: výšky desetiletých chlapců



$$\left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right)$$

- ▶ náhodně vybráno  $n = 15$  desetiletých chlapců,
- ▶ je známo (předpokládá se), že je  $\sigma = 6,4$  cm
- ▶ průměrná výška ve výběru 139,1 cm
- ▶  $\alpha = 5 \%$ , tedy  $z(\alpha/2) = z(0,025) = 1,96$
- ▶ 95% interval spolehlivosti pro **průměrnou výšku všech desetiletých chlapců (populační průměr)**:

$$\left( 139,13 - \frac{6,4}{\sqrt{15}} \cdot 1,96; 139,13 + \frac{6,4}{\sqrt{15}} \cdot 1,96 \right)$$

$$(135,9; 142,3)$$

- ▶ **(populační) průměr výšek všech desetiletých chlapců leží s pstí 95 % v rozmezí od 135,9 cm do 142,3 cm**

## příklad: výšky desetiletých chlapců



$$\left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right)$$

- ▶ náhodně vybráno  $n = 15$  desetiletých chlapců,
- ▶ je známo (předpokládá se), že je  $\sigma = 6,4$  cm
- ▶ průměrná výška ve výběru 139,1 cm
- ▶  $\alpha = 5$  %, tedy  $z(\alpha/2) = z(0,025) = 1,96$
- ▶ 95% interval spolehlivosti pro **průměrnou výšku všech desetiletých chlapců (populační průměr)**:

$$\left( 139,13 - \frac{6,4}{\sqrt{15}} \cdot 1,96; 139,13 + \frac{6,4}{\sqrt{15}} \cdot 1,96 \right)$$

$$(135,9; 142,3)$$

- ▶ **(populační) průměr výšek všech desetiletých chlapců leží s pstí 95 % v rozmezí od 135,9 cm do 142,3 cm**

## příklad: výšky desetiletých chlapců



$$\left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right)$$

- ▶ náhodně vybráno  $n = 15$  desetiletých chlapců,
- ▶ je známo (předpokládá se), že je  $\sigma = 6,4$  cm
- ▶ průměrná výška ve výběru 139,1 cm
- ▶  $\alpha = 5$  %, tedy  $z(\alpha/2) = z(0,025) = 1,96$
- ▶ 95% interval spolehlivosti pro **průměrnou výšku všech desetiletých chlapců (populační průměr)**:

$$\left( 139,13 - \frac{6,4}{\sqrt{15}} \cdot 1,96; 139,13 + \frac{6,4}{\sqrt{15}} \cdot 1,96 \right)$$

$$(135,9; 142,3)$$

- ▶ **(populační) průměr výšek všech desetiletých chlapců leží s pstí 95 % v rozmezí od 135,9 cm do 142,3 cm**



## příklad: výšky desetiletých chlapců



$$\left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right)$$

- ▶ náhodně vybráno  $n = 15$  desetiletých chlapců,
- ▶ je známo (předpokládá se), že je  $\sigma = 6,4$  cm
- ▶ průměrná výška ve výběru 139,1 cm
- ▶  $\alpha = 5$  %, tedy  $z(\alpha/2) = z(0,025) = 1,96$
- ▶ 95% interval spolehlivosti pro **průměrnou výšku všech desetiletých chlapců (populační průměr)**:

$$\left( 139,13 - \frac{6,4}{\sqrt{15}} \cdot 1,96; 139,13 + \frac{6,4}{\sqrt{15}} \cdot 1,96 \right)$$

$$(135,9; 142,3)$$

- ▶ **(populační) průměr výšek všech desetiletých chlapců leží s pstí 95 % v rozmezí od 135,9 cm do 142,3 cm**

## příklad: výšky desetiletých chlapců



$$\left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right)$$

- ▶ náhodně vybráno  $n = 15$  desetiletých chlapců,
- ▶ je známo (předpokládá se), že je  $\sigma = 6,4$  cm
- ▶ průměrná výška ve výběru 139,1 cm
- ▶  $\alpha = 5$  %, tedy  $z(\alpha/2) = z(0,025) = 1,96$
- ▶ 95% interval spolehlivosti pro **průměrnou výšku všech desetiletých chlapců (populační průměr)**:

$$\left( 139,13 - \frac{6,4}{\sqrt{15}} \cdot 1,96; 139,13 + \frac{6,4}{\sqrt{15}} \cdot 1,96 \right)$$

$$(135,9; 142,3)$$

- ▶ **(populační) průměr výšek všech desetiletých chlapců leží s pstí 95 % v rozmezí od 135,9 cm do 142,3 cm**

## příklad: výšky desetiletých chlapců



$$\left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right)$$

- ▶ náhodně vybráno  $n = 15$  desetiletých chlapců,
- ▶ je známo (předpokládá se), že je  $\sigma = 6,4$  cm
- ▶ průměrná výška ve výběru 139,1 cm
- ▶  $\alpha = 5$  %, tedy  $z(\alpha/2) = z(0,025) = 1,96$
- ▶ 95% interval spolehlivosti pro **průměrnou výšku všech desetiletých chlapců (populační průměr)**:

$$\left( 139,13 - \frac{6,4}{\sqrt{15}} \cdot 1,96; 139,13 + \frac{6,4}{\sqrt{15}} \cdot 1,96 \right)$$

$$(135,9; 142,3)$$

- ▶ (populační) průměr výšek všech desetiletých chlapců leží s pstí 95 % v rozmezí od 135,9 cm do 142,3 cm

## příklad: výšky desetiletých chlapců



$$\left( \bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(\alpha/2) \right)$$

- ▶ náhodně vybráno  $n = 15$  desetiletých chlapců,
- ▶ je známo (předpokládá se), že je  $\sigma = 6,4$  cm
- ▶ průměrná výška ve výběru 139,1 cm
- ▶  $\alpha = 5$  %, tedy  $z(\alpha/2) = z(0,025) = 1,96$
- ▶ 95% interval spolehlivosti pro **průměrnou výšku všech desetiletých chlapců (populační průměr)**:

$$\left( 139,13 - \frac{6,4}{\sqrt{15}} \cdot 1,96; 139,13 + \frac{6,4}{\sqrt{15}} \cdot 1,96 \right)$$

$$(135,9; 142,3)$$

- ▶ **(populační) průměr výšek všech desetiletých chlapců leží s ptí 95 % v rozmezí od 135,9 cm do 142,3 cm**

## interval spolehlivosti při neznámém $\sigma$

- ▶ když neznáme směr. odchylku  $\sigma$ , je třeba použít kritické hodnoty Studentova  $t$ -rozdělení (pozor na **jinak značené** kritické hodnoty Studentova  $t$ -rozdělení)

$$P\left(\bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha) < \mu < \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha)\right) = 1 - \alpha$$

- ▶ jako odhad  $\sigma$  se použije **výběrová** směrodatná odchylka

$$S_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

- ▶ při velkých  $n$  ( $n \geq 50$ ) stačí použít  $z(\alpha/2)$  místo  $t_{n-1}(\alpha)$
- ▶ interval spolehlivosti se počítá i při odhadu jiných parametrů
- ▶ je to interval, který s požadovanou pravděpodobností překryje odhadovaný parametr – **intervalový odhad**

## interval spolehlivosti při neznámém $\sigma$

- ▶ když neznáme směr. odchylku  $\sigma$ , je třeba použít kritické hodnoty Studentova  $t$ -rozdělení (pozor na **jinak značené** kritické hodnoty Studentova  $t$ -rozdělení)

$$P\left(\bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha) < \mu < \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha)\right) = 1 - \alpha$$

- ▶ jako odhad  $\sigma$  se použije **výběrová** směrodatná odchylka

$$S_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

- ▶ při velkých  $n$  ( $n \geq 50$ ) stačí použít  $z(\alpha/2)$  místo  $t_{n-1}(\alpha)$
- ▶ interval spolehlivosti se počítá i při odhadu jiných parametrů
- ▶ je to interval, který s požadovanou pravděpodobností překryje odhadovaný parametr – **intervalový odhad**

## interval spolehlivosti při neznámém $\sigma$

- ▶ když neznáme směr. odchylku  $\sigma$ , je třeba použít kritické hodnoty Studentova  $t$ -rozdělení (pozor na **jinak značené** kritické hodnoty Studentova  $t$ -rozdělení)

$$P\left(\bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha) < \mu < \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha)\right) = 1 - \alpha$$

- ▶ jako odhad  $\sigma$  se použije **výběrová** směrodatná odchylka

$$S_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

- ▶ při velkých  $n$  ( $n \geq 50$ ) stačí použít  $z(\alpha/2)$  místo  $t_{n-1}(\alpha)$
- ▶ interval spolehlivosti se počítá i při odhadu jiných parametrů
- ▶ je to interval, který s požadovanou pravděpodobností překryje odhadovaný parametr – **intervalový odhad**

## interval spolehlivosti při neznámém $\sigma$

- ▶ když neznáme směr. odchylku  $\sigma$ , je třeba použít kritické hodnoty Studentova  $t$ -rozdělení (pozor na **jinak značené** kritické hodnoty Studentova  $t$ -rozdělení)

$$P\left(\bar{X} - \frac{S_x}{\sqrt{n}}t_{n-1}(\alpha) < \mu < \bar{X} + \frac{S_x}{\sqrt{n}}t_{n-1}(\alpha)\right) = 1 - \alpha$$

- ▶ jako odhad  $\sigma$  se použije **výběrová** směrodatná odchylka

$$S_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

- ▶ při velkých  $n$  ( $n \geq 50$ ) stačí použít  $z(\alpha/2)$  místo  $t_{n-1}(\alpha)$
- ▶ interval spolehlivosti se počítá i při odhadu jiných parametrů
- ▶ je to interval, který s požadovanou pravděpodobností překryje odhadovaný parametr – **intervalový odhad**



## interval spolehlivosti při neznámém $\sigma$

- ▶ když neznáme směr. odchylku  $\sigma$ , je třeba použít kritické hodnoty Studentova  $t$ -rozdělení (pozor na **jinak značené** kritické hodnoty Studentova  $t$ -rozdělení)

$$P\left(\bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha) < \mu < \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha)\right) = 1 - \alpha$$

- ▶ jako odhad  $\sigma$  se použije **výběrová** směrodatná odchylka

$$S_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

- ▶ při velkých  $n$  ( $n \geq 50$ ) stačí použít  $z(\alpha/2)$  místo  $t_{n-1}(\alpha)$
- ▶ interval spolehlivosti se počítá i při odhadu jiných parametrů
- ▶ je to interval, který s požadovanou pravděpodobností překryje odhadovaný parametr – **intervalový odhad**

## příklad: věk matek

normální rozdělení průměrů dáno CLT a velkým  $n$ ,  $t_{98}(0,05) = 1,98$

- ▶ 95% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek

$$\left( 25,7 - 1,98 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 1,98 \cdot \frac{4,1}{\sqrt{99}} \right) = (24,9; 26,5)$$

`[confint(lm(vek.m~1,data=Kojeni))], [t.test(Kojeni$vek.m)]`

- ▶ 99% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek (bude užší nebo širší?)
- ▶ větší jistota zajistí delší interval spolehlivosti (delší – méně vypovídající)

$$\left( 25,7 - 2,63 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 2,63 \cdot \frac{4,1}{\sqrt{99}} \right) = (24,6; 26,8)$$

`[confint(lm(vek.m~1,data=Kojeni),level=0.99)]`

## příklad: věk matek

normální rozdělení průměrů dáno CLT a velkým  $n$ ,  $t_{98}(0,05) = 1,98$

- ▶ 95% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek

$$\left( 25,7 - 1,98 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 1,98 \cdot \frac{4,1}{\sqrt{99}} \right) = (24,9; 26,5)$$

`[confint(lm(vek.m~1,data=Kojeni))], [t.test(Kojeni$vek.m)]`

- ▶ 99% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek (bude užší nebo širší?)
- ▶ větší jistota zajistí delší interval spolehlivosti (delší – méně vypovídající)

$$\left( 25,7 - 2,63 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 2,63 \cdot \frac{4,1}{\sqrt{99}} \right) = (24,6; 26,8)$$

`[confint(lm(vek.m~1,data=Kojeni),level=0.99)]`

## příklad: věk matek

normální rozdělení průměrů dáno CLT a velkým  $n$ ,  $t_{98}(0,05) = 1,98$

- ▶ 95% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek

$$\left( 25,7 - 1,98 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 1,98 \cdot \frac{4,1}{\sqrt{99}} \right) = (24,9; 26,5)$$

`[confint(lm(vek.m~1,data=Kojeni))]`, `[t.test(Kojeni$vek.m)]`

- ▶ 99% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek (bude užší nebo širší?)
- ▶ větší jistotu zajistí delší interval spolehlivosti (delší – méně vypovídající)

$$\left( 25,7 - 2,63 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 2,63 \cdot \frac{4,1}{\sqrt{99}} \right) = (24,6; 26,8)$$

`[confint(lm(vek.m~1,data=Kojeni),level=0.99)]`

## příklad: věk matek

normální rozdělení průměrů dáno CLT a velkým  $n$ ,  $t_{98}(0,10) = 1,66$

- ▶ 90% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek

$$\left( 25,7 - 1,66 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 1,66 \cdot \frac{4,1}{\sqrt{99}} \right) = (25,0; 26,4)$$

`[confint(lm(vek.m~1,data=Kojeni),level=0.9)]`

- ▶ příklady **nesprávné interpretace** 90% intervalu spolehlivosti:
  - ▶ *90 % žen má věk v intervalu (25,0; 26,4)*  
např. mezi našimi 99 matkami je jen 12 žen ve věku 25 a 10 ve věku 26 roků, navíc, s rostoucím  $n$  se interval zužuje
  - ▶ *výběrový průměr věku matek je s pravděpodobností 90 % v intervalu (25,0; 26,4)*  
výběrový průměr je uprostřed (tedy uvnitř) intervalu vždy

## příklad: věk matek

normální rozdělení průměrů dáno CLT a velkým  $n$ ,  $t_{98}(0,10) = 1,66$

- ▶ 90% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek

$$\left( 25,7 - 1,66 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 1,66 \cdot \frac{4,1}{\sqrt{99}} \right) = (25,0; 26,4)$$

`[confint(lm(vek.m~1,data=Kojeni),level=0.9)]`

- ▶ příklady **nesprávné interpretace** 90% intervalu spolehlivosti:
  - ▶ *90 % žen má věk v intervalu (25,0; 26,4)*  
např. mezi našimi 99 matkami je jen 12 žen ve věku 25 a 10 ve věku 26 roků, navíc, s rostoucím  $n$  se interval zužuje
  - ▶ *výběrový průměr věku matek je s pravděpodobností 90 % v intervalu (25,0; 26,4)*  
výběrový průměr je uprostřed (tedy uvnitř) intervalu **vždy**

## příklad: věk matek

normální rozdělení průměrů dáno CLT a velkým  $n$ ,  $t_{98}(0,10) = 1,66$

- ▶ 90% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek

$$\left( 25,7 - 1,66 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 1,66 \cdot \frac{4,1}{\sqrt{99}} \right) = (25,0; 26,4)$$

[confint(lm(vek.m~1,data=Kojeni),level=0.9)]

- ▶ příklady **nesprávné interpretace** 90% intervalu spolehlivosti:
  - ▶ 90 % žen má věk v intervalu (25,0; 26,4)  
např. mezi našimi 99 matkami je jen 12 žen ve věku 25 a 10 ve věku 26 roků, navíc, s rostoucím  $n$  se interval zužuje
  - ▶ výběrový průměr věku matek je s pravděpodobností 90 % v intervalu (25,0; 26,4)  
výběrový průměr je uprostřed (tedy uvnitř) intervalu **vždy**

## příklad: věk matek

normální rozdělení průměrů dáno CLT a velkým  $n$ ,  $t_{98}(0,10) = 1,66$


- ▶ 90% interval spolehlivosti pro populační průměr věku *všech* matek na základě výběru 99 matek

$$\left( 25,7 - 1,66 \cdot \frac{4,1}{\sqrt{99}}; 25,7 + 1,66 \cdot \frac{4,1}{\sqrt{99}} \right) = (25,0; 26,4)$$

[confint(lm(vek.m~1,data=Kojeni),level=0.9)]

- ▶ příklady **nesprávné interpretace** 90% intervalu spolehlivosti:
  - ▶ 90 % žen má věk v intervalu (25,0; 26,4)  
např. mezi našimi 99 matkami je jen 12 žen ve věku 25 a 10 ve věku 26 roků, navíc, s rostoucím  $n$  se interval zužuje
  - ▶ výběrový průměr věku matek je s pravděpodobností 90 % v intervalu (25,0; 26,4)  
výběrový průměr je uprostřed (tedy uvnitř) intervalu **vždy**



simulované výběry pro  $n = 100$  (věk matek)

znázorněno celkem 100 95% intervalů spolehlivosti pro  $\mu$   
 ve skutečnosti mimořádně víme, že  $\mu = 25,4$   
 v 7 případech je  $\mu$  nepřekryto  
 (7 je realizace náhodné veličiny s rozdělením  $bi(100, 0,05)$ )

## centrální limitní věta pro četnosti

- ▶ (CLT obecně:) Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$ . Potom pro velké  $n$  má průměr z nich přibl. rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , jejich součet přibl. rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶  $Y \sim \text{bi}(n, \pi)$ :  $Y$  je absolutní četnost výskytu jevu s pravděpodobností výskytu  $\pi$  v  $n$  nezávislých pokusech
- ▶  $Y = \sum_{i=1}^n X_i$  je součet nezávislých náhodných veličin  $X_i$  s alternativním rozdělením,  $X_i \sim \text{alt}(\pi)$ ,  $\text{var } X_i = \pi(1 - \pi)$
- ▶ podle CLT proto přibližně  $Y \sim N(n\pi, n\pi(1 - \pi))$
- ▶ relativní četnost  $Y/n = \bar{X}$  je průměr veličin s alternativním rozdělením, označme  $\hat{\pi} = Y/n$
- ▶ podle CLT je přibližně  $\hat{\pi} \sim N(\pi, \pi(1 - \pi)/n)$
- ▶  $\hat{\pi}$  je **nestranný** odhad  $\pi$

## centrální limitní věta pro četnosti

- ▶ (CLT obecně:) Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$ . Potom pro velké  $n$  má průměr z nich přibl. rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , jejich součet přibl. rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶  $Y \sim \text{bi}(n, \pi)$ :  $Y$  je absolutní četnost výskytu jevu s pravděpodobností výskytu  $\pi$  v  $n$  nezávislých pokusech
- ▶  $Y = \sum_{i=1}^n X_i$  je součet nezávislých náhodných veličin  $X_i$  s alternativním rozdělením,  $X_i \sim \text{alt}(\pi)$ ,  $\text{var } X_i = \pi(1 - \pi)$
- ▶ podle CLT proto přibližně  $Y \sim N(n\pi, n\pi(1 - \pi))$
- ▶ relativní četnost  $Y/n = \bar{X}$  je průměr veličin s alternativním rozdělením, označme  $\hat{\pi} = Y/n$
- ▶ podle CLT je přibližně  $\hat{\pi} \sim N(\pi, \pi(1 - \pi)/n)$
- ▶  $\hat{\pi}$  je **nestranný** odhad  $\pi$

## centrální limitní věta pro četnosti

- ▶ (CLT obecně:) Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$ . Potom pro velké  $n$  má průměr z nich přibl. rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , jejich součet přibl. rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶  $Y \sim \text{bi}(n, \pi)$ :  $Y$  je absolutní četnost výskytu jevu s pravděpodobností výskytu  $\pi$  v  $n$  nezávislých pokusech
- ▶  $Y = \sum_{i=1}^n X_i$  je součet nezávislých náhodných veličin  $X_i$  s alternativním rozdělením,  $X_i \sim \text{alt}(\pi)$ ,  $\text{var } X_i = \pi(1 - \pi)$ 
  - ▶ podle CLT proto přibližně  $Y \sim N(n\pi, n\pi(1 - \pi))$
  - ▶ relativní četnost  $Y/n = \bar{X}$  je průměr veličin s alternativním rozdělením, označme  $\hat{\pi} = Y/n$
  - ▶ podle CLT je přibližně  $\hat{\pi} \sim N(\pi, \pi(1 - \pi)/n)$
  - ▶  $\hat{\pi}$  je **nestranný** odhad  $\pi$

## centrální limitní věta pro četnosti

- ▶ (CLT obecně:) Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$ . Potom pro velké  $n$  má průměr z nich přibl. rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , jejich součet přibl. rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶  $Y \sim \text{bi}(n, \pi)$ :  $Y$  je absolutní četnost výskytu jevu s pravděpodobností výskytu  $\pi$  v  $n$  nezávislých pokusech
- ▶  $Y = \sum_{i=1}^n X_i$  je součet nezávislých náhodných veličin  $X_i$  s alternativním rozdělením,  $X_i \sim \text{alt}(\pi)$ ,  $\text{var } X_i = \pi(1 - \pi)$
- ▶ podle CLT proto přibližně  $Y \sim N(n\pi, n\pi(1 - \pi))$
- ▶ relativní četnost  $Y/n = \bar{X}$  je průměr veličin s alternativním rozdělením, označme  $\hat{\pi} = Y/n$
- ▶ podle CLT je přibližně  $\hat{\pi} \sim N(\pi, \pi(1 - \pi)/n)$
- ▶  $\hat{\pi}$  je **nestranný** odhad  $\pi$

## centrální limitní věta pro četnosti

- ▶ (CLT obecně:) Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$ . Potom pro velké  $n$  má průměr z nich přibl. rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , jejich součet přibl. rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶  $Y \sim \text{bi}(n, \pi)$ :  $Y$  je absolutní četnost výskytu jevu s pravděpodobností výskytu  $\pi$  v  $n$  nezávislých pokusech
- ▶  $Y = \sum_{i=1}^n X_i$  je součet nezávislých náhodných veličin  $X_i$  s alternativním rozdělením,  $X_i \sim \text{alt}(\pi)$ ,  $\text{var } X_i = \pi(1 - \pi)$
- ▶ podle CLT proto přibližně  $Y \sim N(n\pi, n\pi(1 - \pi))$
- ▶ relativní četnost  $Y/n = \bar{X}$  je průměr veličin s alternativním rozdělením, označme  $\hat{\pi} = Y/n$
- ▶ podle CLT je přibližně  $\hat{\pi} \sim N(\pi, \pi(1 - \pi)/n)$
- ▶  $\hat{\pi}$  je **nestranný** odhad  $\pi$

## centrální limitní věta pro četnosti

- ▶ (CLT obecně:) Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$ . Potom pro velké  $n$  má průměr z nich přibl. rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , jejich součet přibl. rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶  $Y \sim \text{bi}(n, \pi)$ :  $Y$  je absolutní četnost výskytu jevu s pravděpodobností výskytu  $\pi$  v  $n$  nezávislých pokusech
- ▶  $Y = \sum_{i=1}^n X_i$  je součet nezávislých náhodných veličin  $X_i$  s alternativním rozdělením,  $X_i \sim \text{alt}(\pi)$ ,  $\text{var } X_i = \pi(1 - \pi)$
- ▶ podle CLT proto přibližně  $Y \sim N(n\pi, n\pi(1 - \pi))$
- ▶ relativní četnost  $Y/n = \bar{X}$  je průměr veličin s alternativním rozdělením, označme  $\hat{\pi} = Y/n$
- ▶ podle CLT je přibližně  $\hat{\pi} \sim N(\pi, \pi(1 - \pi)/n)$
- ▶  $\hat{\pi}$  je **nestranný** odhad  $\pi$

## centrální limitní věta pro četnosti

- ▶ (CLT obecně:) Necht'  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$ . Potom pro velké  $n$  má průměr z nich přibl. rozdělení  $N\left(\mu, \frac{\sigma^2}{n}\right)$ , jejich součet přibl. rozdělení  $N(n\mu, n\sigma^2)$ .
- ▶  $Y \sim \text{bi}(n, \pi)$ :  $Y$  je absolutní četnost výskytu jevu s pravděpodobností výskytu  $\pi$  v  $n$  nezávislých pokusech
- ▶  $Y = \sum_{i=1}^n X_i$  je součet nezávislých náhodných veličin  $X_i$  s alternativním rozdělením,  $X_i \sim \text{alt}(\pi)$ ,  $\text{var } X_i = \pi(1 - \pi)$
- ▶ podle CLT proto přibližně  $Y \sim N(n\pi, n\pi(1 - \pi))$
- ▶ relativní četnost  $Y/n = \bar{X}$  je průměr veličin s alternativním rozdělením, označme  $\hat{\pi} = Y/n$
- ▶ podle CLT je přibližně  $\hat{\pi} \sim N(\pi, \pi(1 - \pi)/n)$
- ▶  $\hat{\pi}$  je **nestranný** odhad  $\pi$



interval spolehlivosti pro pravděpodobnost  $\pi$ 

- ▶ odmocnina z rozptylu odhadu  $\hat{\pi}$  je  $\sqrt{\frac{\pi(1-\pi)}{n}}$
- ▶ střední chyba relativní četnosti = směrodatná odchylka relativní četnosti
- ▶ pravděpodobnost  $\pi$  neznáme, odhadneme ji pomocí relativní četnosti  $\hat{\pi} = Y/n$
- ▶ odtud je  $100(1 - \alpha)\%$  přibližný interval spolehlivosti pro  $\pi$

$$\left( \hat{\pi} - z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}}; \hat{\pi} + z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}} \right)$$

[prop.test(y,n,correct=FALSE)]

- ▶ existují přesnější (pracnější) postupy  
[binom.test(y,n)]

interval spolehlivosti pro pravděpodobnost  $\pi$ 

- ▶ odmocnina z rozptylu odhadu  $\hat{\pi}$  je  $\sqrt{\frac{\pi(1-\pi)}{n}}$
- ▶ střední chyba relativní četnosti = směrodatná odchylka relativní četnosti
- ▶ pravděpodobnost  $\pi$  neznáme, odhadneme ji pomocí relativní četnosti  $\hat{\pi} = Y/n$
- ▶ odtud je  $100(1 - \alpha)\%$  přibližný interval spolehlivosti pro  $\pi$

$$\left( \hat{\pi} - z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}}; \hat{\pi} + z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}} \right)$$

[prop.test(y,n,correct=FALSE)]

- ▶ existují přesnější (pracnější) postupy  
[binom.test(y,n)]

interval spolehlivosti pro pravděpodobnost  $\pi$ 

- ▶ odmocnina z rozptylu odhadu  $\hat{\pi}$  je  $\sqrt{\frac{\pi(1-\pi)}{n}}$
- ▶ střední chyba relativní četnosti = směrodatná odchylka relativní četnosti
- ▶ pravděpodobnost  $\pi$  neznáme, odhadneme ji pomocí relativní četnosti  $\hat{\pi} = Y/n$
- ▶ odtud je  $100(1 - \alpha)\%$  přibližný interval spolehlivosti pro  $\pi$

$$\left( \hat{\pi} - z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}}; \hat{\pi} + z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}} \right)$$

[prop.test(y,n,correct=FALSE)]

- ▶ existují přesnější (pracnější) postupy  
[binom.test(y,n)]

interval spolehlivosti pro pravděpodobnost  $\pi$ 

- ▶ odmocnina z rozptylu odhadu  $\hat{\pi}$  je  $\sqrt{\frac{\pi(1-\pi)}{n}}$
- ▶ střední chyba relativní četnosti = směrodatná odchylka relativní četnosti
- ▶ pravděpodobnost  $\pi$  neznáme, odhadneme ji pomocí relativní četnosti  $\hat{\pi} = Y/n$
- ▶ odtud je  $100(1 - \alpha)\%$  přibližný interval spolehlivosti pro  $\pi$

$$\left( \hat{\pi} - z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}}; \hat{\pi} + z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}} \right)$$

[prop.test(y,n,correct=FALSE)]

- ▶ existují přesnější (pracnější) postupy  
[binom.test(y,n)]

interval spolehlivosti pro pravděpodobnost  $\pi$ 

- ▶ odmocnina z rozptylu odhadu  $\hat{\pi}$  je  $\sqrt{\frac{\pi(1-\pi)}{n}}$
- ▶ střední chyba relativní četnosti = směrodatná odchylka relativní četnosti
- ▶ pravděpodobnost  $\pi$  neznáme, odhadneme ji pomocí relativní četnosti  $\hat{\pi} = Y/n$
- ▶ odtud je  $100(1 - \alpha)\%$  přibližný interval spolehlivosti pro  $\pi$

$$\left( \hat{\pi} - z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}}; \hat{\pi} + z(\alpha/2) \cdot \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}} \right)$$

[prop.test(y,n,correct=FALSE)]

- ▶ existují přesnější (pracnější) postupy  
[binom.test(y,n)]

## příklad: hody s hrací kostkou

- ▶ odhadujeme pravděpodobnost šestky,  $\alpha = 0,05$
- ▶ kostka A:  $n = 100, y = 17, \hat{\pi}_A = 0,17$

$$\left( 0,17 - 1,96 \cdot \sqrt{\frac{0,17 \cdot 0,83}{100}}; 0,17 + 1,96 \cdot \sqrt{\frac{0,17 \cdot 0,83}{100}} \right) = (0,10; 0,24)$$

- ▶ kostka B:  $n = 100, y = 41, \hat{\pi}_B = 0,41$

$$\left( 0,41 - 1,96 \cdot \sqrt{\frac{0,41 \cdot 0,59}{100}}; 0,41 + 1,96 \cdot \sqrt{\frac{0,41 \cdot 0,59}{100}} \right) = (0,31; 0,51)$$

- ▶ důležitý rozdíl: u kostky A patří  $1/6 = 0,167$  do 95% intervalu spolehlivosti; u kostky B nikoliv

## příklad: hody s hrací kostkou

- ▶ odhadujeme pravděpodobnost šestky,  $\alpha = 0,05$
- ▶ kostka A:  $n = 100, y = 17, \hat{\pi}_A = 0,17$

$$\left( 0,17 - 1,96 \cdot \sqrt{\frac{0,17 \cdot 0,83}{100}}; 0,17 + 1,96 \cdot \sqrt{\frac{0,17 \cdot 0,83}{100}} \right) = (0,10; 0,24)$$

- ▶ kostka B:  $n = 100, y = 41, \hat{\pi}_B = 0,41$

$$\left( 0,41 - 1,96 \cdot \sqrt{\frac{0,41 \cdot 0,59}{100}}; 0,41 + 1,96 \cdot \sqrt{\frac{0,41 \cdot 0,59}{100}} \right) = (0,31; 0,51)$$

- ▶ důležitý rozdíl: u kostky A patří  $1/6 = 0,167$  do 95% intervalu spolehlivosti; u kostky B nikoliv

## příklad: hody s hrací kostkou

- ▶ odhadujeme pravděpodobnost šestky,  $\alpha = 0,05$
- ▶ kostka A:  $n = 100, y = 17, \hat{\pi}_A = 0,17$

$$\left( 0,17 - 1,96 \cdot \sqrt{\frac{0,17 \cdot 0,83}{100}}; 0,17 + 1,96 \cdot \sqrt{\frac{0,17 \cdot 0,83}{100}} \right) = (0,10; 0,24)$$

- ▶ kostka B:  $n = 100, y = 41, \hat{\pi}_B = 0,41$

$$\left( 0,41 - 1,96 \cdot \sqrt{\frac{0,41 \cdot 0,59}{100}}; 0,41 + 1,96 \cdot \sqrt{\frac{0,41 \cdot 0,59}{100}} \right) = (0,31; 0,51)$$

- ▶ důležitý rozdíl: u kostky A patří  $1/6 = 0,167$  do 95% intervalu spolehlivosti; u kostky B nikoliv



## příklad: hody s hrací kostkou

- ▶ odhadujeme pravděpodobnost šestky,  $\alpha = 0,05$
- ▶ kostka A:  $n = 100, y = 17, \hat{\pi}_A = 0,17$

$$\left( 0,17 - 1,96 \cdot \sqrt{\frac{0,17 \cdot 0,83}{100}}; 0,17 + 1,96 \cdot \sqrt{\frac{0,17 \cdot 0,83}{100}} \right) = (0,10; 0,24)$$

- ▶ kostka B:  $n = 100, y = 41, \hat{\pi}_B = 0,41$

$$\left( 0,41 - 1,96 \cdot \sqrt{\frac{0,41 \cdot 0,59}{100}}; 0,41 + 1,96 \cdot \sqrt{\frac{0,41 \cdot 0,59}{100}} \right) = (0,31; 0,51)$$

- ▶ důležitý rozdíl: u kostky A patří  $1/6 = 0,167$  do 95% intervalu spolehlivosti; u kostky B nikoliv

# populace a výběr

[population, (random) sample, representative, parameter, statistics, estimator]

- ▶ **populace (základní soubor)**: soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  $\Rightarrow$  rozdělení náhodné veličiny
- ▶ **výběr**: náhodně vybraná vyšetřovaná část populace (vzorek)
- ▶ **reprezentativní výběr** obráží poměry v populaci (nutná vlastnost výběru, aby mohl vypovídat o populaci)
- ▶ **náhodný výběr**: nezávislé náhodné veličiny se stejným rozdělením (model pro měření na výběru)
- ▶ **parametr**: (neznámé) číslo popisující nějakou **vlastnost populace**, charakteristika rozdělení náhodné veličiny
- ▶ **statistika**: funkce náhodného výběru (pozorování)
- ▶ **odhad**: statistika použitá k odhadu parametru

# populace a výběr

[population, (random) sample, representative, parameter, statistics, estimator]

- ▶ **populace (základní soubor)**: soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  $\Rightarrow$  rozdělení náhodné veličiny
- ▶ **výběr**: náhodně vybraná vyšetřovaná část populace (vzorek)
- ▶ **reprezentativní výběr** obráží poměry v populaci (nutná vlastnost výběru, aby mohl vypovídat o populaci)
- ▶ **náhodný výběr**: nezávislé náhodné veličiny se stejným rozdělením (model pro měření na výběru)
- ▶ **parametr**: (neznámé) číslo popisující nějakou **vlastnost populace**, charakteristika rozdělení náhodné veličiny
- ▶ **statistika**: funkce náhodného výběru (pozorování)
- ▶ **odhad**: statistika použitá k odhadu parametru

# populace a výběr

[population, (random) sample, representative, parameter, statistics, estimator]

- ▶ **populace (základní soubor)**: soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  $\Rightarrow$  rozdělení náhodné veličiny
- ▶ **výběr**: náhodně vybraná vyšetřovaná část populace (vzorek)
- ▶ **reprezentativní výběr** odráží poměry v populaci (nutná vlastnost výběru, aby mohl vypovídat o populaci)
- ▶ **náhodný výběr**: nezávislé náhodné veličiny se stejným rozdělením (model pro měření na výběru)
- ▶ **parametr**: (neznámé) číslo popisující nějakou **vlastnost populace**, charakteristika rozdělení náhodné veličiny
- ▶ **statistika**: funkce náhodného výběru (pozorování)
- ▶ **odhad**: statistika použitá k odhadu parametru

# populace a výběr

[population, (random) sample, representative, parameter, statistics, estimator]

- ▶ **populace (základní soubor)**: soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  $\Rightarrow$  rozdělení náhodné veličiny
- ▶ **výběr**: náhodně vybraná vyšetřovaná část populace (vzorek)
- ▶ **reprezentativní výběr** obráží poměry v populaci (nutná vlastnost výběru, aby mohl vypovídat o populaci)
- ▶ **náhodný výběr**: nezávislé náhodné veličiny se stejným rozdělením (model pro měření na výběru)
- ▶ **parametr**: (neznámé) číslo popisující nějakou **vlastnost populace**, charakteristika rozdělení náhodné veličiny
- ▶ **statistika**: funkce náhodného výběru (pozorování)
- ▶ **odhad**: statistika použitá k odhadu parametru

# populace a výběr

[population, (random) sample, representative, parameter, statistics, estimator]

- ▶ **populace (základní soubor)**: soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  $\Rightarrow$  rozdělení náhodné veličiny
- ▶ **výběr**: náhodně vybraná vyšetřovaná část populace (vzorek)
- ▶ **reprezentativní výběr** odráží poměry v populaci (nutná vlastnost výběru, aby mohl vypovídat o populaci)
- ▶ **náhodný výběr**: nezávislé náhodné veličiny se stejným rozdělením (model pro měření na výběru)
- ▶ **parametr**: (neznámé) číslo popisující nějakou **vlastnost populace**, charakteristika rozdělení náhodné veličiny
- ▶ **statistika**: funkce náhodného výběru (pozorování)
- ▶ **odhad**: statistika použitá k odhadu parametru

# populace a výběr

[population, (random) sample, representative, parameter, statistics, estimator]

- ▶ **populace (základní soubor)**: soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  $\Rightarrow$  rozdělení náhodné veličiny
- ▶ **výběr**: náhodně vybraná vyšetřovaná část populace (vzorek)
- ▶ **reprezentativní výběr** odráží poměry v populaci (nutná vlastnost výběru, aby mohl vypovídat o populaci)
- ▶ **náhodný výběr**: nezávislé náhodné veličiny se stejným rozdělením (model pro měření na výběru)
- ▶ **parametr**: (neznámé) číslo popisující nějakou **vlastnost populace**, charakteristika rozdělení náhodné veličiny
- ▶ **statistika**: funkce náhodného výběru (pozorování)
- ▶ **odhad**: statistika použitá k odhadu parametru

# populace a výběr

[population, (random) sample, representative, parameter, statistics, estimator]

- ▶ **populace (základní soubor)**: soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  $\Rightarrow$  rozdělení náhodné veličiny
- ▶ **výběr**: náhodně vybraná vyšetřovaná část populace (vzorek)
- ▶ **reprezentativní výběr** odráží poměry v populaci (nutná vlastnost výběru, aby mohl vypovídat o populaci)
- ▶ **náhodný výběr**: nezávislé náhodné veličiny se stejným rozdělením (model pro měření na výběru)
- ▶ **parametr**: (neznámé) číslo popisující nějakou **vlastnost populace**, charakteristika rozdělení náhodné veličiny
- ▶ **statistika**: funkce náhodného výběru (pozorování)
- ▶ **odhad**: statistika použitá k odhadu parametru



# Jsou desetiletí hoši stejně vysokí jako desetileté dívky?

(odpovíme až příště!)

- ▶ Jak porovnat různě vysoké chlapce s různě vysokými dívkami?
- ▶ potřebujeme nějaké číslo charakterizující výšky **všech** chlapců a podobné číslo pro dívky: **populační průměry**
- ▶ budeme rozhodovat o porovnání **populačního** průměr výšek chlapců s **populačním** průměrem výšek dívek
- ▶  $X_1, \dots, X_n$  jsou výšky **náhodně vybraných** chlapců; předem je neznáme  $\Rightarrow$  v úvahách jsou to **náhodné veličiny**
- ▶ hodnoty  $X_1, \dots, X_n$  kolísají kolem střední hodnoty  $E X_i = \mu_X$  (populační průměr)
- ▶ velikost kolísání popisuje rozptyl  $\sigma^2$
- ▶ (bodovým) odhadem populačního průměru bude výběrový průměr  $\bar{X}$  spočítaný z  $n$  skutečně zjištěných výšek
- ▶ Jaké vlastnosti má průměr  $\bar{X}$ ?

# Jsou desetiletí hoši stejně vysokí jako desetileté dívky?

(odpovíme až příště!)

- ▶ Jak porovnat různě vysoké chlapce s různě vysokými dívkami?
- ▶ potřebujeme nějaké číslo charakterizující výšky **všech** chlapců a podobné číslo pro dívky: **populační průměry**
- ▶ budeme rozhodovat o porovnání **populačního** průměr výšek chlapců s **populačním** průměrem výšek dívek
- ▶  $X_1, \dots, X_n$  jsou výšky **náhodně vybraných** chlapců; předem je neznáme  $\Rightarrow$  v úvahách jsou to **náhodné veličiny**
- ▶ hodnoty  $X_1, \dots, X_n$  kolísají kolem střední hodnoty  $E X_i = \mu_X$  (populační průměr)
- ▶ velikost kolísání popisuje rozptyl  $\sigma^2$
- ▶ (bodovým) odhadem populačního průměru bude výběrový průměr  $\bar{X}$  spočítaný z  $n$  skutečně zjištěných výšek
- ▶ Jaké vlastnosti má průměr  $\bar{X}$ ?

# Jsou desetiletí hoši stejně vysokí jako desetileté dívky?

(odpovíme až příště!)

- ▶ Jak porovnat různě vysoké chlapce s různě vysokými dívkami?
- ▶ potřebujeme nějaké číslo charakterizující výšky **všech** chlapců a podobné číslo pro dívky: **populační průměry**
- ▶ budeme rozhodovat o porovnání **populačního** průměr výšek chlapců s **populačním** průměrem výšek dívek
- ▶  $X_1, \dots, X_n$  jsou výšky **náhodně vybraných** chlapců; předem je neznáme  $\Rightarrow$  v úvahách jsou to **náhodné veličiny**
- ▶ hodnoty  $X_1, \dots, X_n$  kolísají kolem střední hodnoty  $E X_i = \mu_X$  (populační průměr)
- ▶ velikost kolísání popisuje rozptyl  $\sigma^2$
- ▶ (bodovým) odhadem populačního průměru bude výběrový průměr  $\bar{X}$  spočítaný z  $n$  skutečně zjištěných výšek
- ▶ Jaké vlastnosti má průměr  $\bar{X}$ ?

## Jsou desetiletí hoši stejně vysokí jako desetileté dívky?

(odpovíme až příště!)

- ▶ Jak porovnat různě vysoké chlapce s různě vysokými dívkami?
- ▶ potřebujeme nějaké číslo charakterizující výšky **všech** chlapců a podobné číslo pro dívky: **populační průměry**
- ▶ budeme rozhodovat o porovnání **populačního** průměr výšek chlapců s **populačním** průměrem výšek dívek
- ▶  $X_1, \dots, X_n$  jsou výšky **náhodně vybraných** chlapců; předem je neznáme  $\Rightarrow$  v úvahách jsou to **náhodné veličiny**
- ▶ hodnoty  $X_1, \dots, X_n$  kolísají kolem střední hodnoty  $E X_i = \mu_X$  (populační průměr)
- ▶ velikost kolísání popisuje rozptyl  $\sigma^2$
- ▶ (bodovým) odhadem populačního průměru bude výběrový průměr  $\bar{X}$  spočítaný z  $n$  skutečně zjištěných výšek
- ▶ Jaké vlastnosti má průměr  $\bar{X}$ ?

# Jsou desetiletí hoši stejně vysokí jako desetileté dívky?

(odpovíme až příště!)

- ▶ Jak porovnat různě vysoké chlapce s různě vysokými dívkami?
- ▶ potřebujeme nějaké číslo charakterizující výšky **všech** chlapců a podobné číslo pro dívky: **populační průměry**
- ▶ budeme rozhodovat o porovnání **populačního** průměr výšek chlapců s **populačním** průměrem výšek dívek
- ▶  $X_1, \dots, X_n$  jsou výšky **náhodně vybraných** chlapců; předem je neznáme  $\Rightarrow$  v úvahách jsou to **náhodné veličiny**
- ▶ hodnoty  $X_1, \dots, X_n$  kolísají kolem střední hodnoty  $E X_i = \mu_X$  (populační průměr)
- ▶ velikost kolísání popisuje rozptyl  $\sigma^2$
- ▶ (bodovým) odhadem populačního průměru bude výběrový průměr  $\bar{X}$  spočítaný z  $n$  skutečně zjištěných výšek
- ▶ Jaké vlastnosti má průměr  $\bar{X}$ ?

# Jsou desetiletí hoši stejně vysokí jako desetileté dívky?

(odpovíme až příště!)

- ▶ Jak porovnat různě vysoké chlapce s různě vysokými dívkami?
- ▶ potřebujeme nějaké číslo charakterizující výšky **všech** chlapců a podobné číslo pro dívky: **populační průměry**
- ▶ budeme rozhodovat o porovnání **populačního** průměr výšek chlapců s **populačním** průměrem výšek dívek
- ▶  $X_1, \dots, X_n$  jsou výšky **náhodně vybraných** chlapců; předem je neznáme  $\Rightarrow$  v úvahách jsou to **náhodné veličiny**
- ▶ hodnoty  $X_1, \dots, X_n$  kolísají kolem střední hodnoty  $E X_i = \mu_X$  (populační průměr)
- ▶ velikost kolísání popisuje rozptyl  $\sigma^2$
- ▶ (bodovým) odhadem populačního průměru bude výběrový průměr  $\bar{X}$  spočítaný z  $n$  skutečně zjištěných výšek
- ▶ Jaké vlastnosti má průměr  $\bar{X}$ ?

## Jsou desetiletí hoši stejně vysokí jako desetileté dívky?

(odpovíme až příště!)

- ▶ Jak porovnat různě vysoké chlapce s různě vysokými dívkami?
- ▶ potřebujeme nějaké číslo charakterizující výšky **všech** chlapců a podobné číslo pro dívky: **populační průměry**
- ▶ budeme rozhodovat o porovnání **populačního** průměr výšek chlapců s **populačním** průměrem výšek dívek
- ▶  $X_1, \dots, X_n$  jsou výšky **náhodně vybraných** chlapců; předem je neznáme  $\Rightarrow$  v úvahách jsou to **náhodné veličiny**
- ▶ hodnoty  $X_1, \dots, X_n$  kolísají kolem střední hodnoty  $E X_i = \mu_X$  (populační průměr)
- ▶ velikost kolísání popisuje rozptyl  $\sigma^2$
- ▶ (bodovým) odhadem populačního průměru bude výběrový průměr  $\bar{X}$  spočítaný z  $n$  skutečně zjištěných výšek
- ▶ Jaké vlastnosti má průměr  $\bar{X}$ ?

## Jsou desetiletí hoši stejně vysokí jako desetileté dívky?

(odpovíme až příště!)

- ▶ Jak porovnat různě vysoké chlapce s různě vysokými dívkami?
- ▶ potřebujeme nějaké číslo charakterizující výšky **všech** chlapců a podobné číslo pro dívky: **populační průměry**
- ▶ budeme rozhodovat o porovnání **populačního** průměr výšek chlapců s **populačním** průměrem výšek dívek
- ▶  $X_1, \dots, X_n$  jsou výšky **náhodně vybraných** chlapců; předem je neznáme  $\Rightarrow$  v úvahách jsou to **náhodné veličiny**
- ▶ hodnoty  $X_1, \dots, X_n$  kolísají kolem střední hodnoty  $E X_i = \mu_X$  (populační průměr)
- ▶ velikost kolísání popisuje rozptyl  $\sigma^2$
- ▶ (bodovým) odhadem populačního průměru bude výběrový průměr  $\bar{X}$  spočítaný z  $n$  skutečně zjištěných výšek
- ▶ Jaké vlastnosti má průměr  $\bar{X}$ ?



## příklad: výška desetiletých chlapců

- ▶ v roce 1951 bylo provedeno rozsáhlé měření výšky desetiletých hochů, výška byla vyšetřena v populaci desetiletých chlapců:  
 $\mu = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ na základě výběru pořízeného v roce 1961 máme rozhodnout, zda se po deseti letech výška populace desetiletých **zvýšila**
- ▶ hodnoty zjištěné v roce 1961 [cm]: 130, 140, 136, 141, 139, 133, 149, 151, 139, 136, 138, 142, 127, 139, 147
- ▶  $\bar{x} = 139,13$  cm,  $s^2 = 6,56^2$  cm<sup>2</sup>
- ▶ jiný (další) výběr z roku 1961 by obsahoval jiných 15 hochů, tedy by vedl k jinému výběrovému průměru (náhodná veličina)
- ▶ stačí rozdíl  $139,13 - 136,1 = 3,03$  (náhodná veličina, proč?), abychom prokázali, že se **populační průměr** výšek desetiletých chlapců po deseti letech změnil?

## příklad: výška desetiletých chlapců

- ▶ v roce 1951 bylo provedeno rozsáhlé měření výšky desetiletých hochů, výška byla vyšetřena v populaci desetiletých chlapců:  
 $\mu = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ na základě výběru pořízeného v roce 1961 máme rozhodnout, zda se po deseti letech výška populace desetiletých **zvýšila**
- ▶ hodnoty zjištěné v roce 1961 [cm]: 130, 140, 136, 141, 139, 133, 149, 151, 139, 136, 138, 142, 127, 139, 147
- ▶  $\bar{x} = 139,13$  cm,  $s^2 = 6,56^2$  cm<sup>2</sup>
- ▶ jiný (další) výběr z roku 1961 by obsahoval jiných 15 hochů, tedy by vedl k jinému výběrovému průměru (náhodná veličina)
- ▶ stačí rozdíl  $139,13 - 136,1 = 3,03$  (náhodná veličina, proč?), abychom prokázali, že se **populační průměr** výšek desetiletých chlapců po deseti letech změnil?

## příklad: výška desetiletých chlapců

- ▶ v roce 1951 bylo provedeno rozsáhlé měření výšky desetiletých hochů, výška byla vyšetřena v populaci desetiletých chlapců:  
 $\mu = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ na základě výběru pořízeného v roce 1961 máme rozhodnout, zda se po deseti letech výška populace desetiletých **zvýšila**
- ▶ hodnoty zjištěné v roce 1961 [cm]: 130, 140, 136, 141, 139, 133, 149, 151, 139, 136, 138, 142, 127, 139, 147
- ▶  $\bar{x} = 139,13$  cm,  $s^2 = 6,56^2$  cm<sup>2</sup>
- ▶ jiný (další) výběr z roku 1961 by obsahoval jiných 15 hochů, tedy by vedl k jinému výběrovému průměru (náhodná veličina)
- ▶ stačí rozdíl  $139,13 - 136,1 = 3,03$  (náhodná veličina, proč?), abychom prokázali, že se **populační průměr** výšek desetiletých chlapců po deseti letech změnil?

## příklad: výška desetiletých chlapců

- ▶ v roce 1951 bylo provedeno rozsáhlé měření výšky desetiletých hochů, výška byla vyšetřena v populaci desetiletých chlapců:  
 $\mu = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ na základě výběru pořízeného v roce 1961 máme rozhodnout, zda se po deseti letech výška populace desetiletých **zvýšila**
- ▶ hodnoty zjištěné v roce 1961 [cm]: 130, 140, 136, 141, 139, 133, 149, 151, 139, 136, 138, 142, 127, 139, 147
- ▶  $\bar{x} = 139,13$  cm,  $s^2 = 6,56^2$  cm<sup>2</sup>
- ▶ jiný (další) výběr z roku 1961 by obsahoval jiných 15 hochů, tedy by vedl k jinému výběrovému průměru (náhodná veličina)
- ▶ stačí rozdíl  $139,13 - 136,1 = 3,03$  (náhodná veličina, proč?), abychom prokázali, že se **populační průměr** výšek desetiletých chlapců po deseti letech změnil?

## příklad: výška desetiletých chlapců

- ▶ v roce 1951 bylo provedeno rozsáhlé měření výšky desetiletých hochů, výška byla vyšetřena v populaci desetiletých chlapců:  
 $\mu = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ na základě výběru pořízeného v roce 1961 máme rozhodnout, zda se po deseti letech výška populace desetiletých **zvýšila**
- ▶ hodnoty zjištěné v roce 1961 [cm]: 130, 140, 136, 141, 139, 133, 149, 151, 139, 136, 138, 142, 127, 139, 147
- ▶  $\bar{x} = 139,13$  cm,  $s^2 = 6,56^2$  cm<sup>2</sup>
- ▶ jiný (další) výběr z roku 1961 by obsahoval jiných 15 hochů, tedy by vedl k jinému výběrovému průměru (náhodná veličina)
- ▶ stačí rozdíl  $139,13 - 136,1 = 3,03$  (náhodná veličina, proč?), abychom prokázali, že se **populační průměr** výšek desetiletých chlapců po deseti letech změnil?

## příklad: výška desetiletých chlapců

- ▶ v roce 1951 bylo provedeno rozsáhlé měření výšky desetiletých hochů, výška byla vyšetřena v populaci desetiletých chlapců:  $\mu = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ na základě výběru pořízeného v roce 1961 máme rozhodnout, zda se po deseti letech výška populace desetiletých **zvýšila**
- ▶ hodnoty zjištěné v roce 1961 [cm]: 130, 140, 136, 141, 139, 133, 149, 151, 139, 136, 138, 142, 127, 139, 147
- ▶  $\bar{x} = 139,13$  cm,  $s^2 = 6,56^2$  cm<sup>2</sup>
- ▶ jiný (další) výběr z roku 1961 by obsahoval jiných 15 hochů, tedy by vedl k jinému výběrovému průměru (náhodná veličina)
- ▶ stačí rozdíl  $139,13 - 136,1 = 3,03$  (náhodná veličina, proč?), abychom prokázali, že se **populační průměr** výšek desetiletých chlapců po deseti letech změnil?

## testování statistických hypotéz

[hypothesis testing, null hypothesis, alternative hypothesis, critical (rejection) region, Type I (II) error, significance level]

- ▶ **nulová hypotéza**  $H_0$ : tvrzení o populaci (parametru), o jehož platnosti rozhodujeme (**není rozdíl, nezávisí, neliší se od ...**)
- ▶ **alternativní hypotéza**  $H_1$ : (alternativa) zbývající možnost (k  $H_0$ ), často „vědecká hypotéza“, kterou chceme dokázat
- ▶ hypotézy  $H_0, H_1$  jsou dány úlohou, nikoliv naší volbou
- ▶ **kritický obor**: možné výsledky pokusu, kdy  $H_0$  zamítáme; zpravidla popsán pomocí statistiky (např.  $|Z| \geq z(\alpha/2)$ )
- ▶ **obor přijetí**: možné výsledky pokusu, kdy  $H_0$  nezamítáme
- ▶ **chyba prvního druhu**: (náhodný jev) rozhodnutí zamítnout  $H_0$ , když platí  $H_0$ , tj. falešně prokázat „vědeckou hypotézu“
- ▶ **chyba druhého druhu**: (náhodný jev) rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$ , tj. nepoznat neplatnost  $H_0$

## testování statistických hypotéz

[hypothesis testing, null hypothesis, alternative hypothesis, critical (rejection) region, Type I (II) error, significance level]

- ▶ **nulová hypotéza**  $H_0$ : tvrzení o populaci (parametru), o jehož platnosti rozhodujeme (**není** rozdíl, **nezávisí**, **neliší** se od ...)
- ▶ **alternativní hypotéza**  $H_1$ : (alternativa) zbývající možnost (k  $H_0$ ), často „vědecká hypotéza“, kterou chceme dokázat
- ▶ hypotézy  $H_0, H_1$  jsou dány úlohou, nikoliv naší volbou
- ▶ **kritický obor**: možné výsledky pokusu, kdy  $H_0$  zamítáme; zpravidla popsán pomocí statistiky (např.  $|Z| \geq z(\alpha/2)$ )
- ▶ **obor přijetí**: možné výsledky pokusu, kdy  $H_0$  nezamítáme
- ▶ **chyba prvního druhu**: (náhodný jev) rozhodnutí zamítnout  $H_0$ , když platí  $H_0$ , tj. falešně prokázat „vědeckou hypotézu“
- ▶ **chyba druhého druhu**: (náhodný jev) rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$ , tj. nepoznat neplatnost  $H_0$



## testování statistických hypotéz

[hypothesis testing, null hypothesis, alternative hypothesis, critical (rejection) region, Type I (II) error, significance level]

- ▶ **nulová hypotéza**  $H_0$ : tvrzení o populaci (parametru), o jehož platnosti rozhodujeme (**není** rozdíl, **nezávisí**, **neliší** se od ...)
- ▶ **alternativní hypotéza**  $H_1$ : (alternativa) zbývající možnost (k  $H_0$ ), často „vědecká hypotéza“, kterou chceme dokázat
- ▶ hypotézy  $H_0, H_1$  jsou dány úlohou, nikoliv naší volbou
- ▶ **kritický obor**: možné výsledky pokusu, kdy  $H_0$  zamítáme; zpravidla popsán pomocí statistiky (např.  $|Z| \geq z(\alpha/2)$ )
- ▶ **obor přijetí**: možné výsledky pokusu, kdy  $H_0$  nezamítáme
- ▶ **chyba prvního druhu**: (náhodný jev) rozhodnutí zamítnout  $H_0$ , když platí  $H_0$ , tj. falešně prokázat „vědeckou hypotézu“
- ▶ **chyba druhého druhu**: (náhodný jev) rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$ , tj. nepoznat neplatnost  $H_0$

## testování statistických hypotéz

[hypothesis testing, null hypothesis, alternative hypothesis, critical (rejection) region, Type I (II) error, significance level]

- ▶ **nulová hypotéza**  $H_0$ : tvrzení o populaci (parametru), o jehož platnosti rozhodujeme (**není** rozdíl, **nezávisí**, **neliší** se od ...)
- ▶ **alternativní hypotéza**  $H_1$ : (alternativa) zbývající možnost (k  $H_0$ ), často „vědecká hypotéza“, kterou chceme dokázat
- ▶ hypotézy  $H_0, H_1$  jsou dány úlohou, nikoliv naší volbou
- ▶ **kritický obor**: možné výsledky pokusu, kdy  $H_0$  zamítáme; zpravidla popsán pomocí statistiky (např.  $|Z| \geq z(\alpha/2)$ )
- ▶ **obor přijetí**: možné výsledky pokusu, kdy  $H_0$  nezamítáme
- ▶ **chyba prvního druhu**: (náhodný jev) rozhodnutí zamítnout  $H_0$ , když platí  $H_0$ , tj. falešně prokázat „vědeckou hypotézu“
- ▶ **chyba druhého druhu**: (náhodný jev) rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$ , tj. nepoznat neplatnost  $H_0$

## testování statistických hypotéz

[hypothesis testing, null hypothesis, alternative hypothesis, critical (rejection) region, Type I (II) error, significance level]

- ▶ **nulová hypotéza**  $H_0$ : tvrzení o populaci (parametru), o jehož platnosti rozhodujeme (**není** rozdíl, **nezávisí**, **neliší** se od ...)
- ▶ **alternativní hypotéza**  $H_1$ : (alternativa) zbývající možnost (k  $H_0$ ), často „vědecká hypotéza“, kterou chceme dokázat
- ▶ hypotézy  $H_0, H_1$  jsou dány úlohou, nikoliv naší volbou
- ▶ **kritický obor**: možné výsledky pokusu, kdy  $H_0$  zamítáme; zpravidla popsán pomocí statistiky (např.  $|Z| \geq z(\alpha/2)$ )
- ▶ **obor přijetí**: možné výsledky pokusu, kdy  $H_0$  nezamítáme
- ▶ **chyba prvního druhu**: (náhodný jev) rozhodnutí zamítnout  $H_0$ , když platí  $H_0$ , tj. falešně prokázat „vědeckou hypotézu“
- ▶ **chyba druhého druhu**: (náhodný jev) rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$ , tj. nepoznat neplatnost  $H_0$

## testování statistických hypotéz

[hypothesis testing, null hypothesis, alternative hypothesis, critical (rejection) region, Type I (II) error, significance level]

- ▶ **nulová hypotéza**  $H_0$ : tvrzení o populaci (parametru), o jehož platnosti rozhodujeme (**není** rozdíl, **nezávisí**, **neliší** se od ...)
- ▶ **alternativní hypotéza**  $H_1$ : (alternativa) zbývající možnost (k  $H_0$ ), často „vědecká hypotéza“, kterou chceme dokázat
- ▶ hypotézy  $H_0, H_1$  jsou dány úlohou, nikoliv naší volbou
- ▶ **kritický obor**: možné výsledky pokusu, kdy  $H_0$  zamítáme; zpravidla popsán pomocí statistiky (např.  $|Z| \geq z(\alpha/2)$ )
- ▶ **obor přijetí**: možné výsledky pokusu, kdy  $H_0$  nezamítáme
- ▶ **chyba prvního druhu**: (náhodný jev) rozhodnutí zamítnout  $H_0$ , když platí  $H_0$ , tj. falešně prokázat „vědeckou hypotézu“
- ▶ **chyba druhého druhu**: (náhodný jev) rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$ , tj. nepoznat neplatnost  $H_0$

## testování statistických hypotéz

[hypothesis testing, null hypothesis, alternative hypothesis, critical (rejection) region, Type I (II) error, significance level]

- ▶ **nulová hypotéza**  $H_0$ : tvrzení o populaci (parametru), o jehož platnosti rozhodujeme (**není** rozdíl, **nezávisí**, **neliší** se od ...)
- ▶ **alternativní hypotéza**  $H_1$ : (alternativa) zbývající možnost (k  $H_0$ ), často „vědecká hypotéza“, kterou chceme dokázat
- ▶ hypotézy  $H_0, H_1$  jsou dány úlohou, nikoliv naší volbou
- ▶ **kritický obor**: možné výsledky pokusu, kdy  $H_0$  zamítáme; zpravidla popsán pomocí statistiky (např.  $|Z| \geq z(\alpha/2)$ )
- ▶ **obor přijetí**: možné výsledky pokusu, kdy  $H_0$  nezamítáme
- ▶ **chyba prvního druhu**: (náhodný jev) rozhodnutí zamítnout  $H_0$ , když platí  $H_0$ , tj. falešně prokázat „vědeckou hypotézu“
- ▶ **chyba druhého druhu**: (náhodný jev) rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$ , tj. nepoznat neplatnost  $H_0$

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to náhodná veličina, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to náhodná veličina, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to náhodná veličina, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)



# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to náhodná veličina, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to náhodná veličina, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to náhodná veličina, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to náhodná veličina, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to náhodná veličina, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to **náhodná veličina**, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to **náhodná veličina**, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to **náhodná veličina**, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)



# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to **náhodná veličina**, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to **náhodná veličina**, nikoliv pravděpodobnost  $H_0$

▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$

(zapamatovat)

# statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5 \%$ )
  - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
  - ▶ volí se před pokusem, nezávisle na jeho výsledku
  - ▶ **pevná** (nenáhodná) hodnota
- ▶ **síla testu**  $1 - \beta$ 
  - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
  - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“, pokud platí
  - ▶ závisí na skutečné hodnotě parametru
- ▶ **p-hodnota**
  - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
  - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
  - ▶ „stupeň důvěry“ v platnost nulové hypotézy
  - ▶ je to **náhodná veličina**, nikoliv pravděpodobnost  $H_0$
- ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  **(zapamatovat)**

## testování statistických hypotéz

rozhodnutí	skutečnost	
	$H_0$ platí	$H_0$ neplatí
$H_0$ zamítnout (reject)	<b>chyba 1. druhu</b> ( $pst \leq \alpha$ )	správné rozhodnutí ( $pst = 1 - \beta$ )
$H_0$ nezamítnout (accept)	správné rozhodnutí ( $pst \geq 1 - \alpha$ )	chyba 2. druhu ( $pst = \beta$ )

- ▶ zamítnutí  $\Leftrightarrow$  výsledek pokusu v kritickém oboru
- ▶ přijetí  $\Leftrightarrow$  výsledek pokusu v oboru přijetí
- ▶ nikdy spolehlivě nevíme, zda  $H_0$  platí
- ▶ chybu 1. druhu nechceme dělat často  $\Rightarrow \alpha$  volíme malé

## testování statistických hypotéz

rozhodnutí	skutečnost	
	$H_0$ platí	$H_0$ neplatí
$H_0$ zamítnout (reject)	<b>chyba 1. druhu</b> ( $pst \leq \alpha$ )	správné rozhodnutí ( $pst = 1 - \beta$ )
$H_0$ nezamítnout (accept)	správné rozhodnutí ( $pst \geq 1 - \alpha$ )	chyba 2. druhu ( $pst = \beta$ )

- ▶ zamítnutí  $\Leftrightarrow$  výsledek pokusu v kritickém oboru
- ▶ přijetí  $\Leftrightarrow$  výsledek pokusu v oboru přijetí
- ▶ nikdy spolehlivě nevíme, zda  $H_0$  platí
- ▶ chybu 1. druhu nechceme dělat často  $\Rightarrow \alpha$  volíme malé

## testování statistických hypotéz

rozhodnutí	skutečnost	
	$H_0$ platí	$H_0$ neplatí
$H_0$ zamítnout (reject)	<b>chyba 1. druhu</b> ( $pst \leq \alpha$ )	správné rozhodnutí ( $pst = 1 - \beta$ )
$H_0$ nezamítnout (accept)	správné rozhodnutí ( $pst \geq 1 - \alpha$ )	chyba 2. druhu ( $pst = \beta$ )

- ▶ zamítnutí  $\Leftrightarrow$  výsledek pokusu v kritickém oboru
- ▶ přijetí  $\Leftrightarrow$  výsledek pokusu v oboru přijetí
- ▶ nikdy spolehlivě nevíme, zda  $H_0$  platí
- ▶ chybu 1. druhu nechceme dělat často  $\Rightarrow \alpha$  volíme malé

## testování statistických hypotéz

rozhodnutí	skutečnost	
	$H_0$ platí	$H_0$ neplatí
$H_0$ zamítnout (reject)	<b>chyba 1. druhu</b> ( $pst \leq \alpha$ )	správné rozhodnutí ( $pst = 1 - \beta$ )
$H_0$ nezamítnout (accept)	správné rozhodnutí ( $pst \geq 1 - \alpha$ )	chyba 2. druhu ( $pst = \beta$ )

- ▶ zamítnutí  $\Leftrightarrow$  výsledek pokusu v kritickém oboru
- ▶ přijetí  $\Leftrightarrow$  výsledek pokusu v oboru přijetí
- ▶ nikdy spolehlivě nevíme, zda  $H_0$  platí
- ▶ chybu 1. druhu nechceme dělat často  $\Rightarrow \alpha$  volíme malé

## rozhodování o populačním průměru normálního rozdělení ( $\sigma$ známé)

▶  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**;  $\sigma > 0$  známe

▶  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy S.E.( $\bar{X}$ ) =  $\sigma/\sqrt{n}$

▶  $H_0 : \mu = \mu_0$  (dané číslo, jiný zápis  $H_0 : \mu - \mu_0 = 0$ )

▶ platí-li  $H_0$ , pak 
$$Z = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$$

▶  $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$

▶  $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$

▶  $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$

▶ volba jednostranné alternativy jen podle zadání úlohy, nikoliv podle výsledku pokusu (nezávisle na datech)



## rozhodování o populačním průměru normálního rozdělení ( $\sigma$ známé)

▶  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**;  $\sigma > 0$  známe

▶  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy S.E.( $\bar{X}$ ) =  $\sigma/\sqrt{n}$

▶  $H_0 : \mu = \mu_0$  (dané číslo, jiný zápis  $H_0 : \mu - \mu_0 = 0$ )

▶ platí-li  $H_0$ , pak 
$$Z = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$$

▶  $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$

▶  $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$

▶  $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$

▶ volba jednostranné alternativy jen podle zadání úlohy, nikoliv podle výsledku pokusu (nezávisle na datech)

## rozhodování o populačním průměru normálního rozdělení ( $\sigma$ známé)

- ▶  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**;  $\sigma > 0$  známe
- ▶  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy S.E.( $\bar{X}$ ) =  $\sigma/\sqrt{n}$
- ▶  $H_0 : \mu = \mu_0$  (dané číslo, jiný zápis  $H_0 : \mu - \mu_0 = 0$ )

- ▶ platí-li  $H_0$ , pak 
$$Z = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$$

- ▶  $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$

- ▶  $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$

- ▶  $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$

- ▶ volba jednostranné alternativy jen podle zadání úlohy, nikoliv podle výsledku pokusu (nezávisle na datech)

## rozhodování o populačním průměru normálního rozdělení ( $\sigma$ známé)

- ▶  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**;  $\sigma > 0$  známe
- ▶  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $S.E.(\bar{X}) = \sigma/\sqrt{n}$
- ▶  $H_0 : \mu = \mu_0$  (dané číslo, jiný zápis  $H_0 : \mu - \mu_0 = 0$ )

- ▶ platí-li  $H_0$ , pak 
$$Z = \frac{\bar{X} - \mu_0}{S.E.(\bar{X})} = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$$

- ▶  $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$
- ▶  $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$
- ▶  $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$
- ▶ volba jednostranné alternativy jen podle zadání úlohy, nikoliv podle výsledku pokusu (nezávisle na datech)

## rozhodování o populačním průměru normálního rozdělení ( $\sigma$ známé)

- ▶  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**;  $\sigma > 0$  známe
- ▶  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $S.E.(\bar{X}) = \sigma/\sqrt{n}$
- ▶  $H_0 : \mu = \mu_0$  (dané číslo, jiný zápis  $H_0 : \mu - \mu_0 = 0$ )

- ▶ platí-li  $H_0$ , pak 
$$Z = \frac{\bar{X} - \mu_0}{S.E.(\bar{X})} = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$$

- ▶  $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$

- ▶  $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$

- ▶  $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$

- ▶ volba jednostranné alternativy jen podle zadání úlohy, nikoliv podle výsledku pokusu (nezávisle na datech)

## rozhodování o populačním průměru normálního rozdělení ( $\sigma$ známé)

- ▶  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**;  $\sigma > 0$  známe
- ▶  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $S.E.(\bar{X}) = \sigma/\sqrt{n}$
- ▶  $H_0 : \mu = \mu_0$  (dané číslo, jiný zápis  $H_0 : \mu - \mu_0 = 0$ )

- ▶ platí-li  $H_0$ , pak  $Z = \frac{\bar{X} - \mu_0}{S.E.(\bar{X})} = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$

- ▶  $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$

- ▶  $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$

- ▶  $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$

- ▶ volba jednostranné alternativy jen podle zadání úlohy, nikoliv podle výsledku pokusu (nezávisle na datech)

## rozhodování o populačním průměru normálního rozdělení ( $\sigma$ známé)

- ▶  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**;  $\sigma > 0$  známe
- ▶  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $S.E.(\bar{X}) = \sigma/\sqrt{n}$
- ▶  $H_0 : \mu = \mu_0$  (dané číslo, jiný zápis  $H_0 : \mu - \mu_0 = 0$ )

- ▶ platí-li  $H_0$ , pak 
$$Z = \frac{\bar{X} - \mu_0}{S.E.(\bar{X})} = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$$

- ▶  $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$

- ▶  $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$

- ▶  $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$

- ▶ volba jednostranné alternativy jen podle zadání úlohy, nikoliv podle výsledku pokusu (nezávisle na datech)

## rozhodování o populačním průměru normálního rozdělení ( $\sigma$ známé)

- ▶  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**;  $\sigma > 0$  známe
- ▶  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $S.E.(\bar{X}) = \sigma/\sqrt{n}$
- ▶  $H_0 : \mu = \mu_0$  (dané číslo, jiný zápis  $H_0 : \mu - \mu_0 = 0$ )

- ▶ platí-li  $H_0$ , pak 
$$Z = \frac{\bar{X} - \mu_0}{S.E.(\bar{X})} = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$$

- ▶  $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$


- ▶  $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$

- ▶  $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$

- ▶ volba jednostranné alternativy jen podle zadání úlohy, nikoliv podle výsledku pokusu (nezávisle na datech)

kritický obor pro  $Z = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n}$

červeně na 5% hladině, červeně a fialově na 10% hladině, hustota  $Z$  za  $H_0$





## příklad: výška desetiletých chlapců

pozor, **jednostranná** alternativa!

- ▶ zvolíme klasickou hladinu  $\alpha = 5 \%$
- ▶ v roce 1951 velký výběr:  $\mu_0 = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ v roce 1961 změřeno  $n = 15$  náhodně vybraných desetiletých hochů,  $\bar{x} = 139,13$  cm
- ▶ stačí tento vzrůst k důkazu, že nová generace je vyšší?
- ▶ vzrostla výška desetiletých ?  $H_0 : \mu = \mu_0$  proti  $H_1 : \mu > \mu_0$

$$z = \frac{139,13 - 136,1}{6,4} \sqrt{15} = 1,836$$

- ▶  $z(0,05) = 1,645 < 1,836$ , tedy  $H_0$  na 5% hladině **zamítáme**
- ▶ na 5% hladině jsme prokázali, že nová generace je vyšší
- ▶ v případě, že nová generace není vyšší, riskovali jsme jen 5% pravděpodobnost, že budeme nesprávně tvrdit, že vyšší je

## příklad: výška desetiletých chlapců

pozor, **jednostranná** alternativa!

- ▶ zvolíme klasickou hladinu  $\alpha = 5 \%$
- ▶ v roce 1951 velký výběr:  $\mu_0 = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ v roce 1961 změřeno  $n = 15$  náhodně vybraných desetiletých hochů,  $\bar{x} = 139,13$  cm
- ▶ stačí tento vzrůst k důkazu, že nová generace je vyšší?
- ▶ vzrostla výška desetiletých ?  $H_0 : \mu = \mu_0$  proti  $H_1 : \mu > \mu_0$

$$z = \frac{139,13 - 136,1}{6,4} \sqrt{15} = 1,836$$

- ▶  $z(0,05) = 1,645 < 1,836$ , tedy  $H_0$  na 5% hladině **zamítáme**
- ▶ na 5% hladině jsme prokázali, že nová generace je vyšší
- ▶ v případě, že nová generace není vyšší, riskovali jsme jen 5% pravděpodobnost, že budeme nesprávně tvrdit, že vyšší je

## příklad: výška desetiletých chlapců

pozor, **jednostranná** alternativa!

- ▶ zvolíme klasickou hladinu  $\alpha = 5 \%$
- ▶ v roce 1951 velký výběr:  $\mu_0 = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ v roce 1961 změřeno  $n = 15$  náhodně vybraných desetiletých hochů,  $\bar{x} = 139,13$  cm
- ▶ stačí tento vzrůst k důkazu, že nová generace je vyšší?
- ▶ vzrostla výška desetiletých ?  $H_0 : \mu = \mu_0$  proti  $H_1 : \mu > \mu_0$

$$z = \frac{139,13 - 136,1}{6,4} \sqrt{15} = 1,836$$

- ▶  $z(0,05) = 1,645 < 1,836$ , tedy  $H_0$  na 5% hladině **zamítáme**
- ▶ na 5% hladině jsme prokázali, že nová generace je vyšší
- ▶ v případě, že nová generace není vyšší, riskovali jsme jen 5% pravděpodobnost, že budeme nesprávně tvrdit, že vyšší je

## příklad: výška desetiletých chlapců

pozor, **jednostranná** alternativa!

- ▶ zvolíme klasickou hladinu  $\alpha = 5 \%$
- ▶ v roce 1951 velký výběr:  $\mu_0 = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ v roce 1961 změřeno  $n = 15$  náhodně vybraných desetiletých hochů,  $\bar{x} = 139,13$  cm
- ▶ stačí tento vzrůst k důkazu, že nová generace je vyšší?
- ▶ vzrostla výška desetiletých ?  $H_0 : \mu = \mu_0$  proti  $H_1 : \mu > \mu_0$

$$z = \frac{139,13 - 136,1}{6,4} \sqrt{15} = 1,836$$

- ▶  $z(0,05) = 1,645 < 1,836$ , tedy  $H_0$  na 5% hladině **zamítáme**
- ▶ na 5% hladině jsme prokázali, že nová generace je vyšší
- ▶ v případě, že nová generace není vyšší, riskovali jsme jen 5% pravděpodobnost, že budeme nesprávně tvrdit, že vyšší je

## příklad: výška desetiletých chlapců

pozor, **jednostranná** alternativa!

- ▶ zvolíme klasickou hladinu  $\alpha = 5 \%$
- ▶ v roce 1951 velký výběr:  $\mu_0 = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ v roce 1961 změřeno  $n = 15$  náhodně vybraných desetiletých hochů,  $\bar{x} = 139,13$  cm
- ▶ stačí tento vzrůst k důkazu, že nová generace je vyšší?
- ▶ vzrostla výška desetiletých ?  $H_0 : \mu = \mu_0$  proti  $H_1 : \mu > \mu_0$

$$z = \frac{139,13 - 136,1}{6,4} \sqrt{15} = 1,836$$

- ▶  $z(0,05) = 1,645 < 1,836$ , tedy  $H_0$  na 5% hladině **zamítáme**
- ▶ na 5% hladině jsme prokázali, že nová generace je vyšší
- ▶ v případě, že nová generace není vyšší, riskovali jsme jen 5% pravděpodobnost, že budeme nesprávně tvrdit, že vyšší je

## příklad: výška desetiletých chlapců

pozor, **jednostranná** alternativa!

- ▶ zvolíme klasickou hladinu  $\alpha = 5 \%$
- ▶ v roce 1951 velký výběr:  $\mu_0 = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ v roce 1961 změřeno  $n = 15$  náhodně vybraných desetiletých hochů,  $\bar{x} = 139,13$  cm
- ▶ stačí tento vzrůst k důkazu, že nová generace je vyšší?
- ▶ vzrostla výška desetiletých ?  $H_0 : \mu = \mu_0$  proti  $H_1 : \mu > \mu_0$

$$z = \frac{139,13 - 136,1}{6,4} \sqrt{15} = 1,836$$

- ▶  $z(0,05) = 1,645 < 1,836$ , tedy  $H_0$  na 5% hladině **zamítáme**
- ▶ na 5% hladině jsme prokázali, že nová generace je vyšší
- ▶ v případě, že nová generace není vyšší, riskovali jsme jen 5% pravděpodobnost, že budeme nesprávně tvrdit, že vyšší je

## příklad: výška desetiletých chlapců

pozor, **jednostranná** alternativa!

- ▶ zvolíme klasickou hladinu  $\alpha = 5 \%$
- ▶ v roce 1951 velký výběr:  $\mu_0 = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ v roce 1961 změřeno  $n = 15$  náhodně vybraných desetiletých hochů,  $\bar{x} = 139,13$  cm
- ▶ stačí tento vzrůst k důkazu, že nová generace je vyšší?
- ▶ vzrostla výška desetiletých ?  $H_0 : \mu = \mu_0$  proti  $H_1 : \mu > \mu_0$

$$z = \frac{139,13 - 136,1}{6,4} \sqrt{15} = 1,836$$

- ▶  $z(0,05) = 1,645 < 1,836$ , tedy  $H_0$  na 5% hladině **zamítáme**
- ▶ na 5% hladině jsme prokázali, že nová generace je vyšší
- ▶ v případě, že nová generace není vyšší, riskovali jsme jen 5% pravděpodobnost, že budeme nesprávně tvrdit, že vyšší je

## příklad: výška desetiletých chlapců

pozor, **jednostranná** alternativa!

- ▶ zvolíme klasickou hladinu  $\alpha = 5 \%$
- ▶ v roce 1951 velký výběr:  $\mu_0 = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ v roce 1961 změřeno  $n = 15$  náhodně vybraných desetiletých hochů,  $\bar{x} = 139,13$  cm
- ▶ stačí tento vzrůst k důkazu, že nová generace je vyšší?
- ▶ vzrostla výška desetiletých ?  $H_0 : \mu = \mu_0$  proti  $H_1 : \mu > \mu_0$

$$z = \frac{139,13 - 136,1}{6,4} \sqrt{15} = 1,836$$

- ▶  $z(0,05) = 1,645 < 1,836$ , tedy  $H_0$  na 5% hladině **zamítáme**
- ▶ na 5% hladině jsme prokázali, že nová generace je vyšší
- ▶ v případě, že nová generace není vyšší, riskovali jsme jen 5% pravděpodobnost, že budeme nesprávně tvrdit, že vyšší je



## příklad: výška desetiletých chlapců

kritický obor (nezapomeň na jednostrannou alternativu!)

- ▶ kritický obor pomocí  $Z$ :

$$Z = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \geq z(\alpha)$$

- ▶ totéž pro  $\bar{X}$ :

$$\bar{X} \geq \mu_0 + \frac{\sigma}{\sqrt{n}} z(\alpha)$$

- ▶ konkrétně pro výšku hochů:

$$\bar{X} \geq 136,1 + \frac{6,4}{\sqrt{15}} \cdot 1,645 = 138,82$$

## příklad: výška desetiletých chlapců

kritický obor (nezapomeň na jednostrannou alternativu!)

- ▶ kritický obor pomocí  $Z$ :

$$Z = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \geq z(\alpha)$$

- ▶ totéž pro  $\bar{X}$ :

$$\bar{X} \geq \mu_0 + \frac{\sigma}{\sqrt{n}} z(\alpha)$$

- ▶ konkrétně pro výšku hochů:

$$\bar{X} \geq 136,1 + \frac{6,4}{\sqrt{15}} \cdot 1,645 = 138,82$$

## příklad: výška desetiletých chlapců

kritický obor (nezapomeň na jednostrannou alternativu!)

- ▶ kritický obor pomocí  $Z$ :

$$Z = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \geq z(\alpha)$$

- ▶ totéž pro  $\bar{X}$ :

$$\bar{X} \geq \mu_0 + \frac{\sigma}{\sqrt{n}} z(\alpha)$$


- ▶ konkrétně pro výšku hochů:

$$\bar{X} \geq 136,1 + \frac{6,4}{\sqrt{15}} \cdot 1,645 = 138,82$$

## výška desetiletých hochů

hustota  $\bar{X}$  za platnosti hypotézy  $H_0: \mu = 136,1$ , $H_1: \mu > \mu_0$  při  $\sigma = 6,4$ 


- ▶  $p$ -hodnota – pst, že za  $H_0: Z = (\bar{X} - \mu_0)\sqrt{n}/\sigma > 1,836$  tj.  
 $\bar{X} > 136,1 + 1,836 \cdot 6,4/\sqrt{15} = 139,13$  [1-pnorm(1.836)]
- ▶  $p$ -hodnota – modrá plocha napravo od 139,13,  $p = 3,3\%$



## výška desetiletých hochů

hustota  $\bar{X}$  za platnosti hypotézy  $H_0: \mu = 136,1$ , $H_1: \mu > \mu_0$  při  $\sigma = 6,4$ 

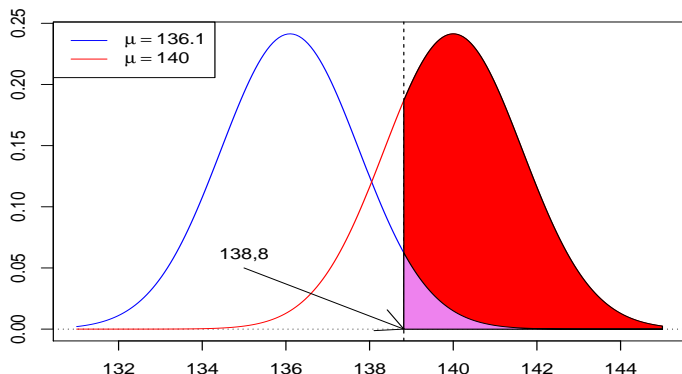
- ▶  $p$ -hodnota – pst, že za  $H_0: Z = (\bar{X} - \mu_0)\sqrt{n}/\sigma > 1,836$  tj.  
 $\bar{X} > 136,1 + 1,836 \cdot 6,4/\sqrt{15} = 139,13$  [1-pnorm(1.836)]
- ▶  $p$ -hodnota – modrá plocha napravo od 139,13,  $p = 3,3\%$



## výška desetiletých chlapců – síla testu

hustota  $\bar{X}$  za hypotézy (modře) a při  $\mu = 140$  (červeně)

hladina testu = fialová plocha, síla testu = fialová + červená plocha



hraniční hodnota  $\bar{X}$ , při které se „láme“ rozhodování (hranice kritického oboru a oboru přijetí):  $136,1 + 6,4/\sqrt{15} \cdot 1,645 = 138,8$

## volba rozsahu výběru

$H_0 : \mu = \mu_0$  proti  $H_1 : \mu \neq \mu_0$

- ▶ pro zvolenou hodnotu  $\mu_1 \neq \mu_0$  požadujeme sílu  $1 - \beta$
- ▶  $1 - \beta$  je pravděpodobnost, s jakou odhalíme neplatnost  $H_0$ , je-li ve skutečnosti  $\mu = \mu_1$

$$n \geq \left( \frac{z(\alpha/2) + z(\beta)}{\mu_1 - \mu_0} \right)^2 \sigma^2$$

- ▶ při jednostranné alternativě by bylo  $z(\alpha)$  místo  $z(\alpha/2)$
- ▶ aby při jednostranné alternativě pro  $\mu_1 = 140$  byla síla 90 % (tj.  $1 - \beta = 0,9$ ,  $\beta = 0,1$ ,  $z(0,1) = 1,282$ ), bude třeba aspoň

$$n \geq \left( \frac{1,645 + 1,282}{140 - 136,1} \right)^2 6,4^2 = 23,1$$

(místo 15 pozorování jich potřebujeme aspoň 24,  
při oboustranné alternativě aspoň 29)

## volba rozsahu výběru

$H_0 : \mu = \mu_0$  proti  $H_1 : \mu \neq \mu_0$

- ▶ pro zvolenou hodnotu  $\mu_1 \neq \mu_0$  požadujeme sílu  $1 - \beta$
- ▶  $1 - \beta$  je pravděpodobnost, s jakou odhalíme neplatnost  $H_0$ , je-li ve skutečnosti  $\mu = \mu_1$

$$n \geq \left( \frac{z(\alpha/2) + z(\beta)}{\mu_1 - \mu_0} \right)^2 \sigma^2$$

- ▶ při jednostranné alternativě by bylo  $z(\alpha)$  místo  $z(\alpha/2)$
- ▶ aby při jednostranné alternativě pro  $\mu_1 = 140$  byla síla 90 % (tj.  $1 - \beta = 0,9$ ,  $\beta = 0,1$ ,  $z(0,1) = 1,282$ ), bude třeba aspoň

$$n \geq \left( \frac{1,645 + 1,282}{140 - 136,1} \right)^2 6,4^2 = 23,1$$

(místo 15 pozorování jich potřebujeme aspoň 24,  
při oboustranné alternativě aspoň 29)



## volba rozsahu výběru

$H_0 : \mu = \mu_0$  proti  $H_1 : \mu \neq \mu_0$

- ▶ pro zvolenou hodnotu  $\mu_1 \neq \mu_0$  požadujeme sílu  $1 - \beta$
- ▶  $1 - \beta$  je pravděpodobnost, s jakou odhalíme neplatnost  $H_0$ , je-li ve skutečnosti  $\mu = \mu_1$

$$n \geq \left( \frac{z(\alpha/2) + z(\beta)}{\mu_1 - \mu_0} \right)^2 \sigma^2$$

- ▶ při jednostranné alternativě by bylo  $z(\alpha)$  místo  $z(\alpha/2)$
- ▶ aby při jednostranné alternativě pro  $\mu_1 = 140$  byla síla 90 % (tj.  $1 - \beta = 0,9$ ,  $\beta = 0,1$ ,  $z(0,1) = 1,282$ ), bude třeba aspoň

$$n \geq \left( \frac{1,645 + 1,282}{140 - 136,1} \right)^2 6,4^2 = 23,1$$

(místo 15 pozorování jich potřebujeme aspoň 24,  
při oboustranné alternativě aspoň 29)

## volba rozsahu výběru

$H_0 : \mu = \mu_0$  proti  $H_1 : \mu \neq \mu_0$

- ▶ pro zvolenou hodnotu  $\mu_1 \neq \mu_0$  požadujeme sílu  $1 - \beta$
- ▶  $1 - \beta$  je pravděpodobnost, s jakou odhalíme neplatnost  $H_0$ , je-li ve skutečnosti  $\mu = \mu_1$

$$n \geq \left( \frac{z(\alpha/2) + z(\beta)}{\mu_1 - \mu_0} \right)^2 \sigma^2$$

- ▶ při jednostranné alternativě by bylo  $z(\alpha)$  místo  $z(\alpha/2)$
- ▶ aby při jednostranné alternativě pro  $\mu_1 = 140$  byla síla 90 % (tj.  $1 - \beta = 0,9$ ,  $\beta = 0,1$ ,  $z(0,1) = 1,282$ ), bude třeba aspoň

$$n \geq \left( \frac{1,645 + 1,282}{140 - 136,1} \right)^2 6,4^2 = 23,1$$

(místo 15 pozorování jich potřebujeme aspoň 24,  
při oboustranné alternativě aspoň 29)

# jednovýběrový t-test

výběr z  $N(\mu, \sigma^2)$ ,  $\sigma$  **neznámé**

- ▶  $n$  nezávislých pozorování  $X_1, \dots, X_n$  z rozdělení  $N(\mu, \sigma^2)$
- ▶  $H_0 : \mu = \mu_0$  (populační průměr roven dané konstantě)
- ▶ nutno odhadnout neznámý rozptyl  $\sigma^2$

$$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ▶ statistika (místo  $\sigma$  použijeme  $S_x$ )

$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S_x} \sqrt{n}$$

- ▶  $H_1 : \mu \neq \mu_0$  zamítnat při  $|T| \geq t_{n-1}(\alpha)$
- ▶  $H_1 : \mu > \mu_0$  zamítnat při  $T \geq t_{n-1}(2\alpha)$
- ▶  $H_1 : \mu < \mu_0$  zamítnat při  $T \leq -t_{n-1}(2\alpha)$

# jednovýběrový $t$ -test

výběr z  $N(\mu, \sigma^2)$ ,  $\sigma$  **neznámé**

- ▶  $n$  nezávislých pozorování  $X_1, \dots, X_n$  z rozdělení  $N(\mu, \sigma^2)$
- ▶  $H_0 : \mu = \mu_0$  (populační průměr roven dané konstantě)
- ▶ nutno odhadnout neznámý rozptyl  $\sigma^2$

$$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ▶ statistika (místo  $\sigma$  použijeme  $S_x$ )

$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S_x} \sqrt{n}$$

- ▶  $H_1 : \mu \neq \mu_0$  zamítnat při  $|T| \geq t_{n-1}(\alpha)$
- ▶  $H_1 : \mu > \mu_0$  zamítnat při  $T \geq t_{n-1}(2\alpha)$
- ▶  $H_1 : \mu < \mu_0$  zamítnat při  $T \leq -t_{n-1}(2\alpha)$

# jednovýběrový t-test

výběr z  $N(\mu, \sigma^2)$ ,  $\sigma$  **neznámé**

- ▶  $n$  nezávislých pozorování  $X_1, \dots, X_n$  z rozdělení  $N(\mu, \sigma^2)$
- ▶  $H_0 : \mu = \mu_0$  (populační průměr roven dané konstantě)
- ▶ nutno odhadnout neznámý rozptyl  $\sigma^2$

$$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ▶ statistika (místo  $\sigma$  použijeme  $S_x$ )

$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S_x} \sqrt{n}$$

- ▶  $H_1 : \mu \neq \mu_0$  zamítnat při  $|T| \geq t_{n-1}(\alpha)$
- ▶  $H_1 : \mu > \mu_0$  zamítnat při  $T \geq t_{n-1}(2\alpha)$
- ▶  $H_1 : \mu < \mu_0$  zamítnat při  $T \leq -t_{n-1}(2\alpha)$

# jednovýběrový $t$ -test

výběr z  $N(\mu, \sigma^2)$ ,  $\sigma$  **neznámé**

- ▶  $n$  nezávislých pozorování  $X_1, \dots, X_n$  z rozdělení  $N(\mu, \sigma^2)$
- ▶  $H_0 : \mu = \mu_0$  (populační průměr roven dané konstantě)
- ▶ nutno odhadnout neznámý rozptyl  $\sigma^2$

$$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ▶ statistika (místo  $\sigma$  použijeme  $S_x$ )

$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S_x} \sqrt{n}$$

- ▶  $H_1 : \mu \neq \mu_0$  zamítnat při  $|T| \geq t_{n-1}(\alpha)$
- ▶  $H_1 : \mu > \mu_0$  zamítnat při  $T \geq t_{n-1}(2\alpha)$
- ▶  $H_1 : \mu < \mu_0$  zamítnat při  $T \leq -t_{n-1}(2\alpha)$

# jednovýběrový t-test

výběr z  $N(\mu, \sigma^2)$ ,  $\sigma$  **neznámé**

- ▶  $n$  nezávislých pozorování  $X_1, \dots, X_n$  z rozdělení  $N(\mu, \sigma^2)$
- ▶  $H_0 : \mu = \mu_0$  (populační průměr roven dané konstantě)
- ▶ nutno odhadnout neznámý rozptyl  $\sigma^2$

$$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ▶ statistika (místo  $\sigma$  použijeme  $S_x$ )

$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S_x} \sqrt{n}$$

- ▶  $H_1 : \mu \neq \mu_0$  zamítnat při  $|T| \geq t_{n-1}(\alpha)$
- ▶  $H_1 : \mu > \mu_0$  zamítnat při  $T \geq t_{n-1}(2\alpha)$
- ▶  $H_1 : \mu < \mu_0$  zamítnat při  $T \leq -t_{n-1}(2\alpha)$

# jednovýběrový $t$ -test

výběr z  $N(\mu, \sigma^2)$ ,  $\sigma$  **neznámé**

- ▶  $n$  nezávislých pozorování  $X_1, \dots, X_n$  z rozdělení  $N(\mu, \sigma^2)$
- ▶  $H_0 : \mu = \mu_0$  (populační průměr roven dané konstantě)
- ▶ nutno odhadnout neznámý rozptyl  $\sigma^2$

$$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ▶ statistika (místo  $\sigma$  použijeme  $S_x$ )

$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S_x} \sqrt{n}$$

- ▶  $H_1 : \mu \neq \mu_0$  zamítnat při  $|T| \geq t_{n-1}(\alpha)$
- ▶  $H_1 : \mu > \mu_0$  zamítnat při  $T \geq t_{n-1}(2\alpha)$
- ▶  $H_1 : \mu < \mu_0$  zamítnat při  $T \leq -t_{n-1}(2\alpha)$



# jednovýběrový t-test

výběr z  $N(\mu, \sigma^2)$ ,  $\sigma$  **neznámé**

- ▶  $n$  nezávislých pozorování  $X_1, \dots, X_n$  z rozdělení  $N(\mu, \sigma^2)$
- ▶  $H_0 : \mu = \mu_0$  (populační průměr roven dané konstantě)
- ▶ nutno odhadnout neznámý rozptyl  $\sigma^2$

$$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ▶ statistika (místo  $\sigma$  použijeme  $S_x$ )

$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S_x} \sqrt{n}$$

- ▶  $H_1 : \mu \neq \mu_0$  zamítnat při  $|T| \geq t_{n-1}(\alpha)$
- ▶  $H_1 : \mu > \mu_0$  zamítnat při  $T \geq t_{n-1}(2\alpha)$
- ▶  $H_1 : \mu < \mu_0$  zamítnat při  $T \leq -t_{n-1}(2\alpha)$

výšky hochů pro případ neznámého  $\sigma$ 

- ▶  $H_0 : \mu = 136,1$  proti  $H_1 : \mu > 136,1$  ( $\alpha = 5 \%$ )

$$\bar{x} = 139,133 \quad s_x^2 = 6,556^2$$

$$t = \frac{139,133 - 136,1}{6,556} \sqrt{15} = 1,792 > 1,761 = t_{14}(0,10)$$

$$p = P(T \geq 1,792) = 0,047 \quad (\text{tj. } 4,7 \%)$$

- ▶ na 5% hladině jsme prokázali zvýšení populačního průměru ( $H_0$  se na 5% hladině **zamítá**)
- ▶ `[t.test(hosi,mu=136.1,alternative="greater")]`

výšky hochů pro případ neznámého  $\sigma$ 

- ▶  $H_0 : \mu = 136,1$  proti  $H_1 : \mu > 136,1$  ( $\alpha = 5 \%$ )

$$\bar{x} = 139,133 \quad s_x^2 = 6,556^2$$

$$t = \frac{139,133 - 136,1}{6,556} \sqrt{15} = 1,792 > 1,761 = t_{14}(0,10)$$

$$p = P(T \geq 1,792) = 0,047 \quad (\text{tj. } 4,7 \%)$$

- ▶ na 5% hladině jsme prokázali zvýšení populačního průměru ( $H_0$  se na 5% hladině **zamítá**)
- ▶ `[t.test(hosi,mu=136.1,alternative="greater")]`

výšky hochů pro případ neznámého  $\sigma$ 

- ▶  $H_0 : \mu = 136,1$  proti  $H_1 : \mu > 136,1$  ( $\alpha = 5 \%$ )

$$\bar{x} = 139,133 \quad s_x^2 = 6,556^2$$

$$t = \frac{139,133 - 136,1}{6,556} \sqrt{15} = 1,792 > 1,761 = t_{14}(0,10)$$

$$p = P(T \geq 1,792) = 0,047 \quad (\text{tj. } 4,7 \%)$$

- ▶ na 5% hladině jsme prokázali zvýšení populačního průměru ( $H_0$  se na 5% hladině **zamítá**)
- ▶ `[t.test(hosi,mu=136.1,alternative="greater")]`

# výšky hochů pro případ neznámého $\sigma$

(jiné zadání úlohy)

- ▶ **kdybychom** předem neměli určenu jednostrannou alternativu, museli bychom zvolit  $H_1 : \mu \neq 136,1$ , pak

$$|t| = |1,792| < 2,145 = t_{14}(0,05)$$

$$p = P(|T| \geq 1,792) = 0,0948 \quad (\text{tj. } 9,48 \%)$$

- ▶ hypotézu na 5% hladině nezamítáme
- ▶ `[t.test(hosi,mu=136.1,alternative="two.sided")]`,  
stačí ale `[t.test(hosi,mu=136.1)]`

# výšky hochů pro případ neznámého $\sigma$

(jiné zadání úlohy)

- ▶ **kdybychom** předem neměli určenu jednostrannou alternativu, museli bychom zvolit  $H_1 : \mu \neq 136,1$ , pak

$$|t| = |1,792| < 2,145 = t_{14}(0,05)$$

$$p = P(|T| \geq 1,792) = 0,0948 \quad (\text{tj. } 9,48 \%)$$

- ▶ hypotézu na 5% hladině nezamítáme
- ▶ `[t.test(hosi,mu=136.1,alternative="two.sided")]`,  
stačí ale `[t.test(hosi,mu=136.1)]`

# výšky hochů pro případ neznámého $\sigma$

(jiné zadání úlohy)

- ▶ **kdybychom** předem neměli určenu jednostrannou alternativu, museli bychom zvolit  $H_1 : \mu \neq 136,1$ , pak

$$|t| = |1,792| < 2,145 = t_{14}(0,05)$$

$$p = P(|T| \geq 1,792) = 0,0948 \quad (\text{tj. } 9,48 \%)$$

- ▶ hypotézu na 5% hladině nezamítáme
- ▶ `[t.test(hosi,mu=136.1,alternative="two.sided")]`,  
stačí ale `[t.test(hosi,mu=136.1)]`

## výšky hochů pro případ neznámého $\sigma$

- ▶ 95% interval spolehlivosti: (135,5; 142,8)  
s 95% pravděpodobností je skutečný populační průměr (střední hodnota  $\mu$ ) v uvedeném intervalu
- ▶ je jen 5% riziko, že leží mimo uvedený interval
- ▶ 99% interval spolehlivosti (134,1; 144,2)  
`[t.test(hosi,mu=136.1,conf.level=0.99)]` (vedlejší výsledek)  
`[confint(lm(hosi~1),level=0.99)]`
- ▶ aby byla zajištěna větší spolehlivost intervalu (větší pravděpodobnost, že zachytí skutečnou hodnotu), je nutně 99% interval spolehlivosti delší, než 95% interval spolehlivosti



## výšky hochů pro případ neznámého $\sigma$

- ▶ 95% interval spolehlivosti: (135,5; 142,8)  
s 95% pravděpodobností je skutečný populační průměr (střední hodnota  $\mu$ ) v uvedeném intervalu
- ▶ je jen 5% riziko, že leží mimo uvedený interval
- ▶ 99% interval spolehlivosti (134,1; 144,2)  
`[t.test(hosi,mu=136.1,conf.level=0.99)]` (vedlejší výsledek)  
`[confint(lm(hosi~1),level=0.99)]`
- ▶ aby byla zajištěna větší spolehlivost intervalu (větší pravděpodobnost, že zachytí skutečnou hodnotu), je nutně 99% interval spolehlivosti delší, než 95% interval spolehlivosti

## výšky hochů pro případ neznámého $\sigma$

- ▶ 95% interval spolehlivosti: (135,5; 142,8)  
s 95% pravděpodobností je skutečný populační průměr (střední hodnota  $\mu$ ) v uvedeném intervalu
- ▶ je jen 5% riziko, že leží mimo uvedený interval
- ▶ 99% interval spolehlivosti (134,1; 144,2)  
`[t.test(hosi,mu=136.1,conf.level=0.99)]` (vedlejší výsledek)  
`[confint(lm(hosi~1),level=0.99)]`
- ▶ aby byla zajištěna větší spolehlivost intervalu (větší pravděpodobnost, že zachytí skutečnou hodnotu), je nutně 99% interval spolehlivosti delší, než 95% interval spolehlivosti

## výšky hochů pro případ neznámého $\sigma$

- ▶ 95% interval spolehlivosti: (135,5; 142,8)  
s 95% pravděpodobností je skutečný populační průměr (střední hodnota  $\mu$ ) v uvedeném intervalu
- ▶ je jen 5% riziko, že leží mimo uvedený interval
- ▶ 99% interval spolehlivosti (134,1; 144,2)  
`[t.test(hosi,mu=136.1,conf.level=0.99)]` (vedlejší výsledek)  
`[confint(lm(hosi~1),level=0.99)]`
- ▶ aby byla zajištěna větší spolehlivost intervalu (větší pravděpodobnost, že zachytí skutečnou hodnotu), je nutně 99% interval spolehlivosti delší, než 95% interval spolehlivosti

## souvislost s intervalem spolehlivosti pro $\mu$

při oboustranné alternativě

- ▶ oboustranný interval spolehlivosti pro  $\mu$  (viz str. 110)

$$\left( \bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha), \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha) \right)$$

- ▶  $\mu_0$  patří do intervalu spolehlivosti, právě když platí

$$|\bar{X} - \mu_0| < \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha)$$

- ▶ tedy, právě když se nezamítne hypotéza  $H_0 : \mu = \mu_0$  při oboustranné alternativě  $H_1 : \mu \neq \mu_0$
- ▶ interval spolehlivosti obsahuje takové hodnoty  $\mu_0$ , pro které bychom **nezamítli** hypotézu  $H_0 : \mu = \mu_0$
- ▶ podobně u jednostranných intervalů spolehlivosti a jednostranných alternativ

## souvislost s intervalem spolehlivosti pro $\mu$

při oboustranné alternativě

- ▶ oboustranný interval spolehlivosti pro  $\mu$  (viz str. 110)

$$\left( \bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha), \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha) \right)$$

- ▶  $\mu_0$  patří do intervalu spolehlivosti, právě když platí

$$|\bar{X} - \mu_0| < \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha)$$

- ▶ tedy, právě když se nezamítne hypotéza  $H_0 : \mu = \mu_0$  při oboustranné alternativě  $H_1 : \mu \neq \mu_0$
- ▶ interval spolehlivosti obsahuje takové hodnoty  $\mu_0$ , pro které bychom **nezamítli** hypotézu  $H_0 : \mu = \mu_0$
- ▶ podobně u jednostranných intervalů spolehlivosti a jednostranných alternativ

## souvislost s intervalem spolehlivosti pro $\mu$

při oboustranné alternativě

- ▶ oboustranný interval spolehlivosti pro  $\mu$  (viz str. 110)

$$\left( \bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha), \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha) \right)$$

- ▶  $\mu_0$  patří do intervalu spolehlivosti, právě když platí

$$|\bar{X} - \mu_0| < \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha)$$

- ▶ tedy, právě když se nezamítne hypotéza  $H_0 : \mu = \mu_0$  při oboustranné alternativě  $H_1 : \mu \neq \mu_0$
- ▶ interval spolehlivosti obsahuje takové hodnoty  $\mu_0$ , pro které bychom **nezamítli** hypotézu  $H_0 : \mu = \mu_0$
- ▶ podobně u jednostranných intervalů spolehlivosti a jednostranných alternativ

## souvislost s intervalem spolehlivosti pro $\mu$

při oboustranné alternativě

- ▶ oboustranný interval spolehlivosti pro  $\mu$  (viz str. 110)

$$\left( \bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha), \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha) \right)$$

- ▶  $\mu_0$  patří do intervalu spolehlivosti, právě když platí

$$|\bar{X} - \mu_0| < \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha)$$

- ▶ tedy, právě když se nezamítne hypotéza  $H_0 : \mu = \mu_0$  při oboustranné alternativě  $H_1 : \mu \neq \mu_0$
- ▶ interval spolehlivosti obsahuje takové hodnoty  $\mu_0$ , pro které bychom **nezamítli** hypotézu  $H_0 : \mu = \mu_0$
- ▶ podobně u jednostranných intervalů spolehlivosti a jednostranných alternativ

## souvislost s intervalem spolehlivosti pro $\mu$

při oboustranné alternativě

- ▶ oboustranný interval spolehlivosti pro  $\mu$  (viz str. 110)

$$\left( \bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha), \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha) \right)$$


- ▶  $\mu_0$  patří do intervalu spolehlivosti, právě když platí

$$|\bar{X} - \mu_0| < \frac{S_x}{\sqrt{n}} t_{n-1}(\alpha)$$

- ▶ tedy, právě když se nezamítne hypotéza  $H_0 : \mu = \mu_0$  při oboustranné alternativě  $H_1 : \mu \neq \mu_0$
- ▶ interval spolehlivosti obsahuje takové hodnoty  $\mu_0$ , pro které bychom **nezamítli** hypotézu  $H_0 : \mu = \mu_0$
- ▶ podobně u jednostranných intervalů spolehlivosti a jednostranných alternativ



## ověření předpokladu o normálním rozdělení



- ▶ **Shapirův-Wilkův test**
- ▶  $H_0$  : normální rozdělení s nějakými (neznámými) parametry
- ▶ `[shapiro.test(hosi)]`
- ▶  $W = 0,966, p = 80 \%$
- ▶ test hodnotí kvalitu přiblížení bodů k přímce na diagramu normality
- ▶ `[qqnorm(hosi);qqline(hosi)]`

# pravděpodobnost výskytu jevu

test hypotézy o parametru  $\pi$  binomického rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$   $H_0 : \pi = \pi_0$ :  

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{\hat{\pi} - \pi_0}{\text{S.E.}(\hat{\pi})} = \frac{\hat{\pi} - \pi_0}{\sqrt{\pi_0(1 - \pi_0)/n}} \sim N(0, 1)$$
- ▶ podobnost s intervalem spolehlivosti pro  $\pi$  na str. 116
- ▶ někdy s opravou na spojitost (Yates)

$$Z = \frac{|Y - n\pi_0| - 0,5}{\sqrt{n\pi_0(1 - \pi_0)}} \text{sign}(Y - n\pi_0) \sim N(0, 1)$$

- ▶  $H_1 : \pi \neq \pi_0$ : zamítnout pokud  $|Z| \geq z(\alpha/2)$
- ▶  $H_1 : \pi > \pi_0$ : zamítnout pokud  $Z \geq z(\alpha)$
- ▶  $H_1 : \pi < \pi_0$ : zamítnout pokud  $Z \leq -z(\alpha)$
- ▶ existuje přesný postup, bez použití aproximace

# pravděpodobnost výskytu jevu

test hypotézy o parametru  $\pi$  binomického rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$   $H_0 : \pi = \pi_0$ :  

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{\hat{\pi} - \pi_0}{\text{S.E.}(\hat{\pi})} = \frac{\hat{\pi} - \pi_0}{\sqrt{\pi_0(1 - \pi_0)/n}} \sim N(0, 1)$$
- ▶ podobnost s intervalem spolehlivosti pro  $\pi$  na str. 116
- ▶ někdy s opravou na spojitost (Yates)

$$Z = \frac{|Y - n\pi_0| - 0,5}{\sqrt{n\pi_0(1 - \pi_0)}} \text{sign}(Y - n\pi_0) \sim N(0, 1)$$

- ▶  $H_1 : \pi \neq \pi_0$ : zamítnout pokud  $|Z| \geq z(\alpha/2)$
- ▶  $H_1 : \pi > \pi_0$ : zamítnout pokud  $Z \geq z(\alpha)$
- ▶  $H_1 : \pi < \pi_0$ : zamítnout pokud  $Z \leq -z(\alpha)$
- ▶ existuje přesný postup, bez použití aproximace

# pravděpodobnost výskytu jevu

test hypotézy o parametru  $\pi$  binomického rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$   $H_0 : \pi = \pi_0$ :  

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{\hat{\pi} - \pi_0}{\text{S.E.}(\hat{\pi})} = \frac{\hat{\pi} - \pi_0}{\sqrt{\pi_0(1 - \pi_0)/n}} \sim N(0, 1)$$
- ▶ podobnost s intervalem spolehlivosti pro  $\pi$  na str. 116
- ▶ někdy s opravou na spojitost (Yates)

$$Z = \frac{|Y - n\pi_0| - 0,5}{\sqrt{n\pi_0(1 - \pi_0)}} \text{sign}(Y - n\pi_0) \sim N(0, 1)$$

- ▶  $H_1 : \pi \neq \pi_0$ : zamítnout pokud  $|Z| \geq z(\alpha/2)$
- ▶  $H_1 : \pi > \pi_0$ : zamítnout pokud  $Z \geq z(\alpha)$
- ▶  $H_1 : \pi < \pi_0$ : zamítnout pokud  $Z \leq -z(\alpha)$
- ▶ existuje přesný postup, bez použití aproximace

# pravděpodobnost výskytu jevu

test hypotézy o parametru  $\pi$  binomického rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$   $H_0 : \pi = \pi_0$ :  

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{\hat{\pi} - \pi_0}{\text{S.E.}(\hat{\pi})} = \frac{\hat{\pi} - \pi_0}{\sqrt{\pi_0(1 - \pi_0)/n}} \sim N(0, 1)$$
- ▶ podobnost s intervalem spolehlivosti pro  $\pi$  na str. 116
- ▶ někdy s opravou na spojitost (Yates)

$$Z = \frac{|Y - n\pi_0| - 0,5}{\sqrt{n\pi_0(1 - \pi_0)}} \text{sign}(Y - n\pi_0) \sim N(0, 1)$$

- ▶  $H_1 : \pi \neq \pi_0$ : zamítnout pokud  $|Z| \geq z(\alpha/2)$
- ▶  $H_1 : \pi > \pi_0$ : zamítnout pokud  $Z \geq z(\alpha)$
- ▶  $H_1 : \pi < \pi_0$ : zamítnout pokud  $Z \leq -z(\alpha)$
- ▶ existuje přesný postup, bez použití aproximace

# pravděpodobnost výskytu jevu

test hypotézy o parametru  $\pi$  binomického rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$   $H_0 : \pi = \pi_0$ :  

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{\hat{\pi} - \pi_0}{\text{S.E.}(\hat{\pi})} = \frac{\hat{\pi} - \pi_0}{\sqrt{\pi_0(1 - \pi_0)/n}} \sim N(0, 1)$$
- ▶ podobnost s intervalem spolehlivosti pro  $\pi$  na str. 116
- ▶ někdy s opravou na spojitost (Yates)

$$Z = \frac{|Y - n\pi_0| - 0,5}{\sqrt{n\pi_0(1 - \pi_0)}} \text{sign}(Y - n\pi_0) \sim N(0, 1)$$

- ▶  $H_1 : \pi \neq \pi_0$ : zamítnout pokud  $|Z| \geq z(\alpha/2)$
- ▶  $H_1 : \pi > \pi_0$ : zamítnout pokud  $Z \geq z(\alpha)$
- ▶  $H_1 : \pi < \pi_0$ : zamítnout pokud  $Z \leq -z(\alpha)$
- ▶ existuje přesný postup, bez použití aproximace

# pravděpodobnost výskytu jevu

test hypotézy o parametru  $\pi$  binomického rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$   $H_0 : \pi = \pi_0$ :  

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{\hat{\pi} - \pi_0}{\text{S.E.}(\hat{\pi})} = \frac{\hat{\pi} - \pi_0}{\sqrt{\pi_0(1 - \pi_0)/n}} \sim N(0, 1)$$
- ▶ podobnost s intervalem spolehlivosti pro  $\pi$  na str. 116
- ▶ někdy s opravou na spojitost (Yates)

$$Z = \frac{|Y - n\pi_0| - 0,5}{\sqrt{n\pi_0(1 - \pi_0)}} \text{sign}(Y - n\pi_0) \sim N(0, 1)$$

- ▶  $H_1 : \pi \neq \pi_0$ : zamítnout pokud  $|Z| \geq z(\alpha/2)$
- ▶  $H_1 : \pi > \pi_0$ : zamítnout pokud  $Z \geq z(\alpha)$
- ▶  $H_1 : \pi < \pi_0$ : zamítnout pokud  $Z \leq -z(\alpha)$
- ▶ existuje přesný postup, bez použití aproximace

# pravděpodobnost výskytu jevu

test hypotézy o parametru  $\pi$  binomického rozdělení

- ▶  $Y \sim \text{bi}(n, \pi)$   $H_0 : \pi = \pi_0$ :  

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{\hat{\pi} - \pi_0}{\text{S.E.}(\hat{\pi})} = \frac{\hat{\pi} - \pi_0}{\sqrt{\pi_0(1 - \pi_0)/n}} \sim N(0, 1)$$
- ▶ podobnost s intervalem spolehlivosti pro  $\pi$  na str. 116
- ▶ někdy s opravou na spojitost (Yates)

$$Z = \frac{|Y - n\pi_0| - 0,5}{\sqrt{n\pi_0(1 - \pi_0)}} \text{sign}(Y - n\pi_0) \sim N(0, 1)$$

- ▶  $H_1 : \pi \neq \pi_0$ : zamítnout pokud  $|Z| \geq z(\alpha/2)$
- ▶  $H_1 : \pi > \pi_0$ : zamítnout pokud  $Z \geq z(\alpha)$
- ▶  $H_1 : \pi < \pi_0$ : zamítnout pokud  $Z \leq -z(\alpha)$
- ▶ existuje přesný postup, bez použití aproximace



## příklad kalous

- ▶ pokusit se prokázat, že kalous dá přednost infikované myši před myši neinfikovanou
- ▶  $Y$  – počet „zdarů“,  $n = 50$ ,  $\pi$  – pst, že zvolí infikovanou
- ▶  $Y$  má **binomické rozdělení**  
za  $H_0 : \pi = 1/2$  ( $= \pi_0$ , myši se neliší) je  $Y \sim \text{bi}(50, 1/2)$
- ▶ **alternativní hypotéza**:  $H_1 : \pi > 1/2$
- ▶ v pokusu z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou
- ▶ **kritický obor**: velká hodnota  $Y$  (tj. velké  $\hat{\pi}$  resp. velké  $Z$ )

$$z = \frac{33 - 50 \cdot 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,263 \quad p = P(Z \geq 2,263) = 0,0118$$

- ▶ s opravou na spojitost jsme opatrnější:

$$z = \frac{33 - 50 \cdot 0,5 - 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,121 \quad p = P(Z \geq 2,121) = 0,0169$$

## příklad kalous

- ▶ pokusit se prokázat, že kalous dá přednost infikované myši před myší neinfikovanou
- ▶  $Y$  – počet „zdarů“,  $n = 50$ ,  $\pi$  – pst, že zvolí infikovanou
- ▶  $Y$  má **binomické rozdělení**  
za  $H_0 : \pi = 1/2$  ( $= \pi_0$ , myši se neliší) je  $Y \sim \text{bi}(50, 1/2)$
- ▶ **alternativní hypotéza**:  $H_1 : \pi > 1/2$
- ▶ v pokusu z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou
- ▶ **kritický obor**: velká hodnota  $Y$  (tj. velké  $\hat{\pi}$  resp. velké  $Z$ )

$$z = \frac{33 - 50 \cdot 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,263 \quad p = P(Z \geq 2,263) = 0,0118$$

- ▶ s opravou na spojitost jsme opatrnější:

$$z = \frac{33 - 50 \cdot 0,5 - 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,121 \quad p = P(Z \geq 2,121) = 0,0169$$

## příklad kalous

- ▶ pokusit se prokázat, že kalous dá přednost infikované myši před myší neinfikovanou
- ▶  $Y$  – počet „zdarů“,  $n = 50$ ,  $\pi$  – pst, že zvolí infikovanou
- ▶  $Y$  má **binomické rozdělení**  
za  $H_0 : \pi = 1/2$  ( $= \pi_0$ , myši se neliší) je  $Y \sim \text{bi}(50, 1/2)$
- ▶ **alternativní hypotéza**:  $H_1 : \pi > 1/2$
- ▶ v pokusu z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou
- ▶ **kritický obor**: velká hodnota  $Y$  (tj. velké  $\hat{\pi}$  resp. velké  $Z$ )

$$z = \frac{33 - 50 \cdot 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,263 \quad p = P(Z \geq 2,263) = 0,0118$$

- ▶ s opravou na spojitost jsme opatrnější:

$$z = \frac{33 - 50 \cdot 0,5 - 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,121 \quad p = P(Z \geq 2,121) = 0,0169$$

## příklad kalous

- ▶ pokusit se prokázat, že kalous dá přednost infikované myši před myší neinfikovanou
- ▶  $Y$  – počet „zdarů“,  $n = 50$ ,  $\pi$  – pst, že zvolí infikovanou
- ▶  $Y$  má **binomické rozdělení**  
za  $H_0 : \pi = 1/2$  ( $= \pi_0$ , myši se neliší) je  $Y \sim \text{bi}(50, 1/2)$
- ▶ **alternativní hypotéza:**  $H_1 : \pi > 1/2$
- ▶ v pokusu z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou
- ▶ **kritický obor:** velká hodnota  $Y$  (tj. velké  $\hat{\pi}$  resp. velké  $Z$ )

$$z = \frac{33 - 50 \cdot 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,263 \quad p = P(Z \geq 2,263) = 0,0118$$

- ▶ s opravou na spojitost jsme opatrnější:

$$z = \frac{33 - 50 \cdot 0,5 - 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,121 \quad p = P(Z \geq 2,121) = 0,0169$$

## příklad kalous

- ▶ pokusit se prokázat, že kalous dá přednost infikované myši před myši neinfikovanou
- ▶  $Y$  – počet „zdarů“,  $n = 50$ ,  $\pi$  – pst, že zvolí infikovanou
- ▶  $Y$  má **binomické rozdělení**  
za  $H_0 : \pi = 1/2$  ( $= \pi_0$ , myši se neliší) je  $Y \sim \text{bi}(50, 1/2)$
- ▶ **alternativní hypotéza**:  $H_1 : \pi > 1/2$
- ▶ v pokusu z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou
- ▶ **kritický obor**: velká hodnota  $Y$  (tj. velké  $\hat{\pi}$  resp. velké  $Z$ )

$$z = \frac{33 - 50 \cdot 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,263 \quad p = P(Z \geq 2,263) = 0,0118$$

- ▶ s opravou na spojitost jsme opatrnější:

$$z = \frac{33 - 50 \cdot 0,5 - 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,121 \quad p = P(Z \geq 2,121) = 0,0169$$

## příklad kalous

- ▶ pokusit se prokázat, že kalous dá přednost infikované myši před myší neinfikovanou
- ▶  $Y$  – počet „zdarů“,  $n = 50$ ,  $\pi$  – pst, že zvolí infikovanou
- ▶  $Y$  má **binomické rozdělení**  
za  $H_0 : \pi = 1/2$  ( $= \pi_0$ , myši se neliší) je  $Y \sim \text{bi}(50, 1/2)$
- ▶ **alternativní hypotéza**:  $H_1 : \pi > 1/2$
- ▶ v pokusu z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou
- ▶ **kritický obor**: velká hodnota  $Y$  (tj. velké  $\hat{\pi}$  resp. velké  $Z$ )

$$z = \frac{33 - 50 \cdot 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,263 \quad p = P(Z \geq 2,263) = 0,0118$$

- ▶ s opravou na spojitost jsme opatrnější:

$$z = \frac{33 - 50 \cdot 0,5 - 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,121 \quad p = P(Z \geq 2,121) = 0,0169$$

## příklad kalous

- ▶ pokusit se prokázat, že kalous dá přednost infikované myši před myši neinfikovanou
- ▶  $Y$  – počet „zdarů“,  $n = 50$ ,  $\pi$  – pst, že zvolí infikovanou
- ▶  $Y$  má **binomické rozdělení**  
za  $H_0 : \pi = 1/2$  ( $= \pi_0$ , myši se neliší) je  $Y \sim \text{bi}(50, 1/2)$
- ▶ **alternativní hypotéza**:  $H_1 : \pi > 1/2$
- ▶ v pokusu z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou
- ▶ **kritický obor**: velká hodnota  $Y$  (tj. velké  $\hat{\pi}$  resp. velké  $Z$ )

$$z = \frac{33 - 50 \cdot 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,263 \quad p = P(Z \geq 2,263) = 0,0118$$

- ▶ s opravou na spojitost jsme opatrnější:

$$z = \frac{33 - 50 \cdot 0,5 - 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,121 \quad p = P(Z \geq 2,121) = 0,0169$$

## příklad kalous

- ▶ `prop.test()` počítá  $Z^2$ , která má za  $H_0$  : rozdělení  $\chi_1^2$   
`[prop.test(33,n=50,p=0.5,alternative="greater",correct=FALSE)]`  
`[prop.test(33,50,alternative="greater")]`  
`[binom.test(33,50,alternative="greater")]`
- ▶  $p$ -hodnota (dosažená hladina): za  $H_0$  počítaná  $pst$ , že dostaneme výsledek aspoň tolik odporující nulové hypotéze, jako ve skutečném pokusu:

$$\begin{aligned}
 p &= P(Y \geq 33) = 1 - P(Y \leq 32) \\
 &= \sum_{k=33}^{50} \binom{50}{k} 0,5^k (1 - 0,5)^{50-k} \\
 &= 0,0164
 \end{aligned}$$

`[1-pbinom(32,50,1/2)]`
`[sum(dbinom(33:50,50,0.5))]`



## příklad kalous

- ▶ `prop.test()` počítá  $Z^2$ , která má za  $H_0$  : rozdělení  $\chi_1^2$   
`[prop.test(33,n=50,p=0.5,alternative="greater",correct=FALSE)]`  
`[prop.test(33,50,alternative="greater")]`  
`[binom.test(33,50,alternative="greater")]`
- ▶ **p-hodnota (dosažená hladina)**: za  $H_0$  počítaná pst, že dostaneme výsledek aspoň tolik odporující nulové hypotéze, jako ve skutečném pokusu:

$$\begin{aligned}
 p &= P(Y \geq 33) = 1 - P(Y \leq 32) \\
 &= \sum_{k=33}^{50} \binom{50}{k} 0,5^k (1 - 0,5)^{50-k} \\
 &= 0,0164
 \end{aligned}$$

`[1-pbinom(32,50,1/2)]`
`[sum(dbinom(33:50,50,0.5))]`

# párové testy

(převědou úlohu na jednovýběrové testy)

- ▶  $(U_1, V_1), \dots, (U_n, V_n)$  – párová pozorování  
**nezávislé** dvojice (možná) závislých náhodných veličin
- ▶  $U_i, V_i$  – dvojice měření na stejných jedincích, např. hodnota zjištěná před ošetřením a po něm
- ▶ např. výška otce a jeho syna nebo věk otce a věk matky
- ▶ **nezajímá nás** zda je mezi nimi **závislost**, tu připouštíme, těsná závislost uvnitř dvojic je dokonce výhodná
- ▶ **zajímá nás zda jsou co do polohy stejné**, nebo např. synové v (populačním) průměru vyšší, než otcové
- ▶  $X_i = U_i - V_i$  (označení rozdílů)
- ▶ předp. **stejný druh rozdělení**  $X_1, \dots, X_n$  (např. normální)
- ▶  $H_0$  tvrdí, že např. mezi výškami otců a synů **není rozdíl**, tedy že rozdíly  $X_i$  **kolísají kolem nuly**: populační míra polohy rozdílů je nulová (např. populační průměr – střední hodnota)

## párové testy

(převědou úlohu na jednovýběrové testy)

- ▶  $(U_1, V_1), \dots, (U_n, V_n)$  – párová pozorování  
**nezávislé** dvojice (možná) závislých náhodných veličin
- ▶  $U_i, V_i$  – dvojice měření na stejných jedincích, např. hodnota zjištěná před ošetřením a po něm
- ▶ např. výška otce a jeho syna nebo věk otce a věk matky
- ▶ **nezajímá nás** zda je mezi nimi **závislost**, tu připouštíme, těsná závislost uvnitř dvojic je dokonce výhodná
- ▶ **zajímá nás zda jsou co do polohy stejné**, nebo např. synové v (populačním) průměru vyšší, než otcové
- ▶  $X_i = U_i - V_i$  (označení rozdílů)
- ▶ předp. **stejný druh rozdělení**  $X_1, \dots, X_n$  (např. normální)
- ▶  $H_0$  tvrdí, že např. mezi výškami otců a synů **není rozdíl**, tedy že rozdíly  $X_i$  **kolísají kolem nuly**: populační míra polohy rozdílů je nulová (např. populační průměr – střední hodnota)

# párové testy

(převědou úlohu na jednovýběrové testy)

- ▶  $(U_1, V_1), \dots, (U_n, V_n)$  – párová pozorování **nezávislé** dvojice (možná) závislých náhodných veličin
- ▶  $U_i, V_i$  – dvojice měření na stejných jedincích, např. hodnota zjištěná před ošetřením a po něm
- ▶ např. výška otce a jeho syna nebo věk otce a věk matky
- ▶ **nezajímá nás** zda je mezi nimi **závislost**, tu připouštíme, těsná závislost uvnitř dvojic je dokonce výhodná
- ▶ **zajímá nás** zda jsou **co do polohy stejné**, nebo např. synové v (populačním) průměru vyšší, než otcové
- ▶  $X_i = U_i - V_i$  (označení rozdílů)
- ▶ předp. **stejný druh rozdělení**  $X_1, \dots, X_n$  (např. normální)
- ▶  $H_0$  tvrdí, že např. mezi výškami otců a synů **není rozdíl**, tedy že rozdílly  $X_i$  **kolísají kolem nuly**: populační míra polohy rozdílů je nulová (např. populační průměr – střední hodnota)

# párové testy

(převědou úlohu na jednovýběrové testy)

- ▶  $(U_1, V_1), \dots, (U_n, V_n)$  – párová pozorování  
**nezávislé** dvojice (možná) závislých náhodných veličin
- ▶  $U_i, V_i$  – dvojice měření na stejných jedincích, např. hodnota zjištěná před ošetřením a po něm
- ▶ např. výška otce a jeho syna nebo věk otce a věk matky
- ▶ **nezajímá nás** zda je mezi nimi **závislost**, tu připouštíme, těsná závislost uvnitř dvojic je dokonce výhodná
- ▶ **zajímá nás** zda jsou **co do polohy stejné**, nebo např. synové v (populačním) průměru vyšší, než otcové
- ▶  $X_i = U_i - V_i$  (označení rozdílů)
- ▶ předp. **stejný druh rozdělení**  $X_1, \dots, X_n$  (např. normální)
- ▶  $H_0$  tvrdí, že např. mezi výškami otců a synů **není rozdíl**, tedy že rozdíly  $X_i$  **kolísají kolem nuly**: populační míra polohy rozdílů je nulová (např. populační průměr – střední hodnota)

## párové testy

(převědou úlohu na jednovýběrové testy)

- ▶  $(U_1, V_1), \dots, (U_n, V_n)$  – párová pozorování  
**nezávislé** dvojice (možná) závislých náhodných veličin
- ▶  $U_i, V_i$  – dvojice měření na stejných jedincích, např. hodnota zjištěná před ošetřením a po něm
- ▶ např. výška otce a jeho syna nebo věk otce a věk matky
- ▶ **nezajímá nás** zda je mezi nimi **závislost**, tu připouštíme, těsná závislost uvnitř dvojic je dokonce výhodná
- ▶ **zajímá nás zda jsou co do polohy stejné**, nebo např. synové v (populačním) průměru vyšší, než otcové
- ▶  $X_i = U_i - V_i$  (označení rozdílů)
- ▶ předp. **stejný druh rozdělení**  $X_1, \dots, X_n$  (např. normální)
- ▶  $H_0$  tvrdí, že např. mezi výškami otců a synů **není rozdíl**, tedy že rozdílů  $X_i$  **kolísají kolem nuly**: populační míra polohy rozdílů je nulová (např. populační průměr – střední hodnota)

## párové testy

(převědou úlohu na jednovýběrové testy)

- ▶  $(U_1, V_1), \dots, (U_n, V_n)$  – párová pozorování  
**nezávislé** dvojice (možná) závislých náhodných veličin
- ▶  $U_i, V_i$  – dvojice měření na stejných jedincích, např. hodnota zjištěná před ošetřením a po něm
- ▶ např. výška otce a jeho syna nebo věk otce a věk matky
- ▶ **nezajímá nás** zda je mezi nimi **závislost**, tu připouštíme, těsná závislost uvnitř dvojic je dokonce výhodná
- ▶ **zajímá nás zda** jsou **co do polohy stejné**, nebo např. synové v (populačním) průměru vyšší, než otcové
- ▶  $X_i = U_i - V_i$  (označení rozdílů)
- ▶ předp. **stejný druh rozdělení**  $X_1, \dots, X_n$  (např. normální)
- ▶  $H_0$  tvrdí, že např. mezi výškami otců a synů **není rozdíl**, tedy že rozdílů  $X_i$  **kolísají kolem nuly**: populační míra polohy rozdílů je nulová (např. populační průměr – střední hodnota)

## párové testy

(převědou úlohu na jednovýběrové testy)

- ▶  $(U_1, V_1), \dots, (U_n, V_n)$  – párová pozorování  
**nezávislé** dvojice (možná) závislých náhodných veličin
- ▶  $U_i, V_i$  – dvojice měření na stejných jedincích, např. hodnota zjištěná před ošetřením a po něm
- ▶ např. výška otce a jeho syna nebo věk otce a věk matky
- ▶ **nezajímá nás** zda je mezi nimi **závislost**, tu připouštíme, těsná závislost uvnitř dvojic je dokonce výhodná
- ▶ **zajímá nás zda** jsou **co do polohy stejné**, nebo např. synové v (populačním) průměru vyšší, než otcové
- ▶  $X_i = U_i - V_i$  (označení rozdílů)
- ▶ předp. **stejný druh rozdělení**  $X_1, \dots, X_n$  (např. normální)
- ▶  $H_0$  tvrdí, že např. mezi výškami otců a synů **není rozdíl**, tedy že rozdíly  $X_i$  **kolísají kolem nuly**: populační míra polohy rozdílů je nulová (např. populační průměr – střední hodnota)



## párové testy

(převědou úlohu na jednovýběrové testy)

- ▶  $(U_1, V_1), \dots, (U_n, V_n)$  – párová pozorování  
**nezávislé** dvojice (možná) závislých náhodných veličin
- ▶  $U_i, V_i$  – dvojice měření na stejných jedincích, např. hodnota zjištěná před ošetřením a po něm
- ▶ např. výška otce a jeho syna nebo věk otce a věk matky
- ▶ **nezajímá nás** zda je mezi nimi **závislost**, tu připouštíme, těsná závislost uvnitř dvojic je dokonce výhodná
- ▶ **zajímá nás zda** jsou **co do polohy stejné**, nebo např. synové v (populačním) průměru vyšší, než otcové
- ▶  $X_i = U_i - V_i$  (označení rozdílů)
- ▶ předp. **stejný druh rozdělení**  $X_1, \dots, X_n$  (např. normální)
- ▶  $H_0$  tvrdí, že např. mezi výškami otců a synů **není rozdíl**, tedy že rozdíly  $X_i$  **kolísají kolem nuly**: populační míra polohy rozdílů je nulová (např. populační průměr – střední hodnota)

## párový $t$ -test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový  $t$ -test** pro  $X_i = U_i - V_i$
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )
- ▶ odhad  $\sigma^2$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$
- ▶ 
$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$$
- ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
- ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
- ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$

## párový $t$ -test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový  $t$ -test** pro  $X_i = U_i - V_i$
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )
- ▶ odhad  $\sigma^2$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$
- ▶ 
$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$$
- ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
- ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
- ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$

## párový $t$ -test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový  $t$ -test** pro  $X_i = U_i - V_i$
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )

▶ odhad  $\sigma^2$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

▶ 
$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$$

- ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
- ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
- ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$

## párový $t$ -test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový  $t$ -test** pro  $X_i = U_i - V_i$
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )

▶ odhad  $\sigma^2$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

▶ 
$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$$

- ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
- ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
- ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$

## párový $t$ -test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový  $t$ -test** pro  $X_i = U_i - V_i$
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )

▶ odhad  $\sigma^2$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

▶ 
$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$$

- ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
- ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
- ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$

## párový $t$ -test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový  $t$ -test** pro  $X_i = U_i - V_i$
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )
- ▶ odhad  $\sigma^2$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$
- ▶ 
$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$$
  - ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
  - ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
  - ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$

## párový t-test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový t-test** pro  $X_i = U_i - V_i$
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )
- ▶ odhad  $\sigma^2$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$
- ▶ 
$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$$
- ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
- ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
- ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$



## párový $t$ -test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový  $t$ -test** pro  $X_i = U_i - V_i$
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )
- ▶ odhad  $\sigma^2$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$
- ▶ 
$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$$
- ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
- ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
- ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$

## párový t-test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový t-test** pro  $X_i = U_i - V_i$
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )
- ▶ odhad  $\sigma^2$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$
- ▶ 
$$T = \frac{\bar{X} - \mu_0}{\text{S.E.}(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$$
- ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
- ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
- ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$

## příklad: výšky rodičů (párová pozorování!)

$H_0$ : otcové jsou o 10 cm vyšší než matky,  $H_1$  oboustranná

- ▶  $U$  – výška otce,  $V$  – výška matky,  $X = U - V$
- ▶  $\alpha = 0,05$ ,  $H_0 : \mu_U = \mu_V + 10$  resp.  $\mu_U - \mu_V = 10$
- ▶  $n = 99$ ,  $\bar{u} = 179,267$ ,  $\bar{v} = 166,970$
- ▶  $\bar{x} = \bar{u} - \bar{v} = 12,293$ ,  $s_X = s_{U-V} = 8,144$
- ▶  $t = \frac{12,293-10}{8,144} \sqrt{99} = 2,801$ , tedy  
 $|t| > t_{98}(0,05) = 1,9845 \Rightarrow$  zamítnout  $H_0$
- ▶  $p = P(|T| \geq |t|) = 0,0061$  (0,61 %)
- ▶ 95% interval spolehlivosti pro  $\mu_U - \mu_V$ :

$$\left( 12,293 - \frac{8,144}{\sqrt{99}} 1,9845 ; 12,293 + \frac{8,144}{\sqrt{99}} 1,9845 \right) = (10,67; 13,92)$$

[shapiro.test(vyska.o-vyska.m)]

ověření normality

[t.test(vyska.o,vyska.m, mu=10, paired=TRUE)]

[t.test(vyska.o-vyska.m, mu=10)]

## příklad: výšky rodičů (párová pozorování!)

$H_0$ : otcové jsou o 10 cm vyšší než matky,  $H_1$  oboustranná

- ▶  $U$  – výška otce,  $V$  – výška matky,  $X = U - V$
- ▶  $\alpha = 0,05$ ,  $H_0 : \mu_U = \mu_V + 10$  resp.  $\mu_U - \mu_V = 10$
- ▶  $n = 99$ ,  $\bar{u} = 179,267$ ,  $\bar{v} = 166,970$
- ▶  $\bar{x} = \bar{u} - \bar{v} = 12,293$ ,  $s_X = s_{U-V} = 8,144$
- ▶  $t = \frac{12,293-10}{8,144} \sqrt{99} = 2,801$ , tedy  
 $|t| > t_{98}(0,05) = 1,9845 \Rightarrow$  zamítnout  $H_0$
- ▶  $p = P(|T| \geq |t|) = 0,0061$  (0,61 %)
- ▶ 95% interval spolehlivosti pro  $\mu_U - \mu_V$ :

$$\left( 12,293 - \frac{8,144}{\sqrt{99}} 1,9845 ; 12,293 + \frac{8,144}{\sqrt{99}} 1,9845 \right) = (10,67; 13,92)$$

[shapiro.test(vyska.o-vyska.m)]

ověření normality

[t.test(vyska.o,vyska.m, mu=10, paired=TRUE)]

[t.test(vyska.o-vyska.m, mu=10)]

## příklad: výšky rodičů (párová pozorování!)

$H_0$ : otcové jsou o 10 cm vyšší než matky,  $H_1$  oboustranná

- ▶  $U$  – výška otce,  $V$  – výška matky,  $X = U - V$
- ▶  $\alpha = 0,05$ ,  $H_0 : \mu_U = \mu_V + 10$  resp.  $\mu_U - \mu_V = 10$
- ▶  $n = 99$ ,  $\bar{u} = 179,267$ ,  $\bar{v} = 166,970$
- ▶  $\bar{x} = \bar{u} - \bar{v} = 12,293$ ,  $s_X = s_{U-V} = 8,144$
- ▶  $t = \frac{12,293-10}{8,144} \sqrt{99} = 2,801$ , tedy  
 $|t| > t_{98}(0,05) = 1,9845 \Rightarrow$  zamítnout  $H_0$
- ▶  $p = P(|T| \geq |t|) = 0,0061$  (0,61 %)
- ▶ 95% interval spolehlivosti pro  $\mu_U - \mu_V$ :

$$\left( 12,293 - \frac{8,144}{\sqrt{99}} 1,9845 ; 12,293 + \frac{8,144}{\sqrt{99}} 1,9845 \right) = (10,67; 13,92)$$

[shapiro.test(vyska.o-vyska.m)] ověření normality

[t.test(vyska.o,vyska.m, mu=10, paired=TRUE)]

[t.test(vyska.o-vyska.m, mu=10)]

## příklad: výšky rodičů (párová pozorování!)

$H_0$ : otcové jsou o 10 cm vyšší než matky,  $H_1$  oboustranná

- ▶  $U$  – výška otce,  $V$  – výška matky,  $X = U - V$
- ▶  $\alpha = 0,05$ ,  $H_0 : \mu_U = \mu_V + 10$  resp.  $\mu_U - \mu_V = 10$
- ▶  $n = 99$ ,  $\bar{u} = 179,267$ ,  $\bar{v} = 166,970$
- ▶  $\bar{x} = \bar{u} - \bar{v} = 12,293$ ,  $s_X = s_{U-V} = 8,144$
- ▶  $t = \frac{12,293-10}{8,144} \sqrt{99} = 2,801$ , tedy  
 $|t| > t_{98}(0,05) = 1,9845 \Rightarrow$  zamítnout  $H_0$
- ▶  $p = P(|T| \geq |t|) = 0,0061$  (0,61 %)
- ▶ 95% interval spolehlivosti pro  $\mu_U - \mu_V$ :

$$\left( 12,293 - \frac{8,144}{\sqrt{99}} 1,9845 ; 12,293 + \frac{8,144}{\sqrt{99}} 1,9845 \right) = (10,67; 13,92)$$

[shapiro.test(vyska.o-vyska.m)] ověření normality

[t.test(vyska.o,vyska.m, mu=10, paired=TRUE)]

[t.test(vyska.o-vyska.m, mu=10)]

## příklad: výšky rodičů (párová pozorování!)

$H_0$ : otcové jsou o 10 cm vyšší než matky,  $H_1$  oboustranná

- ▶  $U$  – výška otce,  $V$  – výška matky,  $X = U - V$
- ▶  $\alpha = 0,05$ ,  $H_0 : \mu_U = \mu_V + 10$  resp.  $\mu_U - \mu_V = 10$
- ▶  $n = 99$ ,  $\bar{u} = 179,267$ ,  $\bar{v} = 166,970$
- ▶  $\bar{x} = \bar{u} - \bar{v} = 12,293$ ,  $s_X = s_{U-V} = 8,144$
- ▶  $t = \frac{12,293-10}{8,144} \sqrt{99} = 2,801$ , tedy  
 $|t| > t_{98}(0,05) = 1,9845 \Rightarrow$  zamítnout  $H_0$
- ▶  $p = P(|T| \geq |t|) = 0,0061$  (0,61 %)
- ▶ 95% interval spolehlivosti pro  $\mu_U - \mu_V$ :

$$\left( 12,293 - \frac{8,144}{\sqrt{99}} 1,9845 ; 12,293 + \frac{8,144}{\sqrt{99}} 1,9845 \right) = (10,67; 13,92)$$

[shapiro.test(vyska.o-vyska.m)]

ověření normality

[t.test(vyska.o,vyska.m, mu=10, paired=TRUE)]

[t.test(vyska.o-vyska.m, mu=10)]

## příklad: výšky rodičů (párová pozorování!)

$H_0$ : otcové jsou o 10 cm vyšší než matky,  $H_1$  oboustranná

- ▶  $U$  – výška otce,  $V$  – výška matky,  $X = U - V$
- ▶  $\alpha = 0,05$ ,  $H_0 : \mu_U = \mu_V + 10$  resp.  $\mu_U - \mu_V = 10$
- ▶  $n = 99$ ,  $\bar{u} = 179,267$ ,  $\bar{v} = 166,970$
- ▶  $\bar{x} = \bar{u} - \bar{v} = 12,293$ ,  $s_X = s_{U-V} = 8,144$
- ▶  $t = \frac{12,293-10}{8,144} \sqrt{99} = 2,801$ , tedy  
 $|t| > t_{98}(0,05) = 1,9845 \Rightarrow$  zamítnout  $H_0$
- ▶  $p = P(|T| \geq |t|) = 0,0061$  (0,61 %)
- ▶ 95% interval spolehlivosti pro  $\mu_U - \mu_V$ :

$$\left( 12,293 - \frac{8,144}{\sqrt{99}} 1,9845 ; 12,293 + \frac{8,144}{\sqrt{99}} 1,9845 \right) = (10,67; 13,92)$$

[shapiro.test(vyska.o-vyska.m)]

ověření normality

[t.test(vyska.o,vyska.m, mu=10, paired=TRUE)]

[t.test(vyska.o-vyska.m, mu=10)]



## příklad: výšky rodičů (párová pozorování!)

$H_0$ : otcové jsou o 10 cm vyšší než matky,  $H_1$  oboustranná

- ▶  $U$  – výška otce,  $V$  – výška matky,  $X = U - V$
- ▶  $\alpha = 0,05$ ,  $H_0 : \mu_U = \mu_V + 10$  resp.  $\mu_U - \mu_V = 10$
- ▶  $n = 99$ ,  $\bar{u} = 179,267$ ,  $\bar{v} = 166,970$
- ▶  $\bar{x} = \bar{u} - \bar{v} = 12,293$ ,  $s_X = s_{U-V} = 8,144$
- ▶  $t = \frac{12,293-10}{8,144} \sqrt{99} = 2,801$ , tedy  
 $|t| > t_{98}(0,05) = 1,9845 \Rightarrow$  zamítnout  $H_0$
- ▶  $p = P(|T| \geq |t|) = 0,0061$  (0,61 %)
- ▶ 95% interval spolehlivosti pro  $\mu_U - \mu_V$ :

$$\left( 12,293 - \frac{8,144}{\sqrt{99}} 1,9845 ; 12,293 + \frac{8,144}{\sqrt{99}} 1,9845 \right) = (10,67; 13,92)$$

[shapiro.test(vyska.o-vyska.m)]

ověření normality

[t.test(vyska.o,vyska.m, mu=10, paired=TRUE)]

[t.test(vyska.o-vyska.m, mu=10)]

## znaménkový test

bez předpokladu normálního rozdělení, stačí libovolné **spojité** rozdělení

- ▶ stačí znát znaménka rozdílů  $X_i = U_i - V_i$
- ▶ pozorování s  $U_i = V_i$  (tj.  $X_i = 0$ ) se vynechají, upraví se  $n$
- ▶  $Y$  – počet **kladných** znamének  $X_i = U_i - V_i$
- ▶  $H_0$  : rozdělení  $U$  a  $V$  jsou stejná, pak je nutně  $P(U_i > V_i) = P(X_i > 0) = 1/2$ , tedy  $Y \sim \text{bi}(n, 1/2)$
- ▶  $H_0$  zamítáme pro velká nebo malá  $Y$ :

$$Z = \frac{Y - n/2}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

- ▶ pro malá  $n$  je bezpečnější použít Yatesovu korekci

$$Z = \frac{|Y - n/2| - 0,5}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

## znaménkový test

bez předpokladu normálního rozdělení, stačí libovolné **spojité** rozdělení

- ▶ stačí znát znaménka rozdílů  $X_i = U_i - V_i$
- ▶ pozorování s  $U_i = V_i$  (tj.  $X_i = 0$ ) se vynechají, upraví se  $n$
- ▶  $Y$  – počet **kladných** znamének  $X_i = U_i - V_i$
- ▶  $H_0$  : rozdělení  $U$  a  $V$  jsou stejná, pak je nutně  $P(U_i > V_i) = P(X_i > 0) = 1/2$ , tedy  $Y \sim \text{bi}(n, 1/2)$
- ▶  $H_0$  zamítáme pro velká nebo malá  $Y$ :

$$Z = \frac{Y - n/2}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

- ▶ pro malá  $n$  je bezpečnější použít Yatesovu korekci

$$Z = \frac{|Y - n/2| - 0,5}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

## znaménkový test

bez předpokladu normálního rozdělení, stačí libovolné **spojité** rozdělení

- ▶ stačí znát znaménka rozdílů  $X_i = U_i - V_i$
- ▶ pozorování s  $U_i = V_i$  (tj.  $X_i = 0$ ) se vynechají, upraví se  $n$
- ▶  $Y$  – počet **kladných** znamének  $X_i = U_i - V_i$
- ▶  $H_0$  : rozdělení  $U$  a  $V$  jsou stejná, pak je nutně  $P(U_i > V_i) = P(X_i > 0) = 1/2$ , tedy  $Y \sim \text{bi}(n, 1/2)$
- ▶  $H_0$  zamítáme pro velká nebo malá  $Y$ :

$$Z = \frac{Y - n/2}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

- ▶ pro malá  $n$  je bezpečnější použít Yatesovu korekci

$$Z = \frac{|Y - n/2| - 0,5}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

## znaménkový test

bez předpokladu normálního rozdělení, stačí libovolné **spojité** rozdělení

- ▶ stačí znát znaménka rozdílů  $X_i = U_i - V_i$
- ▶ pozorování s  $U_i = V_i$  (tj.  $X_i = 0$ ) se vynechají, upraví se  $n$
- ▶  $Y$  – počet **kladných** znamének  $X_i = U_i - V_i$
- ▶  $H_0$  : rozdělení  $U$  a  $V$  jsou stejná, pak je nutně  $P(U_i > V_i) = P(X_i > 0) = 1/2$ , tedy  $Y \sim \text{bi}(n, 1/2)$
- ▶  $H_0$  zamítáme pro velká nebo malá  $Y$ :

$$Z = \frac{Y - n/2}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

- ▶ pro malá  $n$  je bezpečnější použít Yatesovu korekci

$$Z = \frac{|Y - n/2| - 0,5}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

## znaménkový test

bez předpokladu normálního rozdělení, stačí libovolné **spojité** rozdělení

- ▶ stačí znát znaménka rozdílů  $X_i = U_i - V_i$
- ▶ pozorování s  $U_i = V_i$  (tj.  $X_i = 0$ ) se vynechají, upraví se  $n$
- ▶  $Y$  – počet **kladných** znamének  $X_i = U_i - V_i$
- ▶  $H_0$  : rozdělení  $U$  a  $V$  jsou stejná, pak je nutně  $P(U_i > V_i) = P(X_i > 0) = 1/2$ , tedy  $Y \sim \text{bi}(n, 1/2)$
- ▶  $H_0$  zamítáme pro velká nebo malá  $Y$ :

$$Z = \frac{Y - n/2}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

- ▶ pro malá  $n$  je bezpečnější použít Yatesovu korekci

$$Z = \frac{|Y - n/2| - 0,5}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

## znaménkový test

bez předpokladu normálního rozdělení, stačí libovolné **spojité** rozdělení

- ▶ stačí znát znaménka rozdílů  $X_i = U_i - V_i$
- ▶ pozorování s  $U_i = V_i$  (tj.  $X_i = 0$ ) se vynechají, upraví se  $n$
- ▶  $Y$  – počet **kladných** znamének  $X_i = U_i - V_i$
- ▶  $H_0$  : rozdělení  $U$  a  $V$  jsou stejná, pak je nutně  $P(U_i > V_i) = P(X_i > 0) = 1/2$ , tedy  $Y \sim \text{bi}(n, 1/2)$
- ▶  $H_0$  zamítáme pro velká nebo malá  $Y$ :

$$Z = \frac{Y - n/2}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

- ▶ pro malá  $n$  je bezpečnější použít Yatesovu korekci

$$Z = \frac{|Y - n/2| - 0,5}{\sqrt{n/4}}, \quad |Z| \geq z(\alpha/2)$$

## příklad: věk rodičů (párová pozorování!)

normalitu rozdílu věku rodičů sotva lze předpokládat

- ▶ celkem 99 dvojic (otec, matka), sledujeme jejich věk ( $U, V$ )
- ▶  $H_0 : \mu_U = \mu_V + 2$  (populační míra polohy věku otců je o 2 roky větší, než matek),  $H_1$  oboustranná
- ▶ v jedenácti případech je vek.o – vek.m = 2, tyto dvojice nepoužijeme, proto  $n = 99 - 11 = 88$
- ▶ u 50 dvojic je vek.o – vek.m > 2, proto

$$z = \frac{50 - 88/2}{\sqrt{88/4}} = 1,279, \quad p = 0,201 \text{ (20,1 \%)}$$

- ▶ s Yatesovou korekcí:  $z = 1,172, p = 0,241 \text{ (24,1 \%)}$

```
[n = sum(vek.o-vek.m != 2)]
[y = sum(vek.o-vek.m > 2)]
[prop.test(y,n,correct=FALSE)]
[prop.test(y,n,correct=TRUE)]
```

počet nenulových  $X_i$   
 počet kladných  $X_i$   
 bez Yatesovy korekce  
 s Yatesovou korekcí



## příklad: věk rodičů (párová pozorování!)

normalitu rozdílu věku rodičů sotva lze předpokládat

- ▶ celkem 99 dvojic (otec, matka), sledujeme jejich věk ( $U, V$ )
- ▶  $H_0 : \mu_U = \mu_V + 2$  (populační míra polohy věku otců je o 2 roky větší, než matek),  $H_1$  oboustranná
- ▶ v jedenácti případech je vek.o – vek.m = 2, tyto dvojice nepoužijeme, proto  $n = 99 - 11 = 88$
- ▶ u 50 dvojic je vek.o – vek.m > 2, proto

$$z = \frac{50 - 88/2}{\sqrt{88/4}} = 1,279, \quad p = 0,201 \text{ (20,1 \%)}$$

- ▶ s Yatesovou korekcí:  $z = 1,172, p = 0,241 \text{ (24,1 \%)}$

```
[n = sum(vek.o-vek.m != 2)]
[y = sum(vek.o-vek.m > 2)]
[prop.test(y,n,correct=FALSE)]
[prop.test(y,n,correct=TRUE)]
```

počet nenulových  $X_i$   
 počet kladných  $X_i$   
 bez Yatesovy korekce  
 s Yatesovou korekcí

## příklad: věk rodičů (párová pozorování!)

normalitu rozdílu věku rodičů sotva lze předpokládat

- ▶ celkem 99 dvojic (otec, matka), sledujeme jejich věk ( $U, V$ )
- ▶  $H_0 : \mu_U = \mu_V + 2$  (populační míra polohy věku otců je o 2 roky větší, než matek),  $H_1$  oboustranná
- ▶ v jedenácti případech je vek.o – vek.m = 2, tyto dvojice nepoužijeme, proto  $n = 99 - 11 = 88$
- ▶ u 50 dvojic je vek.o – vek.m > 2, proto

$$z = \frac{50 - 88/2}{\sqrt{88/4}} = 1,279, \quad p = 0,201 \text{ (20,1 \%)}$$

- ▶ s Yatesovou korekcí:  $z = 1,172, p = 0,241 \text{ (24,1 \%)}$

```
[n = sum(vek.o-vek.m != 2)]
[y = sum(vek.o-vek.m > 2)]
[prop.test(y,n,correct=FALSE)]
[prop.test(y,n,correct=TRUE)]
```

počet nenulových  $X_i$   
 počet kladných  $X_i$   
 bez Yatesovy korekce  
 s Yatesovou korekcí

## příklad: věk rodičů (párová pozorování!)

normalitu rozdílu věku rodičů sotva lze předpokládat

- ▶ celkem 99 dvojic (otec, matka), sledujeme jejich věk ( $U, V$ )
- ▶  $H_0 : \mu_U = \mu_V + 2$  (populační míra polohy věku otců je o 2 roky větší, než matek),  $H_1$  oboustranná
- ▶ v jedenácti případech je vek.o – vek.m = 2, tyto dvojice nepoužijeme, proto  $n = 99 - 11 = 88$
- ▶ u 50 dvojic je vek.o – vek.m > 2, proto

$$z = \frac{50 - 88/2}{\sqrt{88/4}} = 1,279, \quad p = 0,201 \text{ (20,1 \%)}$$

- ▶ s Yatesovou korekcí:  $z = 1,172, p = 0,241 \text{ (24,1 \%)}$

$[n = \text{sum}(\text{vek.o-vek.m} \neq 2)]$

$[y = \text{sum}(\text{vek.o-vek.m} > 2)]$

$[\text{prop.test}(y,n,\text{correct}=\text{FALSE})]$

$[\text{prop.test}(y,n,\text{correct}=\text{TRUE})]$

počet nenulových  $X_i$

počet kladných  $X_i$

bez Yatesovy korekce

s Yatesovou korekcí

## příklad: věk rodičů (párová pozorování!)

normalitu rozdílu věku rodičů sotva lze předpokládat

- ▶ celkem 99 dvojic (otec, matka), sledujeme jejich věk ( $U, V$ )
- ▶  $H_0 : \mu_U = \mu_V + 2$  (populační míra polohy věku otců je o 2 roky větší, než matek),  $H_1$  oboustranná
- ▶ v jedenácti případech je vek.o – vek.m = 2, tyto dvojice nepoužijeme, proto  $n = 99 - 11 = 88$
- ▶ u 50 dvojic je vek.o – vek.m > 2, proto

$$z = \frac{50 - 88/2}{\sqrt{88/4}} = 1,279, \quad p = 0,201 \text{ (20,1 \%)}$$

- ▶ s Yatesovou korekcí:  $z = 1,172, p = 0,241 \text{ (24,1 \%)}$

$[n = \text{sum}(\text{vek.o-vek.m} \neq 2)]$

$[y = \text{sum}(\text{vek.o-vek.m} > 2)]$

$[\text{prop.test}(y,n,\text{correct}=\text{FALSE})]$

$[\text{prop.test}(y,n,\text{correct}=\text{TRUE})]$

počet nenulových  $X_i$

počet kladných  $X_i$

bez Yatesovy korekce

s Yatesovou korekcí

## párový Wilcoxonův test [Wilcoxon signed rank test]

(silnější předpoklad, než u znaménkového testu)

- ▶ nutné **spojité a symetrické** rozdělení  $X_i = U_i - V_i$
- ▶  $H_0$  : populační medián  $X_i$  je roven 0 (tj.  $P(X_i > 0) = 0,5$ )
- ▶ opět vyloučíme případy  $U_i = V_i$  (tj.  $X_i = 0$ )
- ▶ určíme pořadí  $R_i^+$  absolutních hodnot  $|X_i| = |U_i - V_i|$
- ▶  $W$  součet těch pořadí, kde bylo  $U_i > V_i$  (tj.  $X_i > 0$ )

$$Z = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}}$$

- ▶ pod odmocninou bývá ještě oprava na výskyt shodných hodnot, která jmenovatele poněkud zmenší  
[`wilcox.test(vyska.o,vyska.m,mu=10,paired=TRUE)`]
- ▶ pro malá  $n$  se číselník zpravidla přibližuje o 1/2 k nule:  
(všimněte si zkrácených názvů parametrů – jednoznačnost!)  
[`wilcox.test(vyska.o,vyska.m,m=10,p=TRUE,cor=FALSE)`]

## párový Wilcoxonův test [Wilcoxon signed rank test]

(silnější předpoklad, než u znaménkového testu)

- ▶ nutné **spojité a symetrické** rozdělení  $X_i = U_i - V_i$
- ▶  $H_0$  : populační medián  $X_i$  je roven 0 (tj.  $P(X_i > 0) = 0,5$ )
- ▶ opět vyloučíme případy  $U_i = V_i$  (tj.  $X_i = 0$ )
- ▶ určíme pořadí  $R_i^+$  absolutních hodnot  $|X_i| = |U_i - V_i|$
- ▶  $W$  součet těch pořadí, kde bylo  $U_i > V_i$  (tj.  $X_i > 0$ )

$$Z = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}}$$

- ▶ pod odmocninou bývá ještě oprava na výskyt shodných hodnot, která jmenovatele poněkud zmenší  
[`wilcox.test(vyska.o,vyska.m,mu=10,paired=TRUE)`]
- ▶ pro malá  $n$  se číselník zpravidla přibližuje o  $1/2$  k nule:  
(všimněte si zkrácených názvů parametrů – jednoznačnost!)  
[`wilcox.test(vyska.o,vyska.m,m=10,p=TRUE,cor=FALSE)`]

## párový Wilcoxonův test [Wilcoxon signed rank test]

(silnější předpoklad, než u znaménkového testu)

- ▶ nutné **spojité a symetrické** rozdělení  $X_i = U_i - V_i$
- ▶  $H_0$  : populační medián  $X_i$  je roven 0 (tj.  $P(X_i > 0) = 0,5$ )
- ▶ opět vyloučíme případy  $U_i = V_i$  (tj.  $X_i = 0$ )
- ▶ určíme pořadí  $R_i^+$  absolutních hodnot  $|X_i| = |U_i - V_i|$
- ▶  $W$  součet těch pořadí, kde bylo  $U_i > V_i$  (tj.  $X_i > 0$ )

$$Z = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}}$$

- ▶ pod odmocninou bývá ještě oprava na výskyt shodných hodnot, která jmenovatele poněkud zmenší  
[`wilcox.test(vyska.o,vyska.m,mu=10,paired=TRUE)`]
- ▶ pro malá  $n$  se číselník zpravidla přibližuje o  $1/2$  k nule:  
(všimněte si zkrácených názvů parametrů – jednoznačnost!)  
[`wilcox.test(vyska.o,vyska.m,m=10,p=TRUE,cor=FALSE)`]

## párový Wilcoxonův test [Wilcoxon signed rank test]

(silnější předpoklad, než u znaménkového testu)

- ▶ nutné **spojité a symetrické** rozdělení  $X_i = U_i - V_i$
- ▶  $H_0$  : populační medián  $X_i$  je roven 0 (tj.  $P(X_i > 0) = 0,5$ )
- ▶ opět vyloučíme případy  $U_i = V_i$  (tj.  $X_i = 0$ )
- ▶ určíme pořadí  $R_i^+$  absolutních hodnot  $|X_i| = |U_i - V_i|$
- ▶  $W$  součet těch pořadí, kde bylo  $U_i > V_i$  (tj.  $X_i > 0$ )

$$Z = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}}$$

- ▶ pod odmocninou bývá ještě oprava na výskyt shodných hodnot, která jmenovatele poněkud zmenší  
[`wilcox.test(vyska.o,vyska.m,mu=10,paired=TRUE)`]
- ▶ pro malá  $n$  se čítec zpravidla přibližuje o  $1/2$  k nule:  
(všimněte si zkrácených názvů parametrů – jednoznačnost!)  
[`wilcox.test(vyska.o,vyska.m,m=10,p=TRUE,cor=FALSE)`]



## párový Wilcoxonův test [Wilcoxon signed rank test]

(silnější předpoklad, než u znaménkového testu)

- ▶ nutné **spojité a symetrické** rozdělení  $X_i = U_i - V_i$
- ▶  $H_0$  : populační medián  $X_i$  je roven 0 (tj.  $P(X_i > 0) = 0,5$ )
- ▶ opět vyloučíme případy  $U_i = V_i$  (tj.  $X_i = 0$ )
- ▶ určíme pořadí  $R_i^+$  absolutních hodnot  $|X_i| = |U_i - V_i|$
- ▶  $W$  součet těch pořadí, kde bylo  $U_i > V_i$  (tj.  $X_i > 0$ )

$$Z = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}}$$

- ▶ pod odmocninou bývá ještě oprava na výskyt shodných hodnot, která jmenovatele poněkud zmenší  
[`wilcox.test(vyska.o,vyska.m,mu=10,paired=TRUE)`]
- ▶ pro malá  $n$  se číselník zpravidla přibližuje o  $1/2$  k nule:  
(všimněte si zkrácených názvů parametrů – jednoznačnost!)  
[`wilcox.test(vyska.o,vyska.m,m=10,p=TRUE,cor=FALSE)`]

## párový Wilcoxonův test [Wilcoxon signed rank test]

(silnější předpoklad, než u znaménkového testu)

- ▶ nutné **spojité a symetrické** rozdělení  $X_i = U_i - V_i$
- ▶  $H_0$  : populační medián  $X_i$  je roven 0 (tj.  $P(X_i > 0) = 0,5$ )
- ▶ opět vyloučíme případy  $U_i = V_i$  (tj.  $X_i = 0$ )
- ▶ určíme pořadí  $R_i^+$  absolutních hodnot  $|X_i| = |U_i - V_i|$
- ▶  $W$  součet těch pořadí, kde bylo  $U_i > V_i$  (tj.  $X_i > 0$ )

$$Z = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}}$$

- ▶ pod odmocninou bývá ještě oprava na výskyt shodných hodnot, která jmenovatele poněkud zmenší  
[`wilcox.test(vyska.o,vyska.m,mu=10,paired=TRUE)`]
- ▶ pro malá  $n$  se číselník zpravidla přibližuje o  $1/2$  k nule:  
(všimněte si zkrácených názvů parametrů – jednoznačnost!)  
[`wilcox.test(vyska.o,vyska.m,m=10,p=TRUE,cor=FALSE)`]

## párový Wilcoxonův test [Wilcoxon signed rank test]

(silnější předpoklad, než u znaménkového testu)

- ▶ nutné **spojité a symetrické** rozdělení  $X_i = U_i - V_i$
- ▶  $H_0$  : populační medián  $X_i$  je roven 0 (tj.  $P(X_i > 0) = 0,5$ )
- ▶ opět vyloučíme případy  $U_i = V_i$  (tj.  $X_i = 0$ )
- ▶ určíme pořadí  $R_i^+$  absolutních hodnot  $|X_i| = |U_i - V_i|$
- ▶  $W$  součet těch pořadí, kde bylo  $U_i > V_i$  (tj.  $X_i > 0$ )

$$Z = \frac{W - n(n+1)/4}{\sqrt{n(n+1)(2n+1)/24}}$$

- ▶ pod odmocninou bývá ještě oprava na výskyt shodných hodnot, která jmenovatele poněkud zmenší  
[`wilcox.test(vyska.o,vyska.m,mu=10,paired=TRUE)`]
- ▶ pro malá  $n$  se čitatel zpravidla přibližuje o  $1/2$  k nule:  
(všimněte si zkrácených názvů parametrů – jednoznačnost!)  
[`wilcox.test(vyska.o,vyska.m,m=10,p=TRUE,cor=FALSE)`]

## příklad: porovnání dvou metod učení nazpaměť

- ▶ u **devíti** osob provedeno porovnávání dvou způsobů předávání informace (např. poslouchání vers. čtení)
- ▶ rozhodnout, zda je mezi oběma způsoby rozdíl
- ▶  $H_0$ : rozdělení  $U$  a  $V$  stejná, tedy populační medián rozdílu  $X = U - V$  je roven 0
- ▶ znaménkový test s Yatesovou korekcí (málo pozorování):

$$y = 5 \quad n = 8$$

$$z = \frac{|5 - 8/2| - 0,5}{\sqrt{8/4}} = 0,3536 \quad p = 72,4 \%$$

$u_i$	90	86	72	65	44	52	46	38	43
$v_i$	85	87	70	62	44	53	42	35	46
$x_i$	5	-1	2	3	0	-1	4	3	-3
$r_i^+$	8	1,5	3	5	-	1,5	7	5	5

## příklad: porovnání dvou metod učení nazpaměť

- ▶ u **devíti** osob provedeno porovnávání dvou způsobů předávání informace (např. poslouchání vers. čtení)
- ▶ rozhodnout, zda je mezi oběma způsoby rozdíl
- ▶  $H_0$ : rozdělení  $U$  a  $V$  stejná, tedy populační medián rozdílu  $X = U - V$  je roven 0
- ▶ znaménkový test s Yatesovou korekcí (málo pozorování):

$$y = 5 \quad n = 8$$

$$z = \frac{|5 - 8/2| - 0,5}{\sqrt{8/4}} = 0,3536 \quad p = 72,4 \%$$

$u_i$	90	86	72	65	44	52	46	38	43
$v_i$	85	87	70	62	44	53	42	35	46
$x_i$	5	-1	2	3	0	-1	4	3	-3
$r_i^+$	8	1,5	3	5	-	1,5	7	5	5

## příklad: porovnání dvou metod učení nazpaměť

- ▶ u **devíti** osob provedeno porovnávání dvou způsobů předávání informace (např. poslouchání vers. čtení)
- ▶ rozhodnout, zda je mezi oběma způsoby rozdíl
- ▶  $H_0$ : rozdělení  $U$  a  $V$  stejná, tedy populační medián rozdílů  $X = U - V$  je roven 0
- ▶ znaménkový test s Yatesovou korekcí (málo pozorování):

$$y = 5 \quad n = 8$$

$$z = \frac{|5 - 8/2| - 0,5}{\sqrt{8/4}} = 0,3536 \quad p = 72,4 \%$$

$u_i$	90	86	72	65	44	52	46	38	43
$v_i$	85	87	70	62	44	53	42	35	46
$x_i$	5	-1	2	3	0	-1	4	3	-3
$r_i^+$	8	1,5	3	5	-	1,5	7	5	5

## příklad: porovnání dvou metod učení nazpaměť

- ▶ u **devíti** osob provedeno porovnávání dvou způsobů předávání informace (např. poslouchání vers. čtení)
- ▶ rozhodnout, zda je mezi oběma způsoby rozdíl
- ▶  $H_0$ : rozdělení  $U$  a  $V$  stejná, tedy populační medián rozdílů  $X = U - V$  je roven 0
- ▶ znaménkový test s Yatesovou korekcí (málo pozorování):

$$y = 5 \quad n = 8$$

$$z = \frac{|5 - 8/2| - 0,5}{\sqrt{8/4}} = 0,3536 \quad p = 72,4 \%$$

$u_i$	90	86	72	65	44	52	46	38	43
$v_i$	85	87	70	62	44	53	42	35	46
$x_i$	5	-1	2	3	0	-1	4	3	-3
$r_i^+$	8	1,5	3	5	-	1,5	7	5	5

## příklad: porovnání dvou metod učení nazpaměť

párový Wilcoxonův test [Wilcoxon signed-rank test]

- ▶  $H_0$  : populační medián rozdílů = 0
- ▶ nově předpokládáme symetrii

▶ Wilcoxonův test: 
$$\frac{u_i - v_i}{r_i^+} \quad \begin{array}{c|cccccccc} 5 & -1 & 2 & 3 & -1 & 4 & 3 & -3 \\ \hline 8 & 1,5 & 3 & 5 & 1,5 & 7 & 5 & 5 \end{array}$$

$$n = 8$$

$$w = 8 + 3 + 5 + 7 + 5 = 28$$

$$z = \frac{28 - 8 \cdot 9/4 - 1/2}{\sqrt{8 \cdot 9 \cdot 17/24}} = \frac{9,5}{\sqrt{51}} = 1,33$$

$$p = 18,3 \%$$

- ▶ program R dá  $p = 18,1 \%$ , protože kromě opravy na spojitost bere ohled na shody (přesný výpočet by dal  $p = 19,5 \%$ )



## příklad: porovnání dvou metod učení nazpaměť

párový Wilcoxonův test [Wilcoxon signed-rank test]

- ▶  $H_0$  : populační medián rozdílů = 0
- ▶ nově předpokládáme symetrii

▶ Wilcoxonův test: 
$$\frac{u_i - v_i}{r_i^+} \quad \begin{array}{|c|c|c|c|c|c|c|c|c|} \hline 5 & -1 & 2 & 3 & -1 & 4 & 3 & -3 \\ \hline 8 & 1,5 & 3 & 5 & 1,5 & 7 & 5 & 5 \\ \hline \end{array}$$

$$n = 8$$

$$w = 8 + 3 + 5 + 7 + 5 = 28$$

$$z = \frac{28 - 8 \cdot 9/4 - 1/2}{\sqrt{8 \cdot 9 \cdot 17/24}} = \frac{9,5}{\sqrt{51}} = 1,33$$

$$p = 18,3 \%$$

- ▶ program R dá  $p = 18,1 \%$ , protože kromě opravy na spojitost bere ohled na shody (přesný výpočet by dal  $p = 19,5 \%$ )

## příklad: porovnání dvou metod učení nazpaměť

párový Wilcoxonův test [Wilcoxon signed-rank test]

- ▶  $H_0$  : populační medián rozdílů = 0
- ▶ nově předpokládáme symetrii

▶ Wilcoxonův test:

$u_i - v_i$	5	-1	2	3	-1	4	3	-3
$r_i^+$	8	1,5	3	5	1,5	7	5	5

$$n = 8$$

$$w = 8 + 3 + 5 + 7 + 5 = 28$$

$$z = \frac{28 - 8 \cdot 9/4 - 1/2}{\sqrt{8 \cdot 9 \cdot 17/24}} = \frac{9,5}{\sqrt{51}} = 1,33$$

$$p = 18,3 \%$$

- ▶ program R dá  $p = 18,1 \%$ , protože kromě opravy na spojitost bere ohled na shody (přesný výpočet by dal  $p = 19,5 \%$ )

## příklad: porovnání dvou metod učení nazpaměť

párový Wilcoxonův test [Wilcoxon signed-rank test]

- ▶  $H_0$  : populační medián rozdílů = 0
- ▶ nově předpokládáme symetrii

▶ Wilcoxonův test:

$u_i - v_i$	5	-1	2	3	-1	4	3	-3
$r_i^+$	8	1,5	3	5	1,5	7	5	5

$$n = 8$$

$$w = 8 + 3 + 5 + 7 + 5 = 28$$

$$z = \frac{28 - 8 \cdot 9/4 - 1/2}{\sqrt{8 \cdot 9 \cdot 17/24}} = \frac{9,5}{\sqrt{51}} = 1,33$$

$$p = 18,3 \%$$

- ▶ program R dá  $p = 18,1 \%$ , protože kromě opravy na spojitost bere ohled na shody (přesný výpočet by dal  $p = 19,5 \%$ )

## porovnání populačních měř polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový $t$ -test	jednovýběrový Wilcoxonův, znaménkový
výběr dvojic	párový $t$ -test	párový Wilcoxonův, znaménkový
dva nezávislé výběry	dvouvýběrový $t$ -test	Mann-Whitney (Kolmogorov-Smirnov)
$k$ nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr $r$ -tic	analýza rozptylu náhodné bloky	Friedman

## dvouvýběrový $t$ -test

(předpoklad **normálního rozdělení**, testuje se **shoda středních hodnot**  $\mu_X = \mu_Y$ )

- ▶  $n_X$  nezávislých pozorování  $X$ ,  $n_Y$  nezávislých pozorování  $Y$
- ▶ tyto výběry musí být **nezávislé**  
(musí to zajistit způsob pořízení dat)
- ▶ rozptyly  $\sigma_X^2, \sigma_Y^2$  shodné (lze ověřit, odhady  $S_X^2, S_Y^2$  podobné)
- ▶ normální rozdělení v obou výběrech (lze ověřit, pro velká  $n_X, n_Y$  nenormalita tolik nevádí)
- ▶ společný odhad rozptylu (vážený průměr odhadů z jednotlivých výběrů)

$$S^2 = \frac{n_X - 1}{n_X + n_Y - 2} S_X^2 + \frac{n_Y - 1}{n_X + n_Y - 2} S_Y^2$$

- ▶ statistika (pro test hypotézy, že rozdělení  $X$  a  $Y$  jsou stejná)

$$T = \frac{\bar{X} - \bar{Y}}{\text{S.E.}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{S} \sqrt{\frac{n_X n_Y}{n_X + n_Y}}$$

## dvouvýběrový t-test

(předpoklad **normálního rozdělení**, testuje se **shoda středních hodnot**  $\mu_X = \mu_Y$ )

- ▶  $n_X$  nezávislých pozorování  $X$ ,  $n_Y$  nezávislých pozorování  $Y$
- ▶ tyto výběry musí být **nezávislé**  
(musí to zajistit způsob pořízení dat)
- ▶ rozptyly  $\sigma_X^2, \sigma_Y^2$  shodné (lze ověřit, odhady  $S_X^2, S_Y^2$  podobné)
- ▶ normální rozdělení v obou výběrech (lze ověřit, pro velká  $n_X, n_Y$  nenormalita tolik nevádí)
- ▶ společný odhad rozptylu (vážený průměr odhadů z jednotlivých výběrů)

$$S^2 = \frac{n_X - 1}{n_X + n_Y - 2} S_X^2 + \frac{n_Y - 1}{n_X + n_Y - 2} S_Y^2$$

- ▶ statistika (pro test hypotézy, že rozdělení  $X$  a  $Y$  jsou stejná)

$$T = \frac{\bar{X} - \bar{Y}}{\text{S.E.}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{S} \sqrt{\frac{n_X n_Y}{n_X + n_Y}}$$

## dvouvýběrový $t$ -test

(předpoklad **normálního rozdělení**, testuje se **shoda středních hodnot**  $\mu_X = \mu_Y$ )

- ▶  $n_X$  nezávislých pozorování  $X$ ,  $n_Y$  nezávislých pozorování  $Y$
- ▶ tyto výběry musí být **nezávislé**  
(musí to zajistit způsob pořízení dat)
- ▶ rozptyly  $\sigma_X^2, \sigma_Y^2$  shodné (lze ověřit, odhady  $S_X^2, S_Y^2$  podobné)
- ▶ normální rozdělení v obou výběrech (lze ověřit, pro velká  $n_X, n_Y$  nenormalita tolik nevádí)
- ▶ společný odhad rozptylu (vážený průměr odhadů z jednotlivých výběrů)

$$S^2 = \frac{n_X - 1}{n_X + n_Y - 2} S_X^2 + \frac{n_Y - 1}{n_X + n_Y - 2} S_Y^2$$

- ▶ statistika (pro test hypotézy, že rozdělení  $X$  a  $Y$  jsou stejná)

$$T = \frac{\bar{X} - \bar{Y}}{\text{S.E.}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{S} \sqrt{\frac{n_X n_Y}{n_X + n_Y}}$$

## dvouvýběrový $t$ -test

(předpoklad **normálního rozdělení**, testuje se **shoda středních hodnot**  $\mu_X = \mu_Y$ )

- ▶  $n_X$  nezávislých pozorování  $X$ ,  $n_Y$  nezávislých pozorování  $Y$
- ▶ tyto výběry musí být **nezávislé**  
(musí to zajistit způsob pořízení dat)
- ▶ rozptyly  $\sigma_X^2, \sigma_Y^2$  shodné (lze ověřit, odhady  $S_X^2, S_Y^2$  podobné)
- ▶ normální rozdělení v obou výběrech (lze ověřit, pro velká  $n_X, n_Y$  nenormalita tolik nevádí)
- ▶ společný odhad rozptylu (vážený průměr odhadů z jednotlivých výběrů)

$$S^2 = \frac{n_X - 1}{n_X + n_Y - 2} S_X^2 + \frac{n_Y - 1}{n_X + n_Y - 2} S_Y^2$$

- ▶ statistika (pro test hypotézy, že rozdělení  $X$  a  $Y$  jsou stejná)

$$T = \frac{\bar{X} - \bar{Y}}{\text{S.E.}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{S} \sqrt{\frac{n_X n_Y}{n_X + n_Y}}$$



## dvouvýběrový $t$ -test

(předpoklad **normálního rozdělení**, testuje se **shoda středních hodnot**  $\mu_X = \mu_Y$ )

- ▶  $n_X$  nezávislých pozorování  $X$ ,  $n_Y$  nezávislých pozorování  $Y$
- ▶ tyto výběry musí být **nezávislé**  
(musí to zajistit způsob pořízení dat)
- ▶ rozptyly  $\sigma_X^2, \sigma_Y^2$  shodné (lze ověřit, odhady  $S_X^2, S_Y^2$  podobné)
- ▶ normální rozdělení v obou výběrech (lze ověřit, pro velká  $n_X, n_Y$  nenormalita tolik nevádí)
- ▶ společný odhad rozptylu (vážený průměr odhadů z jednotlivých výběrů)

$$S^2 = \frac{n_X - 1}{n_X + n_Y - 2} S_X^2 + \frac{n_Y - 1}{n_X + n_Y - 2} S_Y^2$$

- ▶ statistika (pro test hypotézy, že rozdělení  $X$  a  $Y$  jsou stejná)

$$T = \frac{\bar{X} - \bar{Y}}{\text{S.E.}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{S} \sqrt{\frac{n_X n_Y}{n_X + n_Y}}$$

## dvouvýběrový $t$ -test

(předpoklad **normálního rozdělení**, testuje se **shoda středních hodnot**  $\mu_X = \mu_Y$ )

- ▶  $n_X$  nezávislých pozorování  $X$ ,  $n_Y$  nezávislých pozorování  $Y$
- ▶ tyto výběry musí být **nezávislé**  
(musí to zajistit způsob pořízení dat)
- ▶ rozptyly  $\sigma_X^2, \sigma_Y^2$  shodné (lze ověřit, odhady  $S_X^2, S_Y^2$  podobné)
- ▶ normální rozdělení v obou výběrech (lze ověřit, pro velká  $n_X, n_Y$  nenormalita tolik nevadí)
- ▶ společný odhad rozptylu (vážený průměr odhadů z jednotlivých výběrů)

$$S^2 = \frac{n_X - 1}{n_X + n_Y - 2} S_X^2 + \frac{n_Y - 1}{n_X + n_Y - 2} S_Y^2$$

- ▶ statistika (pro test hypotézy, že rozdělení  $X$  a  $Y$  jsou stejná)

$$T = \frac{\bar{X} - \bar{Y}}{\text{S.E.}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{S} \sqrt{\frac{n_X n_Y}{n_X + n_Y}}$$

## dvouvýběrový t-test

- ▶  $H_0 : \mu_X = \mu_Y$   
zamítnout ve prospěch alternativy
  - ▶  $H_1 : \mu_X \neq \mu_Y$  když  $|T| \geq t_{n_X+n_Y-2}(\alpha)$
  - ▶  $H_1 : \mu_X > \mu_Y$  když  $T \geq t_{n_X+n_Y-2}(2\alpha)$
  - ▶  $H_1 : \mu_X < \mu_Y$  když  $T \leq -t_{n_X+n_Y-2}(2\alpha)$

[t.test(hosi,divky,var.equal=TRUE)]

nebo

[t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)]

- ▶ zamítáme-li  $H_0$ , říkáme, že rozdíl výběrových průměrů je **(statisticky) významný**
- ▶ pochyby o shodě rozptylů: Welchův test (modifikace t-testu)
  - [t.test(hosi,divky,var.equal=FALSE)] (pro  $\sigma_X \neq \sigma_Y$ )
  - [t.test(hosi,divky)] resp. [t.test(vyska~Hoch)] (pro  $\sigma_X \neq \sigma_Y$ )
- ▶ shodu rozptylů lze ověřit např.  $F$ -testem ( $H_0 : \sigma_X = \sigma_Y$ )
  - [var.test(hosi,divky)]
- ▶ ověření normality nutně pro každý výběr zvlášť!

## dvouvýběrový t-test

- ▶  $H_0 : \mu_X = \mu_Y$   
zamítnout ve prospěch alternativy
  - ▶  $H_1 : \mu_X \neq \mu_Y$  když  $|T| \geq t_{n_X+n_Y-2}(\alpha)$
  - ▶  $H_1 : \mu_X > \mu_Y$  když  $T \geq t_{n_X+n_Y-2}(2\alpha)$
  - ▶  $H_1 : \mu_X < \mu_Y$  když  $T \leq -t_{n_X+n_Y-2}(2\alpha)$

[t.test(hosi,divky,var.equal=TRUE)]

nebo

[t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)]

- ▶ zamítáme-li  $H_0$ , říkáme, že rozdíl výběrových průměrů je (statisticky) významný
- ▶ pochyby o shodě rozptylů: Welchův test (modifikace t-testu)
  - [t.test(hosi,divky,var.equal=FALSE)] (pro  $\sigma_X \neq \sigma_Y$ )
  - [t.test(hosi,divky)] resp. [t.test(vyska~Hoch)] (pro  $\sigma_X \neq \sigma_Y$ )
- ▶ shodu rozptylů lze ověřit např.  $F$ -testem ( $H_0 : \sigma_X = \sigma_Y$ )
  - [var.test(hosi,divky)]
- ▶ ověření normality nutně pro každý výběr zvlášť!

## dvouvýběrový t-test

- ▶  $H_0 : \mu_X = \mu_Y$   
zamítnout ve prospěch alternativy
  - ▶  $H_1 : \mu_X \neq \mu_Y$  když  $|T| \geq t_{n_X+n_Y-2}(\alpha)$
  - ▶  $H_1 : \mu_X > \mu_Y$  když  $T \geq t_{n_X+n_Y-2}(2\alpha)$
  - ▶  $H_1 : \mu_X < \mu_Y$  když  $T \leq -t_{n_X+n_Y-2}(2\alpha)$

[t.test(hosi,divky,var.equal=TRUE)]

nebo

[t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)]

- ▶ zamítáme-li  $H_0$ , říkáme, že rozdíl výběrových průměrů je **(statisticky) významný**
- ▶ pochyby o shodě rozptylů: Welchův test (modifikace t-testu)  
[t.test(hosi,divky,var.equal=FALSE)] (pro  $\sigma_X \neq \sigma_Y$ )  
[t.test(hosi,divky)] resp. [t.test(vyska~Hoch)] (pro  $\sigma_X \neq \sigma_Y$ )
- ▶ shodu rozptylů lze ověřit např.  $F$ -testem ( $H_0 : \sigma_X = \sigma_Y$ )  
[var.test(hosi,divky)]
- ▶ ověření normality nutně pro každý výběr zvlášť!

## dvouvýběrový t-test

- ▶  $H_0 : \mu_X = \mu_Y$   
zamítnout ve prospěch alternativy
  - ▶  $H_1 : \mu_X \neq \mu_Y$  když  $|T| \geq t_{n_X+n_Y-2}(\alpha)$
  - ▶  $H_1 : \mu_X > \mu_Y$  když  $T \geq t_{n_X+n_Y-2}(2\alpha)$
  - ▶  $H_1 : \mu_X < \mu_Y$  když  $T \leq -t_{n_X+n_Y-2}(2\alpha)$

[t.test(hosi,divky,var.equal=TRUE)]

nebo

[t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)]

- ▶ zamítáme-li  $H_0$ , říkáme, že rozdíl výběrových průměrů je (statisticky) významný
- ▶ pochyby o shodě rozptylů: Welchův test (modifikace t-testu)
  - [t.test(hosi,divky,var.equal=FALSE)] (pro  $\sigma_X \neq \sigma_Y$ )
  - [t.test(hosi,divky)] resp. [t.test(vyska~Hoch)] (pro  $\sigma_X \neq \sigma_Y$ )
- ▶ shodu rozptylů lze ověřit např.  $F$ -testem ( $H_0 : \sigma_X = \sigma_Y$ )
  - [var.test(hosi,divky)]
- ▶ ověření normality nutně pro každý výběr zvlášť!

## dvouvýběrový t-test

- ▶  $H_0 : \mu_X = \mu_Y$   
zamítnout ve prospěch alternativy
  - ▶  $H_1 : \mu_X \neq \mu_Y$  když  $|T| \geq t_{n_X+n_Y-2}(\alpha)$
  - ▶  $H_1 : \mu_X > \mu_Y$  když  $T \geq t_{n_X+n_Y-2}(2\alpha)$
  - ▶  $H_1 : \mu_X < \mu_Y$  když  $T \leq -t_{n_X+n_Y-2}(2\alpha)$

[t.test(hosi,divky,var.equal=TRUE)]

nebo

[t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)]

- ▶ zamítáme-li  $H_0$ , říkáme, že rozdíl výběrových průměrů **je (statisticky) významný**
- ▶ pochyby o shodě rozptylů: Welchův test (modifikace t-testu)  
[t.test(hosi,divky,var.equal=FALSE)] (pro  $\sigma_X \neq \sigma_Y$ )  
[t.test(hosi,divky)] resp. [t.test(vyska~Hoch)] (pro  $\sigma_X \neq \sigma_Y$ )
- ▶ shodu rozptylů lze ověřit např.  $F$ -testem ( $H_0 : \sigma_X = \sigma_Y$ )  
[var.test(hosi,divky)]
- ▶ ověření normality nutně pro každý výběr zvlášť!

dvouvýběrový  $t$ -test

- ▶  $H_0 : \mu_X = \mu_Y$   
zamítnout ve prospěch alternativy
  - ▶  $H_1 : \mu_X \neq \mu_Y$  když  $|T| \geq t_{n_X+n_Y-2}(\alpha)$
  - ▶  $H_1 : \mu_X > \mu_Y$  když  $T \geq t_{n_X+n_Y-2}(2\alpha)$
  - ▶  $H_1 : \mu_X < \mu_Y$  když  $T \leq -t_{n_X+n_Y-2}(2\alpha)$

[t.test(hosi,divky,var.equal=TRUE)]

nebo

[t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)]

- ▶ zamítáme-li  $H_0$ , říkáme, že rozdíl výběrových průměrů **je (statisticky) významný**
- ▶ pochyby o shodě rozptylů: Welchův test (modifikace  $t$ -testu)
  - [t.test(hosi,divky,var.equal=FALSE)] (pro  $\sigma_X \neq \sigma_Y$ )
  - [t.test(hosi,divky)] resp. [t.test(vyska~Hoch)] (pro  $\sigma_X \neq \sigma_Y$ )
- ▶ shodu rozptylů lze ověřit např.  $F$ -testem ( $H_0 : \sigma_X = \sigma_Y$ )
  - [var.test(hosi,divky)]
- ▶ ověření normality nutně pro každý výběr zvlášť!



dvouvýběrový  $t$ -test

- ▶  $H_0 : \mu_X = \mu_Y$   
zamítnout ve prospěch alternativy
  - ▶  $H_1 : \mu_X \neq \mu_Y$  když  $|T| \geq t_{n_X+n_Y-2}(\alpha)$
  - ▶  $H_1 : \mu_X > \mu_Y$  když  $T \geq t_{n_X+n_Y-2}(2\alpha)$
  - ▶  $H_1 : \mu_X < \mu_Y$  když  $T \leq -t_{n_X+n_Y-2}(2\alpha)$

[t.test(hosi,divky,var.equal=TRUE)]

nebo

[t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)]

- ▶ zamítáme-li  $H_0$ , říkáme, že rozdíl výběrových průměrů **je (statisticky) významný**
- ▶ pochyby o shodě rozptylů: Welchův test (modifikace  $t$ -testu)
  - [t.test(hosi,divky,var.equal=FALSE)] (pro  $\sigma_X \neq \sigma_Y$ )
  - [t.test(hosi,divky)] resp. [t.test(vyska~Hoch)] (pro  $\sigma_X \neq \sigma_Y$ )
- ▶ shodu rozptylů lze ověřit např.  $F$ -testem ( $H_0 : \sigma_X = \sigma_Y$ )
  - [var.test(hosi,divky)]
- ▶ ověření normality nutně pro každý výběr zvlášť!

dvouvýběrový  $t$ -test

- ▶  $H_0 : \mu_X = \mu_Y$   
zamítnout ve prospěch alternativy
  - ▶  $H_1 : \mu_X \neq \mu_Y$  když  $|T| \geq t_{n_X+n_Y-2}(\alpha)$
  - ▶  $H_1 : \mu_X > \mu_Y$  když  $T \geq t_{n_X+n_Y-2}(2\alpha)$
  - ▶  $H_1 : \mu_X < \mu_Y$  když  $T \leq -t_{n_X+n_Y-2}(2\alpha)$

[t.test(hosi,divky,var.equal=TRUE)]

nebo

[t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)]

- ▶ zamítáme-li  $H_0$ , říkáme, že rozdíl výběrových průměrů **je (statisticky) významný**
- ▶ pochyby o shodě rozptylů: Welchův test (modifikace  $t$ -testu)
  - [t.test(hosi,divky,var.equal=FALSE)] (pro  $\sigma_X \neq \sigma_Y$ )
  - [t.test(hosi,divky)] resp. [t.test(vyska~Hoch)] (pro  $\sigma_X \neq \sigma_Y$ )
- ▶ shodu rozptylů lze ověřit např.  $F$ -testem ( $H_0 : \sigma_X = \sigma_Y$ )
  - [var.test(hosi,divky)]
- ▶ ověření normality nutně pro každý výběr zvlášť!

## příklad: výšky desetiletých dětí

	rozsah	průměr	výb. rozptyl
hoši	15	139,13	42,98
dívky	12	140,83	33,79

$$s^2 = \frac{15 - 1}{15 + 12 - 2} 42,98 + \frac{12 - 1}{15 + 12 - 2} 33,79 = 38,936$$

$$|t| = \frac{|139,13 - 140,83|}{\sqrt{38,936}} \sqrt{\frac{15 \cdot 12}{15 + 12}} = | -0,703 | < 2,06 = t_{25}(0,05)$$

[shapiro.test(hosi)]  $p = 80 \%$

[shapiro.test(divky)]  $p = 38 \%$



[tapply(vyska,Hoch,shapiro.test)] (spočítá test pro oba výběry)

[var.test(hosi,divky)]  $p = 70 \%$

[t.test(hosi,divky,var.equal=TRUE)]  $p = 49 \%$

[t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)]

## příklad: váha dětí maturantek v 24. týdnu věku dítěte

 $t = 2,52$ ,  $p = 1,5 \%$ , rozdíl je významný

## dvouvýběrový $t$ -test a intervaly spolehlivosti

(poznámka na okraj, platí pro  $\alpha = 5\%$ )

**D: disjunktní int. spol.** versus **V: významný rozdíl**  
**(PP: průměry jsou v CI druhého výběru)**

**D**  $\Rightarrow$  **V** disjunktní intervaly spolehlivosti  $\Rightarrow$  významný rozdíl  
 non **V**  $\Rightarrow$  non **D** nevýznamný rozdíl průměrů  $\Rightarrow$  překryv intervalů

**V**  $\not\Rightarrow$  **D** rozdíl průměrů může být významný a současně se intervaly mohou překrývat

**PP**  $\Rightarrow$  non **V** pokud každý z intervalů spolehlivosti obsahuje výběrový průměr druhého výběru, rozdíl průměrů není významný (nemusí platit v případě, kdy oba rozsahy výběru jsou do čtyř)

příklad: váha dětí matek maturantek v 24. týdnu

- ▶ 95% interval spolehlivosti pro hochy [kg]: (7,51; 8,25)
- ▶ 95% interval spolehlivosti pro dívky [kg]: (6,98; 7,59)
- ▶ intervaly se poněkud překrývají, přestože  $t$ -test dal:  
 $t = 2,52$ ,  $p = 1,5\%$ , tedy významný rozdíl

## dvouvýběrový $t$ -test a intervaly spolehlivosti

(poznámka na okraj, platí pro  $\alpha = 5 \%$ )

**D: disjunktní int. spol.** versus **V: významný rozdíl**  
**(PP: průměry jsou v CI druhého výběru)**

**D**  $\Rightarrow$  **V** disjunktní intervaly spolehlivosti  $\Rightarrow$  významný rozdíl  
**non V**  $\Rightarrow$  **non D** nevýznamný rozdíl průměrů  $\Rightarrow$  překryv intervalů

**V**  $\not\Rightarrow$  **D** rozdíl průměrů může být významný a současně se intervaly mohou překrývat

**PP**  $\Rightarrow$  **non V** pokud každý z intervalů spolehlivosti obsahuje výběrový průměr druhého výběru, rozdíl průměrů není významný (nemusí platit v případě, kdy oba rozsahy výběru jsou do čtyř)

příklad: váha dětí matek maturantek v 24. týdnu

- ▶ 95% interval spolehlivosti pro hochy [kg]: (7,51; 8,25)
- ▶ 95% interval spolehlivosti pro dívky [kg]: (6,98; 7,59)
- ▶ intervaly se poněkud překrývají, přestože  $t$ -test dal:  
 $t = 2,52$ ,  $p = 1,5 \%$ , tedy významný rozdíl

## dvouvýběrový $t$ -test a intervaly spolehlivosti

(poznámka na okraj, platí pro  $\alpha = 5 \%$ )

**D: disjunktní int. spol.** versus **V: významný rozdíl**  
**(PP: průměry jsou v CI druhého výběru)**

**D**  $\Rightarrow$  **V** disjunktní intervaly spolehlivosti  $\Rightarrow$  významný rozdíl  
**non V**  $\Rightarrow$  **non D** nevýznamný rozdíl průměrů  $\Rightarrow$  překryv intervalů

**V**  $\nRightarrow$  **D** rozdíl průměrů může být významný a současně se intervaly mohou překrývat

**PP**  $\Rightarrow$  **non V** pokud každý z intervalů spolehlivosti obsahuje výběrový průměr druhého výběru, rozdíl průměrů není významný (nemusí platit v případě, kdy oba rozsahy výběru jsou do čtyř)

příklad: váha dětí matek maturantek v 24. týdnu

- ▶ 95% interval spolehlivosti pro hochy [kg]: (7,51; 8,25)
- ▶ 95% interval spolehlivosti pro dívky [kg]: (6,98; 7,59)
- ▶ intervaly se poněkud překrývají, přestože  $t$ -test dal:  
 $t = 2,52$ ,  $p = 1,5 \%$ , tedy významný rozdíl

## dvouvýběrový $t$ -test a intervaly spolehlivosti

(poznámka na okraj, platí pro  $\alpha = 5\%$ )

**D: disjunktní int. spol.** versus **V: významný rozdíl**  
**(PP: průměry jsou v CI druhého výběru)**

**D**  $\Rightarrow$  **V** disjunktní intervaly spolehlivosti  $\Rightarrow$  významný rozdíl  
**non V**  $\Rightarrow$  **non D** nevýznamný rozdíl průměrů  $\Rightarrow$  překryv intervalů

**V**  $\nRightarrow$  **D** rozdíl průměrů může být významný a současně se intervaly mohou překrývat

**PP**  $\Rightarrow$  **non V** pokud každý z intervalů spolehlivosti obsahuje výběrový průměr druhého výběru, rozdíl průměrů není významný (nemusí platit v případě, kdy oba rozsahy výběru jsou do čtyř)

příklad: váha dětí matek maturantek v 24. týdnu

- ▶ 95% interval spolehlivosti pro hochy [kg]: (7,51; 8,25)
- ▶ 95% interval spolehlivosti pro dívky [kg]: (6,98; 7,59)
- ▶ intervaly se poněkud překrývají, přestože  $t$ -test dal:  
 $t = 2,52$ ,  $p = 1,5\%$ , tedy významný rozdíl



## dvouvýběrový $t$ -test a intervaly spolehlivosti

(poznámka na okraj, platí pro  $\alpha = 5 \%$ )

**D: disjunktní int. spol.** versus **V: významný rozdíl**  
**(PP: průměry jsou v CI druhého výběru)**

**D**  $\Rightarrow$  **V** disjunktní intervaly spolehlivosti  $\Rightarrow$  významný rozdíl  
**non V**  $\Rightarrow$  **non D** nevýznamný rozdíl průměrů  $\Rightarrow$  překryv intervalů

**V**  $\nRightarrow$  **D** rozdíl průměrů může být významný a současně se intervaly mohou překrývat

**PP**  $\Rightarrow$  **non V** pokud každý z intervalů spolehlivosti obsahuje výběrový průměr druhého výběru, rozdíl průměrů není významný (nemusí platit v případě, kdy oba rozsahy výběru jsou do čtyř)

příklad: váha dětí matek maturantek v 24. týdnu

- ▶ 95% interval spolehlivosti pro hochy [kg]: (7,51; 8,25)
- ▶ 95% interval spolehlivosti pro dívky [kg]: (6,98; 7,59)
- ▶ intervaly se poněkud překrývají, přestože  $t$ -test dal:  
 $t = 2,52$ ,  $p = 1,5 \%$ , tedy významný rozdíl

## dvouvýběrový $t$ -test a intervaly spolehlivosti

(poznámka na okraj, platí pro  $\alpha = 5\%$ )

**D: disjunktní int. spol.** versus **V: významný rozdíl**  
**(PP: průměry jsou v CI druhého výběru)**

**D**  $\Rightarrow$  **V** disjunktní intervaly spolehlivosti  $\Rightarrow$  významný rozdíl  
**non V**  $\Rightarrow$  **non D** nevýznamný rozdíl průměrů  $\Rightarrow$  překryv intervalů

**V**  $\nRightarrow$  **D** rozdíl průměrů může být významný a současně se intervaly mohou překrývat

**PP**  $\Rightarrow$  **non V** pokud každý z intervalů spolehlivosti obsahuje výběrový průměr druhého výběru, rozdíl průměrů není významný (nemusí platit v případě, kdy oba rozsahy výběru jsou do čtyř)

příklad: váha dětí matek maturantek v 24. týdnu

- ▶ 95% interval spolehlivosti pro hochy [kg]: (7,51; 8,25)
- ▶ 95% interval spolehlivosti pro dívky [kg]: (6,98; 7,59)
- ▶ intervaly se poněkud překrývají, přestože  $t$ -test dal:  
 $t = 2,52$ ,  $p = 1,5\%$ , tedy významný rozdíl

## dvouvýběrový $t$ -test a intervaly spolehlivosti

(poznámka na okraj, platí pro  $\alpha = 5 \%$ )

**D: disjunktní int. spol.** versus **V: významný rozdíl**  
**(PP: průměry jsou v CI druhého výběru)**

**D**  $\Rightarrow$  **V** disjunktní intervaly spolehlivosti  $\Rightarrow$  významný rozdíl  
**non V**  $\Rightarrow$  **non D** nevýznamný rozdíl průměrů  $\Rightarrow$  překryv intervalů

**V**  $\not\Rightarrow$  **D** rozdíl průměrů může být významný a současně se intervaly mohou překrývat

**PP**  $\Rightarrow$  **non V** pokud každý z intervalů spolehlivosti obsahuje výběrový průměr druhého výběru, rozdíl průměrů není významný (nemusí platit v případě, kdy oba rozsahy výběru jsou do čtyř)

příklad: váha dětí matek maturantek v 24. týdnu

- ▶ 95% interval spolehlivosti pro hochy [kg]: (7,51; 8,25)
- ▶ 95% interval spolehlivosti pro dívky [kg]: (6,98; 7,59)
- ▶ intervaly se poněkud překrývají, přestože  $t$ -test dal:  
 $t = 2,52$ ,  $p = 1,5 \%$ , tedy významný rozdíl

# dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí **spojité rozdělení**)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nestejně variabilitě

# dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí **spojité rozdělení**)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojité rozdělení
- ▶  $H_0$ : rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nestejně variabilitě

# dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí **spojité rozdělení**)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nesteržné variabilitě

# dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí **spojité rozdělení**)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nestejně variabilitě

# dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí **spojité rozdělení**)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nesterjné variabilitě



# dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí **spojité rozdělení**)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nestejně variabilitě

# dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí **spojité rozdělení**)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nesterjné variabilitě

# dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí **spojité rozdělení**)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nestejně variabilitě

# dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí **spojité rozdělení**)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nestejně variabilitě

## příklad: věk matek vers. plánované těhotenství

- ▶ věk matky nemá normální rozdělení: Shapirův-Wilkův test dal  $p$ -hodnoty  $p = 0,0045$  a  $p = 0,0470$   
[`tapply(vek.m,Plan,shapiro.test)`]
- ▶ rozdělení věku matek je nepochybně spojité
- ▶ výběry (0 – neplánované, 1 – plánované těhotenství) jsou nezávislé
- ▶ dvouvýběrový Wilcoxonův test  $H_0$  : shodná rozdělení (shodné mediány) dal  $p = 0,02067$ , rozdíl je na 5 % hladině **průkazný**  
[`wilcox.test(vek.m~Plan)`]
- ▶  $W = 864$  je  $\#(vek0 > vek1) + \#(vek0 == vek1)/2$ ,  
kde  $vek0$  je věk matky s  $Plan == 0$ , podobně  $vek1$

## příklad: věk matek vers. plánované těhotenství

- ▶ věk matky nemá normální rozdělení: Shapirův-Wilkův test dal  $p$ -hodnoty  $p = 0,0045$  a  $p = 0,0470$   
[`tapply(vek.m,Plan,shapiro.test)`]
- ▶ rozdělení věku matek je nepochybně spojité
- ▶ výběry (0 – neplánované, 1 – plánované těhotenství) jsou nezávislé
- ▶ dvouvýběrový Wilcoxonův test  $H_0$  : shodná rozdělení (shodné mediány) dal  $p = 0,02067$ , rozdíl je na 5 % hladině **průkazný**  
[`wilcox.test(vek.m~Plan)`]
- ▶  $W = 864$  je  $\#(vek0 > vek1) + \#(vek0 == vek1)/2$ ,  
kde  $vek0$  je věk matky s  $Plan == 0$ , podobně  $vek1$

## příklad: věk matek vers. plánované těhotenství

- ▶ věk matky nemá normální rozdělení: Shapirův-Wilkův test dal  $p$ -hodnoty  $p = 0,0045$  a  $p = 0,0470$   
[`tapply(vek.m,Plan,shapiro.test)`]
- ▶ rozdělení věku matek je nepochybně spojitě
- ▶ výběry (0 – neplánované, 1 – plánované těhotenství) jsou nezávislé
- ▶ dvouvýběrový Wilcoxonův test  $H_0$  : shodná rozdělení (shodné mediány) dal  $p = 0,02067$ , rozdíl je na 5 % hladině **průkazný**  
[`wilcox.test(vek.m~Plan)`]
- ▶  $W = 864$  je  $\#(vek0 > vek1) + \#(vek0 == vek1)/2$ ,  
kde  $vek0$  je věk matky s  $Plan == 0$ , podobně  $vek1$

## příklad: věk matek vers. plánované těhotenství

- ▶ věk matky nemá normální rozdělení: Shapirův-Wilkův test dal  $p$ -hodnoty  $p = 0,0045$  a  $p = 0,0470$   
[`tapply(vek.m,Plan,shapiro.test)`]
- ▶ rozdělení věku matek je nepochybně spojitě
- ▶ výběry (0 – neplánované, 1 – plánované těhotenství) jsou nezávislé
- ▶ dvouvýběrový Wilcoxonův test  $H_0$  : shodná rozdělení (shodné mediány) dal  $p = 0,02067$ , rozdíl je na 5 % hladině **průkazný**  
[`wilcox.test(vek.m~Plan)`]
- ▶  $W = 864$  je  $\#(vek0 > vek1) + \#(vek0 == vek1)/2$ ,  
kde  $vek0$  je věk matky s  $Plan == 0$ , podobně  $vek1$



## příklad: věk matek vers. plánované těhotenství


- ▶ věk matky nemá normální rozdělení: Shapirův-Wilkův test dal  $p$ -hodnoty  $p = 0,0045$  a  $p = 0,0470$   
[`tapply(vek.m,Plan,shapiro.test)`]
- ▶ rozdělení věku matek je nepochybně spojité
- ▶ výběry (0 – neplánované, 1 – plánované těhotenství) jsou nezávislé
- ▶ dvouvýběrový Wilcoxonův test  $H_0$  : shodná rozdělení (shodné mediány) dal  $p = 0,02067$ , rozdíl je na 5 % hladině **průkazný**  
[`wilcox.test(vek.m~Plan)`]
- ▶  $W = 864$  je  $\#(vek0 > vek1) + \#(vek0 == vek1)/2$ ,  
kde  $vek0$  je věk matky s  $Plan == 0$ , podobně  $vek1$

# Kolmogorovův-Smirnovův test

(stačí **spojité** rozdělení)

- ▶ porovná empirické distribuční funkce dvou **nezávislých** výběrů
- ▶ určí jejich největší „svislou“ vzdálenost
- ▶ citlivý vůči všem neshodám (nejen co do populačního průměru či populačního mediánu)
- ▶ porovnání věku matek podle plánovaného těhotenství
- ▶  $D = \frac{20}{41} - \frac{12}{58} = 0,2808$   
 $p = 4,5 \%$

`[ks.test(vek.m[Plan==0],vek.m[Plan==1])]`




# Kolmogorovův-Smirnovův test

(stačí **spojité** rozdělení)

- ▶ porovná empirické distribuční funkce dvou **nezávislých** výběrů
- ▶ určí jejich největší „svislou“ vzdálenost
- ▶ citlivý vůči všem neshodám (nejen co do populačního průměru či populačního mediánu)
- ▶ porovnání věku matek podle plánovaného těhotenství
- ▶  $D = \frac{20}{41} - \frac{12}{58} = 0,2808$   
 $p = 4,5 \%$


`[ks.test(vek.m[Plan==0],vek.m[Plan==1])]`



# Kolmogorovův-Smirnovův test

(stačí **spojité** rozdělení)

- ▶ porovná empirické distribuční funkce dvou **nezávislých** výběrů
- ▶ určí jejich největší „svislou“ vzdálenost
- ▶ citlivý vůči všem neshodám (nejen co do populačního průměru či populačního mediánu)
- ▶ porovnání věku matek podle plánovaného těhotenství
- ▶  $D = \frac{20}{41} - \frac{12}{58} = 0,2808$   
 $p = 4,5 \%$



`[ks.test(vek.m[Plan==0],vek.m[Plan==1])]`

# Kolmogorovův-Smirnovův test


(stačí **spojité** rozdělení)

- ▶ porovná empirické distribuční funkce dvou **nezávislých** výběrů
- ▶ určí jejich největší „svislou“ vzdálenost
- ▶ citlivý vůči všem neshodám (nejen co do populačního průměru či populačního mediánu)
- ▶ porovnání věku matek podle plánovaného těhotenství

$$D = \frac{20}{41} - \frac{12}{58} = 0,2808$$

$$p = 4,5 \%$$

`[ks.test(vek.m[Plan==0],vek.m[Plan==1])]`




# Kolmogorovův-Smirnovův test

(stačí **spojité** rozdělení)

- ▶ porovná empirické distribuční funkce dvou **nezávislých** výběrů
- ▶ určí jejich největší „svislou“ vzdálenost
- ▶ citlivý vůči všem neshodám (nejen co do populačního průměru či populačního mediánu)
- ▶ porovnání věku matek podle plánovaného těhotenství
- ▶  $D = \frac{20}{41} - \frac{12}{58} = 0,2808$   
 $p = 4,5 \%$

`[ks.test(vek.m[Plan==0],vek.m[Plan==1])]`





## porovnání populačních měř polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový $t$ - test	jednovýběrový Wilcoxon
výběr dvojic	párový $t$ -test	znaménkový, Wilcoxon
dva nezávislé výběry	dvouvýběrový $t$ -test	Mann-Whitney (Kolmogorov-Smirnov)
$k$ nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr $r$ -tic	analýza rozptylu náhodné bloky	Friedman

## motivační příklad pro analýzu rozptylu (játra):



- ▶ pět míst na řece, vždy vyloveno po 7 rybách
- ▶ zjišťována koncentrace mědi v játrech
- ▶ liší se tato místa svým znečištěním?
- ▶ logaritmování na pravé straně stabilizuje rozptyl







## motivační příklad pro analýzu rozptylu (játra):

- ▶ pět míst na řece, vždy vyloveno po 7 rybách
- ▶ zjišťována koncentrace mědi v játrech
- ▶ liší se tato místa svým znečištěním?
- ▶ logaritmování na pravé straně stabilizuje rozptyl





## motivační příklad pro analýzu rozptylu (játra):

- ▶ pět míst na řece, vždy vyloveno po 7 rybách
- ▶ zjišťována koncentrace mědi v játrech
- ▶ liší se tato místa svým znečištěním?
- ▶ logaritmování na pravé straně stabilizuje rozptyl





## motivační příklad pro analýzu rozptylu (játra):

- ▶ pět míst na řece, vždy vyloveno po 7 rybách
- ▶ zjišťována koncentrace mědi v játrech
- ▶ liší se tato místa svým znečištěním?
- ▶ logaritmování na pravé straně stabilizuje rozptyl





## jiné zobrazení dat (error bars)

- ▶ v obou grafech jsou znázorněny průměry na jednotlivých místech
- ▶ vlevo: úsečky = směrodatné odchytky, vyjadřují **variabilitu dat**
- ▶ vpravo úsečky = střední chyba průměru, vyjadřují **přesnost odhadů středních hodnot**





## jiné zobrazení dat (error bars)

- ▶ v obou grafech jsou znázorněny průměry na jednotlivých místech
- ▶ vlevo: úsečky = směrodatné odchytky, vyjadřují **variabilitu dat**
- ▶ vpravo úsečky = střední chyba průměru, vyjadřují **přesnost odhadů středních hodnot**



## jiné zobrazení dat (error bars)

- ▶ v obou grafech jsou znázorněny průměry na jednotlivých místech
- ▶ vlevo: úsečky = směrodatné odchytky, vyjadřují **variabilitu dat**
- ▶ vpravo úsečky = střední chyba průměru, vyjadřují **přesnost odhadů středních hodnot**



## analýza rozptylu jednoduchého třídění (ANOVA)

- ▶  $Y_{11}, \dots, Y_{1n_1} \sim N(\mu_1, \sigma^2)$  (první výběr, průměr  $\bar{Y}_{1\bullet}$ )
- ▶  $Y_{21}, \dots, Y_{2n_2} \sim N(\mu_2, \sigma^2)$  (druhý výběr, průměr  $\bar{Y}_{2\bullet}$ )

...

$Y_{k1}, \dots, Y_{kn_k} \sim N(\mu_k, \sigma^2)$  ( $k$ -tý výběr, průměr  $\bar{Y}_{k\bullet}$ )

- ▶ **nezávislé** výběry (shodné rozptyly, normální rozdělení)
- ▶  $H_0 : \mu_1 = \mu_2 = \dots = \mu_k$  ( $= \mu$ )     $H_1 : \text{neplatí } H_0$
- ▶ celkový průměr  $\bar{Y}_{\bullet\bullet}$ , celkový rozsah  $n = \sum_{i=1}^k n_i$
- ▶ rozklad součtu čtverců

$$\sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^k n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{i\bullet})^2$$

(celková variabilita) = (variabilita mezi) + (variabilita uvnitř)

$$S_T = S_A + S_e$$

$$f_T = f_A + f_e$$

$$(n - 1) = (k - 1) + (n - k)$$

## analýza rozptylu jednoduchého třídění (ANOVA)

- ▶  $Y_{11}, \dots, Y_{1n_1} \sim N(\mu_1, \sigma^2)$  (první výběr, průměr  $\bar{Y}_{1\bullet}$ )
- $Y_{21}, \dots, Y_{2n_2} \sim N(\mu_2, \sigma^2)$  (druhý výběr, průměr  $\bar{Y}_{2\bullet}$ )
- ...
- $Y_{k1}, \dots, Y_{kn_k} \sim N(\mu_k, \sigma^2)$  ( $k$ -tý výběr, průměr  $\bar{Y}_{k\bullet}$ )
- ▶ **nezávislé** výběry (shodné rozptyly, normální rozdělení)
- ▶  $H_0 : \mu_1 = \mu_2 = \dots = \mu_k$  ( $= \mu$ )     $H_1 : \text{neplatí } H_0$
- ▶ celkový průměr  $\bar{Y}_{\bullet\bullet}$ , celkový rozsah  $n = \sum_{i=1}^k n_i$
- ▶ rozklad součtu čtverců

$$\sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^k n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{i\bullet})^2$$

(celková variabilita) = (variabilita mezi) + (variabilita uvnitř)

$$S_T = S_A + S_e$$

$$f_T = f_A + f_e$$

$$(n - 1) = (k - 1) + (n - k)$$



## analýza rozptylu jednoduchého třídění (ANOVA)

- ▶  $Y_{11}, \dots, Y_{1n_1} \sim N(\mu_1, \sigma^2)$  (první výběr, průměr  $\bar{Y}_{1\bullet}$ )
- ▶  $Y_{21}, \dots, Y_{2n_2} \sim N(\mu_2, \sigma^2)$  (druhý výběr, průměr  $\bar{Y}_{2\bullet}$ )

...

- ▶  $Y_{k1}, \dots, Y_{kn_k} \sim N(\mu_k, \sigma^2)$  ( $k$ -tý výběr, průměr  $\bar{Y}_{k\bullet}$ )

- ▶ **nezávislé** výběry (shodné rozptyly, normální rozdělení)

- ▶  $H_0 : \mu_1 = \mu_2 = \dots = \mu_k$  ( $= \mu$ )     $H_1 : \text{neplatí } H_0$

- ▶ celkový průměr  $\bar{Y}_{\bullet\bullet}$ , celkový rozsah  $n = \sum_{i=1}^k n_i$

- ▶ rozklad součtu čtverců

$$\sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^k n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{i\bullet})^2$$

(celková variabilita) = (variabilita mezi) + (variabilita uvnitř)

$$S_T = S_A + S_e$$

$$f_T = f_A + f_e$$

$$(n - 1) = (k - 1) + (n - k)$$

## analýza rozptylu jednoduchého třídění (ANOVA)

- ▶  $Y_{11}, \dots, Y_{1n_1} \sim N(\mu_1, \sigma^2)$  (první výběr, průměr  $\bar{Y}_{1\bullet}$ )
- ▶  $Y_{21}, \dots, Y_{2n_2} \sim N(\mu_2, \sigma^2)$  (druhý výběr, průměr  $\bar{Y}_{2\bullet}$ )

...

- ▶  $Y_{k1}, \dots, Y_{kn_k} \sim N(\mu_k, \sigma^2)$  ( $k$ -tý výběr, průměr  $\bar{Y}_{k\bullet}$ )

- ▶ **nezávislé** výběry (shodné rozptyly, normální rozdělení)
- ▶  $H_0 : \mu_1 = \mu_2 = \dots = \mu_k$  ( $= \mu$ )      $H_1 : \text{neplatí } H_0$

- ▶ celkový průměr  $\bar{Y}_{\bullet\bullet}$ , celkový rozsah  $n = \sum_{i=1}^k n_i$

- ▶ rozklad součtu čtverců

$$\sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^k n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{i\bullet})^2$$

(celková variabilita) = (variabilita mezi) + (variabilita uvnitř)

$$S_T = S_A + S_e$$

$$f_T = f_A + f_e$$

$$(n - 1) = (k - 1) + (n - k)$$

## analýza rozptylu jednoduchého třídění (ANOVA)

- ▶  $Y_{11}, \dots, Y_{1n_1} \sim N(\mu_1, \sigma^2)$  (první výběr, průměr  $\bar{Y}_{1\bullet}$ )
- $Y_{21}, \dots, Y_{2n_2} \sim N(\mu_2, \sigma^2)$  (druhý výběr, průměr  $\bar{Y}_{2\bullet}$ )
- ...
- $Y_{k1}, \dots, Y_{kn_k} \sim N(\mu_k, \sigma^2)$  ( $k$ -tý výběr, průměr  $\bar{Y}_{k\bullet}$ )
- ▶ **nezávislé** výběry (shodné rozptyly, normální rozdělení)
- ▶  $H_0 : \mu_1 = \mu_2 = \dots = \mu_k$  ( $= \mu$ )     $H_1 : \text{neplatí } H_0$
- ▶ celkový průměr  $\bar{Y}_{\bullet\bullet}$ , celkový rozsah  $n = \sum_{i=1}^k n_i$
- ▶ rozklad součtu čtverců

$$\sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^k n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{i\bullet})^2$$

(celková variabilita) = (variabilita mezi) + (variabilita uvnitř)

$$S_T = S_A + S_e$$

$$f_T = f_A + f_e$$

$$(n - 1) = (k - 1) + (n - k)$$

## analýza rozptylu jednoduchého třídění (ANOVA)

- ▶  $Y_{11}, \dots, Y_{1n_1} \sim N(\mu_1, \sigma^2)$  (první výběr, průměr  $\bar{Y}_{1\bullet}$ )
- $Y_{21}, \dots, Y_{2n_2} \sim N(\mu_2, \sigma^2)$  (druhý výběr, průměr  $\bar{Y}_{2\bullet}$ )

...

$Y_{k1}, \dots, Y_{kn_k} \sim N(\mu_k, \sigma^2)$  ( $k$ -tý výběr, průměr  $\bar{Y}_{k\bullet}$ )

- ▶ **nezávislé** výběry (shodné rozptyly, normální rozdělení)
- ▶  $H_0 : \mu_1 = \mu_2 = \dots = \mu_k$  ( $= \mu$ )     $H_1 : \text{neplatí } H_0$
- ▶ celkový průměr  $\bar{Y}_{\bullet\bullet}$ , celkový rozsah  $n = \sum_{i=1}^k n_i$
- ▶ rozklad součtu čtverců

$$\sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^k n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{i\bullet})^2$$

(celková variabilita) = (variabilita mezi) + (variabilita uvnitř)

$$S_T = S_A + S_e$$

$$f_T = f_A + f_e$$


$$(n - 1) = (k - 1) + (n - k)$$

## rozklad součtu čtverců

příklad játra (celkový průměr  $\bar{y}_{\bullet\bullet} = 0,36$ )

(celková variabilita) = (variabilita mezi) + (variabilita uvnitř)

$$\sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^k n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{i\bullet})^2$$



## tabulka analýzy rozptylu

$$H_0 \text{ zamítnout, je-li } F_A = \frac{S_A/f_A}{S_e/f_e} \geq F_{f_A, f_e}(\alpha)$$

variabilita	$S$	$f$	$S/f$	$F$	$p$
výběry	$S_A$	$f_A = k - 1$	$S_A/f_A$	$F_A$	$p_A$
reziduální	$S_e$	$f_e = n - k$	$S_e/f_e$		
celková	$S_T$	$f_T = n - 1$			

- ▶  $S$  – součty čtverců, jejich rozklad
- ▶  $f$  – počty stupňů volnosti
- ▶  $S/f$  – průměrné čtverce
- ▶  $F$  –  $F$ -statistika
- ▶  $p$  –  $p$ -hodnota

## tabulka analýzy rozptylu

$$H_0 \text{ zamítnout, je-li } F_A = \frac{S_A/f_A}{S_e/f_e} \geq F_{f_A, f_e}(\alpha)$$

variabilita	$S$	$f$	$S/f$	$F$	$p$
výběry	$S_A$	$f_A = k - 1$	$S_A/f_A$	$F_A$	$p_A$
reziduální	$S_e$	$f_e = n - k$	$S_e/f_e$		
celková	$S_T$	$f_T = n - 1$			

- ▶  $S$  – součty čtverců, jejich rozklad
- ▶  $f$  – počty stupňů volnosti
- ▶  $S/f$  – průměrné čtverce
- ▶  $F$  –  $F$ -statistika
- ▶  $p$  –  $p$ -hodnota

## tabulka analýzy rozptylu

$$H_0 \text{ zamítnout, je-li } F_A = \frac{S_A/f_A}{S_e/f_e} \geq F_{f_A, f_e}(\alpha)$$

variabilita	$S$	$f$	$S/f$	$F$	$p$
výběry	$S_A$	$f_A = k - 1$	$S_A/f_A$	$F_A$	$p_A$
reziduální	$S_e$	$f_e = n - k$	$S_e/f_e$		
celková	$S_T$	$f_T = n - 1$			

- ▶  $S$  – součty čtverců, jejich rozklad
- ▶  $f$  – počty stupňů volnosti
- ▶  $S/f$  – průměrné čtverce
- ▶  $F$  –  $F$ -statistika
- ▶  $p$  –  $p$ -hodnota



## tabulka analýzy rozptylu

$$H_0 \text{ zamítnout, je-li } F_A = \frac{S_A/f_A}{S_e/f_e} \geq F_{f_A, f_e}(\alpha)$$

variabilita	$S$	$f$	$S/f$	$F$	$p$
výběry	$S_A$	$f_A = k - 1$	$S_A/f_A$	$F_A$	$p_A$
reziduální	$S_e$	$f_e = n - k$	$S_e/f_e$		
celková	$S_T$	$f_T = n - 1$			

- ▶  $S$  – součty čtverců, jejich rozklad
- ▶  $f$  – počty stupňů volnosti
- ▶  $S/f$  – průměrné čtverce
- ▶  $F$  –  $F$ -statistika
- ▶  $p$  –  $p$ -hodnota

## tabulka analýzy rozptylu

$$H_0 \text{ zamítnout, je-li } F_A = \frac{S_A/f_A}{S_e/f_e} \geq F_{f_A, f_e}(\alpha)$$

variabilita	$S$	$f$	$S/f$	$F$	$p$
výběry	$S_A$	$f_A = k - 1$	$S_A/f_A$	$F_A$	$p_A$
reziduální	$S_e$	$f_e = n - k$	$S_e/f_e$		
celková	$S_T$	$f_T = n - 1$			

- ▶  $S$  – součty čtverců, jejich rozklad
- ▶  $f$  – počty stupňů volnosti
- ▶  $S/f$  – průměrné čtverce
- ▶  $F$  –  $F$ -statistika
- ▶  $p$  –  $p$ -hodnota

## příklad játra

variab.	$S$	$f$	$S/f$	$F$	$p$
místa	1,796	4	0,4490	5,862	0,0013
rezid.	2,285	30	0,0762		
celk.	4,081	34			

$$F = 5,862 > F_{4,30}(0,05) = 2,690$$

na 5% hladině jsme **prokázali rozdíl**

`[summary(aov(lnCu~Misto,data=Med))]`

nebo také

`[anova(lm(lnCu~Misto,data=Med))]`

## ověření předpokladů

- ▶ **nezávislost:** dáno organizací (plánem) pokusu  
předpoklad nelze vynechat či nahradit
- ▶ **shoda rozptylů:** (vyvážený model je málo citlivý na neshodu)
  - ▶ Leveneův test  
(vlastně jednoduché třídění s  $|Y_{ik} - \text{med}_k Y_{ik}|$ )  
 $p = 64,8 \%$  [levene.test(lnCu, Misto)]
  - ▶ Bartlettův test  
(citlivý na splnění předpokladu o normálním rozdělení)  
 $p = 45,3 \%$  [bartlett.test(lnCu, Misto)]
- ▶ **normální rozdělení:** (vyvážený model je málo citlivý na nenormalitu), test normality nutno uplatnit na rezidua  $Y_{it} - \bar{Y}_{i\bullet}$  (na všech  $n$  reziduí najednou)  $p = 6,8 \%$   
 [shapiro.test(resid(aov(lnCu~Misto)))]  
 nebo [shapiro.test(resid(lm(lnCu~Misto)))]

## ověření předpokladů

- ▶ **nezávislost**: dáno organizací (plánem) pokusu  
předpoklad nelze vynechat či nahradit
- ▶ **shoda rozptylů**: (vyvážený model je málo citlivý na neshodu)
  - ▶ Leveneův test  
(vlastně jednoduché třídění s  $|Y_{it} - \text{med}_t Y_{it}|$ )  
 $p = 64,8 \%$  [levne.test(lnCu,Misto)]
  - ▶ Bartlettův test  
(citlivý na splnění předpokladu o normálním rozdělení)  
 $p = 45,3 \%$  [bartlett.test(lnCu,Misto)]
- ▶ **normální rozdělení**: (vyvážený model je málo citlivý na nenormalitu), test normality nutno uplatnit na rezidua  $Y_{it} - \bar{Y}_{i\bullet}$  (na všech  $n$  reziduí najednou)  $p = 6,8 \%$   
[shapiro.test(resid(aov(lnCu~Misto)))]  
 nebo [shapiro.test(resid(lm(lnCu~Misto)))]

## ověření předpokladů

- ▶ **nezávislost**: dáno organizací (plánem) pokusu  
předpoklad nelze vynechat či nahradit
- ▶ **shoda rozptylů**: (vyvážený model je málo citlivý na neshodu)
  - ▶ Leveneův test  
(vlastně jednoduché třídění s  $|Y_{it} - \text{med}_t Y_{it}|$ )  
 $p = 64,8 \%$  [levene.test(lnCu,Misto)]
  - ▶ Bartlettův test  
(citlivý na splnění předpokladu o normálním rozdělení)  
 $p = 45,3 \%$  [bartlett.test(lnCu,Misto)]
- ▶ **normální rozdělení**: (vyvážený model je málo citlivý na nenormalitu), test normality nutno uplatnit na rezidua  $Y_{it} - \bar{Y}_{i\bullet}$  (na všech  $n$  reziduí najednou)  $p = 6,8 \%$   
[shapiro.test(resid(aov(lnCu~Misto)))]  
 nebo [shapiro.test(resid(lm(lnCu~Misto)))]

## ověření předpokladů

- ▶ **nezávislost**: dáno organizací (plánem) pokusu  
předpoklad nelze vynechat či nahradit
- ▶ **shoda rozptylů**: (vyvážený model je málo citlivý na neshodu)
  - ▶ Leveneův test  
(vlastně jednoduché třídění s  $|Y_{it} - \text{med}_t Y_{it}|$ )  
 $p = 64,8 \%$  [levene.test(lnCu,Misto)]
  - ▶ Bartlettův test  
(citlivý na splnění předpokladu o normálním rozdělení)  
 $p = 45,3 \%$  [bartlett.test(lnCu,Misto)]
- ▶ **normální rozdělení**: (vyvážený model je málo citlivý na nenormalitu), test normality nutno uplatnit na rezidua  $Y_{it} - \bar{Y}_{i\bullet}$  (na všech  $n$  reziduí najednou)  $p = 6,8 \%$   
[shapiro.test(resid(aov(lnCu~Misto)))]  
 nebo [shapiro.test(resid(lm(lnCu~Misto)))]

## ověření předpokladů

- ▶ **nezávislost**: dáno organizací (plánem) pokusu  
předpoklad nelze vynechat či nahradit
- ▶ **shoda rozptylů**: (vyvážený model je málo citlivý na neshodu)
  - ▶ Leveneův test  
(vlastně jednoduché třídění s  $|Y_{it} - \text{med}_t Y_{it}|$ )  
 $p = 64,8 \%$  [levene.test(lnCu,Misto)]
  - ▶ Bartlettův test  
(citlivý na splnění předpokladu o normálním rozdělení)  
 $p = 45,3 \%$  [bartlett.test(lnCu,Misto)]
- ▶ **normální rozdělení**: (vyvážený model je málo citlivý na nenormalitu), test normality nutno uplatnit na rezidua  $Y_{it} - \bar{Y}_{i\bullet}$  (na všech  $n$  reziduí najednou)  $p = 6,8 \%$   
[shapiro.test(resid(aov(lnCu~Misto)))]  
 nebo [shapiro.test(resid(lm(lnCu~Misto)))]



## varianty zápisu modelu AR jednoduchého třídění

- ▶ **model** – idealizovaná představa o vzniku pozorované hodnoty
- ▶ měření = úroveň + náhodná „chyba“  
měření = systematická složka + náhodná složka

$$\begin{aligned}
 Y_{it} &= \mu_i + E_{it} & 1 \leq t \leq n_i, \quad 1 \leq i \leq k \\
 &= \mu + (\mu_i - \mu) + E_{it} & E_{it} \text{ nezávislé} \\
 &= \mu + \alpha_i + E_{it} & E_{it} \sim N(0, \sigma^2)
 \end{aligned}$$

- ▶ reparametrizace ( $\alpha_i$  – efekty faktoru  $A$ ):

$$\sum_{i=1}^k \alpha_i = 0$$

- ▶  $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_k$  (totéž jako  $\mu_1 = \mu_2 = \dots = \mu_k$ )
- ▶ pro  $k = 2$  je  $F_A = T^2$  (vztah s dvouvýběrovým  $t$ -testem)

## varianty zápisu modelu AR jednoduchého třídění

- ▶ **model** – idealizovaná představa o vzniku pozorované hodnoty
- ▶ měření = úroveň + náhodná „chyba“  
měření = systematická složka + náhodná složka

$$\begin{aligned}
 Y_{it} &= \mu_i + E_{it} & 1 \leq t \leq n_i, & \quad 1 \leq i \leq k \\
 &= \mu + (\mu_i - \mu) + E_{it} & & \quad E_{it} \text{ nezávislé} \\
 &= \mu + \alpha_i + E_{it} & & \quad E_{it} \sim N(0, \sigma^2)
 \end{aligned}$$

- ▶ reparametrizace ( $\alpha_i$  – efekty faktoru  $A$ ):

$$\sum_{i=1}^k \alpha_i = 0$$

- ▶  $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_k$  (totéž jako  $\mu_1 = \mu_2 = \dots = \mu_k$ )
- ▶ pro  $k = 2$  je  $F_A = T^2$  (vztah s dvouvýběrovým  $t$ -testem)

## varianty zápisu modelu AR jednoduchého třídění

- ▶ **model** – idealizovaná představa o vzniku pozorované hodnoty
- ▶ měření = úroveň + náhodná „chyba“  
měření = systematická složka + náhodná složka

$$\begin{aligned}
 Y_{it} &= \mu_i + E_{it} & 1 \leq t \leq n_i, & \quad 1 \leq i \leq k \\
 &= \mu + (\mu_i - \mu) + E_{it} & & \quad E_{it} \text{ nezávislé} \\
 &= \mu + \alpha_i + E_{it} & & \quad E_{it} \sim N(0, \sigma^2)
 \end{aligned}$$

- ▶ **reparametrizace** ( $\alpha_i$  – efekty faktoru  $A$ ):

$$\sum_{i=1}^k \alpha_i = 0$$

- ▶  $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_k$  (totéž jako  $\mu_1 = \mu_2 = \dots = \mu_k$ )
- ▶ pro  $k = 2$  je  $F_A = T^2$  (vztah s dvouvýběrovým  $t$ -testem)

## varianty zápisu modelu AR jednoduchého třídění

- ▶ **model** – idealizovaná představa o vzniku pozorované hodnoty
- ▶ měření = úroveň + náhodná „chyba“  
měření = systematická složka + náhodná složka

$$\begin{aligned} Y_{it} &= \mu_i + E_{it} & 1 \leq t \leq n_i, \quad 1 \leq i \leq k \\ &= \mu + (\mu_i - \mu) + E_{it} & E_{it} \text{ nezávislé} \\ &= \mu + \alpha_i + E_{it} & E_{it} \sim N(0, \sigma^2) \end{aligned}$$

- ▶ **reparametrizace** ( $\alpha_i$  – efekty faktoru  $A$ ):

$$\sum_{i=1}^k \alpha_i = 0$$

- ▶  $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_k$  (totéž jako  $\mu_1 = \mu_2 = \dots = \mu_k$ )
- ▶ pro  $k = 2$  je  $F_A = T^2$  (vztah s dvouvýběrovým  $t$ -testem)

## varianty zápisu modelu AR jednoduchého třídění

- ▶ **model** – idealizovaná představa o vzniku pozorované hodnoty
- ▶ měření = úroveň + náhodná „chyba“  
měření = systematická složka + náhodná složka

$$\begin{aligned}
 Y_{it} &= \mu_i + E_{it} & 1 \leq t \leq n_i, & \quad 1 \leq i \leq k \\
 &= \mu + (\mu_i - \mu) + E_{it} & & \quad E_{it} \text{ nezávislé} \\
 &= \mu + \alpha_i + E_{it} & & \quad E_{it} \sim N(0, \sigma^2)
 \end{aligned}$$

- ▶ **reparametrizace** ( $\alpha_i$  – efekty faktoru  $A$ ):

$$\sum_{i=1}^k \alpha_i = 0$$

- ▶  $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_k$  (totéž jako  $\mu_1 = \mu_2 = \dots = \mu_k$ )
- ▶ pro  $k = 2$  je  $F_A = T^2$  (vztah s dvouvýběrovým  $t$ -testem)

## mnohonásobná srovnání

(Tukeyův test, Kramerova verze)

- ▶ nutnost zachovat zvolenou hladinu testu i při současném rozhodování o řadě hypotéz  
(např. že  $\mu_1 = \mu_2$ ,  $\mu_1 = \mu_3$ ,  $\mu_2 = \mu_3$ , ...)
- ▶ které dvojice úrovní faktoru (stř. hodnoty  $\mu_i$  resp. efekty  $\alpha_i$ ) se liší?

$$|\bar{Y}_{i\bullet} - \bar{Y}_{j\bullet}| \geq q_{k,n-k}(\alpha) \sqrt{\frac{S^2}{2} \left( \frac{1}{n_i} + \frac{1}{n_j} \right)}$$

kde  $q_{k,n-k}(\alpha)$  je tabelovaná kritická hodnota

$$S^2 = \frac{S_e}{f_e} = \frac{\sum \sum (Y_{it} - \bar{Y}_{i\bullet})^2}{n - k}$$

## mnohonásobná srovnání

(Tukeyův test, Kramerova verze)

- ▶ nutnost zachovat zvolenou hladinu testu i při současném rozhodování o řadě hypotéz  
(např. že  $\mu_1 = \mu_2$ ,  $\mu_1 = \mu_3$ ,  $\mu_2 = \mu_3$ , ...)
- ▶ které dvojice úrovní faktoru (stř. hodnoty  $\mu_i$  resp. efekty  $\alpha_i$ ) se liší?

$$|\bar{Y}_{i\bullet} - \bar{Y}_{j\bullet}| \geq q_{k,n-k}(\alpha) \sqrt{\frac{S^2}{2} \left( \frac{1}{n_i} + \frac{1}{n_j} \right)}$$

kde  $q_{k,n-k}(\alpha)$  je tabelovaná kritická hodnota

$$S^2 = \frac{S_e}{f_e} = \frac{\sum \sum (Y_{it} - \bar{Y}_{i\bullet})^2}{n - k}$$

## příklad játra

místo	počet	průměr	efekt	směr. odchylka
A	7	0,568	0,206	0,312
B	7	0,484	0,121	0,279
C	7	0,495	0,133	0,318
D	7	-0,063	-0,426	0,290
E	7	0,329	-0,034	0,144
celkem	35	0,363	0,000	0,104

$$q_{5,30}(0,05) \sqrt{\frac{0,0762}{2} \left( \frac{1}{7} + \frac{1}{7} \right)} = 4,10 \cdot 0,104 = 0,428$$

$-0,063 + 0,428 = 0,365 \Rightarrow$  na 5% hladině se místa D s nejmenším průměrem liší všechna místa s průměry aspoň 0,365, tedy místa A, B, C, nikoliv E


[TukeyHSD(aov(lnCu~Misto,data=Med))]



## příklad játra

funkce `[TukeyHSD(aov(lnCu~Misto,data=Med))]`  
 dá tabulku porovnání všech dvojic  
 pomocí knihovny Rcmdr dostaneme také graf

95% family-wise confidence level



# Kruskalův-Wallisův text

(neparametrický test)

- ▶ zobecnění dvouvýběrového Wilcoxonova testu (použije opět pořadí místo původních hodnot)
- ▶ předpoklady:
  - ▶  $k$  nezávislých výběrů
  - ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná (tedy i mediány jsou stejné)
- ▶  $T_i$  - součet pořadí v  $i$ -tém výběru

$$Q = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{T_i^2}{n_i} - 3(n+1)$$

$H_0$  se zamítá při  $Q \geq \chi_{k-1}^2(\alpha)$   
(velká variabilita průměrných pořadí)

# Kruskalův-Wallisův text

(neparametrický test)

- ▶ zobecnění dvouvýběrového Wilcoxonova testu (použije opět pořadí místo původních hodnot)
- ▶ předpoklady:
  - ▶  $k$  nezávislých výběrů
  - ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná (tedy i mediány jsou stejné)
- ▶  $T_i$  - součet pořadí v  $i$ -tém výběru

$$Q = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{T_i^2}{n_i} - 3(n+1)$$

$H_0$  se zamítá při  $Q \geq \chi_{k-1}^2(\alpha)$   
(velká variabilita průměrných pořadí)

# Kruskalův-Wallisův text

(neparametrický test)

- ▶ zobecnění dvouvýběrového Wilcoxonova testu (použije opět pořadí místo původních hodnot)
- ▶ předpoklady:
  - ▶  $k$  nezávislých výběrů
  - ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná (tedy i mediány jsou stejné)
- ▶  $T_i$  - součet pořadí v  $i$ -tém výběru

$$Q = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{T_i^2}{n_i} - 3(n+1)$$

$H_0$  se zamítá při  $Q \geq \chi_{k-1}^2(\alpha)$   
(velká variabilita průměrných pořadí)

# Kruskalův-Wallisův text

(neparametrický test)

- ▶ zobecnění dvouvýběrového Wilcoxonova testu (použije opět pořadí místo původních hodnot)
- ▶ předpoklady:
  - ▶  $k$  nezávislých výběrů
  - ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná (tedy i mediány jsou stejné)
- ▶  $T_i$  - součet pořadí v  $i$ -tém výběru

$$Q = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{T_i^2}{n_i} - 3(n+1)$$

$H_0$  se zamítá při  $Q \geq \chi_{k-1}^2(\alpha)$   
(velká variabilita průměrných pořadí)

# Kruskalův-Wallisův text

(neparametrický test)

- ▶ zobecnění dvouvýběrového Wilcoxonova testu (použije opět pořadí místo původních hodnot)
- ▶ předpoklady:
  - ▶  $k$  nezávislých výběrů
  - ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná (tedy i mediány jsou stejné)
- ▶  $T_i$  - součet pořadí v  $i$ -tém výběru

$$Q = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{T_i^2}{n_i} - 3(n+1)$$

$H_0$  se zamítá při  $Q \geq \chi_{k-1}^2(\alpha)$   
(velká variabilita průměrných pořadí)

# Kruskalův-Wallisův text


(neparametrický test)

- ▶ zobecnění dvouvýběrového Wilcoxonova testu (použije opět pořadí místo původních hodnot)
- ▶ předpoklady:
  - ▶  $k$  nezávislých výběrů
  - ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná (tedy i mediány jsou stejné)
- ▶  $T_i$  - součet pořadí v  $i$ -tém výběru

$$Q = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{T_i^2}{n_i} - 3(n+1)$$

$H_0$  se zamítá při  $Q \geq \chi_{k-1}^2(\alpha)$   
(velká variabilita průměrných pořadí)

## příklad kojení – věk matek podle vzdělání



je patrná nesymetrie, zejména u základního vzdělání



## příklad kojení – věk matek podle vzdělání

vzdělání	$n_i$	průměrný věk	střední chyba	součet pořadí	průměrné pořadí
základní	34	23,412	0,638	1025	30,15
maturita	47	26,278	0,543	2618	55,70
VŠ	18	28,500	0,877	1307	72,61
celk.	99	25,697		4950	50,00

$$Q = \frac{12}{99 \cdot 100} \left( \frac{1025^2}{34} + \frac{2618^2}{47} + \frac{1307^2}{18} \right) - 3 \cdot 100 = 29,25$$

$$\chi_2^2(0,05) = 5,99 \quad p < 0,0001$$

[kruskal.test(vek.m~Vzdelani,data=Kojeni)]

(přesnější hodnocení přihlíží ke shodám při určování pořadí)

## porovnání populačních měř polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový $t$ - test	jednovýběrový Wilcoxon
výběr dvojic	párový $t$ -test	znaménkový, Wilcoxon
dva nezávislé výběry	dvouvýběrový $t$ -test	Mann-Whitney (Kolmogorov-Smirnov)
$k$ nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr $r$ -tic	analýza rozptylu náhodné bloky	Friedman

# motivační příklad diety: váhové přírůstky za danou dobu

rozšíření úlohy párového testu

vrh	dieta				průměr
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
průměr	8,56	8,06	10,28	10,58	9,370

- ▶  $r = 4$  ošetření (pevné efekty, zvolili jsme je sami)
- ▶  $k = 5$  vrhů (náhodné efekty, zvolila je náhodně příroda)
- ▶ jsou patrné rozdíly mezi průměry pro jednotlivá ošetření i pro jednotlivé vrhy
- ▶ kdyby byly jen dvě diety ( $r = 2$ ), použili bychom párový test (sourozenci možná reagují na dietu podobně)

# motivační příklad diety: váhové přírůstky za danou dobu

rozšíření úlohy párového testu

vrh	dieta				průměr
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
průměr	8,56	8,06	10,28	10,58	9,370

- ▶  $r = 4$  ošetření (pevné efekty, zvolili jsme je sami)
- ▶  $k = 5$  vrhů (náhodné efekty, zvolila je náhodně příroda)
- ▶ jsou patrné rozdíly mezi průměry pro jednotlivá ošetření i pro jednotlivé vrhy
- ▶ kdyby byly jen dvě diety ( $r = 2$ ), použili bychom párový test (sourozenci možná reagují na dietu podobně)

# motivační příklad diety: váhové přírůstky za danou dobu

rozšíření úlohy párového testu

vrh	dieta				průměr
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
průměr	8,56	8,06	10,28	10,58	9,370

- ▶  $r = 4$  ošetření (pevné efekty, zvolili jsme je sami)
- ▶  $k = 5$  vrhů (náhodné efekty, zvolila je náhodně příroda)
- ▶ jsou patrné rozdíly mezi průměry pro jednotlivá ošetření i pro jednotlivé vrhy
- ▶ kdyby byly jen dvě diety ( $r = 2$ ), použili bychom párový test (sourozenci možná reagují na dietu podobně)

# motivační příklad diety: váhové přírůstky za danou dobu

rozšíření úlohy párového testu

vrh	dieta				průměr
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
průměr	8,56	8,06	10,28	10,58	9,370

- ▶  $r = 4$  ošetření (pevné efekty, zvolili jsme je sami)
- ▶  $k = 5$  vrhů (náhodné efekty, zvolila je náhodně příroda)
- ▶ jsou patrné rozdíly mezi průměry pro jednotlivá ošetření i pro jednotlivé vrhy
- ▶ kdyby byly jen dvě diety ( $r = 2$ ), použili bychom párový test (sourozenci možná reagují na dietu podobně)

# náhodné bloky

## normální rozdělení náhodné složky modelu

- ▶ účel: porovnat dvě nebo více **ošetření** na stejných objektech
- ▶ zobecnění **párových testů** na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření (nebo jeho násobek)
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně**  
(každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2) \quad j = 1, \dots, r; i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$   
(vliv ošetření je stejný při různých hodnotách  $A_i$ )

# náhodné bloky

## normální rozdělení náhodné složky modelu

- ▶ účel: porovnat dvě nebo více **ošetření** na stejných objektech
- ▶ zobecnění **párových testů** na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření (nebo jeho násobek)
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně**  
(každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2) \quad j = 1, \dots, r; i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$   
(vliv ošetření je stejný při různých hodnotách  $A_i$ )



# náhodné bloky

## normální rozdělení náhodné složky modelu

- ▶ účel: porovnat dvě nebo více **ošetření** na stejných objektech
- ▶ zobecnění **párových testů** na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření (nebo jeho násobek)
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně** (každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2) \quad j = 1, \dots, r; i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$   
(vliv ošetření je stejný při různých hodnotách  $A_i$ )

# náhodné bloky

## normální rozdělení náhodné složky modelu

- ▶ účel: porovnat dvě nebo více **ošetření** na stejných objektech
- ▶ zobecnění **párových testů** na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření (nebo jeho násobek)
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně** (každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2) \quad j = 1, \dots, r; i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$   
(vliv ošetření je stejný při různých hodnotách  $A_i$ )

# náhodné bloky

## normální rozdělení náhodné složky modelu

- ▶ účel: porovnat dvě nebo více **ošetření** na stejných objektech
- ▶ zobecnění **párových testů** na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření (nebo jeho násobek)
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně** (každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2) \quad j = 1, \dots, r; i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$   
(vliv ošetření je stejný při různých hodnotách  $A_i$ )

# náhodné bloky

## normální rozdělení náhodné složky modelu

- ▶ účel: porovnat dvě nebo více **ošetření** na stejných objektech
- ▶ zobecnění **párových testů** na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření (nebo jeho násobek)
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně** (každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2) \quad j = 1, \dots, r; i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$   
(vliv ošetření je stejný při různých hodnotách  $A_i$ )

# náhodné bloky

## normální rozdělení náhodné složky modelu

- ▶ účel: porovnat dvě nebo více **ošetření** na stejných objektech
- ▶ zobecnění **párových testů** na  $r$ -tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina  $r$  objektů
  - ▶ počet objektů ve skupině = počet ošetření (nebo jeho násobek)
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně** (každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2) \quad j = 1, \dots, r; i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$   
(vliv ošetření je stejný při různých hodnotách  $A_i$ )

# náhodné bloky

## ▶ testované hypotézy

▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

## ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

## ▶ vliv dvou faktorů

- ▶  $A$  – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
- ▶  $B$  – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
- ▶ rozhodování zda  $A$  je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

- ▶ testované hypotézy

- ▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

- ▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou faktorů

- ▶  $A$  – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶  $B$  – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda  $A$  je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

- ▶ testované hypotézy

- ▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

- ▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou faktorů

- ▶  $A$  – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶  $B$  – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda  $A$  je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci



# náhodné bloky

- ▶ testované hypotézy

- ▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

- ▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou faktorů

- ▶  $A$  – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶  $B$  – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda  $A$  je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

- ▶ testované hypotézy

- ▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

- ▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou **faktorů**

- ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

## náhodné bloky

- ▶ testované hypotézy
  - ▶  $H_B : \beta_1 = \dots = \beta_r = 0$  (ošetření  $B$  nemá vliv)
  - ▶ případně  $H_A : \sigma_A^2 = 0$  (nulová variabilita mezi bloky)
- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou **faktorů**
  - ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

# náhodné bloky

- ▶ testované hypotézy

- ▶  $H_B : \beta_1 = \dots = \beta_r = 0$

(ošetření  $B$  nemá vliv)

- ▶ případně  $H_A : \sigma_A^2 = 0$

(nulová variabilita mezi bloky)

- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou **faktorů**

- ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné

- ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné

- ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

## náhodné bloky

- ▶ testované hypotézy
  - ▶  $H_B : \beta_1 = \dots = \beta_r = 0$  (ošetření  $B$  nemá vliv)
  - ▶ případně  $H_A : \sigma_A^2 = 0$  (nulová variabilita mezi bloky)
- ▶ rozklad variability

$$S_T = S_A + S_B + S_e$$

- ▶ vliv dvou **faktorů**
  - ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

## příklad diety

- ▶ tabulka ANOVA (správná)

variabilita	$S$	$f$	$S/f$	$F$	$p$
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů

## příklad diety

- ▶ tabulka ANOVA (správná)

variabilita	$S$	$f$	$S/f$	$F$	$p$
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů

## příklad diety

- ▶ tabulka ANOVA (správná)

variabilita	$S$	$f$	$S/f$	$F$	$p$
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů



## příklad diety

- ▶ tabulka ANOVA (správná)

variabilita	$S$	$f$	$S/f$	$F$	$p$
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů

## příklad diety

- ▶ tabulka ANOVA (správná)

variabilita	$S$	$f$	$S/f$	$F$	$p$
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- ▶ na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4 \%$ )
- ▶ variabilita mezi vrhy je také průkazná ( $p < 0,1 \%$ )
- ▶ `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- ▶ pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů

## příklad diety

- ▶ kdybychom **nesprávně** nevzali v úvahu závislost některých pozorování způsobenou náhodnými bloky (vrhy), dostali bychom model ANOVA jednoduchého třídění

variabilita	$S$	$f$	$S/f$	$F$	$p$
dieta	23,332	3	7,774	1,193	0,344
reziduální	104,320	16	6,520	-	-
celk.	127,642	19	-	-	-

- ▶ `[summary(aov(prirustek~Dieta,data=Mysi))]`
- ▶ porovnání se správnou tabulkou analýzy rozptylu

$$S_e = 91,932 + 12,388 = 104,320, \quad f_e = 4 + 12 = 16$$

## příklad diety

- ▶ kdybychom **nesprávně** nevzali v úvahu závislost některých pozorování způsobenou náhodnými bloky (vrhy), dostali bychom model ANOVA jednoduchého třídění

variabilita	$S$	$f$	$S/f$	$F$	$p$
dieta	23,332	3	7,774	1,193	0,344
reziduální	104,320	16	6,520	-	-
celk.	127,642	19	-	-	-

- ▶ `[summary(aov(prirustek~Dieta,data=Mysi))]`
- ▶ porovnání se správnou tabulkou analýzy rozptylu

$$S_e = 91,932 + 12,388 = 104,320, \quad f_e = 4 + 12 = 16$$

## příklad diety

- ▶ kdybychom **nesprávně** nevzali v úvahu závislost některých pozorování způsobenou náhodnými bloky (vrhy), dostali bychom model ANOVA jednoduchého třídění

variabilita	$S$	$f$	$S/f$	$F$	$p$
dieta	23,332	3	7,774	1,193	0,344
reziduální	104,320	16	6,520	-	-
celk.	127,642	19	-	-	-

- ▶ `[summary(aov(prirustek~Dieta,data=Mysi))]`
- ▶ porovnání se správnou tabulkou analýzy rozptylu

$$S_e = 91,932 + 12,388 = 104,320, \quad f_e = 4 + 12 = 16$$

# Friedmanův test, zobecnění znaménkového testu

(neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt,  
jde vlastně o **dvojné třídění** bez interakcí)
- ▶  $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ urči pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu

(neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt,  
jde vlastně o **dvojné třídění** bez interakcí)
- ▶  $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ urči pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu

(neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt,  
jde vlastně o **dvojně třídění** bez interakcí)
- ▶  $E_{ij}$  nezávislé, spojitě rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ určí pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$



## Friedmanův test, zobecnění znaménkového testu

(neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt,  
jde vlastně o **dvojné třídění** bez interakcí)
- ▶  $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ urči pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu

(neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt,  
jde vlastně o **dvojné třídění** bez interakcí)
- ▶  $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ urči pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu

(neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt,  
jde vlastně o **dvojné třídění** bez interakcí)
- ▶  $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ urči pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

▶

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## Friedmanův test, zobecnění znaménkového testu

(neparametrický test, bez předpokladu normality)

- ▶ model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt,  
jde vlastně o **dvojné třídění** bez interakcí)
- ▶  $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
- ▶  $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
- ▶ urči pořadí v rámci každého bloku (řádku)  $R_{ij}$
- ▶ za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné

$$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$

- ▶ zamítnat  $H_0$  : pro  $Q \geq \chi_{r-1}^2(\alpha)$

## příklad diety

```
[friedman.test(prirustek~Dieta|Vrh,data=Mysi)]
```

vrh	dieta				prům.
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
prům.	8,56	8,06	10,28	10,58	9,370

vrh	dieta			
	A	B	C	D
1	2	1	3	4
2	1	2	4	3
3	2	1	4	3
4	3	1	2	4
5	1	2	4	3
součet	9	7	17	17

$$k = 5$$

$$r = 4$$

$$Q = \frac{12}{5 \cdot 4 \cdot 5} (9^2 + 7^2 + 17^2 + 17^2) - 3 \cdot 5 \cdot 5 = 9,96$$

$$Q > \chi_3^2(0,05) = 7,8147$$

$$p = 0,0189$$

# dvojné třídění s interakcemi

motivační příklad Howells

údaje zjištěné na exhumovaných lebkách

- ▶ místo: Austrálie (AUSTR), Rakousko (BERG), Sibiř (BURIAT)
- ▶ pohlaví: M, F
- ▶ vysvětlované znaky:
  - ▶ největší délka mozkovny GOL
  - ▶ týlní úhel OCA
- ▶ bude rozdíl mezi pohlavími na všech místech stejný?
  - ▶ pokud ano (vliv je aditivní, dvojné tř. bez interakcí)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + E_{ijt}$$

- ▶ pokud ne (vliv není aditivní, rozdíl závisí na místě)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt}$$

# dvojné třídění s interakcemi

motivační příklad Howells

údaje zjištěné na exhumovaných lebkách

- ▶ místo: Austrálie (AUSTR), Rakousko (BERG), Sibiř (BURIAT)
- ▶ pohlaví: M, F
- ▶ vysvětlované znaky:
  - ▶ největší délka mozkovny GOL
  - ▶ týlní úhel OCA
- ▶ bude rozdíl mezi pohlavími na všech místech stejný?
  - ▶ pokud ano (vliv je aditivní, dvojné tř. bez interakcí)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + E_{ijt}$$

- ▶ pokud ne (vliv není aditivní, rozdíl závisí na místě)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt}$$

# dvojné třídění s interakcemi

motivační příklad Howells

údaje zjištěné na exhumovaných lebkách

- ▶ místo: Austrálie (AUSTR), Rakousko (BERG), Sibiř (BURIAT)
- ▶ pohlaví: M, F
- ▶ vysvětlované znaky:
  - ▶ největší délka mozkovny GOL
  - ▶ týlní úhel OCA
- ▶ bude rozdíl mezi pohlavími na všech místech stejný?
  - ▶ pokud ano (vliv je aditivní, dvojné tř. bez interakcí)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + E_{ijt}$$

- ▶ pokud ne (vliv není aditivní, rozdíl závisí na místě)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt}$$



# dvojné třídění s interakcemi

motivační příklad Howells

údaje zjištěné na exhumovaných lebkách

- ▶ místo: Austrálie (AUSTR), Rakousko (BERG), Sibiř (BURIAT)
- ▶ pohlaví: M, F
- ▶ vysvětlované znaky:
  - ▶ největší délka mozkovny GOL
  - ▶ týlní úhel OCA
- ▶ bude rozdíl mezi pohlavími na všech místech stejný?
  - ▶ pokud ano (vliv je aditivní, dvojné tř. bez interakcí)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + E_{ijt}$$

- ▶ pokud ne (vliv není aditivní, rozdíl závisí na místě)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt}$$

# dvojné třídění s interakcemi

motivační příklad Howells

údaje zjištěné na exhumovaných lebkách

- ▶ místo: Austrálie (AUSTR), Rakousko (BERG), Sibiř (BURIAT)
- ▶ pohlaví: M, F
- ▶ vysvětlované znaky:
  - ▶ největší délka mozkovny GOL
  - ▶ týlní úhel OCA
- ▶ bude rozdíl mezi pohlavími na všech místech stejný?
  - ▶ pokud ano (vliv je aditivní, dvojné tř. bez interakcí)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + E_{ijt}$$

- ▶ pokud ne (vliv není aditivní, rozdíl závisí na místě)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt}$$

# dvojné třídění s interakcemi

motivační příklad Howells

údaje zjištěné na exhumovaných lebkách

- ▶ místo: Austrálie (AUSTR), Rakousko (BERG), Sibiř (BURIAT)
- ▶ pohlaví: M, F
- ▶ vysvětlované znaky:
  - ▶ největší délka mozkovny GOL
  - ▶ týlní úhel OCA
- ▶ bude rozdíl mezi pohlavími na všech místech stejný?
  - ▶ pokud ano (vliv je aditivní, **dvojné tř. bez interakcí**)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + E_{ijt}$$

- ▶ pokud ne (vliv není aditivní, rozdíl závisí na místě)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt}$$

# dvojné třídění s interakcemi

motivační příklad Howells

údaje zjištěné na exhumovaných lebkách

- ▶ místo: Austrálie (AUSTR), Rakousko (BERG), Sibiř (BURIAT)
- ▶ pohlaví: M, F
- ▶ vysvětlované znaky:
  - ▶ největší délka mozkovny GOL
  - ▶ týlní úhel OCA
- ▶ bude rozdíl mezi pohlavími na všech místech stejný?
  - ▶ pokud ano (vliv je aditivní, **dvojné tř. bez interakcí**)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + E_{ijt}$$

- ▶ pokud ne (vliv není aditivní, rozdíl závisí na místě)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt}$$

# dvojné třídění s interakcemi

motivační příklad Howells

údaje zjištěné na exhumovaných lebkách

- ▶ místo: Austrálie (AUSTR), Rakousko (BERG), Sibiř (BURIAT)
- ▶ pohlaví: M, F
- ▶ vysvětlované znaky:
  - ▶ největší délka mozkovny GOL
  - ▶ týlní úhel OCA
- ▶ bude rozdíl mezi pohlavími na všech místech stejný?
  - ▶ pokud ano (vliv je aditivní, **dvojné tř. bez interakcí**)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + E_{ijt}$$

- ▶ pokud ne (vliv není aditivní, rozdíl závisí na místě)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt}$$

# dvojné třídění s interakcemi

opět **normální rozdělení**, oba faktory **pevné**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$
- ▶  $\sum_i \alpha_i = 0$  (reparametrizační podmínka)  
**efekty** faktoru A odpovídající jeho  $k$  úrovním
- ▶  $\sum_j \beta_j = 0$  (reparametrizační podmínka)  
**efekty** faktoru B odpovídající jeho  $r$  úrovním
- ▶  $\sum_i \gamma_{ij} = 0, \sum_j \gamma_{ij} = 0$  (reparametrizační podmínka)  
**interakce** vyjadřují neaditivitu obou faktorů  
(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )

# dvojné třídění s interakcemi

opět **normální rozdělení**, oba faktory **pevné**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$
- ▶  $\sum_i \alpha_i = 0$  (reparametrizační podmínka)  
**efekty** faktoru A odpovídající jeho  $k$  úrovním
- ▶  $\sum_j \beta_j = 0$  (reparametrizační podmínka)  
**efekty** faktoru B odpovídající jeho  $r$  úrovním
- ▶  $\sum_i \gamma_{ij} = 0, \sum_j \gamma_{ij} = 0$  (reparametrizační podmínka)  
**interakce** vyjadřují neaditivitu obou faktorů  
(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )

# dvojné třídění s interakcemi

opět **normální rozdělení**, oba faktory **pevné**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$
- ▶  $\sum_i \alpha_i = 0$  (reparametrizační podmínka)  
**efekty** faktoru A odpovídající jeho  $k$  úrovním
- ▶  $\sum_j \beta_j = 0$  (reparametrizační podmínka)  
**efekty** faktoru B odpovídající jeho  $r$  úrovním
- ▶  $\sum_i \gamma_{ij} = 0, \sum_j \gamma_{ij} = 0$  (reparametrizační podmínka)  
**interakce** vyjadřují neaditivitu obou faktorů  
(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )



# dvojné třídění s interakcemi

opět **normální rozdělení**, oba faktory **pevné**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$
- ▶  $\sum_i \alpha_i = 0$  (reparametrizační podmínka)  
**efekty** faktoru A odpovídající jeho  $k$  úrovním
- ▶  $\sum_j \beta_j = 0$  (reparametrizační podmínka)  
**efekty** faktoru B odpovídající jeho  $r$  úrovním
- ▶  $\sum_i \gamma_{ij} = 0, \sum_j \gamma_{ij} = 0$  (reparametrizační podmínka)  
**interakce** vyjadřují neaditivitu obou faktorů  
(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )

## dvojné třídění s interakcemi

opět **normální rozdělení**, oba faktory **pevné**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

- ▶ symbolicky  $A + B + AB$
- ▶  $\sum_i \alpha_i = 0$  (reparametrizační podmínka)  
**efekty** faktoru A odpovídající jeho  $k$  úrovním
- ▶  $\sum_j \beta_j = 0$  (reparametrizační podmínka)  
**efekty** faktoru B odpovídající jeho  $r$  úrovním
- ▶  $\sum_i \gamma_{ij} = 0, \sum_j \gamma_{ij} = 0$  (reparametrizační podmínka)  
**interakce** vyjadřují neaditivitu obou faktorů  
(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (**aditivita** obou faktorů, interakcí netřeba)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A  
(vliv pohlaví je stejný na všech místech)
- ▶  $H_A : \alpha_i = 0$ : faktor A nemá vliv (nezáleží na místu)
- ▶  $H_B : \beta_j = 0$ : faktor B nemá vliv (nezáleží na pohlaví)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (**aditivita** obou faktorů, interakcí netřeba)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A  
(vliv pohlaví je stejný na všech místech)
- ▶  $H_A : \alpha_i = 0$ : faktor A nemá vliv (nezáleží na místu)
- ▶  $H_B : \beta_j = 0$ : faktor B nemá vliv (nezáleží na pohlaví)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (**aditivita** obou faktorů, interakcí netřeba)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A  
(vliv pohlaví je stejný na všech místech)
- ▶  $H_A : \alpha_i = 0$ : faktor A nemá vliv (nezáleží na místu)
- ▶  $H_B : \beta_j = 0$ : faktor B nemá vliv (nezáleží na pohlaví)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (**aditivita** obou faktorů, interakcí netřeba)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A  
(vliv pohlaví je stejný na všech místech)
- ▶  $H_A : \alpha_i = 0$ : faktor A nemá vliv (nezáleží na místu)
- ▶  $H_B : \beta_j = 0$ : faktor B nemá vliv (nezáleží na pohlaví)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (**aditivita** obou faktorů, interakcí netřeba)  
vliv úrovně faktoru A je stejný při všech úrovních faktoru B  
vliv úrovně faktoru B je stejný při všech úrovních faktoru A  
(vliv pohlaví je stejný na všech místech)
- ▶  $H_A : \alpha_i = 0$ : faktor A nemá vliv (nezáleží na místu)
- ▶  $H_B : \beta_j = 0$ : faktor B nemá vliv (nezáleží na pohlaví)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme největší délku mozkovny GOL

```
[anova(lm(gol~Gender*Popul))]
```

```
[anova(lm(gol~Gender+Popul+Gender:Popul))]
```

nebo



$$p_{AB} = 0,8872$$




## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme největší délku mozkovny GOL

```
[anova(lm(gol~Gender*Popul))]
```

```
[anova(lm(gol~Gender+Popul+Gender:Popul))]
```

nebo



$$p_{AB} = 0,8872$$


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme největší délku mozkovny GOL

`[anova(lm(gol~Gender*Popul))]`

`[anova(lm(gol~Gender+Popul+Gender:Popul))]`

nebo



$$p_{AB} = 0,8872$$

## příklad Howells (GOL)

pohlaví	místo	$n_{ij}$	$\bar{y}_{ij}$	$s_{ij}$
M	Berg	40	180,300	7,293
F	Berg	40	170,450	6,641
M	Austrálie	40	190,375	5,555
F	Austrálie	40	181,375	6,632
M	Sibiř	40	181,175	6,468
F	Sibiř	40	172,175	5,228

variabilita	$S$	$f$	$S/f$	$F$	$p$
místa	5242,1	2	2621,1	65,2	<0,0001
pohlaví	5170,8	1	5170,8	128,6	<0,0001
interakce	9,6	2	4,8	0,1	0,8872
reziduální	9410,6	234	40,2		
celková	19833,2	239			


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme týlní úhel OCA

```
[anova(lm(oca~Gender*Popul))]
```

```
[anova(lm(oca~Gender+Popul+Gender:Popul))]
```

nebo



$$p_{AB} = 0,0222$$


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme týlní úhel OCA

```
[anova(lm(oca~Gender*Popul))]
```

```
[anova(lm(oca~Gender+Popul+Gender:Popul))]
```

nebo



$$p_{AB} = 0,0222$$


## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme týlní úhel OCA

`[anova(lm(oca~Gender*Popul))]`

`[anova(lm(oca~Gender+Popul+Gender:Popul))]`

nebo



$$p_{AB} = 0,0222$$

## příklad Howells (OCA)

pohlaví	místo	$n_{ij}$	$\bar{y}_{ij}$	$s_{ij}$
M	Berg	40	116,675	5,567
F	Berg	40	116,850	5,682
M	Austrálie	40	115,025	4,382
F	Austrálie	40	114,800	4,286
M	Sibiř	40	113,450	4,782
F	Sibiř	40	117,200	4,973

variabilita	$S$	$f$	$S/f$	$F$	$p$
místa	150,908	2	75,454	3,05	0,0493
pohlaví	91,267	1	91,267	3,69	0,0560
interakce	191,608	2	95,804	3,87	0,0222
reziduální	5789,550	234	24,742		
celková	6223,333	239			

## porovnání populačních měř polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový $t$ - test	jednovýběrový Wilcoxon
výběr dvojic	párový $t$ -test	znaménkový, Wilcoxon
dva nezávislé výběry	dvouvýběrový $t$ -test	Mann-Whitney (Kolmogorov-Smirnov)
$k$ nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr $r$ -tic	analýza rozptylu náhodné bloky	Friedman



# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	<i>logistická regrese</i>
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	<i>logistická regrese</i>
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	logistická regrese
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	<i>logistická regrese</i>
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na **nezávisle** proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na **nezávisle** proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na **nezávisle** proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává jak závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti závisle proměnné  $Y$  na nezávisle proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$



# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává jak závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti závisle proměnné  $Y$  na nezávisle proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelace a regrese

[correlation, regression]

- ▶ **korelace** (dvojice náhodných veličin)
  - ▶ měří **sílu** (těsnost) **vzájemné** závislosti **spojitých** veličin
  - ▶ lze použít k **prokazování** existence **vzájemné** závislosti  $X, Y$
  - ▶ k **porovnávání síly** (těsnosti) závislosti v několika populacích
  - ▶ **symetrická** vlastnost veličin  $X$  a  $Y$
- ▶ **regrese** (náhodná veličina na nenáhodné veličině)
  - ▶ udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
  - ▶ **nesymetrická** vlastnost: (záv.  $Y$  na  $x$ )  $\neq$  (záv.  $X$  na  $y$ )
  - ▶ lze použít k **prokazování existence** závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
  - ▶ umožňuje **předpovídat** stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

# korelační koeficient

(rozlišuj **výběrový** a **populační** korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 83)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, **momentový korelační koeficient**, [correlation coefficient]

# korelační koeficient

(rozlišuj **výběrový** a **populační** korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 83)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, **momentový** korelační koeficient, [correlation coefficient]



# korelační koeficient

(rozlišuj **výběrový** a **populační** korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 83)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, **momentový** korelační koeficient, [correlation coefficient]

# korelační koeficient

(rozlišuj **výběrový** a **populační** korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 83)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, **momentový** korelační koeficient, [correlation coefficient]

# korelační koeficient

(rozlišuj **výběrový** a **populační** korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 83)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(rozlišuj **výběrový** a **populační** korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 83)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(rozlišuj **výběrový** a **populační** korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 83)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(rozlišuj **výběrový** a **populační** korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 83)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

# korelační koeficient

(rozlišuj **výběrový** a **populační** korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 83)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu **lineární** závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: **Pearsonův** korelační koeficient, momentový korelační koeficient, [correlation coefficient]

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti je nutné **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : X, Y$  nezávislé (tedy  $\rho_{XY} = 0$ ) se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti (nejen lineární závislosti)
  - ▶ místo hodnot  $X_i, Y_i$  použije jejich pořadí  $R_i, Q_i$
  - ▶ lze upravit na tvar

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)}| \sqrt{n-1} \geq z(\alpha/2)$



## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti je nutné **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : X, Y$  nezávislé (tedy  $\rho_{XY} = 0$ ) se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti (nejen lineární závislosti)
  - ▶ místo hodnot  $X_i, Y_i$  použije jejich pořadí  $R_i, Q_i$
  - ▶ lze upravit na tvar

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti je nutné **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : X, Y$  nezávislé (tedy  $\rho_{XY} = 0$ ) se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti (nejen lineární závislosti)
  - ▶ místo hodnot  $X_i, Y_i$  použije jejich **pořadí**  $R_i, Q_i$
  - ▶ lze upravit na tvar

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti je nutné **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : X, Y$  nezávislé (tedy  $\rho_{XY} = 0$ ) se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti (nejen lineární závislosti)
  - ▶ místo hodnot  $X_i, Y_i$  použije jejich **pořadí**  $R_i, Q_i$
  - ▶ lze upravit na tvar

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti je nutné **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : X, Y$  nezávislé (tedy  $\rho_{XY} = 0$ ) se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti (nejen lineární závislosti)
  - ▶ místo hodnot  $X_i, Y_i$  použije jejich **pořadí**  $R_i, Q_i$
  - ▶ lze upravit na tvar

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti je nutné **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : X, Y$  nezávislé (tedy  $\rho_{XY} = 0$ ) se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti (nejen lineární závislosti)
  - ▶ místo hodnot  $X_i, Y_i$  použije jejich **pořadí**  $R_i, Q_i$
  - ▶ lze upravit na tvar

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti je nutné **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : X, Y$  nezávislé (tedy  $\rho_{XY} = 0$ ) se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)

- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti (nejen lineární závislosti)
  - ▶ místo hodnot  $X_i, Y_i$  použije jejich **pořadí**  $R_i, Q_i$
  - ▶ lze upravit na tvar

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti je nutné **normální** rozdělení  $(X, Y)$
- ▶  $H_0 : X, Y$  nezávislé (tedy  $\rho_{XY} = 0$ ) se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}, \quad |T| \geq t_{n-2}(\alpha)$$

( $r$  je dost daleko od nuly)


- ▶ **Spearmanův** korelační koeficient
  - ▶ měří sílu **monotonní** závislosti (nejen lineární závislosti)
  - ▶ místo hodnot  $X_i, Y_i$  použije jejich **pořadí**  $R_i, Q_i$
  - ▶ lze upravit na tvar

$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2-1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdělení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n-1}| \geq z(\alpha/2)$

## závislost váhy a výšky u mužů

data: Policie

`[plot(weight~height)]``[cor.test(weight,height)]`

$$r = 0,648$$


$$t = 5,814$$

$$p < 0,001$$



## závislost váhy a pulsu u mužů

data: Policie

`[plot(weight~pulse)]``[cor.test(pulse,weight)]`

$$r = -0,245$$

$$t = -1,752$$

$$p = 8,6 \%$$

# Fisherova z-transformace

(přiblíží rozdělení výběrového korelačního koeficientu  $r$  normálnímu rozdělení)

$$Z = \frac{1}{2} \ln \frac{1+r}{1-r} \sim N\left(\frac{1}{2} \ln \frac{1+\rho}{1-\rho}, \frac{1}{n-3}\right)$$

## test shody dvou nezávisle odhadovaných korel. koeficientů

příklad **Kojeni**: výška rodičů chlapců a dívek

- ▶ dívky:  $r_1 = 0,279$ ,  $n_1 = 50$ ,  $z_1 = \frac{1}{2} \ln \frac{1+0,279}{1-0,279} = 0,286$
- ▶ hoši:  $r_2 = 0,150$ ,  $n_2 = 49$ ,  $z_2 = \frac{1}{2} \ln \frac{1+0,150}{1-0,150} = 0,151$
- ▶ test  $H_0 : \rho_1 = \rho_2$  proti  $H_1 : \rho_1 \neq \rho_2$

$$z = \frac{0,286 - 0,151}{\sqrt{\frac{1}{50-3} + \frac{1}{49-3}}} = 0,650.$$

srovnej s kritickou hodnotou  $z(0,05/2) = 1,960$ ,  $p = 51,6\%$

# Fisherova z-transformace

(přiblíží rozdělení výběrového korelačního koeficientu  $r$  normálnímu rozdělení)

$$Z = \frac{1}{2} \ln \frac{1+r}{1-r} \sim N\left(\frac{1}{2} \ln \frac{1+\rho}{1-\rho}, \frac{1}{n-3}\right)$$

## test shody dvou nezávisle odhadovaných korel. koeficientů

příklad **Kojeni**: výška rodičů chlapců a dívek

- ▶ dívky:  $r_1 = 0,279$ ,  $n_1 = 50$ ,  $z_1 = \frac{1}{2} \ln \frac{1+0,279}{1-0,279} = 0,286$
- ▶ hoši:  $r_2 = 0,150$ ,  $n_2 = 49$ ,  $z_2 = \frac{1}{2} \ln \frac{1+0,150}{1-0,150} = 0,151$
- ▶ test  $H_0 : \rho_1 = \rho_2$  proti  $H_1 : \rho_1 \neq \rho_2$

$$z = \frac{0,286 - 0,151}{\sqrt{\frac{1}{50-3} + \frac{1}{49-3}}} = 0,650.$$

srovnej s kritickou hodnotou  $z(0,05/2) = 1,960$ ,  $p = 51,6\%$

## Fisherova z-transformace

(přiblíží rozdělení výběrového korelačního koeficientu  $r$  normálnímu rozdělení)

$$Z = \frac{1}{2} \ln \frac{1+r}{1-r} \sim N\left(\frac{1}{2} \ln \frac{1+\rho}{1-\rho}, \frac{1}{n-3}\right)$$

### test shody dvou nezávisle odhadovaných korel. koeficientů

příklad **Kojeni**: výška rodičů chlapců a dívek

- ▶ dívky:  $r_1 = 0,279$ ,  $n_1 = 50$ ,  $z_1 = \frac{1}{2} \ln \frac{1+0,279}{1-0,279} = 0,286$
- ▶ hoši:  $r_2 = 0,150$ ,  $n_2 = 49$ ,  $z_2 = \frac{1}{2} \ln \frac{1+0,150}{1-0,150} = 0,151$
- ▶ test  $H_0 : \rho_1 = \rho_2$  proti  $H_1 : \rho_1 \neq \rho_2$

$$z = \frac{0,286 - 0,151}{\sqrt{\frac{1}{50-3} + \frac{1}{49-3}}} = 0,650.$$

srovnej s kritickou hodnotou  $z(0,05/2) = 1,960$ ,  $p = 51,6\%$

## interval spolehlivosti pro $\rho$

opět potřebujeme normální rozdělení  $(X, Y)$

▶ ve dvou krocích:

- ▶ interval spolehlivosti pro  $\zeta = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$
- ▶ pomocí inverzní transformace pak int. spol. pro  $\rho$
- ▶ takto postupuje funkce `cor.test()`, např.

```
[cor.test(~vyska.o+vyska.m,subset=HochL,data=Kojeni)]
```

▶ interval spolehlivosti

▶ náš příklad:

skupina	$r$ (bodový odhad)	95% int. spol. pro $\rho$	$\rho$
dívky	0,279	(0,000; 0,517)	5,01 %
hoši	0,150	(-0,137; 0,414)	30,3 %

- ▶ u chlapců nelze prokázat na 5% hladině závislost
- ▶ u děvčat je závislost na 10% hladině průkazná, na 5% hladině těsně nikoliv (interval spolehlivosti je jen přibližný!)

## interval spolehlivosti pro $\rho$

opět potřebujeme normální rozdělení  $(X, Y)$

- ▶ ve dvou krocích:

- ▶ interval spolehlivosti pro  $\zeta = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$
- ▶ pomocí inverzní transformace pak int. spol. pro  $\rho$
- ▶ takto postupuje funkce `cor.test()`, např.

```
[cor.test(~vyska.o+vyska.m,subset=HochL,data=Kojeni)]
```

- ▶ interval spolehlivosti

- ▶ náš příklad:

skupina	$r$ (bodový odhad)	95% int. spol. pro $\rho$	$\rho$
dívky	0,279	(0,000; 0,517)	5,01 %
hoši	0,150	(-0,137; 0,414)	30,3 %

- ▶ u chlapců nelze prokázat na 5% hladině závislost
- ▶ u děvčat je závislost na 10% hladině průkazná, na 5% hladině těsně nikoliv (interval spolehlivosti je jen přibližný!)

## interval spolehlivosti pro $\rho$

opět potřebujeme normální rozdělení  $(X, Y)$

- ▶ ve dvou krocích:

- ▶ interval spolehlivosti pro  $\zeta = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$
- ▶ pomocí inverzní transformace pak int. spol. pro  $\rho$
- ▶ takto postupuje funkce `cor.test()`, např.

```
[cor.test(~vyska.o+vyska.m,subset=HochL,data=Kojeni)]
```

- ▶ interval spolehlivosti

- ▶ náš příklad:

skupina	$r$ (bodový odhad)	95% int. spol. pro $\rho$	$\rho$
dívky	0,279	(0,000; 0,517)	5,01 %
hoši	0,150	(-0,137; 0,414)	30,3 %

- ▶ u chlapců nelze prokázat na 5% hladině závislost
- ▶ u děvčat je závislost na 10% hladině průkazná, na 5% hladině těsně nikoliv (interval spolehlivosti je jen přibližný!)

## interval spolehlivosti pro $\rho$

opět potřebujeme normální rozdělení  $(X, Y)$

- ▶ ve dvou krocích:

- ▶ interval spolehlivosti pro  $\zeta = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$
- ▶ pomocí inverzní transformace pak int. spol. pro  $\rho$
- ▶ takto postupuje funkce `cor.test()`, např.

`[cor.test(~vyska.o+vyska.m,subset=HochL,data=Kojeni)]`

- ▶ interval spolehlivosti

- ▶ náš příklad:

skupina	$r$ (bodový odhad)	95% int. spol. pro $\rho$	$p$
dívky	0,279	(0,000; 0,517)	5,01 %
hoši	0,150	(-0,137; 0,414)	30,3 %

- ▶ u chlapců nelze prokázat na 5% hladině závislost
- ▶ u děvčat je závislost na 10% hladině průkazná, na 5% hladině těsně nikoliv (interval spolehlivosti je jen přibližný!)



## interval spolehlivosti pro $\rho$

opět potřebujeme normální rozdělení  $(X, Y)$

- ▶ ve dvou krocích:

- ▶ interval spolehlivosti pro  $\zeta = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$
- ▶ pomocí inverzní transformace pak int. spol. pro  $\rho$
- ▶ takto postupuje funkce `cor.test()`, např.

`[cor.test(~vyska.o+vyska.m,subset=HochL,data=Kojeni)]`

- ▶ interval spolehlivosti

- ▶ náš příklad:

skupina	$r$ (bodový odhad)	95% int. spol. pro $\rho$	$p$
dívky	0,279	(0,000; 0,517)	5,01 %
hoši	0,150	(-0,137; 0,414)	30,3 %

- ▶ u chlapců nelze prokázat na 5% hladině závislost
- ▶ u děvčat je závislost na 10% hladině průkazná, na 5% hladině těsně nikoliv (interval spolehlivosti je jen přibližný!)

## interval spolehlivosti pro $\rho$

opět potřebujeme normální rozdělení  $(X, Y)$

- ▶ ve dvou krocích:

- ▶ interval spolehlivosti pro  $\zeta = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$
- ▶ pomocí inverzní transformace pak int. spol. pro  $\rho$
- ▶ takto postupuje funkce `cor.test()`, např.

`[cor.test(~vyska.o+vyska.m,subset=HochL,data=Kojeni)]`

- ▶ interval spolehlivosti

- ▶ náš příklad:

skupina	$r$ (bodový odhad)	95% int. spol. pro $\rho$	$p$
dívky	0,279	(0,000; 0,517)	5,01 %
hoši	0,150	(-0,137; 0,414)	30,3 %

- ▶ u chlapců nelze prokázat na 5% hladině závislost
- ▶ u děvčat je závislost na 10% hladině průkazná, na 5% hladině těsně nikoliv (interval spolehlivosti je jen přibližný!)

## interval spolehlivosti pro $\rho$

opět potřebujeme normální rozdělení  $(X, Y)$

- ▶ ve dvou krocích:

- ▶ interval spolehlivosti pro  $\zeta = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$
- ▶ pomocí inverzní transformace pak int. spol. pro  $\rho$
- ▶ takto postupuje funkce `cor.test()`, např.

`[cor.test(~vyska.o+vyska.m,subset=HochL,data=Kojeni)]`

- ▶ interval spolehlivosti

- ▶ náš příklad:

skupina	$r$ (bodový odhad)	95% int. spol. pro $\rho$	$p$
dívky	0,279	(0,000; 0,517)	5,01 %
hoši	0,150	(-0,137; 0,414)	30,3 %

- ▶ u chlapců nelze prokázat na 5% hladině závislost
- ▶ u děvčat je závislost na 10% hladině průkazná, na 5% hladině těsně nikoliv (interval spolehlivosti je jen přibližný!)

## interval spolehlivosti pro $\rho$

opět potřebujeme normální rozdělení  $(X, Y)$

- ▶ ve dvou krocích:

- ▶ interval spolehlivosti pro  $\zeta = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$
- ▶ pomocí inverzní transformace pak int. spol. pro  $\rho$
- ▶ takto postupuje funkce `cor.test()`, např.

`[cor.test(~vyska.o+vyska.m,subset=HochL,data=Kojeni)]`

- ▶ interval spolehlivosti

- ▶ náš příklad:

skupina	$r$ (bodový odhad)	95% int. spol. pro $\rho$	$p$
dívky	0,279	(0,000; 0,517)	5,01 %
hoši	0,150	(-0,137; 0,414)	30,3 %

- ▶ u chlapců nelze prokázat na 5% hladině závislost
- ▶ u děvčat je závislost na 10% hladině průkazná, na 5% hladině těsně nikoliv (interval spolehlivosti je jen přibližný!)

# regrese

(původ pojmu)

- ▶ tendence (návrát) k průměrnosti  
F. Galton (1886) vyšetřoval dědičnost výšky postavy
- ▶ uvažujme otce, jejichž výška je rovna průměrné výšce generace **všech** otců; průměrná výška synů otců této výšky bude rovna průměrné výšce **všech** synů
- ▶ uvažujme otce o 10 cm **vyšší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen asi o 5 cm **vyšší**, než průměrná výška generace synů
- ▶ uvažujme otce o 10 cm **nižší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen o asi 5 cm **nižší**, než průměrná výška generace synů
- ▶ průměrné výšky synů nereprodukuje celou odchylku výšky otce od průměru, je tu návrat k průměru (regrese)

# regrese

(původ pojmu)

- ▶ tendence (návrát) k průměrnosti  
F. Galton (1886) vyšetřoval dědičnost výšky postavy
- ▶ uvažujme otce, jejichž výška je rovna průměrné výšce generace **všech** otců; průměrná výška synů otců této výšky bude rovna průměrné výšce **všech** synů
- ▶ uvažujme otce o 10 cm **vyšší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen asi o 5 cm **vyšší**, než průměrná výška generace synů
- ▶ uvažujme otce o 10 cm **nižší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen o asi 5 cm **nižší**, než průměrná výška generace synů
- ▶ průměrné výšky synů nereprodukuje celou odchylku výšky otce od průměru, je tu návrat k průměru (regrese)

# regrese

(původ pojmu)

- ▶ tendence (návrát) k průměrnosti  
F. Galton (1886) vyšetřoval dědičnost výšky postavy
- ▶ uvažujme otce, jejichž výška je rovna průměrné výšce generace **všech** otců; průměrná výška synů otců této výšky bude rovna průměrné výšce **všech** synů
- ▶ uvažujme otce o 10 cm **vyšší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen asi o 5 cm **vyšší**, než průměrná výška generace synů
- ▶ uvažujme otce o 10 cm **nižší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen o asi 5 cm **nižší**, než průměrná výška generace synů
- ▶ průměrné výšky synů nereprodukuje celou odchylku výšky otce od průměru, je tu návrat k průměru (regrese)

# regrese

(původ pojmu)

- ▶ tendence (návrát) k průměrnosti  
F. Galton (1886) vyšetřoval dědičnost výšky postavy
- ▶ uvažujme otce, jejichž výška je rovna průměrné výšce generace **všech** otců; průměrná výška synů otců této výšky bude rovna průměrné výšce **všech** synů
- ▶ uvažujme otce o 10 cm **vyšší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen asi o 5 cm **vyšší**, než průměrná výška generace synů
- ▶ uvažujme otce o 10 cm **nižší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen o asi 5 cm **nižší**, než průměrná výška generace synů
- ▶ průměrné výšky synů nereprodukuje celou odchylku výšky otce od průměru, je tu návrat k průměru (regrese)




# regrese

(původ pojmu)

- ▶ tendence (návrát) k průměrnosti  
F. Galton (1886) vyšetřoval dědičnost výšky postavy
- ▶ uvažujme otce, jejichž výška je rovna průměrné výšce generace **všech** otců; průměrná výška synů otců této výšky bude rovna průměrné výšce **všech** synů
- ▶ uvažujme otce o 10 cm **vyšší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen asi o 5 cm **vyšší**, než průměrná výška generace synů
- ▶ uvažujme otce o 10 cm **nižší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen o asi 5 cm **nižší**, než průměrná výška generace synů
- ▶ průměrné výšky synů nereprodukuje celou odchylku výšky otce od průměru, je tu návrat k průměru (regrese)

## Závislost výšky syna na výšce otce

výšky v ang. palcích, Galtonova data, ke každému otci náhodně vybrán jeden z jeho synů  
 proložena přímkou:  $y = 35,4 + 0,5x$ , pro porovnání šedivě přímka s jednotkovou směrnici



## regresní přímka

- ▶ **předpokládaná** závislost střední hodnoty  $Y$  na nenáhodné  $x$ :

$$Y_i = \beta_0 + \beta_1 x_i + E_i, \quad E_i \sim N(0, \sigma^2)$$

- ▶  $Y_i$  = systematická složka  $(\beta_0 + \beta_1 x_i)$  + náhodná složka  $(E_i)$
- ▶ k daným  $x_1, \dots, x_n$  zjistíme  $Y_1, \dots, Y_n$
- ▶ předpoklady:

- ▶ **nezávislá** pozorování  $Y_1, \dots, Y_n$  (tedy také  $E_1, \dots, E_n$ )
- ▶ **stejný** rozptyl  $\sigma^2$
- ▶ **normální** rozdělení  $E_1, \dots, E_n$  (potřebné až pro testy, normalitu nelze ověřovat testováním přímo  $Y_1, \dots, Y_n$ !)

- ▶ neznámé populační parametry  $\beta_0, \beta_1$  odhadujeme metodou **nejmenších čtverců**:

minimalizovat přes  $\beta_0, \beta_1$  výraz 
$$\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

- ▶ odhady označíme  $b_0, b_1$

## regresní přímka

- ▶ **předpokládaná** závislost střední hodnoty  $Y$  na nenáhodné  $x$ :

$$Y_i = \beta_0 + \beta_1 x_i + E_i, \quad E_i \sim N(0, \sigma^2)$$

- ▶  $Y_i$  = systematická složka  $(\beta_0 + \beta_1 x_i)$  + náhodná složka  $(E_i)$
- ▶ k daným  $x_1, \dots, x_n$  zjistíme  $Y_1, \dots, Y_n$
- ▶ předpoklady:

- ▶ **nezávislá** pozorování  $Y_1, \dots, Y_n$  (tedy také  $E_1, \dots, E_n$ )
- ▶ **stejný** rozptyl  $\sigma^2$
- ▶ **normální** rozdělení  $E_1, \dots, E_n$  (potřebné až pro testy, normalitu nelze ověřovat testováním přímo  $Y_1, \dots, Y_n$ !)

- ▶ neznámé populační parametry  $\beta_0, \beta_1$  odhadujeme metodou **nejmenších čtverců**:

minimalizovat přes  $\beta_0, \beta_1$  výraz 
$$\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

- ▶ odhady označíme  $b_0, b_1$

## regresní přímka

- ▶ **předpokládaná** závislost střední hodnoty  $Y$  na nenáhodné  $x$ :

$$Y_i = \beta_0 + \beta_1 x_i + E_i, \quad E_i \sim N(0, \sigma^2)$$

- ▶  $Y_i$  = systematická složka  $(\beta_0 + \beta_1 x_i)$  + náhodná složka  $(E_i)$
- ▶ k daným  $x_1, \dots, x_n$  zjistíme  $Y_1, \dots, Y_n$
- ▶ předpoklady:

- ▶ **nezávislá** pozorování  $Y_1, \dots, Y_n$  (tedy také  $E_1, \dots, E_n$ )
- ▶ **stejný** rozptyl  $\sigma^2$
- ▶ **normální** rozdělení  $E_1, \dots, E_n$  (potřebné až pro testy, normalitu nelze ověřovat testováním přímo  $Y_1, \dots, Y_n$ !)

- ▶ neznámé populační parametry  $\beta_0, \beta_1$  odhadujeme metodou **nejmenších čtverců**:

minimalizovat přes  $\beta_0, \beta_1$  výraz 
$$\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

- ▶ odhady označíme  $b_0, b_1$

## metoda nejmenších čtverců


odhadovaná závislost:  $y = \beta_0 + \beta_1 \cdot x$  (populace)

odhad závislosti:  $y = b_0 + b_1 \cdot x$  (výběr)

$i$ -tá vyrovnaná hodnota:  $\hat{Y}_i = b_0 + b_1 \cdot x_i$  (výběr)

$i$ -té reziduum:  $U_i = Y_i - \hat{Y}_i$  (výběr)

celková plocha čtverců:  $S_e = \sum_{i=1}^n U_i^2$  (výběr)



- ▶  $b_1$  – odhad směrnice  $\beta_1$
- ▶  $b_1 = (b_0 + b_1(x + 1)) - (b_0 + b_1x)$   
– odhad změny střední hodnoty závisle proměnné  $Y$  při **jednotkové změně** nezávisle proměnné  $x$
- ▶  $i$ -té residuum  $U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i)$
- ▶  $Y_i = \hat{Y}_i + U_i$
- ▶ (vysvětlováno)=(vysvětleno závislostí)+(nevysvětleno)
- ▶ **reziduální součet čtverců** (nevysvětlená variabilita):

$$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1x_i)^2 = \sum_{i=1}^n U_i^2$$

- ▶ **reziduální rozptyl** (odhad rozptylu  $\sigma^2$ )

$$S^2 = \frac{S_e}{n - 2}$$

- ▶  $b_1$  – odhad směrnice  $\beta_1$
- ▶  $b_1 = (b_0 + b_1(x + 1)) - (b_0 + b_1x)$   
– odhad změny střední hodnoty závisle proměnné  $Y$  při **jednotkové změně** nezávisle proměnné  $x$
- ▶  $i$ -té residuum  $U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i)$
- ▶  $Y_i = \hat{Y}_i + U_i$
- ▶ (vysvětlováno)=(vysvětleno závislostí)+(nevysvětleno)
- ▶ **reziduální součet čtverců** (nevysvětlená variabilita):

$$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1x_i)^2 = \sum_{i=1}^n U_i^2$$

- ▶ **reziduální rozptyl** (odhad rozptylu  $\sigma^2$ )

$$S^2 = \frac{S_e}{n - 2}$$



- ▶  $b_1$  – odhad směrnice  $\beta_1$
- ▶  $b_1 = (b_0 + b_1(x + 1)) - (b_0 + b_1x)$   
– odhad změny střední hodnoty závisle proměnné  $Y$  při **jednotkové změně** nezávisle proměnné  $x$
- ▶  $i$ -té residuum  $U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i)$
- ▶  $Y_i = \hat{Y}_i + U_i$
- ▶ (vysvětlováno)=(vysvětleno závislostí)+(nevysvětleno)
- ▶ **reziduální součet čtverců** (nevysvětlená variabilita):

$$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1x_i)^2 = \sum_{i=1}^n U_i^2$$

- ▶ **reziduální rozptyl** (odhad rozptylu  $\sigma^2$ )

$$S^2 = \frac{S_e}{n - 2}$$

- ▶  $b_1$  – odhad směrnice  $\beta_1$
- ▶  $b_1 = (b_0 + b_1(x + 1)) - (b_0 + b_1x)$   
– odhad změny střední hodnoty závisle proměnné  $Y$  při **jednotkové změně** nezávisle proměnné  $x$
- ▶  $i$ -té residuum  $U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i)$
- ▶  $Y_i = \hat{Y}_i + U_i$
- ▶ (vysvětlováno)=(vysvětleno závislostí)+(nevysvětleno)
- ▶ **reziduální součet čtverců** (nevysvětlená variabilita):

$$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1x_i)^2 = \sum_{i=1}^n U_i^2$$

- ▶ **reziduální rozptyl** (odhad rozptylu  $\sigma^2$ )

$$S^2 = \frac{S_e}{n - 2}$$

- ▶  $b_1$  – odhad směrnice  $\beta_1$
- ▶  $b_1 = (b_0 + b_1(x + 1)) - (b_0 + b_1x)$   
– odhad změny střední hodnoty závisle proměnné  $Y$  při **jednotkové změně** nezávisle proměnné  $x$
- ▶  $i$ -té residuum  $U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i)$
- ▶  $Y_i = \hat{Y}_i + U_i$
- ▶ (vysvětlováno)=(vysvětleno závislostí)+(nevysvětleno)
- ▶ **reziduální součet čtverců** (nevysvětlená variabilita):

$$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1x_i)^2 = \sum_{i=1}^n U_i^2$$

- ▶ **reziduální rozptyl** (odhad rozptylu  $\sigma^2$ )

$$S^2 = \frac{S_e}{n - 2}$$

- ▶  $b_1$  – odhad směrnice  $\beta_1$
- ▶  $b_1 = (b_0 + b_1(x + 1)) - (b_0 + b_1x)$   
– odhad změny střední hodnoty závisle proměnné  $Y$  při **jednotkové změně** nezávisle proměnné  $x$
- ▶  $i$ -té residuum  $U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i)$
- ▶  $Y_i = \hat{Y}_i + U_i$
- ▶ (vysvětlováno)=(vysvětleno závislostí)+(nevysvětleno)
- ▶ **reziduální součet čtverců** (nevysvětlená variabilita):

$$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1x_i)^2 = \sum_{i=1}^n U_i^2$$

- ▶ reziduální rozptyl (odhad rozptylu  $\sigma^2$ )

$$S^2 = \frac{S_e}{n - 2}$$

- ▶  $b_1$  – odhad směrnice  $\beta_1$
- ▶  $b_1 = (b_0 + b_1(x + 1)) - (b_0 + b_1x)$   
– odhad změny střední hodnoty závisle proměnné  $Y$  při **jednotkové změně** nezávisle proměnné  $x$
- ▶  $i$ -té residuum  $U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i)$
- ▶  $Y_i = \hat{Y}_i + U_i$
- ▶ (vysvětlováno)=(vysvětleno závislostí)+(nevysvětleno)
- ▶ **reziduální součet čtverců** (nevysvětlená variabilita):

$$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1x_i)^2 = \sum_{i=1}^n U_i^2$$

- ▶ **reziduální rozptyl** (odhad rozptylu  $\sigma^2$ )

$$s^2 = \frac{S_e}{n - 2}$$

## alternativní formulace

- ▶ uvažovanou závislost lze psát ve tvaru

$$\begin{aligned} Y_i &= (\beta_0 + \beta_1 \bar{x}) + \beta_1(x_i - \bar{x}) + E_i \\ &= \beta_0^* + \beta_1(x_i - \bar{x}) + E_i \end{aligned}$$

- ▶  $\beta_0^*$  vyjadřuje střední úroveň vysvětlované proměnné  $Y$  při průměrné hodnotě nezávisle proměnné  $x$
- ▶  $\beta_1$  vyjadřuje citlivost, s jakou reaguje střední hodnota vysvětlované proměnné  $Y$  na jednotkovou odchylku nezávisle proměnné  $x$  od jejího průměru  $\bar{x}$
- ▶  $E_i$  vyjadřuje náhodnou složku  $i$ -tého pozorování,  $E_i \sim N(0, \sigma^2)$
- ▶ odhadem závislosti je ( $b_1$  je stejné jako při klasickém vyjádření)

$$\hat{Y}_i = \bar{Y} + b_1(x_i - \bar{x})$$

## alternativní formulace

- ▶ uvažovanou závislost lze psát ve tvaru

$$\begin{aligned} Y_i &= (\beta_0 + \beta_1 \bar{x}) + \beta_1(x_i - \bar{x}) + E_i \\ &= \beta_0^* + \beta_1(x_i - \bar{x}) + E_i \end{aligned}$$

- ▶  $\beta_0^*$  vyjadřuje střední úroveň vysvětlované proměnné  $Y$  při průměrné hodnotě nezávisle proměnné  $x$
- ▶  $\beta_1$  vyjadřuje citlivost, s jakou reaguje střední hodnota vysvětlované proměnné  $Y$  na jednotkovou odchylku nezávisle proměnné  $x$  od jejího průměru  $\bar{x}$
- ▶  $E_i$  vyjadřuje náhodnou složku  $i$ -tého pozorování,  $E_i \sim N(0, \sigma^2)$
- ▶ odhadem závislosti je ( $b_1$  je stejné jako při klasickém vyjádření)

$$\hat{Y}_i = \bar{Y} + b_1(x_i - \bar{x})$$

## alternativní formulace

- ▶ uvažovanou závislost lze psát ve tvaru

$$\begin{aligned} Y_i &= (\beta_0 + \beta_1 \bar{x}) + \beta_1(x_i - \bar{x}) + E_i \\ &= \beta_0^* + \beta_1(x_i - \bar{x}) + E_i \end{aligned}$$

- ▶  $\beta_0^*$  vyjadřuje střední úroveň vysvětlované proměnné  $Y$  při průměrné hodnotě nezávisle proměnné  $x$
- ▶  $\beta_1$  vyjadřuje citlivost, s jakou reaguje střední hodnota vysvětlované proměnné  $Y$  na jednotkovou odchylku nezávisle proměnné  $x$  od jejího průměru  $\bar{x}$
- ▶  $E_i$  vyjadřuje náhodnou složku  $i$ -tého pozorování,  
 $E_i \sim N(0, \sigma^2)$
- ▶ odhadem závislosti je ( $b_1$  je stejné jako při klasickém vyjádření)

$$\hat{Y}_i = \bar{Y} + b_1(x_i - \bar{x})$$



## alternativní formulace

- ▶ uvažovanou závislost lze psát ve tvaru

$$\begin{aligned} Y_i &= (\beta_0 + \beta_1 \bar{x}) + \beta_1(x_i - \bar{x}) + E_i \\ &= \beta_0^* + \beta_1(x_i - \bar{x}) + E_i \end{aligned}$$

- ▶  $\beta_0^*$  vyjadřuje střední úroveň vysvětlované proměnné  $Y$  při průměrné hodnotě nezávisle proměnné  $x$
- ▶  $\beta_1$  vyjadřuje citlivost, s jakou reaguje střední hodnota vysvětlované proměnné  $Y$  na jednotkovou odchylku nezávisle proměnné  $x$  od jejího průměru  $\bar{x}$
- ▶  $E_i$  vyjadřuje náhodnou složku  $i$ -tého pozorování,  $E_i \sim N(0, \sigma^2)$
- ▶ odhadem závislosti je ( $b_1$  je stejné jako při klasickém vyjádření)

$$\hat{Y}_i = \bar{Y} + b_1(x_i - \bar{x})$$

## alternativní formulace

- ▶ uvažovanou závislost lze psát ve tvaru

$$\begin{aligned} Y_i &= (\beta_0 + \beta_1 \bar{x}) + \beta_1(x_i - \bar{x}) + E_i \\ &= \beta_0^* + \beta_1(x_i - \bar{x}) + E_i \end{aligned}$$

- ▶  $\beta_0^*$  vyjadřuje střední úroveň vysvětlované proměnné  $Y$  při průměrné hodnotě nezávisle proměnné  $x$
- ▶  $\beta_1$  vyjadřuje citlivost, s jakou reaguje střední hodnota vysvětlované proměnné  $Y$  na jednotkovou odchylku nezávisle proměnné  $x$  od jejího průměru  $\bar{x}$
- ▶  $E_i$  vyjadřuje náhodnou složku  $i$ -tého pozorování,  $E_i \sim N(0, \sigma^2)$
- ▶ odhadem závislosti je ( $b_1$  je stejné jako při klasickém vyjádření)

$$\hat{Y}_i = \bar{Y} + b_1(x_i - \bar{x})$$

## prokazování závislosti

- ▶ modelujeme závislost  $E Y$  na  $x$  pomocí  $E Y = \beta_0 + \beta_1 x$
- ▶ nezávislost  $y = \beta_0 + \beta_1 x$  na  $x$  znamená  $\beta_1 = 0$
- ▶ hypotézu  $H_0 : \beta_1 = 0$  testujeme pomocí statistiky

$$T = \frac{b_1}{\text{S.E.}(b_1)}$$

- ▶ hypotézu zamítáme, je-li  $|T| \geq t_{n-2}(\alpha)$   
tj. je-li příslušná  $p$ -hodnota  $\leq \alpha$
- ▶ pokud  $H_0$  zamítneme, říkáme, na hladině  $\alpha$  je **závislost průkazná**

## prokazování závislosti

- ▶ modelujeme závislost  $E Y$  na  $x$  pomocí  $E Y = \beta_0 + \beta_1 x$
- ▶ nezávislost  $y = \beta_0 + \beta_1 x$  na  $x$  znamená  $\beta_1 = 0$
- ▶ hypotézu  $H_0 : \beta_1 = 0$  testujeme pomocí statistiky

$$T = \frac{b_1}{\text{S.E.}(b_1)}$$

- ▶ hypotézu zamítáme, je-li  $|T| \geq t_{n-2}(\alpha)$   
tj. je-li příslušná  $p$ -hodnota  $\leq \alpha$
- ▶ pokud  $H_0$  zamítneme, říkáme, na hladině  $\alpha$  je **závislost průkazná**

## prokazování závislosti

- ▶ modelujeme závislost  $E Y$  na  $x$  pomocí  $E Y = \beta_0 + \beta_1 x$
- ▶ nezávislost  $y = \beta_0 + \beta_1 x$  na  $x$  znamená  $\beta_1 = 0$
- ▶ hypotézu  $H_0 : \beta_1 = 0$  testujeme pomocí statistiky

$$T = \frac{b_1}{\text{S.E.}(b_1)}$$

- ▶ hypotézu zamítáme, je-li  $|T| \geq t_{n-2}(\alpha)$   
tj. je-li příslušná  $p$ -hodnota  $\leq \alpha$
- ▶ pokud  $H_0$  zamítneme, říkáme, na hladině  $\alpha$  je **závislost průkazná**

## prokazování závislosti

- ▶ modelujeme závislost  $E Y$  na  $x$  pomocí  $E Y = \beta_0 + \beta_1 x$
- ▶ nezávislost  $y = \beta_0 + \beta_1 x$  na  $x$  znamená  $\beta_1 = 0$
- ▶ hypotézu  $H_0 : \beta_1 = 0$  testujeme pomocí statistiky

$$T = \frac{b_1}{\text{S.E.}(b_1)}$$

- ▶ hypotézu zamítáme, je-li  $|T| \geq t_{n-2}(\alpha)$   
tj. je-li příslušná  $p$ -hodnota  $\leq \alpha$
- ▶ pokud  $H_0$  zamítneme, říkáme, na hladině  $\alpha$  je **závislost průkazná**

## prokazování závislosti

- ▶ modelujeme závislost  $E Y$  na  $x$  pomocí  $E Y = \beta_0 + \beta_1 x$
- ▶ nezávislost  $y = \beta_0 + \beta_1 x$  na  $x$  znamená  $\beta_1 = 0$
- ▶ hypotézu  $H_0 : \beta_1 = 0$  testujeme pomocí statistiky

$$T = \frac{b_1}{\text{S.E.}(b_1)}$$

- ▶ hypotézu zamítáme, je-li  $|T| \geq t_{n-2}(\alpha)$   
tj. je-li příslušná  $p$ -hodnota  $\leq \alpha$
- ▶ pokud  $H_0$  zamítneme, říkáme, na hladině  $\alpha$  je **závislost průkazná**

## příklad závislost procenta tuku na výšce

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	-53,870	24,657	-2,185	0,0338
height	0,379	0,138	2,742	0,0086

- ▶ předpověď:  $\hat{Y}_i = -53,870 + 0,379 \cdot x_i$
- ▶  $\widehat{\text{fat}} = -53,870 + 0,379 \cdot \text{height}$
- ▶ závislost procenta tuku na výšce je na 5% hladině průkazná, neboť  $p = 0,86\%$
- ▶ na každý centimetr výšky *v průměru* přibude 0,379 procentního bodu tuku
- ▶ `[summary(lm(fat~height))]`



## příklad závislost procenta tuku na výšce

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	-53,870	24,657	-2,185	0,0338
height	0,379	0,138	2,742	0,0086

- ▶ předpověď:  $\hat{Y}_i = -53,870 + 0,379 \cdot x_i$
- ▶  $\widehat{\text{fat}} = -53,870 + 0,379 \cdot \text{height}$
- ▶ závislost procenta tuku na výšce je na 5% hladině průkazná, neboť  $p = 0,86\%$
- ▶ na každý centimetr výšky *v průměru* přibude 0,379 procentního bodu tuku
- ▶ `[summary(lm(fat~height))]`

## příklad závislost procenta tuku na výšce

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	-53,870	24,657	-2,185	0,0338
height	0,379	0,138	2,742	0,0086

- ▶ předpověď:  $\hat{Y}_i = -53,870 + 0,379 \cdot x_i$
- ▶  $\widehat{\text{fat}} = -53,870 + 0,379 \cdot \text{height}$
- ▶ závislost procenta tuku na výšce je na 5% hladině průkazná, neboť  $p = 0,86 \%$
- ▶ na každý centimetr výšky *v průměru* přibude 0,379 procentního bodu tuku
- ▶ `[summary(lm(fat~height))]`

## příklad závislost procenta tuku na výšce

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	-53,870	24,657	-2,185	0,0338
height	0,379	0,138	2,742	0,0086

- ▶ předpověď:  $\hat{Y}_i = -53,870 + 0,379 \cdot x_i$
- ▶  $\widehat{\text{fat}} = -53,870 + 0,379 \cdot \text{height}$
- ▶ závislost procenta tuku na výšce je na 5% hladině průkazná, neboť  $p = 0,86 \%$
- ▶ na každý centimetr výšky *v průměru* přibude 0,379 procentního bodu tuku
- ▶ `[summary(lm(fat~height))]`

## příklad závislost procenta tuku na výšce

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	-53,870	24,657	-2,185	0,0338
height	0,379	0,138	2,742	0,0086

- ▶ předpověď:  $\hat{Y}_i = -53,870 + 0,379 \cdot x_i$
- ▶  $\widehat{\text{fat}} = -53,870 + 0,379 \cdot \text{height}$
- ▶ závislost procenta tuku na výšce je na 5% hladině průkazná, neboť  $p = 0,86 \%$
- ▶ na každý centimetr výšky *v průměru* přibude 0,379 procentního bodu tuku
- ▶ `[summary(lm(fat~height))]`

# koeficient determinace

[coefficient of determination]

- ▶ podíl variability  $Y$  vysvětlené uvažovanou závislostí (jakou část variability  $Y$  se podařilo závislostí na  $x$  vysvětlit)



$$\begin{aligned}
 R^2 &= \frac{\text{variabilita vysvětlená}}{\text{variabilita vysvětlovaná}} = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{\text{variabilita nevysvětlená}}{\text{variabilita vysvětlovaná}} = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{S_e}{\sum(Y_i - \bar{Y})^2}
 \end{aligned}$$

- ▶  $R^2$  je bezrozměrné číslo, často vyjádřeno v procentech
- ▶  $R^2$  ukazuje, zda má smysl předpovídat pomocí regrese
- ▶ v případě regresní přímky je  $R^2 = r_{XY}^2$

# koeficient determinace

[coefficient of determination]

- ▶ podíl variability  $Y$  vysvětlené uvažovanou závislostí (jakou část variability  $Y$  se podařilo závislostí na  $x$  vysvětlit)
- ▶

$$\begin{aligned}
 R^2 &= \frac{\text{variabilita vysvětlená}}{\text{variabilita vysvětlovaná}} = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{\text{variabilita nevysvětlená}}{\text{variabilita vysvětlovaná}} = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{S_e}{\sum(Y_i - \bar{Y})^2}
 \end{aligned}$$

- ▶  $R^2$  je bezrozměrné číslo, často vyjádřeno v procentech
- ▶  $R^2$  ukazuje, zda má smysl předpovídat pomocí regrese
- ▶ v případě regresní přímky je  $R^2 = r_{XY}^2$

# koeficient determinace

[coefficient of determination]

- ▶ podíl variability  $Y$  vysvětlené uvažovanou závislostí (jakou část variability  $Y$  se podařilo závislostí na  $x$  vysvětlit)
- ▶

$$\begin{aligned}
 R^2 &= \frac{\text{variabilita vysvětlená}}{\text{variabilita vysvětlovaná}} = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{\text{variabilita nevysvětlená}}{\text{variabilita vysvětlovaná}} = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{S_e}{\sum(Y_i - \bar{Y})^2}
 \end{aligned}$$

- ▶  $R^2$  je bezrozměrné číslo, často vyjádřeno v procentech
- ▶  $R^2$  ukazuje, zda má smysl předpovídat pomocí regrese
- ▶ v případě regresní přímky je  $R^2 = r_{XY}^2$

# koeficient determinace

[coefficient of determination]

- ▶ podíl variability  $Y$  vysvětlené uvažovanou závislostí (jakou část variability  $Y$  se podařilo závislostí na  $x$  vysvětlit)



$$\begin{aligned}
 R^2 &= \frac{\text{variabilita vysvětlená}}{\text{variabilita vysvětlovaná}} = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{\text{variabilita nevysvětlená}}{\text{variabilita vysvětlovaná}} = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{S_e}{\sum(Y_i - \bar{Y})^2}
 \end{aligned}$$

- ▶  $R^2$  je bezrozměrné číslo, často vyjádřeno v procentech
- ▶  $R^2$  ukazuje, zda má smysl předpovídat pomocí regrese
- ▶ v případě regresní přímky je  $R^2 = r_{XY}^2$



# koeficient determinace

[coefficient of determination]

- ▶ podíl variability  $Y$  vysvětlené uvažovanou závislostí (jakou část variability  $Y$  se podařilo závislostí na  $x$  vysvětlit)
- ▶

$$\begin{aligned}
 R^2 &= \frac{\text{variabilita vysvětlená}}{\text{variabilita vysvětlovaná}} = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{\text{variabilita nevysvětlená}}{\text{variabilita vysvětlovaná}} = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y})^2} \\
 &= 1 - \frac{S_e}{\sum(Y_i - \bar{Y})^2}
 \end{aligned}$$

- ▶  $R^2$  je bezrozměrné číslo, často vyjádřeno v procentech
- ▶  $R^2$  ukazuje, zda má smysl předpovídat pomocí regrese
- ▶ v případě regresní přímky je  $R^2 = r_{XY}^2$

## tabulka analýzy rozptylu

variabilita	součet čtverců	st. vol.	prům. čtverec	$F$	$p$
regrese	362,54	1	362,54	7,519	0,0086
rezid.	2314,41	48	48,22		
celk.	2676,95	49	(54,63)		



$$s^2 = 48,22$$



$$R^2 = \frac{362,54}{2676,95} = 1 - \frac{2314,41}{2676,95} = 0,135$$

- ▶ závislostí na výšce jsme vysvětlili jen 13,5 % variability procenta tuku
- ▶ `[anova(lm(fat~height))]`

## tabulka analýzy rozptylu

variabilita	součet čtverců	st. vol.	prům. čtverec	$F$	$p$
regrese	362,54	1	362,54	7,519	0,0086
rezid.	2314,41	48	48,22		
celk.	2676,95	49	(54,63)		



$$s^2 = 48,22$$



$$R^2 = \frac{362,54}{2676,95} = 1 - \frac{2314,41}{2676,95} = 0,135$$

- ▶ závislostí na výšce jsme vysvětlili jen 13,5 % variability procenta tuku
- ▶ `[anova(lm(fat~height))]`

## tabulka analýzy rozptylu

variabilita	součet čtverců	st. vol.	prům. čtverec	$F$	$p$
regrese	362,54	1	362,54	7,519	0,0086
rezid.	2314,41	48	48,22		
celk.	2676,95	49	(54,63)		



$$s^2 = 48,22$$



$$R^2 = \frac{362,54}{2676,95} = 1 - \frac{2314,41}{2676,95} = 0,135$$

- ▶ závislostí na výšce jsme vysvětlili jen 13,5 % variability procenta tuku

▶ `[anova(lm(fat~height))]`

## tabulka analýzy rozptylu

variabilita	součet čtverců	st. vol.	prům. čtverec	$F$	$p$
regrese	362,54	1	362,54	7,519	0,0086
rezid.	2314,41	48	48,22		
celk.	2676,95	49	(54,63)		



$$s^2 = 48,22$$



$$R^2 = \frac{362,54}{2676,95} = 1 - \frac{2314,41}{2676,95} = 0,135$$

- ▶ závislostí na výšce jsme vysvětlili jen 13,5 % variability procenta tuku
- ▶ `[anova(lm(fat~height))]`

# mnohonásobná lineární regrese

- ▶ závislost na dvou (nebo více) nezávisle proměnných
- ▶ pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- ▶ představa (model)

$$Y_i = \underbrace{\beta_0 + \beta_1 x_i + \beta_2 v_i}_{E Y_i} + E_i$$

- ▶ střední hodnota  $Y_i$  (tj. systematická, nenáhodná složka  $Y_i$ ) vysvětlena pomocí  $x_i, v_i$  jako  $\beta_0 + \beta_1 x_i + \beta_2 v_i$
- ▶  $E_1, \dots, E_n$  (také  $Y_1, \dots, Y_n$ ) jsou **nezávislé** náhodné veličiny
- ▶  $E_i \sim N(0, \sigma^2)$  (normální rozdělení se stejným rozptylem)
- ▶  $b_0, b_1, b_2$  – odhady parametrů  $\beta_0, \beta_1, \beta_2$

# mnohonásobná lineární regrese

- ▶ závislost na dvou (nebo více) nezávisle proměnných
- ▶ pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- ▶ představa (model)

$$Y_i = \underbrace{\beta_0 + \beta_1 x_i + \beta_2 v_i}_{E Y_i} + E_i$$

- ▶ střední hodnota  $Y_i$  (tj. systematická, nenáhodná složka  $Y_i$ ) vysvětlena pomocí  $x_i, v_i$  jako  $\beta_0 + \beta_1 x_i + \beta_2 v_i$
- ▶  $E_1, \dots, E_n$  (také  $Y_1, \dots, Y_n$ ) jsou **nezávislé** náhodné veličiny
- ▶  $E_i \sim N(0, \sigma^2)$  (normální rozdělení se stejným rozptylem)
- ▶  $b_0, b_1, b_2$  – odhady parametrů  $\beta_0, \beta_1, \beta_2$

## mnohonásobná lineární regrese

- ▶ závislost na dvou (nebo více) nezávisle proměnných
- ▶ pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- ▶ představa (model)

$$Y_i = \underbrace{\beta_0 + \beta_1 x_i + \beta_2 v_i}_{E Y_i} + E_i$$

- ▶ střední hodnota  $Y_i$  (tj. systematická, nenáhodná složka  $Y_i$ ) vysvětlena pomocí  $x_i, v_i$  jako  $\beta_0 + \beta_1 x_i + \beta_2 v_i$
- ▶  $E_1, \dots, E_n$  (také  $Y_1, \dots, Y_n$ ) jsou **nezávislé** náhodné veličiny
- ▶  $E_i \sim N(0, \sigma^2)$  (normální rozdělení se stejným rozptylem)
- ▶  $b_0, b_1, b_2$  – odhady parametrů  $\beta_0, \beta_1, \beta_2$



## mnohonásobná lineární regrese

- ▶ závislost na dvou (nebo více) nezávisle proměnných
- ▶ pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- ▶ představa (model)

$$Y_i = \underbrace{\beta_0 + \beta_1 x_i + \beta_2 v_i}_{E Y_i} + E_i$$

- ▶ střední hodnota  $Y_i$  (tj. systematická, nenáhodná složka  $Y_i$ ) vysvětlena pomocí  $x_i, v_i$  jako  $\beta_0 + \beta_1 x_i + \beta_2 v_i$
- ▶  $E_1, \dots, E_n$  (také  $Y_1, \dots, Y_n$ ) jsou **nezávislé** náhodné veličiny
- ▶  $E_i \sim N(0, \sigma^2)$  (normální rozdělení se stejným rozptylem)
- ▶  $b_0, b_1, b_2$  – odhady parametrů  $\beta_0, \beta_1, \beta_2$

## mnohonásobná lineární regrese

- ▶ závislost na dvou (nebo více) nezávisle proměnných
- ▶ pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- ▶ představa (model)

$$Y_i = \underbrace{\beta_0 + \beta_1 x_i + \beta_2 v_i}_{E Y_i} + E_i$$

- ▶ střední hodnota  $Y_i$  (tj. systematická, nenáhodná složka  $Y_i$ ) vysvětlena pomocí  $x_i, v_i$  jako  $\beta_0 + \beta_1 x_i + \beta_2 v_i$
- ▶  $E_1, \dots, E_n$  (také  $Y_1, \dots, Y_n$ ) jsou **nezávislé** náhodné veličiny
- ▶  $E_i \sim N(0, \sigma^2)$  (normální rozdělení se stejným rozptylem)
- ▶  $b_0, b_1, b_2$  – odhady parametrů  $\beta_0, \beta_1, \beta_2$

## mnohonásobná lineární regrese

- ▶ závislost na dvou (nebo více) nezávisle proměnných
- ▶ pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- ▶ představa (model)

$$Y_i = \underbrace{\beta_0 + \beta_1 x_i + \beta_2 v_i}_{E Y_i} + E_i$$

- ▶ střední hodnota  $Y_i$  (tj. systematická, nenáhodná složka  $Y_i$ ) vysvětlena pomocí  $x_i, v_i$  jako  $\beta_0 + \beta_1 x_i + \beta_2 v_i$
- ▶  $E_1, \dots, E_n$  (také  $Y_1, \dots, Y_n$ ) jsou **nezávislé** náhodné veličiny
- ▶  $E_i \sim N(0, \sigma^2)$  (normální rozdělení se stejným rozptylem)
- ▶  $b_0, b_1, b_2$  – odhady parametrů  $\beta_0, \beta_1, \beta_2$

## mnohonásobná lineární regrese

- ▶ závislost na dvou (nebo více) nezávisle proměnných
- ▶ pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- ▶ představa (model)

$$Y_i = \underbrace{\beta_0 + \beta_1 x_i + \beta_2 v_i}_{E Y_i} + E_i$$

- ▶ střední hodnota  $Y_i$  (tj. systematická, nenáhodná složka  $Y_i$ ) vysvětlena pomocí  $x_i, v_i$  jako  $\beta_0 + \beta_1 x_i + \beta_2 v_i$
- ▶  $E_1, \dots, E_n$  (také  $Y_1, \dots, Y_n$ ) jsou **nezávislé** náhodné veličiny
- ▶  $E_i \sim N(0, \sigma^2)$  (normální rozdělení se stejným rozptylem)
- ▶  $b_0, b_1, b_2$  – odhady parametrů  $\beta_0, \beta_1, \beta_2$

## interpretace

- ▶  $b_1$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $x$  a **nezměněné** hodnotě  $v$
- ▶  $b_2$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $v$  a **nezměněné** hodnotě  $x$
- ▶  $U_i$  – reziduum

$$U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1 x_i + b_2 v_i)$$

- ▶ rozklad variability  $S_T = S_R + S_e$

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

## interpretace

- ▶  $b_1$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $x$  a **nezměněné** hodnotě  $v$
- ▶  $b_2$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $v$  a **nezměněné** hodnotě  $x$
- ▶  $U_i$  – reziduum

$$U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i + b_2v_i)$$

- ▶ rozklad variability  $S_T = S_R + S_e$

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

## interpretace

- ▶  $b_1$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $x$  a **nezměněné** hodnotě  $v$
- ▶  $b_2$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $v$  a **nezměněné** hodnotě  $x$
- ▶  $U_i$  – **reziduum**

$$U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i + b_2v_i)$$

- ▶ rozklad variability  $S_T = S_R + S_e$

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

## interpretace

- ▶  $b_1$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $x$  a **nezměněné** hodnotě  $v$
- ▶  $b_2$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $v$  a **nezměněné** hodnotě  $x$
- ▶  $U_i$  – **reziduum**

$$U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i + b_2v_i)$$

- ▶ **rozklad variability**  $S_T = S_R + S_e$

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$



## koeficient determinace

- ▶ **koeficient determinace  $R^2$**   
podíl celkové variability, který se podařilo vysvětlit závislostí  $Y$  na  $x$  a  $v$  (jakou část variability  $Y$  se podařilo vysvětlit)

$$R^2 = \frac{S_R}{S_T} = 1 - \frac{S_e}{S_T}$$

- ▶  $H_0 : \beta_1 = \beta_2 = 0$  (chování  $Y$  nezávisí ani na  $x$  ani na  $v$ )

$$F = \frac{S_R/2}{S_e/(n-3)} \geq F_{2,n-3}(\alpha)$$

- ▶  $p$ -hodnota tohoto testu bývá uváděna spolu s  $R^2$

## koeficient determinace

- ▶ **koeficient determinace  $R^2$**   
podíl celkové variability, který se podařilo vysvětlit závislostí  $Y$  na  $x$  a  $v$  (jakou část variability  $Y$  se podařilo vysvětlit)

$$R^2 = \frac{S_R}{S_T} = 1 - \frac{S_e}{S_T}$$

- ▶  $H_0 : \beta_1 = \beta_2 = 0$  (chování  $Y$  nezávisí ani na  $x$  ani na  $v$ )

$$F = \frac{S_R/2}{S_e/(n-3)} \geq F_{2,n-3}(\alpha)$$

- ▶  $p$ -hodnota tohoto testu bývá uváděna spolu s  $R^2$

## koeficient determinace

- ▶ **koeficient determinace**  $R^2$   
podíl celkové variability, který se podařilo vysvětlit závislostí  $Y$  na  $x$  a  $v$  (jakou část variability  $Y$  se podařilo vysvětlit)

$$R^2 = \frac{S_R}{S_T} = 1 - \frac{S_e}{S_T}$$

- ▶  $H_0 : \beta_1 = \beta_2 = 0$  (chování  $Y$  nezávisí ani na  $x$  ani na  $v$ )

$$F = \frac{S_R/2}{S_e/(n-3)} \geq F_{2,n-3}(\alpha)$$

- ▶  $p$ -hodnota tohoto testu bývá uváděna spolu s  $R^2$

## testy o přínosu jednotlivých regresorů

▶ model  $y = \beta_0 + \beta_1 x + \beta_2 v$

▶  $H_0 : \beta_2 = 0$

k vysvětlení chování  $Y$  stačí  $x$ , tj.  $y = \beta_0 + \beta_1 x$

$$T_2 = \frac{b_2}{\text{S.E.}(b_2)}, \quad \text{zamítat pro } |T_2| \geq t_{n-3}(\alpha)$$

▶  $H_0 : \beta_1 = 0$

k vysvětlení chování  $Y$  stačí  $v$ , tj.  $y = \beta_0 + \beta_2 v$

$$T_1 = \frac{b_1}{\text{S.E.}(b_1)}, \quad \text{zamítat pro } |T_1| \geq t_{n-3}(\alpha)$$

▶  $H_0 : \beta_0 = 0$  zpravidla nemá reálný smysl

## testy o přínosu jednotlivých regresorů

▶ model  $y = \beta_0 + \beta_1 x + \beta_2 v$

▶  $H_0 : \beta_2 = 0$

k vysvětlení chování  $Y$  stačí  $x$ , tj.  $y = \beta_0 + \beta_1 x$

$$T_2 = \frac{b_2}{\text{S.E.}(b_2)}, \quad \text{zamítat pro } |T_2| \geq t_{n-3}(\alpha)$$

▶  $H_0 : \beta_1 = 0$

k vysvětlení chování  $Y$  stačí  $v$ , tj.  $y = \beta_0 + \beta_2 v$

$$T_1 = \frac{b_1}{\text{S.E.}(b_1)}, \quad \text{zamítat pro } |T_1| \geq t_{n-3}(\alpha)$$

▶  $H_0 : \beta_0 = 0$  zpravidla nemá reálný smysl

## testy o přínosu jednotlivých regresorů

▶ model  $y = \beta_0 + \beta_1 x + \beta_2 v$

▶  $H_0 : \beta_2 = 0$

k vysvětlení chování  $Y$  stačí  $x$ , tj.  $y = \beta_0 + \beta_1 x$

$$T_2 = \frac{b_2}{\text{S.E.}(b_2)}, \quad \text{zamítat pro } |T_2| \geq t_{n-3}(\alpha)$$

▶  $H_0 : \beta_1 = 0$

k vysvětlení chování  $Y$  stačí  $v$ , tj.  $y = \beta_0 + \beta_2 v$

$$T_1 = \frac{b_1}{\text{S.E.}(b_1)}, \quad \text{zamítat pro } |T_1| \geq t_{n-3}(\alpha)$$

▶  $H_0 : \beta_0 = 0$  zpravidla nemá reálný smysl

## testy o přínosu jednotlivých regresorů

▶ model  $y = \beta_0 + \beta_1 x + \beta_2 v$

▶  $H_0 : \beta_2 = 0$

k vysvětlení chování  $Y$  stačí  $x$ , tj.  $y = \beta_0 + \beta_1 x$

$$T_2 = \frac{b_2}{\text{S.E.}(b_2)}, \quad \text{zamítat pro } |T_2| \geq t_{n-3}(\alpha)$$

▶  $H_0 : \beta_1 = 0$

k vysvětlení chování  $Y$  stačí  $v$ , tj.  $y = \beta_0 + \beta_2 v$

$$T_1 = \frac{b_1}{\text{S.E.}(b_1)}, \quad \text{zamítat pro } |T_1| \geq t_{n-3}(\alpha)$$

▶  $H_0 : \beta_0 = 0$  zpravidla nemá reálný smysl

## příklad: závislost procenta tuku na výšce a váze

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	11,327	16,682	0,679	0,5005
height	-0,262	0,110	-2,376	0,0216
weight	0,624	0,0690	9,050	<0,0001

- ▶ `[summary(lm(fat~height+weight))]`
- ▶ při **stejné výšce** očekáváme na každý kg hmotnosti o 0,6 proc. bodu více tuku
- ▶ u mužů, kteří se liší výškou o 10 cm a **mají stejnou hmotnost** očekáváme, že ti vyšší mají v průměru o 2,6 proc. bodu **méně** tuku
- ▶ na 5% hladině nelze vyloučit výšku, průkazně přispívá k vysvětlení pomocí váhy
- ▶ na 1% hladině nelze vyloučit váhu, průkazně přispívá k vysvětlení pomocí výšky



## příklad: závislost procenta tuku na výšce a váze

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	11,327	16,682	0,679	0,5005
height	-0,262	0,110	-2,376	0,0216
weight	0,624	0,0690	9,050	<0,0001

- ▶ `[summary(lm(fat~height+weight))]`
- ▶ při **stejně výšce** očekáváme na každý kg hmotnosti o 0,6 proc. bodu více tuku
- ▶ u mužů, kteří se liší výškou o 10 cm a **mají stejnou hmotnost** očekáváme, že ti vyšší mají v průměru o 2,6 proc. bodu **méně** tuku
- ▶ na 5% hladině nelze vyloučit výšku, průkazně přispívá k vysvětlení pomocí váhy
- ▶ na 1% hladině nelze vyloučit váhu, průkazně přispívá k vysvětlení pomocí výšky

## příklad: závislost procenta tuku na výšce a váze

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	11,327	16,682	0,679	0,5005
height	-0,262	0,110	-2,376	0,0216
weight	0,624	0,0690	9,050	<0,0001

- ▶ `[summary(lm(fat~height+weight))]`
- ▶ při **stejně výšce** očekáváme na každý kg hmotnosti o 0,6 proc. bodu více tuku
- ▶ u mužů, kteří se liší výškou o 10 cm a **mají stejnou hmotnost** očekáváme, že ti vyšší mají v průměru o 2,6 proc. bodu **méně** tuku
- ▶ na 5% hladině nelze vyloučit výšku, průkazně přispívá k vysvětlení pomocí váhy
- ▶ na 1% hladině nelze vyloučit váhu, průkazně přispívá k vysvětlení pomocí výšky

## příklad: závislost procenta tuku na výšce a váze

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	11,327	16,682	0,679	0,5005
height	-0,262	0,110	-2,376	0,0216
weight	0,624	0,0690	9,050	<0,0001

- ▶ `[summary(lm(fat~height+weight))]`
- ▶ při **stejně výšce** očekáváme na každý kg hmotnosti o 0,6 proc. bodu více tuku
- ▶ u mužů, kteří se liší výškou o 10 cm a **mají stejnou hmotnost** očekáváme, že ti vyšší mají v průměru o 2,6 proc. bodu **méně** tuku
- ▶ na 5% hladině nelze vyloučit výšku, průkazně přispívá k vysvětlení pomocí váhy
- ▶ na 1% hladině nelze vyloučit váhu, průkazně přispívá k vysvětlení pomocí výšky

## příklad: závislost procenta tuku na výšce a váze

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	11,327	16,682	0,679	0,5005
height	-0,262	0,110	-2,376	0,0216
weight	0,624	0,0690	9,050	<0,0001

- ▶ `[summary(lm(fat~height+weight))]`
- ▶ při **stejně výšce** očekáváme na každý kg hmotnosti o 0,6 proc. bodu více tuku
- ▶ u mužů, kteří se liší výškou o 10 cm a **mají stejnou hmotnost** očekáváme, že ti vyšší mají v průměru o 2,6 proc. bodu **méně** tuku
- ▶ na 5% hladině nelze vyloučit výšku, průkazně přispívá k vysvětlení pomocí váhy
- ▶ na 1% hladině nelze vyloučit váhu, průkazně přispívá k vysvětlení pomocí výšky

## tabulka analýzy rozptylu

( $F$ -statistika je v summary(), v commanderu nutno zvolit typ I a přínosy regresorů sečíst)

variabilita	souč. čtv,	st. vol.	prům. čtv.	$F$	$p$
regrese	1833,11	2	916,55	51,050	<0,001
rezid.	843,85	47	17,95		
celk.	2676,95	49	(54,63)		

- ▶  $R^2 = 1833,11/2676,95 = 1 - 843,85/2676,95 = 0,685$
- ▶ závislostí na výšce a váze jsme vysvětlili 68,5 % variability procenta tuku
- ▶  $s^2 = 17,95$
- ▶ na každé rozumné hladině zamítáme hypotézu, podle které procento tuku nezávisí ani na výšce ani na váze

## tabulka analýzy rozptylu

( $F$ -statistika je v summary(), v commanderu nutno zvolit typ I a přínosy regresorů sečíst)

variabilita	souč. čtv,	st. vol.	prům. čtv.	$F$	$p$
regrese	1833,11	2	916,55	51,050	<0,001
rezid.	843,85	47	17,95		
celk.	2676,95	49	(54,63)		

- ▶  $R^2 = 1833,11/2676,95 = 1 - 843,85/2676,95 = 0,685$
- ▶ závislostí na výšce a váze jsme vysvětlili 68,5 % variability procenta tuku
- ▶  $s^2 = 17,95$
- ▶ na každé rozumné hladině zamítáme hypotézu, podle které procento tuku nezávisí ani na výšce ani na váze

## tabulka analýzy rozptylu

( $F$ -statistika je v summary(), v commanderu nutno zvolit typ I a přínosy regresorů sečíst)

variabilita	souč. čtv,	st. vol.	prům. čtv.	$F$	$p$
regrese	1833,11	2	916,55	51,050	<0,001
rezid.	843,85	47	17,95		
celk.	2676,95	49	(54,63)		

- ▶  $R^2 = 1833,11/2676,95 = 1 - 843,85/2676,95 = 0,685$
- ▶ závislostí na výšce a váze jsme vysvětlili 68,5 % variability procenta tuku
- ▶  $s^2 = 17,95$
- ▶ na každé rozumné hladině zamítáme hypotézu, podle které procento tuku nezávisí ani na výšce ani na váze

## tabulka analýzy rozptylu

( $F$ -statistika je v summary(), v commanderu nutno zvolit typ I a přínosy regresorů sečíst)

variabilita	souč. čtv,	st. vol.	prům. čtv.	$F$	$p$
regrese	1833,11	2	916,55	51,050	<0,001
rezid.	843,85	47	17,95		
celk.	2676,95	49	(54,63)		

- ▶  $R^2 = 1833,11/2676,95 = 1 - 843,85/2676,95 = 0,685$
- ▶ závislostí na výšce a váze jsme vysvětlili 68,5 % variability procenta tuku
- ▶  $s^2 = 17,95$
- ▶ na každé rozumné hladině zamítáme hypotézu, podle které procento tuku nezávisí ani na výšce ani na váze



# regresní diagnostika

zda byly splněny předpoklady

- a) zvolili jsme správně **tvar závislosti**?
  - b) je **rozptyl** všude **stejný**?
  - c) je přiměřeně splněn předpoklad o **normálním rozdělení**?
  - d) jsou opravdu pozorování **nezávislá**?  
problém často tam, kde působí čas
- ▶ k odstranění problémů s body a), b), c) často pomůže transformace, např. logaritmování závisle proměnné
  - ▶ `[plot(lm(fat~height+weight))]`

# regresní diagnostika

zda byly splněny předpoklady

- a) zvolili jsme správně **tvar závislosti**?
  - b) je **rozptyl** všude **stejný**?
  - c) je přiměřeně splněn předpoklad o **normálním rozdělení**?
  - d) jsou opravdu pozorování **nezávislá**?  
problém často tam, kde působí čas
- ▶ k odstranění problémů s body a), b), c) často pomůže transformace, např. logaritmování závisle proměnné
  - ▶ `[plot(lm(fat~height+weight))]`

# regresní diagnostika

zda byly splněny předpoklady

- a) zvolili jsme správně **tvar závislosti**?
  - b) je **rozptyl** všude **stejný**?
  - c) je přiměřeně splněn předpoklad o **normálním rozdělení**?
  - d) jsou opravdu pozorování **nezávislá**?  
problém často tam, kde působí čas
- ▶ k odstranění problémů s body a), b), c) často pomůže transformace, např. logaritmování závisle proměnné
  - ▶ `[plot(lm(fat~height+weight))]`

# regresní diagnostika

zda byly splněny předpoklady

- a) zvolili jsme správně **tvar závislosti**?
  - b) je **rozptyl** všude **stejný**?
  - c) je přiměřeně splněn předpoklad o **normálním rozdělení**?
  - d) jsou opravdu pozorování **nezávislá**?  
problém často tam, kde působí čas
- ▶ k odstranění problémů s body a), b), c) často pomůže transformace, např. logaritmování závisle proměnné
  - ▶ `[plot(lm(fat~height+weight))]`

# regresní diagnostika

zda byly splněny předpoklady

- a) zvolili jsme správně **tvar závislosti**?
  - b) je **rozptyl** všude **stejný**?
  - c) je přiměřeně splněn předpoklad o **normálním rozdělení**?
  - d) jsou opravdu pozorování **nezávislá**?  
problém často tam, kde působí čas
- ▶ k odstranění problémů s body a), b), c) často pomůže transformace, např. logaritmování závisle proměnné
  - ▶ `[plot(lm(fat~height+weight))]`

# regresní diagnostika

zda byly splněny předpoklady

- a) zvolili jsme správně **tvar závislosti**?
  - b) je **rozptyl** všude **stejný**?
  - c) je přiměřeně splněn předpoklad o **normálním rozdělení**?
  - d) jsou opravdu pozorování **nezávislá**?  
problém často tam, kde působí čas
- ▶ k odstranění problémů s body a), b), c) často pomůže transformace, např. logaritmování závisle proměnné
  - ▶ `[plot(lm(fat~height+weight))]`

## výšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	<b>kontingenční tabulky</b>

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

## výšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	<b>kontingenční tabulky</b>

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů



## výšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	<b>kontingenční tabulky</b>

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

## vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	<b>kontingenční tabulky</b>

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

# hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

# hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

## hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

# hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

# hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

# hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení



# hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

# hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

# hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

# hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlízíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do  $k$  neslučitelných kategorií
- ▶ výsledkem je  $k$ -tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

# multinomické rozdělení

příklad: hod hrací kostkou,  $k = 6$

- ▶ v dílčím pokusu  $k$  možných výsledků (jevů)  $A_1, \dots, A_k$
- ▶  $A_1, \dots, A_k$  jsou neslučitelné jevy, sjednocení všech je jev jistý
- ▶  $\pi_j$  je pst, že vyjde  $A_j$  ( $\pi_1 + \pi_2 + \dots + \pi_k = 1$ )
- ▶  $n$  **nezávislých** dílčích pokusů ( $n$  opakování)
- ▶  $N_j$  – počet dílčích pokusů, kdy nastalo  $A_j$
- ▶  $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
- ▶ **pravděpodobnost** toho, že  $N_1 = n_1, \dots, N_k = n_k$   
 $(n_1 + n_2 + \dots + n_k = n, \quad n_1 \geq 0, \dots, n_k \geq 0)$

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$

# multinomické rozdělení

příklad: hod hrací kostkou,  $k = 6$

- ▶ v dílčím pokusu  $k$  možných výsledků (jevů)  $A_1, \dots, A_k$
- ▶  $A_1, \dots, A_k$  jsou neslučitelné jevy, sjednocení všech je jev jistý
- ▶  $\pi_j$  je pst, že vyjde  $A_j$  ( $\pi_1 + \pi_2 + \dots + \pi_k = 1$ )
- ▶  $n$  **nezávislých** dílčích pokusů ( $n$  opakování)
- ▶  $N_j$  – počet dílčích pokusů, kdy nastalo  $A_j$
- ▶  $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
- ▶ **pravděpodobnost** toho, že  $N_1 = n_1, \dots, N_k = n_k$   
 $(n_1 + n_2 + \dots + n_k = n, \quad n_1 \geq 0, \dots, n_k \geq 0)$

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$

# multinomické rozdělení

příklad: hod hrací kostkou,  $k = 6$

- ▶ v dílčím pokusu  $k$  možných výsledků (jevů)  $A_1, \dots, A_k$
- ▶  $A_1, \dots, A_k$  jsou neslučitelné jevy, sjednocení všech je jev jistý
- ▶  $\pi_j$  je pst, že vyjde  $A_j$  ( $\pi_1 + \pi_2 + \dots + \pi_k = 1$ )
- ▶  $n$  **nezávislých** dílčích pokusů ( $n$  opakování)
- ▶  $N_j$  – počet dílčích pokusů, kdy nastalo  $A_j$
- ▶  $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
- ▶ **pravděpodobnost** toho, že  $N_1 = n_1, \dots, N_k = n_k$   
 $(n_1 + n_2 + \dots + n_k = n, \quad n_1 \geq 0, \dots, n_k \geq 0)$

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$

# multinomické rozdělení

příklad: hod hrací kostkou,  $k = 6$

- ▶ v dílčím pokusu  $k$  možných výsledků (jevů)  $A_1, \dots, A_k$
- ▶  $A_1, \dots, A_k$  jsou neslučitelné jevy, sjednocení všech je jev jistý
- ▶  $\pi_j$  je pst, že vyjde  $A_j$  ( $\pi_1 + \pi_2 + \dots + \pi_k = 1$ )
- ▶  $n$  **nezávislých** dílčích pokusů ( $n$  opakování)
- ▶  $N_j$  – počet dílčích pokusů, kdy nastalo  $A_j$
- ▶  $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
- ▶ **pravděpodobnost** toho, že  $N_1 = n_1, \dots, N_k = n_k$   
( $n_1 + n_2 + \dots + n_k = n, \quad n_1 \geq 0, \dots, n_k \geq 0$ )

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$



# multinomické rozdělení

příklad: hod hrací kostkou,  $k = 6$

- ▶ v dílčím pokusu  $k$  možných výsledků (jevů)  $A_1, \dots, A_k$
- ▶  $A_1, \dots, A_k$  jsou neslučitelné jevy, sjednocení všech je jev jistý
- ▶  $\pi_j$  je pst, že vyjde  $A_j$  ( $\pi_1 + \pi_2 + \dots + \pi_k = 1$ )
- ▶  $n$  **nezávislých** dílčích pokusů ( $n$  opakování)
- ▶  $N_j$  – počet dílčích pokusů, kdy nastalo  $A_j$
- ▶  $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
- ▶ **pravděpodobnost** toho, že  $N_1 = n_1, \dots, N_k = n_k$   
( $n_1 + n_2 + \dots + n_k = n, \quad n_1 \geq 0, \dots, n_k \geq 0$ )

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$

# multinomické rozdělení

příklad: hod hrací kostkou,  $k = 6$

- ▶ v dílčím pokusu  $k$  možných výsledků (jevů)  $A_1, \dots, A_k$
- ▶  $A_1, \dots, A_k$  jsou neslučitelné jevy, sjednocení všech je jev jistý
- ▶  $\pi_j$  je pst, že vyjde  $A_j$  ( $\pi_1 + \pi_2 + \dots + \pi_k = 1$ )
- ▶  $n$  **nezávislých** dílčích pokusů ( $n$  opakování)
- ▶  $N_j$  – počet dílčích pokusů, kdy nastalo  $A_j$
- ▶  $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
- ▶ **pravděpodobnost** toho, že  $N_1 = n_1, \dots, N_k = n_k$   
( $n_1 + n_2 + \dots + n_k = n, \quad n_1 \geq 0, \dots, n_k \geq 0$ )

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$

# multinomické rozdělení

příklad: hod hrací kostkou,  $k = 6$

- ▶ v dílčím pokusu  $k$  možných výsledků (jevů)  $A_1, \dots, A_k$
- ▶  $A_1, \dots, A_k$  jsou neslučitelné jevy, sjednocení všech je jev jistý
- ▶  $\pi_j$  je pst, že vyjde  $A_j$  ( $\pi_1 + \pi_2 + \dots + \pi_k = 1$ )
- ▶  $n$  **nezávislých** dílčích pokusů ( $n$  opakování)
- ▶  $N_j$  – počet dílčích pokusů, kdy nastalo  $A_j$
- ▶  $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
- ▶ **pravděpodobnost** toho, že  $N_1 = n_1, \dots, N_k = n_k$   
( $n_1 + n_2 + \dots + n_k = n, \quad n_1 \geq 0, \dots, n_k \geq 0$ )

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$

## souvislost s binomickým rozdělením

příklad: zajímáme se jen šestku na hrací kostce

- ▶ pro  $k = 2$  jsou v dílčím pokusu jen dva možné výsledky, binomické rozdělení je speciálním případem multinomického

$$P(N_1 = n_1, N_2 = n_2) = \frac{n!}{n_1!n_2!} \pi_1^{n_1} \pi_2^{n_2}$$

je totéž jako (platí přece  $n_1 + n_2 = n$ )

$$P(N_1 = n_1) = \binom{n}{n_1} \pi_1^{n_1} (1 - \pi_1)^{n - n_1}$$

- ▶ každé  $N_j$  (samotné, proti ostatním četnostem) má binomické rozdělení, tedy

$$N_j \sim \text{bi}(n, \pi_j), \quad E N_j = n\pi_j$$

## souvislost s binomickým rozdělením

příklad: zajímáme se jen šestku na hrací kostce

- ▶ pro  $k = 2$  jsou v dílčím pokusu jen dva možné výsledky, binomické rozdělení je speciálním případem multinomického

$$P(N_1 = n_1, N_2 = n_2) = \frac{n!}{n_1!n_2!} \pi_1^{n_1} \pi_2^{n_2}$$

je totéž jako (platí přece  $n_1 + n_2 = n$ )

$$P(N_1 = n_1) = \binom{n}{n_1} \pi_1^{n_1} (1 - \pi_1)^{n - n_1}$$

- ▶ každé  $N_j$  (samotné, proti ostatním četnostem) má binomické rozdělení, tedy

$$N_j \sim \text{bi}(n, \pi_j), \quad E N_j = n\pi_j$$

# vlastnost $\chi^2$ (chí-kvadrát), chí-kvadrát test dobré shody

( $X^2$  – velké  $\chi^2$ )

- ▶ platí pro velká  $n$ , např. pokud  $n\pi_j \geq 5$  pro všechna  $j$ ,

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j)^2}{n\pi_j} \quad \text{má přibližně rozdělení } \chi_{k-1}^2$$

- ▶ **chí-kvadrát test dobré shody**  $H_0 : \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$   
(pravděpodobnosti jsou hypotézou dány **jednoznačně**)
- ▶ platí-li  $H_0$ , očekáváme četnosti blízké hodnotám  $E N_j = n\pi_j^0$ :

- ▶  $H_0$  zamítáme, je-li  $X^2 \geq \chi_{k-1}^2(\alpha)$ ,  $X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j^0)^2}{n\pi_j^0}$

- ▶  $N_j$  – **empirické** (experimentální) četnosti,  
 $n\pi_j^0$  – **očekávané** (teoretické) četnosti
- ▶ statistika  $X^2$  (velké chí-kvadrát) porovnává empirické a očekávané četnosti (měří jejich neshodu, „vzdálenost“)

# vlastnost $\chi^2$ (chí-kvadrát), chí-kvadrát test dobré shody

( $X^2$  – velké  $\chi^2$ )

- ▶ platí pro velká  $n$ , např. pokud  $n\pi_j \geq 5$  pro všechna  $j$ ,

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j)^2}{n\pi_j} \quad \text{má přibližně rozdělení } \chi_{k-1}^2$$

- ▶ **chí-kvadrát test dobré shody**  $H_0 : \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$   
(pravděpodobnosti jsou hypotézou dány **jednoznačně**)
- ▶ platí-li  $H_0$ , očekáváme četnosti blízké hodnotám  $E N_j = n\pi_j^0$ :

- ▶  $H_0$  zamítáme, je-li  $X^2 \geq \chi_{k-1}^2(\alpha)$ ,  $X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j^0)^2}{n\pi_j^0}$

- ▶  $N_j$  – **empirické** (experimentální) četnosti,  
 $n\pi_j^0$  – **očekávané** (teoretické) četnosti
- ▶ statistika  $X^2$  (velké chí-kvadrát) porovnává empirické a očekávané četnosti (měří jejich neshodu, „vzdálenost“)

# vlastnost $\chi^2$ (chí-kvadrát), chí-kvadrát test dobré shody

( $X^2$  – velké  $\chi^2$ )

- ▶ platí pro velká  $n$ , např. pokud  $n\pi_j \geq 5$  pro všechna  $j$ ,

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j)^2}{n\pi_j} \quad \text{má přibližně rozdělení } \chi_{k-1}^2$$

- ▶ **chí-kvadrát test dobré shody**  $H_0 : \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$   
(pravděpodobnosti jsou hypotézou dány **jednoznačně**)
- ▶ platí-li  $H_0$ , očekáváme četnosti blízké hodnotám  $E N_j = n\pi_j^0$ :

- ▶  $H_0$  zamítáme, je-li  $X^2 \geq \chi_{k-1}^2(\alpha)$ ,  $X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j^0)^2}{n\pi_j^0}$

- ▶  $N_j$  – **empirické** (experimentální) četnosti,  
 $n\pi_j^0$  – **očekávané** (teoretické) četnosti
- ▶ statistika  $X^2$  (velké chí-kvadrát) porovnává empirické a očekávané četnosti (měří jejich neshodu, „vzdálenost“)



# vlastnost $\chi^2$ (chí-kvadrát), chí-kvadrát test dobré shody

( $X^2$  – velké  $\chi^2$ )

- ▶ platí pro velká  $n$ , např. pokud  $n\pi_j \geq 5$  pro všechna  $j$ ,

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j)^2}{n\pi_j} \text{ má přibližně rozdělení } \chi_{k-1}^2$$

- ▶ **chí-kvadrát test dobré shody**  $H_0 : \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$   
(pravděpodobnosti jsou hypotézou dány **jednoznačně**)
- ▶ platí-li  $H_0$ , očekáváme četnosti blízké hodnotám  $E N_j = n\pi_j^0$ :

- ▶  $H_0$  zamítáme, je-li  $X^2 \geq \chi_{k-1}^2(\alpha)$ ,

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j^0)^2}{n\pi_j^0}$$

- ▶  $N_j$  – **empirické** (experimentální) četnosti,  
 $n\pi_j^0$  – **očekávané** (teoretické) četnosti
- ▶ statistika  $X^2$  (velké chí-kvadrát) porovnává empirické a očekávané četnosti (měří jejich neshodu, „vzdálenost“)

# vlastnost $\chi^2$ (chí-kvadrát), chí-kvadrát test dobré shody

( $X^2$  – velké  $\chi^2$ )

- ▶ platí pro velká  $n$ , např. pokud  $n\pi_j \geq 5$  pro všechna  $j$ ,

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j)^2}{n\pi_j} \quad \text{má přibližně rozdělení } \chi_{k-1}^2$$

- ▶ **chí-kvadrát test dobré shody**  $H_0 : \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$   
(pravděpodobnosti jsou hypotézou dány **jednoznačně**)
- ▶ platí-li  $H_0$ , očekáváme četnosti blízké hodnotám  $E N_j = n\pi_j^0$ :

- ▶  $H_0$  zamítáme, je-li  $X^2 \geq \chi_{k-1}^2(\alpha)$ , 
$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j^0)^2}{n\pi_j^0}$$

- ▶  $N_j$  – **empirické** (experimentální) četnosti,  
 $n\pi_j^0$  – **očekávané** (teoretické) četnosti
- ▶ statistika  $X^2$  (velké chí-kvadrát) porovnává empirické a očekávané četnosti (měří jejich neshodu, „vzdálenost“)

# vlastnost $\chi^2$ (chí-kvadrát), chí-kvadrát test dobré shody

( $X^2$  – velké  $\chi^2$ )

- ▶ platí pro velká  $n$ , např. pokud  $n\pi_j \geq 5$  pro všechna  $j$ ,

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j)^2}{n\pi_j} \quad \text{má přibližně rozdělení } \chi_{k-1}^2$$

- ▶ **chí-kvadrát test dobré shody**  $H_0 : \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$   
(pravděpodobnosti jsou hypotézou dány **jednoznačně**)
- ▶ platí-li  $H_0$ , očekáváme četnosti blízké hodnotám  $E N_j = n\pi_j^0$ :

- ▶  $H_0$  zamítáme, je-li  $X^2 \geq \chi_{k-1}^2(\alpha)$ ,  $X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j^0)^2}{n\pi_j^0}$

- ▶  $N_j$  – **empirické** (experimentální) četnosti,  
 $n\pi_j^0$  – **očekávané** (teoretické) četnosti
- ▶ statistika  $X^2$  (velké chí-kvadrát) porovnává empirické a očekávané četnosti (měří jejich neshodu, „vzdálenost“)

## počty studentů biologie narozených v jednotlivých měsících

nulová hypotéza: děti se rodí během roku rovnoměrně

[chisq.test(nj,p=c(31,28,31,30,31,30,31,31,30,31,30,31)/365)]

měsíc	$n_j$	$n\pi_j^0$	přínos k chí-kvadrát
1	11	9,43	0,2623
2	9	8,52	0,0276
3	13	9,43	1,3539
4	11	9,12	0,3861
5	8	9,43	0,2161
6	5	9,12	1,8635
7	10	9,43	0,0348
8	6	9,43	1,2461
9	13	9,12	1,6473
10	8	9,43	0,2161
11	8	9,12	0,1383
12	9	9,43	0,0194
celkem	111	111,00	7,4115

$$X^2 = 7,4115 < \chi_{12-1}^2(0,05) = 19,675 \quad p = 76,5 \%$$

## příklad: reprezentativnost výběru

(porovnat procenta v populaci a výběru **nestačí**)

- ▶ ve vzorku pacientů byly počty osob s krevními skupinami 0, A, B a AB po řadě 56, 72, 54, 18 (tedy  $n = 200$ )
- ▶ ve vyšetřované populaci jsou krevní skupiny 0, A, B a AB v poměru 35 %, 35 %, 20 % a 10 % (to určuje  $H_0$ )
- ▶ **v průměru** očekáváme četnosti  $200 \cdot 0,35 = 70$  (70, 40, 20)
- ▶ lze považovat tento výběr za **reprezentativní vzhledem k výskytu krevních skupin?**

$$\begin{aligned}\chi^2 &= \frac{(56 - 70)^2}{70} + \frac{(72 - 70)^2}{70} + \frac{(54 - 40)^2}{40} + \frac{(18 - 20)^2}{20} \\ &= 7,96 > 7,81 = \chi_3^2(0,05) \quad p = 4,7 \%\end{aligned}$$

- ▶ výběr **nelze** považovat za reprezentativní
- ▶ při polovičních četnostech ve výběru (28, 36, 27, 9) by vyšlo  $\chi^2 = 3,98$ ,  $p = 26,4 \%$  (lze považovat za reprezentativní)

## příklad: reprezentativnost výběru

(porovnat procenta v populaci a výběru **nestačí**)

- ▶ ve vzorku pacientů byly počty osob s krevními skupinami 0, A, B a AB po řadě 56, 72, 54, 18 (tedy  $n = 200$ )
- ▶ ve vyšetřované populaci jsou krevní skupiny 0, A, B a AB v poměru 35 %, 35 %, 20 % a 10 % (to určuje  $H_0$ )
- ▶ v průměru očekáváme četnosti  $200 \cdot 0,35 = 70$  (70, 40, 20)
- ▶ lze považovat tento výběr za **reprezentativní** **vzhledem k výskytu krevních skupin?**

$$\begin{aligned}\chi^2 &= \frac{(56 - 70)^2}{70} + \frac{(72 - 70)^2}{70} + \frac{(54 - 40)^2}{40} + \frac{(18 - 20)^2}{20} \\ &= 7,96 > 7,81 = \chi_3^2(0,05) \quad p = 4,7 \%\end{aligned}$$

- ▶ výběr **nelze** považovat za reprezentativní
- ▶ při polovičních četnostech ve výběru (28, 36, 27, 9) by vyšlo  $\chi^2 = 3,98$ ,  $p = 26,4 \%$  (lze považovat za reprezentativní)

## příklad: reprezentativnost výběru

(porovnat procenta v populaci a výběru **nestačí**)

- ▶ ve vzorku pacientů byly počty osob s krevními skupinami 0, A, B a AB po řadě 56, 72, 54, 18 (tedy  $n = 200$ )
- ▶ ve vyšetřované populaci jsou krevní skupiny 0, A, B a AB v poměru 35 %, 35 %, 20 % a 10 % (to určuje  $H_0$ )
- ▶ **v průměru** očekáváme četnosti  $200 \cdot 0,35 = 70$  (70, 40, 20)
- ▶ lze považovat tento výběr za **reprezentativní vzhledem k výskytu krevních skupin?**

$$\begin{aligned}\chi^2 &= \frac{(56 - 70)^2}{70} + \frac{(72 - 70)^2}{70} + \frac{(54 - 40)^2}{40} + \frac{(18 - 20)^2}{20} \\ &= 7,96 > 7,81 = \chi_3^2(0,05) \quad p = 4,7 \%\end{aligned}$$

- ▶ výběr **nelze** považovat za reprezentativní
- ▶ při polovičních četnostech ve výběru (28, 36, 27, 9) by vyšlo  $\chi^2 = 3,98$ ,  $p = 26,4 \%$  (lze považovat za reprezentativní)

## příklad: reprezentativnost výběru

(porovnat procenta v populaci a výběru nestačí)

- ▶ ve vzorku pacientů byly počty osob s krevními skupinami 0, A, B a AB po řadě 56, 72, 54, 18 (tedy  $n = 200$ )
- ▶ ve vyšetřované populaci jsou krevní skupiny 0, A, B a AB v poměru 35 %, 35 %, 20 % a 10 % (to určuje  $H_0$ )
- ▶ **v průměru** očekáváme četnosti  $200 \cdot 0,35 = 70$  (70, 40, 20)
- ▶ lze považovat tento výběr za **reprezentativní vzhledem k výskytu krevních skupin?**

$$\begin{aligned}\chi^2 &= \frac{(56 - 70)^2}{70} + \frac{(72 - 70)^2}{70} + \frac{(54 - 40)^2}{40} + \frac{(18 - 20)^2}{20} \\ &= 7,96 > 7,81 = \chi_3^2(0,05) \qquad p = 4,7 \%\end{aligned}$$

- ▶ výběr **nelze** považovat za reprezentativní
- ▶ při polovičních četnostech ve výběru (28, 36, 27, 9) by vyšlo  $\chi^2 = 3,98$ ,  $p = 26,4 \%$  (lze považovat za reprezentativní)



## příklad: reprezentativnost výběru

(porovnat procenta v populaci a výběru nestačí)

- ▶ ve vzorku pacientů byly počty osob s krevními skupinami 0, A, B a AB po řadě 56, 72, 54, 18 (tedy  $n = 200$ )
- ▶ ve vyšetřované populaci jsou krevní skupiny 0, A, B a AB v poměru 35 %, 35 %, 20 % a 10 % (to určuje  $H_0$ )
- ▶ **v průměru** očekáváme četnosti  $200 \cdot 0,35 = 70$  (70, 40, 20)
- ▶ lze považovat tento výběr za **reprezentativní vzhledem k výskytu krevních skupin?**

$$\begin{aligned}\chi^2 &= \frac{(56 - 70)^2}{70} + \frac{(72 - 70)^2}{70} + \frac{(54 - 40)^2}{40} + \frac{(18 - 20)^2}{20} \\ &= 7,96 > 7,81 = \chi_3^2(0,05) \qquad p = 4,7 \%\end{aligned}$$

- ▶ výběr **nelze** považovat za reprezentativní
- ▶ při polovičních četnostech ve výběru (28, 36, 27, 9) by vyšlo  $\chi^2 = 3,98$ ,  $p = 26,4 \%$  (lze považovat za reprezentativní)

## příklad: reprezentativnost výběru

(porovnat procenta v populaci a výběru nestačí)

- ▶ ve vzorku pacientů byly počty osob s krevními skupinami 0, A, B a AB po řadě 56, 72, 54, 18 (tedy  $n = 200$ )
- ▶ ve vyšetřované populaci jsou krevní skupiny 0, A, B a AB v poměru 35 %, 35 %, 20 % a 10 % (to určuje  $H_0$ )
- ▶ **v průměru** očekáváme četnosti  $200 \cdot 0,35 = 70$  (70, 40, 20)
- ▶ lze považovat tento výběr za **reprezentativní vzhledem k výskytu krevních skupin?**

$$\begin{aligned}\chi^2 &= \frac{(56 - 70)^2}{70} + \frac{(72 - 70)^2}{70} + \frac{(54 - 40)^2}{40} + \frac{(18 - 20)^2}{20} \\ &= 7,96 > 7,81 = \chi_3^2(0,05) \qquad p = 4,7 \%\end{aligned}$$

- ▶ výběr **nelze** považovat za reprezentativní
- ▶ při polovičních četnostech ve výběru (28, 36, 27, 9) by vyšlo  $\chi^2 = 3,98$ ,  $p = 26,4 \%$  (**lze** považovat za reprezentativní)

## příklad hrách: barva květů a tvar pylových zrněk

segregace dvou typů genů (C. R. Rao: Lineární metody statistické indukce ..., str. 439)

- ▶ barva květů – purpurová : červená v poměru 3 : 1 (dáno)
- ▶ tvar pylu – oválný : kulatý v poměru 3 : 1 (dáno)
- ▶ platí-li nulová hypotéza ( $H_0$  : jde o **nezávislou** segregaci), pak čtyři možné kombinace musí být v poměru 9 : 3 : 3 : 1

barva tvar	purpurová oválný	červená oválný	purpurová kulatý	červená kulatý	celkem
$n_j$	296	27	19	85	427
$o_j$	3843/16	1281/16	1281/16	427/16	427
$\frac{(n_j - o_j)^2}{o_j}$	12,97	35,17	46,57	127,41	222,12

$$\chi^2 = 222,12 > \chi_3^2(0,05) = 7,81$$

- ▶ nezávislost jsme **zamítli**

## příklad hrách: barva květů a tvar pylových zrněk

segregace dvou typů genů (C. R. Rao: Lineární metody statistické indukce ..., str. 439)

- ▶ barva květů – purpurová : červená v poměru 3 : 1 (dáno)
- ▶ tvar pylu – oválný : kulatý v poměru 3 : 1 (dáno)
- ▶ platí-li nulová hypotéza ( $H_0$  : jde o **nezávislou** segregaci), pak čtyři možné kombinace musí být v poměru 9 : 3 : 3 : 1

barva tvar	purpurová oválný	červená oválný	purpurová kulatý	červená kulatý	celkem
$n_j$	296	27	19	85	427
$o_j$	3843/16	1281/16	1281/16	427/16	427
$\frac{(n_j - o_j)^2}{o_j}$	12,97	35,17	46,57	127,41	222,12

$$\chi^2 = 222,12 > \chi_3^2(0,05) = 7,81$$

- ▶ nezávislost jsme **zamítli**

## příklad hrách: barva květů a tvar pylových zrněk

segregace dvou typů genů (C. R. Rao: Lineární metody statistické indukce ..., str. 439)

- ▶ barva květů – purpurová : červená v poměru 3 : 1 (dáno)
- ▶ tvar pylu – oválný : kulatý v poměru 3 : 1 (dáno)
- ▶ platí-li nulová hypotéza ( $H_0$  : jde o **nezávislou** segregaci), pak čtyři možné kombinace musí být v poměru 9 : 3 : 3 : 1

barva tvar	purpurová oválný	červená oválný	purpurová kulatý	červená kulatý	celkem
$n_j$	296	27	19	85	427
$o_j$	3843/16	1281/16	1281/16	427/16	427
$\frac{(n_j - o_j)^2}{o_j}$	12,97	35,17	46,57	127,41	222,12

$$\chi^2 = 222,12 > \chi_3^2(0,05) = 7,81$$

- ▶ nezávislost jsme **zamítli**

## příklad hrách: barva květů a tvar pylových zrněk

segregace dvou typů genů (C. R. Rao: Lineární metody statistické indukce ..., str. 439)

- ▶ barva květů – purpurová : červená v poměru 3 : 1 (dáno)
- ▶ tvar pylu – oválný : kulatý v poměru 3 : 1 (dáno)
- ▶ platí-li nulová hypotéza ( $H_0$  : jde o **nezávislou** segregaci), pak čtyři možné kombinace musí být v poměru 9 : 3 : 3 : 1

barva tvar	purpurová oválný	červená oválný	purpurová kulatý	červená kulatý	celkem
$n_j$	296	27	19	85	427
$o_j$	3843/16	1281/16	1281/16	427/16	427
$\frac{(n_j - o_j)^2}{o_j}$	12,97	35,17	46,57	127,41	222,12

$$\chi^2 = 222,12 > \chi_3^2(0,05) = 7,81$$

- ▶ nezávislost jsme **zamítli**

## příklad hrách: barva květů a tvar pylových zrněk

dodatečné ověření předpokladu známého poměru

- ▶ co způsobilo zamítnutí hypotézy?

barva	purpurová	červená	celkem
oválný tvar	296	27	323
kulatý tvar	19	85	104
celkem	315	112	427

- ▶ jsou barvy v očekávaném poměru 3 : 1?  
[chisq.test(c(315,112),p=c(3/4,1/4))]

$$\chi^2 = 0,3443 \quad p = 55,7 \%$$

- ▶ jsou tvary v očekávaném poměru 3 : 1?

$$\chi^2 = 0,0945 \quad p = 75,9 \%$$

- ▶ důvodem zamítnutí je nutně závislost

## příklad hrách: barva květů a tvar pylových zrněk

dodatečné ověření předpokladu známého poměru

- ▶ co způsobilo zamítnutí hypotézy?

barva	purpurová	červená	celkem
oválný tvar	296	27	323
kulatý tvar	19	85	104
celkem	315	112	427

- ▶ jsou barvy v očekávaném poměru 3 : 1?  
[chisq.test(c(315,112),p=c(3/4,1/4))]

$$\chi^2 = 0,3443 \quad p = 55,7 \%$$

- ▶ jsou tvary v očekávaném poměru 3 : 1?

$$\chi^2 = 0,0945 \quad p = 75,9 \%$$

- ▶ důvodem zamítnutí je nutně závislost



## příklad hrách: barva květů a tvar pylových zrněk

dodatečné ověření předpokladu známého poměru

- ▶ co způsobilo zamítnutí hypotézy?

barva	purpurová	červená	celkem
oválný tvar	296	27	323
kulatý tvar	19	85	104
celkem	315	112	427

- ▶ jsou barvy v očekávaném poměru 3 : 1?  
[chisq.test(c(315,112),p=c(3/4,1/4))]

$$\chi^2 = 0,3443 \quad p = 55,7 \%$$

- ▶ jsou tvary v očekávaném poměru 3 : 1?

$$\chi^2 = 0,0945 \quad p = 75,9 \%$$

- ▶ důvodem zamítnutí je nutně závislost

## příklad hrách: barva květů a tvar pylových zrněk

dodatečné ověření předpokladu známého poměru

- ▶ co způsobilo zamítnutí hypotézy?

barva	purpurová	červená	celkem
oválný tvar	296	27	323
kulatý tvar	19	85	104
celkem	315	112	427

- ▶ jsou barvy v očekávaném poměru 3 : 1?

[`chisq.test(c(315,112),p=c(3/4,1/4))`]

$$\chi^2 = 0,3443 \quad p = 55,7 \%$$

- ▶ jsou tvary v očekávaném poměru 3 : 1?

$$\chi^2 = 0,0945 \quad p = 75,9 \%$$

- ▶ důvodem zamítnutí je nutně závislost

## stejný příklad, štěpný poměr neznáme

proč takto počítáme, bude časem

tvar	barva		celkem
	purpurová	červená	
oválný	296	27	323
kulatý	19	85	104
celkem	315	112	427

očekávané četnosti:

$$323 \cdot 315/427 = 238,28$$

$$323 \cdot 112/427 = 84,72$$

$$104 \cdot 315/427 = 76,72$$

$$104 \cdot 112/427 = 27,28$$

$$\chi^2 = \frac{(296-238,28)^2}{238,28} + \frac{(27-84,72)^2}{84,72} + \frac{(19-76,72)^2}{76,72} + \frac{(85-27,28)^2}{27,28} = 215,10$$

$p < 0,001$ , očekávané četnosti jsou větší, než 5

## složená nulová hypotéza (hypotéza o struktuře)

- ▶ hypotéza určuje vztahy mezi pravděpodobnostmi  $\pi_1, \dots, \pi_k$  některé parametry zůstávají volné, je třeba je odhadnout
- ▶ příklad antigen: (Hardy-Weinberg equilibrium, nezávislost) model pro fenotypy AA, Aa, aa

$$P(AA) \equiv \pi_1(\theta) = \theta^2$$

$$P(Aa) \equiv \pi_2(\theta) = 2\theta(1 - \theta)$$

$$P(aa) \equiv \pi_3(\theta) = (1 - \theta)^2$$

- ▶ neurčený parametr  $\theta$  – pravděpodobnost alely A
- ▶ jsou zjištěné četnosti fenotypů  $n_1 = 18$ ,  $n_2 = 17$ ,  $n_3 = 6$  v souladu s modelem, tj. s H-W rovnováhou?

## složená nulová hypotéza (hypotéza o struktuře)

- ▶ hypotéza určuje vztahy mezi pravděpodobnostmi  $\pi_1, \dots, \pi_k$  některé parametry zůstávají volné, je třeba je odhadnout
- ▶ příklad antigen: (Hardy-Weinberg equilibrium, nezávislost) model pro fenotypy AA, Aa, aa

$$P(AA) \equiv \pi_1(\theta) = \theta^2$$

$$P(Aa) \equiv \pi_2(\theta) = 2\theta(1 - \theta)$$

$$P(aa) \equiv \pi_3(\theta) = (1 - \theta)^2$$

- ▶ neurčený parametr  $\theta$  – pravděpodobnost alely A
- ▶ jsou zjištěné četnosti fenotypů  $n_1 = 18$ ,  $n_2 = 17$ ,  $n_3 = 6$  v souladu s modelem, tj. s H-W rovnováhou?

## složená nulová hypotéza (hypotéza o struktuře)

- ▶ hypotéza určuje vztahy mezi pravděpodobnostmi  $\pi_1, \dots, \pi_k$  některé parametry zůstávají volné, je třeba je odhadnout
- ▶ příklad antigen: (Hardy-Weinberg equilibrium, nezávislost) model pro fenotypy AA, Aa, aa

$$P(AA) \equiv \pi_1(\theta) = \theta^2$$

$$P(Aa) \equiv \pi_2(\theta) = 2\theta(1 - \theta)$$

$$P(aa) \equiv \pi_3(\theta) = (1 - \theta)^2$$

- ▶ neurčený parametr  $\theta$  – pravděpodobnost alely A
- ▶ jsou zjištěné četnosti fenotypů  $n_1 = 18$ ,  $n_2 = 17$ ,  $n_3 = 6$  v souladu s modelem, tj. s H-W rovnováhou?

## složená nulová hypotéza (hypotéza o struktuře)

- ▶ hypotéza určuje vztahy mezi pravděpodobnostmi  $\pi_1, \dots, \pi_k$  některé parametry zůstávají volné, je třeba je odhadnout
- ▶ příklad antigen: (Hardy-Weinberg equilibrium, nezávislost) model pro fenotypy AA, Aa, aa

$$P(AA) \equiv \pi_1(\theta) = \theta^2$$

$$P(Aa) \equiv \pi_2(\theta) = 2\theta(1 - \theta)$$

$$P(aa) \equiv \pi_3(\theta) = (1 - \theta)^2$$

- ▶ neurčený parametr  $\theta$  – pravděpodobnost alely A
- ▶ jsou zjištěné četnosti fenotypů  $n_1 = 18$ ,  $n_2 = 17$ ,  $n_3 = 6$  v souladu s modelem, tj. s H-W rovnováhou?

odhad metodou maximální věrohodnosti za  $H_0$ 

[maximum likelihood estimate]

$$P(N_1 = n_1, N_2 = n_2, N_3 = n_3) = \frac{n!}{n_1!n_2!n_3!} (\theta^2)^{n_1} (2\theta(1-\theta))^{n_2} ((1-\theta)^2)^{n_3}$$

- ▶ najít  $\theta$  takové, aby pravděpodobnost konkrétního výsledku byla maximální možná (maximálně věrohodná)
- ▶ odhad  $\theta$  maximalizací *logaritmické věrohodnostní funkce*

$$\begin{aligned} \ell(\theta) &= \ln(P(N_1 = n_1, N_2 = n_2, N_3 = n_3)) \\ &= \ln\left(c_1 (\theta^2)^{n_1} (2\theta(1-\theta))^{n_2} ((1-\theta)^2)^{n_3}\right) \\ &= c_2 + (2n_1 + n_2) \ln \theta + (n_2 + 2n_3) \ln(1-\theta) \end{aligned}$$



odhad metodou maximální věrohodnosti za  $H_0$ 

[maximum likelihood estimate]

$$P(N_1 = n_1, N_2 = n_2, N_3 = n_3) = \frac{n!}{n_1!n_2!n_3!} (\theta^2)^{n_1} (2\theta(1-\theta))^{n_2} ((1-\theta)^2)^{n_3}$$

- ▶ najít  $\theta$  takové, aby pravděpodobnost konkrétního výsledku byla maximální možná (maximálně věrohodná)
- ▶ odhad  $\theta$  maximalizací *logaritmické věrohodnostní funkce*

$$\begin{aligned} \ell(\theta) &= \ln(P(N_1 = n_1, N_2 = n_2, N_3 = n_3)) \\ &= \ln\left(c_1 (\theta^2)^{n_1} (2\theta(1-\theta))^{n_2} ((1-\theta)^2)^{n_3}\right) \\ &= c_2 + (2n_1 + n_2) \ln \theta + (n_2 + 2n_3) \ln(1-\theta) \end{aligned}$$

- ▶ v našem příkladu vyjde

$$\hat{\theta} = \frac{2 \cdot N_1 + N_2}{2n} \quad \left( = \frac{2 \cdot 18 + 17}{82} = 0,646 \right)$$

(počet alel  $A$  na počet „míst“ pro alely)

- ▶  $\theta$  má obecně  $q$  nezávislých složek, zde  $q = 1$   
každý odhadovaný parametr ubere jeden stupeň volnosti
- ▶  $H_0$  zamítá pokud

$$\chi^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j(\hat{\theta}))^2}{n\pi_j(\hat{\theta})} \geq \chi_{k-1-q}^2(\alpha)$$

- ▶ příklad:  $\chi^2 = 0,355 < \chi_{3-1-1}^2(0,05) = 3,84$   
 $p = 55,1 \%$  hypotézu na 5% hladině nemůžeme zamítnout

- ▶ v našem příkladu vyjde

$$\hat{\theta} = \frac{2 \cdot N_1 + N_2}{2n} \quad \left( = \frac{2 \cdot 18 + 17}{82} = 0,646 \right)$$

(počet alel  $A$  na počet „míst“ pro alely)

- ▶  $\theta$  má obecně  $q$  nezávislých složek, zde  $q = 1$   
každý odhadovaný parametr ubere jeden stupeň volnosti
- ▶  $H_0$  zamítá pokud

$$\chi^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j(\hat{\theta}))^2}{n\pi_j(\hat{\theta})} \geq \chi_{k-1-q}^2(\alpha)$$

- ▶ příklad:  $\chi^2 = 0,355 < \chi_{3-1-1}^2(0,05) = 3,84$   
 $p = 55,1 \%$  hypotézu na 5% hladině nemůžeme zamítnout

- ▶ v našem příkladu vyjde

$$\hat{\theta} = \frac{2 \cdot N_1 + N_2}{2n} \quad \left( = \frac{2 \cdot 18 + 17}{82} = 0,646 \right)$$

(počet alel  $A$  na počet „míst“ pro alely)

- ▶  $\theta$  má obecně  $q$  nezávislých složek, zde  $q = 1$   
každý odhadovaný parametr ubere jeden stupeň volnosti
- ▶  $H_0$  zamítá pokud

$$\chi^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j(\hat{\theta}))^2}{n\pi_j(\hat{\theta})} \geq \chi_{k-1-q}^2(\alpha)$$

- ▶ příklad:  $\chi^2 = 0,355 < \chi_{3-1-1}^2(0,05) = 3,84$   
 $p = 55,1 \%$  hypotézu na 5% hladině nemůžeme zamítnout

- ▶ v našem příkladu vyjde

$$\hat{\theta} = \frac{2 \cdot N_1 + N_2}{2n} \quad \left( = \frac{2 \cdot 18 + 17}{82} = 0,646 \right)$$

(počet alel  $A$  na počet „míst“ pro alely)

- ▶  $\theta$  má obecně  $q$  nezávislých složek, zde  $q = 1$   
každý odhadovaný parametr ubere jeden stupeň volnosti
- ▶  $H_0$  zamítá pokud

$$\chi^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j(\hat{\theta}))^2}{n\pi_j(\hat{\theta})} \geq \chi_{k-1-q}^2(\alpha)$$

- ▶ příklad:  $\chi^2 = 0,355 < \chi_{3-1-1}^2(0,05) = 3,84$   
 $p = 55,1 \%$  hypotézu na 5% hladině nemůžeme zamítnout

## nezávislost **nominálních** znaků

příklad hrách: barva květů a tvar pylových zrnků

- ▶ nominální znak s hodnotami  $A_1, \dots, A_r$  (tvar)
- ▶ nominální znak s hodnotami  $B_1, \dots, B_c$  (barva)
- ▶  $N_{ij}$  kolikrát současně  $A_i$  a  $B_j$  (**sdužené četnosti**)
- ▶ **marginální** četnosti

$$N_{i\bullet} = \sum_{j=1}^c N_{ij} \quad N_{\bullet j} = \sum_{i=1}^r N_{ij}$$

- ▶ **nezávislost** znaků: pro všechny dvojice  $i, j$  platí

$$P(A_i \cap B_j) = P(A_i)P(B_j)$$

- ▶ charakteristika nezávislosti: z **marginálních** pstí jevů  $A_i, B_j$  dokážeme rekonstruovat **sdužené** pstí jevů  $A_i \cap B_j$

## nezávislost **nominálních** znaků

příklad hrách: barva květů a tvar pylových zrnků

- ▶ nominální znak s hodnotami  $A_1, \dots, A_r$  (tvar)
- ▶ nominální znak s hodnotami  $B_1, \dots, B_c$  (barva)
- ▶  $N_{ij}$  kolikrát současně  $A_i$  a  $B_j$  (**sdužené četnosti**)
- ▶ **marginální** četnosti

$$N_{i\bullet} = \sum_{j=1}^c N_{ij} \quad N_{\bullet j} = \sum_{i=1}^r N_{ij}$$

- ▶ **nezávislost** znaků: pro všechny dvojice  $i, j$  platí

$$P(A_i \cap B_j) = P(A_i)P(B_j)$$

- ▶ charakteristika nezávislosti: z **marginálních** pstí jevů  $A_i, B_j$  dokážeme rekonstruovat **sdužené** pstí jevů  $A_i \cap B_j$

## nezávislost **nominálních** znaků

příklad hrách: barva květů a tvar pylových zrnků

- ▶ nominální znak s hodnotami  $A_1, \dots, A_r$  (tvar)
- ▶ nominální znak s hodnotami  $B_1, \dots, B_c$  (barva)
- ▶  $N_{ij}$  kolikrát současně  $A_i$  a  $B_j$  (**sdružené četnosti**)
- ▶ **marginální** četnosti

$$N_{i\bullet} = \sum_{j=1}^c N_{ij} \quad N_{\bullet j} = \sum_{i=1}^r N_{ij}$$

- ▶ **nezávislost** znaků: pro všechny dvojice  $i, j$  platí

$$P(A_i \cap B_j) = P(A_i)P(B_j)$$

- ▶ charakteristika nezávislosti: z **marginálních** pstí jevů  $A_i, B_j$  dokážeme rekonstruovat **sdružené** pstí jevů  $A_i \cap B_j$



## nezávislost **nominálních** znaků

příklad hrách: barva květů a tvar pylových zrnků

- ▶ nominální znak s hodnotami  $A_1, \dots, A_r$  (tvar)
- ▶ nominální znak s hodnotami  $B_1, \dots, B_c$  (barva)
- ▶  $N_{ij}$  kolikrát současně  $A_i$  a  $B_j$  (**sdružené četnosti**)
- ▶ **marginální** četnosti

$$N_{i\bullet} = \sum_{j=1}^c N_{ij} \quad N_{\bullet j} = \sum_{i=1}^r N_{ij}$$

- ▶ **nezávislost** znaků: pro všechny dvojice  $i, j$  platí

$$P(A_i \cap B_j) = P(A_i)P(B_j)$$

- ▶ charakteristika nezávislosti: z **marginálních** pstí jevů  $A_i, B_j$  dokážeme rekonstruovat **sdružené** pstí jevů  $A_i \cap B_j$

## nezávislost **nominálních** znaků

příklad hrách: barva květů a tvar pylových zrnků

- ▶ nominální znak s hodnotami  $A_1, \dots, A_r$  (tvar)
- ▶ nominální znak s hodnotami  $B_1, \dots, B_c$  (barva)
- ▶  $N_{ij}$  kolikrát současně  $A_i$  a  $B_j$  (**sdružené četnosti**)
- ▶ **marginální** četnosti

$$N_{i\bullet} = \sum_{j=1}^c N_{ij} \quad N_{\bullet j} = \sum_{i=1}^r N_{ij}$$

- ▶ **nezávislost** znaků: pro všechny dvojice  $i, j$  platí

$$P(A_i \cap B_j) = P(A_i)P(B_j)$$

- ▶ charakteristika nezávislosti: z **marginálních** pstí jevů  $A_i, B_j$  dokážeme rekonstruovat **sdružené** pstí jevů  $A_i \cap B_j$

## nezávislost **nominálních** znaků

příklad hrách: barva květů a tvar pylových zrněk

- ▶ nominální znak s hodnotami  $A_1, \dots, A_r$  (tvar)
- ▶ nominální znak s hodnotami  $B_1, \dots, B_c$  (barva)
- ▶  $N_{ij}$  kolikrát současně  $A_i$  a  $B_j$  (**sdružené četnosti**)
- ▶ **marginální** četnosti

$$N_{i\bullet} = \sum_{j=1}^c N_{ij} \quad N_{\bullet j} = \sum_{i=1}^r N_{ij}$$

- ▶ **nezávislost** znaků: pro všechny dvojice  $i, j$  platí

$$P(A_i \cap B_j) = P(A_i)P(B_j)$$

- ▶ charakteristika nezávislosti: z **marginálních** pstí jevů  $A_i, B_j$  dokážeme rekonstruovat **sdružené** psti jevů  $A_i \cap B_j$

# test nezávislosti dvou kvalitativních znaků

## hodnocení kontingenční tabulky

- ▶  $H_0$  : znaky jsou **nezávislé**

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(N_{ij} - o_{ij})^2}{o_{ij}}$$

- ▶ teoretické četnosti (protějšek  $N_{ij}$ ) – četnosti, které **v průměru očekáváme, platí-li hypotéza**

$$o_{ij} = n \cdot P(\widehat{A_i \cap B_j}) = n \cdot \widehat{P(A_i)} \cdot \widehat{P(B_j)} = n \cdot \frac{N_{i\bullet}}{n} \cdot \frac{N_{\bullet j}}{n} = \frac{N_{i\bullet} N_{\bullet j}}{n}$$

- ▶ nezávislost se zamítá pokud  $\chi^2 \geq \chi^2_{(r-1)(c-1)}(\alpha)$
- ▶ stupně volnosti  $n - 1 - q = r \cdot c - 1 - (r - 1) - (c - 1) = r \cdot c - r - c + 1 = (r - 1)(c - 1)$
- ▶ mělo by být  $o_{ij} \geq 5 \forall (i, j)$  (tj. pro všechny dvojice)

# test nezávislosti dvou kvalitativních znaků

## hodnocení kontingenční tabulky

- ▶  $H_0$  : znaky jsou **nezávislé**

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(N_{ij} - o_{ij})^2}{o_{ij}}$$

- ▶ teoretické četnosti (protějšek  $N_{ij}$ ) – četnosti, které **v průměru očekáváme, platí-li hypotéza**

$$o_{ij} = n \cdot P(\widehat{A_i \cap B_j}) = n \cdot \widehat{P(A_i)} \cdot \widehat{P(B_j)} = n \cdot \frac{N_{i\bullet}}{n} \cdot \frac{N_{\bullet j}}{n} = \frac{N_{i\bullet} N_{\bullet j}}{n}$$

- ▶ nezávislost se zamítá pokud  $\chi^2 \geq \chi^2_{(r-1)(c-1)}(\alpha)$
- ▶ stupně volnosti  $n - 1 - q = r \cdot c - 1 - (r - 1) - (c - 1) = r \cdot c - r - c + 1 = (r - 1)(c - 1)$
- ▶ mělo by být  $o_{ij} \geq 5 \forall (i, j)$  (tj. pro všechny dvojice)

# test nezávislosti dvou kvalitativních znaků

## hodnocení kontingenční tabulky

- ▶  $H_0$  : znaky jsou **nezávislé**

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(N_{ij} - o_{ij})^2}{o_{ij}}$$

- ▶ teoretické četnosti (protějšek  $N_{ij}$ ) – četnosti, které **v průměru očekáváme, platí-li hypotéza**

$$o_{ij} = n \cdot P(\widehat{A_i} \cap \widehat{B_j}) = n \cdot \widehat{P(A_i)} \cdot \widehat{P(B_j)} = n \cdot \frac{N_{i\bullet}}{n} \cdot \frac{N_{\bullet j}}{n} = \frac{N_{i\bullet} N_{\bullet j}}{n}$$

- ▶ nezávislost se zamítá pokud  $\chi^2 \geq \chi^2_{(r-1)(c-1)}(\alpha)$
- ▶ stupně volnosti  $n - 1 - q = r \cdot c - 1 - (r - 1) - (c - 1) = r \cdot c - r - c + 1 = (r - 1)(c - 1)$
- ▶ mělo by být  $o_{ij} \geq 5 \forall (i, j)$  (tj. pro všechny dvojice)

# test nezávislosti dvou kvalitativních znaků

## hodnocení kontingenční tabulky

- ▶  $H_0$  : znaky jsou **nezávislé**

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(N_{ij} - o_{ij})^2}{o_{ij}}$$

- ▶ teoretické četnosti (protějšek  $N_{ij}$ ) – četnosti, které **v průměru očekáváme, platí-li hypotéza**

$$o_{ij} = n \cdot P(\widehat{A_i \cap B_j}) = n \cdot \widehat{P(A_i)} \cdot \widehat{P(B_j)} = n \cdot \frac{N_{i\bullet}}{n} \cdot \frac{N_{\bullet j}}{n} = \frac{N_{i\bullet} N_{\bullet j}}{n}$$

- ▶ nezávislost se zamítá pokud  $\chi^2 \geq \chi^2_{(r-1)(c-1)}(\alpha)$
- ▶ stupně volnosti  $n - 1 - q = r \cdot c - 1 - (r - 1) - (c - 1) = r \cdot c - r - c + 1 = (r - 1)(c - 1)$
- ▶ mělo by být  $o_{ij} \geq 5 \forall (i, j)$  (tj. pro všechny dvojice)

# test nezávislosti dvou kvalitativních znaků

## hodnocení kontingenční tabulky

- ▶  $H_0$  : znaky jsou **nezávislé**

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(N_{ij} - o_{ij})^2}{o_{ij}}$$

- ▶ teoretické četnosti (protějšek  $N_{ij}$ ) – četnosti, které **v průměru očekáváme, platí-li hypotéza**

$$o_{ij} = n \cdot P(\widehat{A_i \cap B_j}) = n \cdot \widehat{P(A_i)} \cdot \widehat{P(B_j)} = n \cdot \frac{N_{i\bullet}}{n} \cdot \frac{N_{\bullet j}}{n} = \frac{N_{i\bullet} N_{\bullet j}}{n}$$

- ▶ nezávislost se zamítá pokud  $\chi^2 \geq \chi^2_{(r-1)(c-1)}(\alpha)$
- ▶ stupně volnosti  $n - 1 - q = r \cdot c - 1 - (r - 1) - (c - 1) = r \cdot c - r - c + 1 = (r - 1)(c - 1)$
- ▶ mělo by být  $o_{ij} \geq 5 \forall (i, j)$  (tj. pro všechny dvojice)



## příklad barva květů a tvar pylových zrněk

štěpný poměr neznáme

tvar	barva		celkem
	purpurová	červená	
oválný	296	27	323
kulatý	19	85	104
celkem	315	112	427

očekávané četnosti:

$$323 \cdot 315 / 427 = 238,28$$

$$323 \cdot 112 / 427 = 84,72$$

$$104 \cdot 315 / 427 = 76,72$$

$$104 \cdot 112 / 427 = 27,28$$

$$\chi^2 = \frac{(296-238,28)^2}{238,28} + \frac{(27-84,72)^2}{84,72} + \frac{(19-76,72)^2}{76,72} + \frac{(85-27,28)^2}{27,28} = 222,12$$

$p < 0,001$ , očekávané četnosti jsou větší, než 5

## příklad: kouření u mužů

data: lchs

**empirické sdružené a marg. četnosti**

vzdělání	zákl.	odb.	mat.	VŠ	celk.
nekuřák	14	55	55	73	197
bývalý k.	11	28	44	42	125
kuřák	14	24	24	17	79
silný k.	78	189	175	106	548
celkem	117	296	298	238	949

**očekávané sdružené a marg. četnosti**

vzdělání	zákl.	odb.	mat.	VŠ	celk.
nekuřák	24,3	61,4	61,9	49,4	197
bývalý k.	15,4	39,0	39,3	31,3	125
kuřák	9,7	24,6	24,8	19,8	79
silný k.	67,6	170,9	172,1	137,4	548
celkem	117	296	298	238	949

[chisq.test(matrix(c(14,11,14,78, 55,28,24,189,  
55,44,24,175, 73,42,17,106),nr=4,nc=4))]

**závislost jsme na 5% hladině prokázali**

$$\chi^2 = \frac{(14 - 24,3)^2}{24,3} + \dots + \frac{(106 - 137,4)^2}{137,4} = 38,68$$

$$f = (4 - 1)(4 - 1) = 9$$

$$p < 0,0001$$

příklad **Baden**

barva očí	barva vlasů				celkem
	světlá	hnědá	černá	ryšavá	
modrá	1 768	807	189	47	2 811
šedá/zelená	946	1 387	746	53	3 132
hnědá	115	438	288	16	857
celkem	2 829	2 632	1 223	116	6 800

- ▶ barva očí  $r = 3$ , barva vlasů  $c = 4$ ,  $n = 6800$
- ▶  $o_{11} = 2811 \cdot 2829/6800 = 1169 \dots$
- ▶  $o_{34} = 116 \cdot 857/6800 = 14,62 \geq 5$

$$\chi^2 = \frac{(1768 - 1169)^2}{1169} + \frac{(807 - 1088)^2}{1088} + \dots = 1073,5$$

$$> \chi_6^2(0,05) = 12,5916$$

$$p < 0,0001$$

závislost je na každé rozumné hladině **prokázána**

příklad **Baden**

barva očí	barva vlasů				celkem
	světlá	hnědá	černá	ryšavá	
modrá	1 768	807	189	47	2 811
šedá/zelená	946	1 387	746	53	3 132
hnědá	115	438	288	16	857
celkem	2 829	2 632	1 223	116	6 800

- ▶ barva očí  $r = 3$ , barva vlasů  $c = 4$ ,  $n = 6800$
- ▶  $o_{11} = 2811 \cdot 2829/6800 = 1169 \dots$
- ▶  $o_{34} = 116 \cdot 857/6800 = 14,62 \geq 5$

$$\chi^2 = \frac{(1768 - 1169)^2}{1169} + \frac{(807 - 1088)^2}{1088} + \dots = 1073,5$$

$$> \chi_6^2(0,05) = 12,5916$$

$$p < 0,0001$$

závislost je na každé rozumné hladině **prokázána**

příklad **Baden**

barva očí	barva vlasů				celkem
	světlá	hnědá	černá	ryšavá	
modrá	1 768	807	189	47	2 811
šedá/zelená	946	1 387	746	53	3 132
hnědá	115	438	288	16	857
celkem	2 829	2 632	1 223	116	6 800

- ▶ barva očí  $r = 3$ , barva vlasů  $c = 4$ ,  $n = 6800$
- ▶  $o_{11} = 2811 \cdot 2829/6800 = 1169 \dots$
- ▶  $o_{34} = 116 \cdot 857/6800 = 14,62 \geq 5$

$$\chi^2 = \frac{(1768 - 1169)^2}{1169} + \frac{(807 - 1088)^2}{1088} + \dots = 1073,5$$

$$> \chi_6^2(0,05) = 12,5916$$

$$p < 0,0001$$

závislost je na každé rozumné hladině **prokázána**

## test homogeneity

- ▶ hodnoty znaku  $B_1, \dots, B_c$
- ▶  $r$  **nezávislých** výběrů z různých populací
- ▶  $H_0$  : populace se **neliší**
- ▶ dál stejně jako pro nezávislost
- ▶ příklad **krevní skupiny**

populace	skupina				celkem
	0	A	B	AB	
C	121	120	79	33	353
D	118	95	121	30	364
celkem	239	215	200	63	717

$$\chi^2 = \frac{(121 - 353 \cdot 239/717)^2}{353 \cdot 239/717} + \dots = 11,742 > \chi_3^2(0,05) = 7,815$$

nejm. teoretická četnost:  $353 \cdot 63/717 = 31,02 > 5$ ,  $p = 0,8 \%$

## test homogeneity

- ▶ hodnoty znaku  $B_1, \dots, B_c$
- ▶  $r$  **nezávislých** výběrů z různých populací
- ▶  $H_0$  : populace se **neliší**
- ▶ dál stejně jako pro nezávislost
- ▶ příklad **krevní skupiny**

populace	skupina				celkem
	0	A	B	AB	
C	121	120	79	33	353
D	118	95	121	30	364
celkem	239	215	200	63	717

$$\chi^2 = \frac{(121 - 353 \cdot 239/717)^2}{353 \cdot 239/717} + \dots = 11,742 > \chi_3^2(0,05) = 7,815$$

nejm. teoretická četnost:  $353 \cdot 63/717 = 31,02 > 5$ ,  $p = 0,8 \%$

## test homogeneity

- ▶ hodnoty znaku  $B_1, \dots, B_c$
- ▶  $r$  **nezávislých** výběrů z různých populací
- ▶  $H_0$  : populace se **neliší**
- ▶ dál stejně jako pro nezávislost
- ▶ příklad **krevní skupiny**

populace	skupina				celkem
	0	A	B	AB	
C	121	120	79	33	353
D	118	95	121	30	364
celkem	239	215	200	63	717

$$\chi^2 = \frac{(121 - 353 \cdot 239/717)^2}{353 \cdot 239/717} + \dots = 11,742 > \chi_3^2(0,05) = 7,815$$

nejm. teoretická četnost:  $353 \cdot 63/717 = 31,02 > 5$ ,  $p = 0,8 \%$



## test homogeneity

- ▶ hodnoty znaku  $B_1, \dots, B_c$
- ▶  $r$  **nezávislých** výběrů z různých populací
- ▶  $H_0$  : populace se **neliší**
- ▶ dál stejně jako pro nezávislost
- ▶ příklad **krevní skupiny**

populace	skupina				celkem
	0	A	B	AB	
C	121	120	79	33	353
D	118	95	121	30	364
celkem	239	215	200	63	717

$$\chi^2 = \frac{(121 - 353 \cdot 239/717)^2}{353 \cdot 239/717} + \dots = 11,742 > \chi_3^2(0,05) = 7,815$$

nejm. teoretická četnost:  $353 \cdot 63/717 = 31,02 > 5$ ,  $p = 0,8 \%$

## test homogeneity

- ▶ hodnoty znaku  $B_1, \dots, B_c$
- ▶  $r$  **nezávislých** výběrů z různých populací
- ▶  $H_0$  : populace se **neliší**
- ▶ dál stejně jako pro nezávislost
- ▶ příklad **krevní skupiny**

populace	skupina				celkem
	0	A	B	AB	
C	121	120	79	33	353
D	118	95	121	30	364
celkem	239	215	200	63	717

$$\chi^2 = \frac{(121 - 353 \cdot 239/717)^2}{353 \cdot 239/717} + \dots = 11,742 > \chi_3^2(0,05) = 7,815$$

nejm. teoretická četnost:  $353 \cdot 63/717 = 31,02 > 5$ ,  $p = 0,8 \%$

# McNemarův test (test symetrie)

nezaměňovat s testem nezávislosti!

- ▶ **párový** test pro nominální veličinu s hodnotami  $B_1, \dots, B_k$
- ▶ zjišťujeme hodnoty nominálního znaku na **stejných** objektech za **dvojích** okolností (před ošetřením, po ošetření)
- ▶  $N_{ij}$  počet objektů, u nichž první měření  $B_i$  a druhé měření  $B_j$
- ▶ **nulová hypotéza**: pravděpodobnosti možných hodnot znaku jsou **stejné** za obojích okolností (před ošetřením i po něm)

$$X^2 = \sum_{i < j} \sum \frac{(N_{ij} - N_{ji})^2}{N_{ij} + N_{ji}}$$

- ▶ hypotézu zamítneme při  $X^2 \geq \chi_{k(k-1)/2}^2(\alpha)$
- ▶ výrazy ve jmenovateli musí být kladné!
- ▶ nezávisí na počtu objektů, kdy vyšly oba výsledky stejně ( $N_{ii}$ )

# McNemarův test (test symetrie)

nezaměňovat s testem nezávislosti!

- ▶ **párový** test pro nominální veličinu s hodnotami  $B_1, \dots, B_k$
- ▶ zjišťujeme hodnoty nominálního znaku na **stejných** objektech za **dvojích** okolností (před ošetřením, po ošetření)
- ▶  $N_{ij}$  počet objektů, u nichž první měření  $B_i$  a druhé měření  $B_j$
- ▶ **nulová hypotéza**: pravděpodobnosti možných hodnot znaku jsou **stejné** za obojích okolností (před ošetřením i po něm)

$$X^2 = \sum_{i < j} \sum \frac{(N_{ij} - N_{ji})^2}{N_{ij} + N_{ji}}$$

- ▶ hypotézu zamítneme při  $X^2 \geq \chi_{k(k-1)/2}^2(\alpha)$
- ▶ výrazy ve jmenovateli musí být kladné!
- ▶ nezávisí na počtu objektů, kdy vyšly oba výsledky stejně ( $N_{ii}$ )

## McNemarův test (test symetrie)

nezaměňovat s testem nezávislosti!

- ▶ **párový** test pro nominální veličinu s hodnotami  $B_1, \dots, B_k$
- ▶ zjišťujeme hodnoty nominálního znaku na **stejných** objektech za **dvojitých** okolností (před ošetřením, po ošetření)
- ▶  $N_{ij}$  počet objektů, u nichž první měření  $B_i$  a druhé měření  $B_j$
- ▶ **nulová hypotéza**: pravděpodobnosti možných hodnot znaku jsou **stejné** za obojích okolností (před ošetřením i po něm)

$$X^2 = \sum_{i < j} \sum \frac{(N_{ij} - N_{ji})^2}{N_{ij} + N_{ji}}$$

- ▶ hypotézu zamítneme při  $X^2 \geq \chi_{k(k-1)/2}^2(\alpha)$
- ▶ výrazy ve jmenovateli musí být kladné!
- ▶ nezávisí na počtu objektů, kdy vyšly oba výsledky stejně ( $N_{ii}$ )

## McNemarův test (test symetrie)

nezaměňovat s testem nezávislosti!

- ▶ **párový** test pro nominální veličinu s hodnotami  $B_1, \dots, B_k$
- ▶ zjišťujeme hodnoty nominálního znaku na **stejných** objektech za **dvojích** okolností (před ošetřením, po ošetření)
- ▶  $N_{ij}$  počet objektů, u nichž první měření  $B_i$  a druhé měření  $B_j$
- ▶ **nulová hypotéza**: pravděpodobnosti možných hodnot znaku jsou **stejně** za obojích okolností (před ošetřením i po něm)

$$X^2 = \sum_{i < j} \sum \frac{(N_{ij} - N_{ji})^2}{N_{ij} + N_{ji}}$$

- ▶ hypotézu zamítneme při  $X^2 \geq \chi_{k(k-1)/2}^2(\alpha)$
- ▶ výrazy ve jmenovateli musí být kladné!
- ▶ nezávisí na počtu objektů, kdy vyšly oba výsledky stejně ( $N_{ii}$ )

## McNemarův test (test symetrie)

nezaměňovat s testem nezávislosti!

- ▶ **párový** test pro nominální veličinu s hodnotami  $B_1, \dots, B_k$
- ▶ zjišťujeme hodnoty nominálního znaku na **stejných** objektech za **dvojích** okolností (před ošetřením, po ošetření)
- ▶  $N_{ij}$  počet objektů, u nichž první měření  $B_i$  a druhé měření  $B_j$
- ▶ **nulová hypotéza**: pravděpodobnosti možných hodnot znaku jsou **stejné** za obojích okolností (před ošetřením i po něm)

$$X^2 = \sum_{i < j} \sum \frac{(N_{ij} - N_{ji})^2}{N_{ij} + N_{ji}}$$

- ▶ hypotézu zamítneme při  $X^2 \geq \chi_{k(k-1)/2}^2(\alpha)$
- ▶ výrazy ve jmenovateli musí být kladné!
- ▶ nezávisí na počtu objektů, kdy vyšly oba výsledky stejně ( $N_{ii}$ )

# McNemarův test (test symetrie)

nezaměňovat s testem nezávislosti!

- ▶ **párový** test pro nominální veličinu s hodnotami  $B_1, \dots, B_k$
- ▶ zjišťujeme hodnoty nominálního znaku na **stejných** objektech za **dvojích** okolností (před ošetřením, po ošetření)
- ▶  $N_{ij}$  počet objektů, u nichž první měření  $B_i$  a druhé měření  $B_j$
- ▶ **nulová hypotéza**: pravděpodobnosti možných hodnot znaku jsou **stejné** za obojích okolností (před ošetřením i po něm)

$$X^2 = \sum_{i < j} \sum \frac{(N_{ij} - N_{ji})^2}{N_{ij} + N_{ji}}$$

- ▶ hypotézu zamítneme při  $X^2 \geq \chi_{k(k-1)/2}^2(\alpha)$
- ▶ výrazy ve jmenovateli musí být kladné!
- ▶ nezávisí na počtu objektů, kdy vyšly oba výsledky stejně ( $N_{ii}$ )



## McNemarův test (test symetrie)

nezaměňovat s testem nezávislosti!

- ▶ **párový** test pro nominální veličinu s hodnotami  $B_1, \dots, B_k$
- ▶ zjišťujeme hodnoty nominálního znaku na **stejných** objektech za **dvojích** okolností (před ošetřením, po ošetření)
- ▶  $N_{ij}$  počet objektů, u nichž první měření  $B_i$  a druhé měření  $B_j$
- ▶ **nulová hypotéza**: pravděpodobnosti možných hodnot znaku jsou **stejné** za obojích okolností (před ošetřením i po něm)

$$X^2 = \sum_{i < j} \sum \frac{(N_{ij} - N_{ji})^2}{N_{ij} + N_{ji}}$$

- ▶ hypotézu zamítneme při  $X^2 \geq \chi_{k(k-1)/2}^2(\alpha)$
- ▶ výrazy ve jmenovateli musí být kladné!
- ▶ nezávisí na počtu objektů, kdy vyšly oba výsledky stejně ( $N_{ii}$ )

## příklad stromy

1994	1995			celkem
	1	2	3	
1	4	3	3	10
2	7	21	11	39
3	1	15	35	51
celkem	12	39	49	100

- ▶ stav týchž stromů ve dvou sezónách
- ▶ celkem 100 stromů

$$\chi^2 = \frac{(3 - 7)^2}{3 + 7} + \frac{(3 - 1)^2}{3 + 1} + \frac{(11 - 15)^2}{11 + 15} = 3,215$$

- ▶  $\chi^2_3(0,05) = 7,8147$ ,  $p = 36,0\%$
- ▶ rozdíl mezi sezónami jsme neprokázali
- ▶ `[mcnemar.test(matrix(c(4,7,1,3,21,15,3,11,35),3,3))]`

## příklad stromy

1994	1995			celkem
	1	2	3	
1	4	3	3	10
2	7	21	11	39
3	1	15	35	51
celkem	12	39	49	100

- ▶ stav týchž stromů ve dvou sezónách
- ▶ celkem 100 stromů

$$\chi^2 = \frac{(3 - 7)^2}{3 + 7} + \frac{(3 - 1)^2}{3 + 1} + \frac{(11 - 15)^2}{11 + 15} = 3,215$$

- ▶  $\chi^2_3(0,05) = 7,8147$ ,  $p = 36,0\%$
- ▶ rozdíl mezi sezónami jsme neprokázali
- ▶ `[mcnemar.test(matrix(c(4,7,1,3,21,15,3,11,35),3,3))]`

## příklad stromy

1994	1995			celkem
	1	2	3	
1	4	3	3	10
2	7	21	11	39
3	1	15	35	51
celkem	12	39	49	100

- ▶ stav týchž stromů ve dvou sezónách
- ▶ celkem 100 stromů

$$\chi^2 = \frac{(3 - 7)^2}{3 + 7} + \frac{(3 - 1)^2}{3 + 1} + \frac{(11 - 15)^2}{11 + 15} = 3,215$$

- ▶  $\chi^2_3(0,05) = 7,8147$ ,  $p = 36,0 \%$
- ▶ rozdíl mezi sezónami jsme neprokázali
- ▶ `[mcnemar.test(matrix(c(4,7,1,3,21,15,3,11,35),3,3))]`

## příklad stromy

1994	1995			celkem
	1	2	3	
1	4	3	3	10
2	7	21	11	39
3	1	15	35	51
celkem	12	39	49	100

- ▶ stav týchž stromů ve dvou sezónách
- ▶ celkem 100 stromů

$$\chi^2 = \frac{(3 - 7)^2}{3 + 7} + \frac{(3 - 1)^2}{3 + 1} + \frac{(11 - 15)^2}{11 + 15} = 3,215$$

- ▶  $\chi^2_3(0,05) = 7,8147$ ,  $p = 36,0 \%$
- ▶ rozdíl mezi sezónami jsme neprokázali

▶ `[mcnemar.test(matrix(c(4,7,1,3,21,15,3,11,35),3,3))]`

## příklad stromy

1994	1995			celkem
	1	2	3	
1	4	3	3	10
2	7	21	11	39
3	1	15	35	51
celkem	12	39	49	100

- ▶ stav týchž stromů ve dvou sezónách
- ▶ celkem 100 stromů

$$\chi^2 = \frac{(3 - 7)^2}{3 + 7} + \frac{(3 - 1)^2}{3 + 1} + \frac{(11 - 15)^2}{11 + 15} = 3,215$$

- ▶  $\chi^2_3(0,05) = 7,8147$ ,  $p = 36,0 \%$
- ▶ rozdíl mezi sezónami jsme neprokázali
- ▶ `[mcnemar.test(matrix(c(4,7,1,3,21,15,3,11,35),3,3))]`

čtyřpolní tabulka (tabulka  $2 \times 2$ )

znovu test nezávislosti či homogenity

$a$	$b$	$a + b$
$c$	$d$	$c + d$
$a + c$	$b + d$	$n$

- ▶ speciální případ kontingenční tabulky pro  $r = c = 2$
- ▶ test nezávislosti i test homogenity  
statistiku lze upravit na pohodlnější vyjádření

$$X^2 = \frac{n(ad - bc)^2}{(a + c)(b + d)(a + b)(c + d)}$$

zamítá se pro  $X^2 \geq \chi_1^2(\alpha) = z(\alpha/2)^2$

čtyřpolní tabulka (tabulka  $2 \times 2$ )

znovu test nezávislosti či homogenity

$a$	$b$	$a + b$
$c$	$d$	$c + d$
$a + c$	$b + d$	$n$

- ▶ speciální případ kontingenční tabulky pro  $r = c = 2$
- ▶ test nezávislosti i test homogenity  
statistiku lze upravit na pohodlnější vyjádření

$$X^2 = \frac{n(ad - bc)^2}{(a + c)(b + d)(a + b)(c + d)}$$

zamítá se pro  $X^2 \geq \chi_1^2(\alpha) = z(\alpha/2)^2$



## případ malých četností

- ▶ je-li některá očekávaná četnost malá, pak lze u čtyřpolní tabulky použít upravený postup: **Yatesova korekce**

$$\chi^2_Y = \frac{n(|ad - bc| - n/2)^2}{(a + c)(b + d)(a + b)(c + d)}$$

- ▶ **Fisherův exaktní** test počítá přímo dosaženou hladinu  $p$
- ▶ pro tabulku s velkými četnostmi je výpočet Fisherova testu výpočetně náročný (paměťové nároky, trvání výpočtu)
- ▶ existuje zobecnění Fisherova testu i pro větší tabulky, než je čtyřpolní

## případ malých četností

- ▶ je-li některá očekávaná četnost malá, pak lze u čtyřpolní tabulky použít upravený postup: **Yatesova korekce**

$$\chi^2_Y = \frac{n(|ad - bc| - n/2)^2}{(a + c)(b + d)(a + b)(c + d)}$$

- ▶ **Fisherův exaktní test** počítá přímo dosaženou hladinu  $p$
- ▶ pro tabulku s velkými četnostmi je výpočet Fisherova testu výpočetně náročný (paměťové nároky, trvání výpočtu)
- ▶ existuje zobecnění Fisherova testu i pro větší tabulky, než je čtyřpolní

## případ malých četností

- ▶ je-li některá očekávaná četnost malá, pak lze u čtyřpolní tabulky použít upravený postup: **Yatesova korekce**

$$\chi_Y^2 = \frac{n(|ad - bc| - n/2)^2}{(a + c)(b + d)(a + b)(c + d)}$$

- ▶ **Fisherův exaktní** test počítá přímo dosaženou hladinu  $p$
- ▶ pro tabulku s velkými četnostmi je výpočet Fisherova testu výpočetně náročný (paměťové nároky, trvání výpočtu)
- ▶ existuje zobecnění Fisherova testu i pro větší tabulky, než je čtyřpolní

## případ malých četností

- ▶ je-li některá očekávaná četnost malá, pak lze u čtyřpolní tabulky použít upravený postup: **Yatesova korekce**

$$\chi_Y^2 = \frac{n(|ad - bc| - n/2)^2}{(a + c)(b + d)(a + b)(c + d)}$$

- ▶ **Fisherův exaktní** test počítá přímo dosaženou hladinu  $p$
- ▶ pro tabulku s velkými četnostmi je výpočet Fisherova testu výpočetně náročný (paměťové nároky, trvání výpočtu)
- ▶ existuje zobecnění Fisherova testu i pro větší tabulky, než je čtyřpolní

## komplexní příklad hraboš

<i>Frenkelia</i> <i>spp.</i>	<i>Sarcocystis spp.</i>		celkem
	+	-	
+	4	27	31
-	11	473	484
celkem	15	500	515

- ▶ souvisí spolu nákazy dvěma cizopasníky?
- ▶ nulová hypotéza: **nezávislost**

$$\chi^2 = \frac{515(4 \cdot 473 - 11 \cdot 27)^2}{15 \cdot 500 \cdot 31 \cdot 484} = 11,643, \quad p = 0,06 \%$$

- ▶ nejmenší očekávaná četnost:  $15 \cdot 31/515 = 0,9 < 5$
- ▶ `[chisq.test(matrix(c(4,11,27,473),2,2),correct=FALSE)]`

## komplexní příklad hraboš

<i>Frenkelia</i> <i>spp.</i>	<i>Sarcocystis spp.</i>		celkem
	+	–	
+	4	27	31
–	11	473	484
celkem	15	500	515

- ▶ souvisí spolu nákazy dvěma cizopasníky?
- ▶ nulová hypotéza: **nezávislost**

$$\chi^2 = \frac{515(4 \cdot 473 - 11 \cdot 27)^2}{15 \cdot 500 \cdot 31 \cdot 484} = 11,643, \quad p = 0,06 \%$$

- ▶ nejmenší očekávaná četnost:  $15 \cdot 31/515 = 0,9 < 5$
- ▶ `[chisq.test(matrix(c(4,11,27,473),2,2),correct=FALSE)]`

## komplexní příklad hraboš

<i>Frenkelia</i> <i>spp.</i>	<i>Sarcocystis spp.</i>		celkem
	+	-	
+	4	27	31
-	11	473	484
celkem	15	500	515

- ▶ souvisí spolu nákazy dvěma cizopasníky?
- ▶ nulová hypotéza: **nezávislost**

$$\chi^2 = \frac{515(4 \cdot 473 - 11 \cdot 27)^2}{15 \cdot 500 \cdot 31 \cdot 484} = 11,643, \quad p = 0,06 \%$$

- ▶ nejmenší očekávaná četnost:  $15 \cdot 31/515 = 0,9 < 5$
- ▶ `[chisq.test(matrix(c(4,11,27,473),2,2),correct=FALSE)]`

## komplexní příklad hraboš

<i>Frenkelia</i> <i>spp.</i>	<i>Sarcocystis spp.</i>		celkem
	+	-	
+	4	27	31
-	11	473	484
celkem	15	500	515

- ▶ souvisí spolu nákazy dvěma cizopasníky?
- ▶ nulová hypotéza: **nezávislost**

$$\chi^2 = \frac{515(4 \cdot 473 - 11 \cdot 27)^2}{15 \cdot 500 \cdot 31 \cdot 484} = 11,643, \quad p = 0,06 \%$$

- ▶ nejmenší očekávaná četnost:  $15 \cdot 31/515 = 0,9 < 5$
- ▶ `[chisq.test(matrix(c(4,11,27,473),2,2),correct=FALSE)]`



## příklad hraboš

- ▶ **Yates:**  $\chi^2 = 8,187$   $p = 0,42$  %  
[chisq.test(matrix(c(4,11,27,473),2,2))]
- ▶ **Fisherův test:**  $p = 0,92$  %  
[fisher.test(matrix(c(4,11,27,473),2,2))]
- ▶ na 5% hladině závislost **prokázána**
- ▶ **vyskytují se dvojí cizopasnici se stejnou pstí?**  
(zcela jiná otázka, než na nezávislost)
- ▶ odpověď dá McNemarův test:

$$\chi^2 = \frac{(11 - 27)^2}{11 + 27} = 6,7368, \quad p = 0,94 \%$$

[mcnemar.test(matrix(c(4,11,27,473),2,2),correct=FALSE)]

## příklad hraboš

- ▶ **Yates:**  $\chi^2 = 8,187$   $p = 0,42$  %  
[chisq.test(matrix(c(4,11,27,473),2,2))]
- ▶ **Fisherův test:**  $p = 0,92$  %  
[fisher.test(matrix(c(4,11,27,473),2,2))]
- ▶ na 5% hladině závislost **prokázána**
- ▶ **vyskytují se dvojí cizopasnici se stejnou pstí?**  
(zcela jiná otázka, než na nezávislost)
- ▶ odpověď dá McNemarův test:

$$\chi^2 = \frac{(11 - 27)^2}{11 + 27} = 6,7368, \quad p = 0,94 \%$$

[mcnemar.test(matrix(c(4,11,27,473),2,2),correct=FALSE)]

## příklad hraboš

- ▶ **Yates:**  $\chi^2 = 8,187$   $p = 0,42$  %  
[chisq.test(matrix(c(4,11,27,473),2,2))]
- ▶ **Fisherův test:**  $p = 0,92$  %  
[fisher.test(matrix(c(4,11,27,473),2,2))]
- ▶ na 5% hladině závislost **prokázána**
- ▶ vyskytují se dvojí cizopasníci se stejnou pstí?  
(zcela jiná otázka, než na nezávislost)
- ▶ odpověď dá McNemarův test:

$$\chi^2 = \frac{(11 - 27)^2}{11 + 27} = 6,7368, \quad p = 0,94 \%$$

[mcnemar.test(matrix(c(4,11,27,473),2,2),correct=FALSE)]

## příklad hraboš

- ▶ **Yates:**  $\chi^2 = 8,187$   $p = 0,42$  %  
[chisq.test(matrix(c(4,11,27,473),2,2))]
- ▶ **Fisherův test:**  $p = 0,92$  %  
[fisher.test(matrix(c(4,11,27,473),2,2))]
- ▶ na 5% hladině závislost **prokázána**
- ▶ **vyskytují se dvojí cizopasnici se stejnou pstí?**  
(zcela jiná otázka, než na nezávislost)
- ▶ odpověď dá McNemarův test:

$$\chi^2 = \frac{(11 - 27)^2}{11 + 27} = 6,7368, \quad p = 0,94 \%$$

[mcnemar.test(matrix(c(4,11,27,473),2,2),correct=FALSE)]

## příklad hraboš

- ▶ **Yates:**  $\chi^2 = 8,187$   $p = 0,42$  %  
[chisq.test(matrix(c(4,11,27,473),2,2))]
- ▶ **Fisherův test:**  $p = 0,92$  %  
[fisher.test(matrix(c(4,11,27,473),2,2))]
- ▶ na 5% hladině závislost **prokázána**
- ▶ **vyskytují se dvojí cizopasnici se stejnou pstí?**  
(zcela jiná otázka, než na nezávislost)
- ▶ odpověď dá McNemarův test:

$$\chi^2 = \frac{(11 - 27)^2}{11 + 27} = 6,7368, \quad p = 0,94 \%$$

[mcnemar.test(matrix(c(4,11,27,473),2,2),correct=FALSE)]

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ pořid' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, ...)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ poříd' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, ...)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ poříd' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, ...)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj



# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ pořid' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, ...)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ pořid' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, ...)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ poříd' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, ...)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ pořid' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, . . .)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ poříd' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, . . .)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ pořid' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, ...)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ pořid' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, . . .)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ pořid' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, . . .)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj



# jak statistiku použijeme

- ▶ co o problému zjistili jiní? (přečti, sepiš)
- ▶ co chceš zjistit?
  - ▶ zformuluj otázku (to určí možné statistické metody)
  - ▶ zformuluj nulovou a alternativní hypotézu
- ▶ zvol hladinu testu  $\alpha$
- ▶ zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- ▶ poříd' data
  - ▶ proved' měření (podrobné záznamy!)
  - ▶ převed' do elektronické formy (kódování)
  - ▶ vyčisti data (grafy, popisné statistiky, . . .)
- ▶ proved' výpočty, kresli grafy
- ▶ použij výsledky a grafy, interpretuj

## dvojí původ dat

### ▶ **plánovaný (organizovaný) pokus**

- ▶ aktivně zasahujeme
- ▶ fixujeme okolnosti (stálá teplota, světelný režim)
- ▶ nastavujeme úroveň zvoleného faktoru (např. živné roztoky)
- ▶ jedincům náhodně přiřazujeme ošetření
- ▶ zjistíme-li rozdíl, známe jeho příčinu

### ▶ **šetření (sledování dění)**

- ▶ pouze sledujeme, nezasahujeme
- ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (confounding) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
- ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
- ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## dvojí původ dat

### ▶ **plánovaný (organizovaný) pokus**

- ▶ aktivně zasahujeme
- ▶ fixujeme okolnosti (stálá teplota, světelný režim)
- ▶ nastavujeme úroveň zvoleného faktoru (např. živné roztoky)
- ▶ jedincům náhodně přiřazujeme ošetření
- ▶ zjistíme-li rozdíl, známe jeho příčinu

### ▶ **šetření (sledování dění)**

- ▶ pouze sledujeme, nezasahujeme
- ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (confounding) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
- ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
- ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## dvojí původ dat

### ▶ **plánovaný (organizovaný) pokus**

- ▶ aktivně zasahujeme
- ▶ fixujeme okolnosti (stálá teplota, světelný režim)
- ▶ nastavujeme úroveň zvoleného faktoru (např. živné roztoky)
- ▶ jedincům náhodně přiřazujeme ošetření
- ▶ zjistíme-li rozdíl, známe jeho příčinu

### ▶ **šetření (sledování dění)**

- ▶ pouze sledujeme, nezasahujeme
- ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (confounding) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
- ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
- ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## dvojí původ dat

### ▶ **plánovaný (organizovaný) pokus**

- ▶ aktivně zasahujeme
- ▶ fixujeme okolnosti (stálá teplota, světelný režim)
- ▶ nastavujeme úrovně zvoleného faktoru (např. živné roztoky)
- ▶ jedincům náhodně přiřazujeme ošetření
- ▶ zjistíme-li rozdíl, známe jeho příčinu

### ▶ **šetření (sledování dění)**

- ▶ pouze sledujeme, nezasahujeme
- ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (confounding) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
- ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
- ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## dvojí původ dat

### ▶ **plánovaný** (organizovaný) **pokus**

- ▶ aktivně zasahujeme
- ▶ fixujeme okolnosti (stálá teplota, světelný režim)
- ▶ nastavujeme úroveň zvoleného faktoru (např. živné roztoky)
- ▶ jedincům náhodně přiřazujeme ošetření
- ▶ zjistíme-li rozdíl, známe jeho příčinu

### ▶ **šetření** (sledování dění)

- ▶ pouze sledujeme, nezasahujeme
- ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (confounding) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
- ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
- ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## dvojí původ dat

### ▶ **plánovaný** (organizovaný) **pokus**

- ▶ aktivně zasahujeme
- ▶ fixujeme okolnosti (stálá teplota, světelný režim)
- ▶ nastavujeme úroveň zvoleného faktoru (např. živné roztoky)
- ▶ jedincům náhodně přiřazujeme ošetření
- ▶ zjistíme-li rozdíl, známe jeho příčinu

### ▶ **šetření** (sledování dění)

- ▶ pouze sledujeme, nezasahujeme
- ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (confounding) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
- ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
- ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## dvojí původ dat

### ▶ **plánovaný** (organizovaný) **pokus**

- ▶ aktivně zasahujeme
- ▶ fixujeme okolnosti (stálá teplota, světelný režim)
- ▶ nastavujeme úroveň zvoleného faktoru (např. živné roztoky)
- ▶ jedincům náhodně přiřazujeme ošetření
- ▶ zjistíme-li rozdíl, známe jeho příčinu

### ▶ **šetření** (sledování dění)

- ▶ pouze sledujeme, nezasahujeme
- ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (**confounding**) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
- ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
- ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)



## dvojí původ dat

- ▶ **plánovaný** (organizovaný) **pokus**
  - ▶ aktivně zasahujeme
  - ▶ fixujeme okolnosti (stálá teplota, světelný režim)
  - ▶ nastavujeme úroveň zvoleného faktoru (např. živné roztoky)
  - ▶ jedincům náhodně přiřazujeme ošetření
  - ▶ zjistíme-li rozdíl, známe jeho příčinu
- ▶ **šetření** (sledování dění)
  - ▶ pouze sledujeme, nezasahujeme
  - ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (**confounding**) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
  - ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
  - ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## dvojí původ dat

- ▶ **plánovaný** (organizovaný) **pokus**
  - ▶ aktivně zasahujeme
  - ▶ fixujeme okolnosti (stálá teplota, světelný režim)
  - ▶ nastavujeme úroveň zvoleného faktoru (např. živné roztoky)
  - ▶ jedincům náhodně přiřazujeme ošetření
  - ▶ zjistíme-li rozdíl, známe jeho příčinu
- ▶ **šetření** (sledování dění)
  - ▶ pouze sledujeme, nezasahujeme
  - ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (**confounding**) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
  - ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
  - ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## dvojí původ dat

- ▶ **plánovaný** (organizovaný) **pokus**
  - ▶ aktivně zasahujeme
  - ▶ fixujeme okolnosti (stálá teplota, světelný režim)
  - ▶ nastavujeme úroveň zvoleného faktoru (např. živné roztoky)
  - ▶ jedincům náhodně přiřazujeme ošetření
  - ▶ zjistíme-li rozdíl, známe jeho příčinu
- ▶ **šetření** (sledování dění)
  - ▶ pouze sledujeme, nezasahujeme
  - ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (**confounding**) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
  - ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
  - ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## dvojí původ dat

- ▶ **plánovaný** (organizovaný) **pokus**
  - ▶ aktivně zasahujeme
  - ▶ fixujeme okolnosti (stálá teplota, světelný režim)
  - ▶ nastavujeme úrovně zvoleného faktoru (např. živné roztoky)
  - ▶ jedincům náhodně přiřazujeme ošetření
  - ▶ zjistíme-li rozdíl, známe jeho příčinu
- ▶ **šetření** (sledování dění)
  - ▶ pouze sledujeme, nezasahujeme
  - ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (**confounding**) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
  - ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
  - ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, ...)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ **predikce** spojitě veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis ⇒ formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ predikce spojitě veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ predikce spojitě veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ predikce spojitě veličiny na spojitých či kvalitativních (regrese)



# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ predikce spojitě veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ predikce spojitě veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ predikce spojitě veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ predikce spojitě veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojité (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ predikce spojité veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojité (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ **predikce** spojitě veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojité (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ **predikce** spojitě veličiny na spojitých či kvalitativních (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojité (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ **predikce** spojitě veličiny na spojitých či kvalitativních (regrese)



# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ **predikce spojitě veličiny na spojitých či kvalitativních** (regrese)

# jaké úlohy řešíme

dělení podle skupin statistických metod

- ▶ **popsat stav** (popisná statistika, Exploratory Data Analysis  $\Rightarrow$  formulace vědeckých hypotéz)
  - ▶ poloha (průměr, medián, kvartily, . . .)
  - ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
  - ▶ tvar rozdělení (šikmost, špičatost)
- ▶ **prokázat vliv ošetření** (induktivní, konfirmační statistika)
  - ▶ změna polohy ( $t$ -testy, analýza rozptylu)
  - ▶ změna variability (Levene,  $F$ -test, Bartlettův test)
  - ▶ jiná změna rozdělení (Kolmogorov-Smirnov)
- ▶ **prokázat závislost** (induktivní, konfirmační statistika)
  - ▶ obě spojitě (korelační koeficient, regrese)
  - ▶ spojitá na kvalitativními (ANOVA)
  - ▶ obě kvalitativní (kontingenční tabulka)
  - ▶ **predikce** spojitě veličiny na spojitých či kvalitativních (regrese)

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
    - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu



# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# výběr metody

- ▶ jakou úlohu řešíme?
- ▶ jsou výběry nezávislé?
  - ▶ zajistit organizací pokusu
- ▶ lze předpokládat normální rozdělení?
  - ▶ lze soudit z grafu (normální diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ v jednotlivých výběrech nebo z reziduí
- ▶ je rozptyl stálý?
  - ▶ lze soudit z grafu (rozptylový diagram)
  - ▶ lze ověřovat pomocí testů
  - ▶ porovnat výběry nebo z reziduí
  - ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

# volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit před pokusem na základě úvah, které nejsou založeny na použitých datech
  - ▶ zpravidla obsahuje více možností než nulová hypotéza
  - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokážeme

# volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit před pokusem na základě úvah, které nejsou založeny na použitých datech
  - ▶ zpravidla obsahuje více možností než nulová hypotéza
  - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokážeme



## volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit před pokusem na základě úvah, které nejsou založeny na použitých datech
  - ▶ zpravidla obsahuje více možností než nulová hypotéza
  - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokážeme

## volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit před pokusem na základě úvah, které nejsou založeny na použitých datech
  - ▶ zpravidla obsahuje více možností než nulová hypotéza
  - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokážeme

## volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit před pokusem na základě úvah, které nejsou založeny na použitých datech
  - ▶ zpravidla obsahuje více možností než nulová hypotéza
  - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokazujeme

## volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit **před pokusem** na základě úvah, které **nejsou** založeny na použitých datech
  - ▶ zpravidla obsahuje více možností než nulová hypotéza
  - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokážeme

## volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit **před pokusem** na základě úvah, které **nejsou** založeny na použitých datech
    - ▶ zpravidla obsahuje více možností než nulová hypotéza
    - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokážeme

## volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit **před pokusem** na základě úvah, které **nejsou** založeny na použitých datech
  - ▶ zpravidla obsahuje více možností než nulová hypotéza
    - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokážeme

## volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit **před pokusem** na základě úvah, které **nejsou** založeny na použitých datech
  - ▶ zpravidla obsahuje více možností než nulová hypotéza
  - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokážeme

## volba nulové a alternativní hypotézy

- ▶  $H_0$  zjednodušuje model
  - ▶ hypotéza přesněji určuje model (např. test shody)
  - ▶ populace se neliší (výběry se liší jen náhodně)
  - ▶ veličiny jsou nezávislé
  - ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu
- ▶  $H_1$  je opak nulové hypotézy
  - ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit **před pokusem** na základě úvah, které **nejsou** založeny na použitých datech
  - ▶ zpravidla obsahuje více možností než nulová hypotéza
  - ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokážeme



## porovnání populačních měř polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový $t$ - test	jednovýběrový Wilcoxon
výběr dvojic	párový $t$ -test	znaménkový, Wilcoxon
dva nezávislé výběry	dvouvýběrový $t$ -test	Mann-Whitney (Kolmogorov-Smirnov)
$k$ nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr $r$ -tic	analýza rozptylu náhodné bloky	Friedman

# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

# vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

## vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

## vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	( <i>logistická regrese</i> )
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů