

MNOHOROZMĚRNÁ STATISTIKA

1 VÍCEROZMĚRNÁ (MNOHOROZMĚRNÁ) DATA

- na každém objektu měříme několik veličin, obecně závislých
- příklady:
 - výška, věk, hmotnost, rasa, pohlaví, … člověka,
 - různé makroekonomické charakteristiky států EU,
 - charakteristiky podnebí (teplota, znečištění vzduchu, množství srážek, povětrnost, …) různých míst ČR
 - …
- počet objektů může být menší než počet měřených veličin

MNOHOROZMĚRNÁ STATISTIKA

- statistické metody pro analýzu mnohorozměrných dat
- spíše průzkumné metody (explorativní charakter)
 - hledání zákonitostí, struktury,
 - zkoumání vztahů mezi objekty a proměnnými,
 - pochopení souvislostí,
 - působí méně exaktním dojmem,
- větší zacílení na jedince než v klasické statistice.

HLAVNÍ CÍLE VÍCEROZMĚRNÉ STATISTIKY:

- redukce vícerozměnosti,
- vizualizace dat, identifikace odlehlých hodnot (netypických jedinců),
- hledání struktury v datech (podobnosti objektů, vztahy mezi proměnnými),
- klasifikační úlohy.

ZÁKLADNÍ METODY:

1. Analýza hlavních komponent (PCA)
2. Faktorová analýza (FA)
3. Diskriminační analýza (DA)
4. Shluková analýza (CA)
5. Další: Kanonické korelace (CC), Korespondenční analýza, Mnohorozměrné škálování, Metoda hlavních koordinát, Klasifikační stromy, atd.

POZNÁMKY

- Většina metod „ideální“ pro normální rozdělení.
- Často standardizace dat.

2 POPISNÁ STATISTIKA A VIZUALIZACE DAT

- 2D grafy, matice grafů
- mnohorozměrná vizualizace (Chernoffovy tváře)
- korelační matice (tabulka korelačních koeficientů)
- kovariance, kovarianční matice

3 ANALÝZA HLAVNÍCH KOMPONENT (PCA)

- snaha snížit variabilitu do méně dimenzí,
- idea: jsou-li dvě proměnné silně korelované, můžeme je do jisté míry nahradit jednou novou (společnou) proměnnou,
- chceme, aby ztráta informace byla minimální.

K ČEMU SLOUŽÍ

- lepší pochopení vztahů mezi proměnnými,
- lepší pochopení vztahů mezi jedinci (vizualizace vícerozměrných dat ve 2D obrázcích),
- hledání odlehlých hodnot,
- následné využití v dalších statistických metodách (regrese).

POSTUP

1. odhad (výpočet) hlavních komponent z korelační (kovarianční) matice,
2. volba počtu hlavních komponent (různá kritéria),
 - komponenty s rozptylem více než 1,
 - sutinnový graf,
 - požadavek na vysvětlenou variabilitu (např. 70 % apod.),
3. interpretace hlavních komponent: korelace s původními proměnnými (loadings), grafické znázornění,
4. znázornění dat vzhledem k novým souřadnicím (hlavním komponentám) — tzv. biploty.

4 FAKTOROVÁ ANALÝZA (FA)

- aplikace zejména v psychologii, sociálních vědách atd.,
- snaha vysvětlit variabilitu v proměnných pomocí menšího počtu latentních (nepozorovatelných) faktorů,
- rozšiřuje interpretační schopnosti PCA,
 - rotace faktorů tak, aby vzniklé veličiny byly hodně korelované s některými málo proměnnými a velmi málo korelované s ostatními proměnnými,
 - interpretace závisí na výsledku rotace – nutná znalost dané problematiky,
 - různé metody rotace (varimax, promax, ...),
- počet faktorů je třeba specifikovat na začátku analýzy.

5 SHLUKOVÁ ANALÝZA (CA)

- snaha rozdělit objekty do skupin, jejichž prvky jsou si v určitém smyslu podobné,
- shluk = skupina objektů, které jsou si podobné a jsou odlišné od objektů patřících do jiných shluků,
- vhodná standardizace dat,
- interpretace výsledných shluků.

METODY SHLUKOVÉ ANALÝZY

- Hierarchické metody:
 - počet shluků nemusí být na začátku stanoven
 - na začátku je každý objekt jeden shluk, potom postupně v každém kroku spojíme dva nejbližší shluky dokud nejsou všechny objekty v jednom velkém shluku.
- Nehierarchické metody:
 - na začátku musíme stanovit požadovaný počet shluků,
 - analýza rozdělí objekty do shluků „optimálně“.

HIERARCHICKÉ METODY

- založené na vzdálenosti (vzdálenější objekty méně podobné),
- vzdálenost dvou objektů (Eukleidovská, Manhattan, ...)
- vzdálenost dvou shluků (princip nejbližšího, nejvzdálenějšího souseda, Wardova metoda, metoda centroidů),
- různé metody mohou dávat různé výsledky,
- grafická prezentace: dendrogram.

METODA K-MEANS

- na začátku specifikujeme počet shluků,
- minimalizuje součet čtverců od center shluků,
- iterační postup,
- výsledek může značně záviset na počáteční volbě center.

6 DISKRIMINAČNÍ ANALÝZA (DA)

- v datech k skupin, na každém objektu měřeno několik znaků,
- chceme najít pravidlo založené na měřených znacích, pomocí něhož by bylo možné rozlišit jednotlivé skupiny,
- příklady: klasifikace rostlin, credit scoring, antropologie, . . . ,
- tzv. učení s učitelem (na rozdíl od shlukové analýzy),
- metoda předpokládá normalitu, ale není moc citlivá na porušení.

POSTUP

1. krok: vytvoření diskriminačního pravidla:
 - vytvoření pravidla pro rozlišení skupin na základě trénovacích dat,
 - příslušnost objektů do skupin je známá,
 - je možné nastavit tzv. apriorní pravděpodobnosti jednotlivých skupin,
 - ověření „kvality“ diskriminace.
2. krok: klasifikace nových objektů:
 - zařazení nového jedince do některé ze skupin,
 - jeho skutečnou příslušnost neznáme.

7 KANONICKÉ KORELACE (CC)

- zkoumá vztah mezi dvěma skupinami proměnných,
- příklad: vztah známk na vysvědčení a sérií IQ testů, vztah environmentálních a druhových proměnných, . . . ,
- kanonické proměnné = lineární kombinace původních, které maximalizují vzájemné korelace,
- kanonické korelace = příslušné korelace kanonických proměnných