

# Bakalářské studium na MFF UK v Praze

## Obecná matematika

### Zaměření: Stochastika

## Podrobnější rozpis okruhů otázek pro třetí část SZZ

Verze: 18. června 2014

---

### 1 Úvodní poznámky

✧ Smyslem SZZ by nemělo být toliko ukazovat schopnost „papouškovat“ definice či věty, ale spíše prokázat schopnost samostatně myslet a propojovat jednotlivé znalosti, resp. ukázat schopnost aktivně používat vybraný matematický aparát, resp. probrané metody. Otázka zadávaná studentovi v rámci SZZ tedy ne nutně obsahuje přímo pojem či okruh, který je explicitně vyjmenován na seznamu požadavků pro SZZ. V rámci otázek zadávaných u SZZ se typicky jedná o jeden z následujících požadavků, případně o výběr z následujících požadavků:

- Matematicky korektní formulace věty nebo tvrzení a její důkaz, jestliže tento nevyžaduje znalost „triku“, ale spíše vzájemné propojení jednotlivých znalostí. Jedná se např. o důkaz nestrannosti vybraných odhadů nebo použití ZVČ při důkazu konzistence vybraných odhadů, důkaz Čebyševovy nerovnosti, použití CLV při odvození některých testů apod.
- Vyřešení jednoduššího početního příkladu souvisejícího se zadanou otázkou (např. použití věty o transformaci pro odvození hustoty  $\chi_1^2$  rozdělení).
- Návrh pravděpodobnostního modelu, formulace testovaných hypotéz a odvození (resp. náznak odvození) příslušného testu pro řešení „praktického“ problému.

Zadávané problémy, resp. požadavky jsou vždy řešitelné pomocí aparátu, který se skrývá pod pojmy vyjmenovanými v oficiálním seznamu požadavků pro SZZ.

✧ V přehledu níže přesněji specifikujeme obsah jednotlivých okruhů zveřejněných v Karolínce v oficiálním seznamu požadavků pro SZZ. Dále se snažíme uvádět, jakým způsobem a do jaké hloubky je ověřována znalost jednotlivých termínů, pojmů, atp.

## 2 Oficiální požadavky dle Karolínky

### 1. Základy teorie pravděpodobnosti

- (1) Pravděpodobnostní prostor, podmíněná pravděpodobnost, Bayesova věta, nezávislost systému náhodných jevů, 0–1 zákony.
- (2) Náhodná veličina, náhodný vektor a jejich rozdělení, charakteristiky (střední hodnota, rozptyl, varianční matice, korelace atd.).
- (3) Charakteristická funkce a její použití, nezávislost náhodných veličin a vektorů, základní jedno- i mnohorozměrná diskrétní a spojitá rozdělení.
- (4) Transformace náhodné veličiny a náhodného vektoru.
- (5) Podmíněné rozdělení a podmíněná střední hodnota.
- (6) Typy konvergence náhodných veličin a vztahy mezi nimi, Čebyševova nerovnost, slabý a silný zákon velkých čísel, centrální limitní věta pro součet nezávislých stejně rozdělených náhodných veličin.
- (7) Cramérova-Sluckého věta.

### 2. Základy matematické statistiky

- (1) Náhodný výběr, uspořádaný náhodný výběr.
- (2) Bodové a intervalové odhady, nestrannost a konsistence odhadů.
- (3) Empirická distribuční funkce.
- (4) Principy testování hypotéz, Neymanovo-Pearsonovo lemma.
- (5) Fisherova informace, Rao-Cramérova věta, odhady metodou maximální věrohodnosti, asymptotické testy založené na maximální věrohodnosti.
- (6) Jednovýběrový, dvouvýběrový, párový t-test.
- (7) Jednovýběrové a dvouvýběrové testy pro vybrané parametrické problémy, test dobré shody na multinomické rozdělení, testy nezávislosti v dvourozměrných kontingenčních tabulkách.

## 3 Podrobnější rozpis požadavků

### 3.1 Základy teorie pravděpodobnosti

#### 1. Pravděpodobnostní prostor, podmíněná pravděpodobnost, Bayesova věta, nezávislost systému náhodných jevů, 0–1 zákony.

- (a) Definice pravděpodobnostního prostoru, co je to  $\sigma$ -algebra, co je to pravděpodobnost a jaké jsou její vlastnosti. Nezávislost systému náhodných jevů.
- (b) Definice podmíněné pravděpodobnosti, věta o násobení pravděpodobností, věta o úplné pravděpodobnosti, Bayesova věta.
- (c) Cantelliho věta, Borelova věta.

#### 2. Náhodná veličina, náhodný vektor a jejich rozdělení, charakteristiky (střední hodnota, rozptyl, varianční matice, korelace atd.).

- (a) Definice náhodné veličiny. Proč se vyžaduje měřitelnost?  $\sigma$ -algebra indukovaná náhodnou veličinou.
- (b) Distribuční funkce náhodné veličiny a její vlastnosti. Hustota (spojité, diskrétní) náhodné veličiny, její vztah k distribuční funkci a její využití pro výpočet  $P(X \in B)$ .
- (c) Střední hodnota a rozptyl náhodné veličiny a jejich vlastnosti.
- (d) Momenty náhodné veličiny (absolutní, centrální). Momentová vytvořující funkce.
- (e) Definice náhodného vektoru a jeho distribuční funkce. Vlastnosti distribuční funkce dvou-rozměrného náhodného vektoru.
- (f) Sdružená versus marginální distribuční funkce (hustota) náhodných vektorů. Podmíněná hustota.
- (g) Kovariance, koeficient korelace, varianční matice a její vlastnosti.
- (h) Rozdělení a momenty měřitelné funkce náhodné veličiny (vektoru).

#### 3. Charakteristická funkce a její použití, nezávislost náhodných veličin a vektorů.

- (a) Definice charakteristické funkce náhodné veličiny a náhodného vektoru, jejich vlastnosti.
- (b) Nezávislost náhodných veličin a vektorů.
- (c) Charakteristická funkce a nezávislost náhodných veličin, charakteristická funkce a transformace náhodných veličin, charakteristická funkce a součet náhodných veličin.
- (d) Charakteristická funkce a konvergence v distribuci.

**Poznámka.** Součástí otázek z výše uvedených okruhů bude zpravidla i jednoduchý příklad, který prověří, zda student umí výše uvedené používat.

#### 4. Základní jedno- i mnohorozměrná diskrétní a spojitá rozdělení.

- (a) Alternativní a binomické rozdělení: hustota, odvození střední hodnoty a rozptylu. Použití alternativního, resp. binomického rozdělení jakožto základního modelu pro dichotomickou odezvu, resp. součet nezávislých dichotomických znaků.
- (b) Multinomické rozdělení: definice, odvození střední hodnoty a varianční matice. Vztah mezi multinomickým a alternativním rozdělením. Představa o oblastech využití (základní pravděpodobnostní model pro kategoriální data).

- (c) Poissonovo rozdělení: hustota, odvození střední hodnoty a rozptylu. Použití Poissonova rozdělení jakožto základního modelu pro počet (událostí, ...).
- (d) Exponenciální rozdělení: hustota, odvození střední hodnoty a rozptylu, „bezpečnost“ exponenciálního rozdělení včetně důkazu. Použití exponenciálního rozdělení jakožto základního modelu pro čas do události, mezi událostmi, ...
- (e) Jednorozměrné normální rozdělení: hustota, odvození střední hodnoty a rozptylu, informativně: hodnota šikmosti a špičatosti, charakteristická funkce. Vztah mezi  $\mathcal{N}(0, 1)$  a  $\mathcal{N}(\mu, \sigma^2)$ , symetrie hustoty, použití vztahu  $\Phi(-x) + \Phi(x) = 1$  ve výpočtech. Odvození charakteristické funkce rozdělení  $\mathcal{N}(\mu, \sigma^2)$ , je-li známa charakteristická funkce rozdělení  $\mathcal{N}(0, 1)$ . Představa o oblastech využití normálního rozdělení: zejména asymptotická inference (CLV, maximální věrohodnost, ...).
- (f) Vícerozměrné normální rozdělení: definice. Informativně základní vlastnosti: vztah mezi nezávislostí a nekorelovaností, rozdělení lineární transformace, normalita marginálních a podmíněných rozdělení.
- (g) Rozdělení  $\chi^2$ : definice, odvození střední hodnoty a rozptylu (bez integrování na základě znalosti momentů normálního rozdělení). Odvození hustoty rozdělení  $\chi_1^2$ . Odvození hustoty  $\chi_2^2$  pomocí konvoluce, je-li zadána hustota rozdělení  $\chi_1^2$ . Konvergence rozdělení  $\chi_n^2$  v distribuci pro  $n \rightarrow \infty$  (s odůvodněním). Představa o oblastech využití rozdělení  $\chi^2$ : intervaly spolehlivosti pro a testy o rozptylu ve výběru z normálního rozdělení, intervaly spolehlivosti a testy založené na asymptotické teorii maximální věrohodnosti, testy dobré shody a testy v kontingenčních tabulkách.
- (h) Studentovo  $t$  rozdělení: definice. Vztah mezi rozdělením  $t_1$  a Cauchyho rozdělením, informativně střední hodnota rozdělení  $t_1$ . Symetrie hustoty, použití této symetrie ve výpočtech (zejména při odvozování intervalů spolehlivosti a testů). Odvození (náznak odvození) hustoty rozdělení  $t_\nu$ , je-li znám předpis hustoty rozdělení  $\chi_\nu^2$ . Konvergence rozdělení  $t_n$  v distribuci pro  $n \rightarrow \infty$  (s odůvodněním). Představa o oblastech využití Studentova  $t$  rozdělení: intervaly spolehlivosti pro a testy o střední hodnotě ve výběru z normálního rozdělení, intervaly spolehlivosti pro a testy o rozdílu středních hodnot v nezávislých výběrech z normálního rozdělení.
- (i) Fisherovo-Snedecorovo  $F$  rozdělení: definice. Odvození (náznak odvození) hustoty rozdělení  $F_{\nu_1, \nu_2}$ , je-li znám předpis hustoty rozdělení  $\chi_\nu^2$ . Představa o oblastech využití Fisherova-Snedecorova  $F$  rozdělení: srovnání rozptylů dvou nezávislých výběrů z normálního rozdělení, analýza rozptylu.

**Poznámka.** V žádném případě se neočekává znalost hustoty rozdělení  $\chi_\nu^2$ ,  $t_\nu$  nebo  $F_{\nu_1, \nu_2}$  z paměti!

## 5. Transformace náhodné veličiny a náhodného vektoru.

- (a) Formulace věty o hustotě transformace náhodné veličiny (též vícerozměrné).
- (b) Postup výpočtu rozdělení po transformaci  $\mathbb{R}^p \rightarrow \mathbb{R}$ .
- (c) Formulace věty o konvoluci a její důkaz (lze ukázat, že se jedná o speciální případ použití postupu transformace  $\mathbb{R}^2 \rightarrow \mathbb{R}$ ).
- (d) Praktické použití věty o transformaci na zadaný problém (jednodušší početní příklad vyžadující výpočet rozdělení po transformaci).

## 6. Podmíněné rozdělení a podmíněná střední hodnota.

- (a) Podmíněná střední hodnota náhodné veličiny, její definice a vlastnosti, podmíněná pravděpodobnost jako podmíněná střední hodnota.
- (b) Definice podmíněného rozdělení náhodné veličiny, věta o podmíněné hustotě, užití podmíněné hustoty při určení podmíněné střední hodnoty.
- (c) Určení podmíněné střední hodnoty pro zadaný problém (jednodušší příklady).

## 7. Typy konvergence náhodných veličin a vztahy mezi nimi, Čebyševova nerovnost, slabý a silný zákon velkých čísel, centrální limitní věta pro součet nezávislých stejně rozdělených náhodných veličin.

- (a) Konvergence skoro jistě a konvergence v pravděpodobnosti a jejich vztah. Metrizovatelnost těchto konvergencí.
- (b) Konvergence v distribuci, její vztah ke konvergenci v pravděpodobnosti.
- (c) Definice silného (slabého) zákona velkých čísel.
- (d) Slabý zákon velkých čísel a jeho důkaz pomocí Čebyševovy nerovnosti.
- (e) Silný zákon velkých čísel pro stejně a nesterjně rozdělené náhodné veličiny, porovnání předpokladů.
- (f) Centrální limitní věta (CLV) pro nezávislé stejně rozdělené náhodné veličiny (bez důkazu). Použití CLV na binomické rozdělení a v dalších příkladech.
- (g) Použití zákona velkých čísel k důkazu konzistence zadaného statistického odhadu.

**Poznámka.** Součástí otázek z výše uvedených okruhů může být některý z následujících úkolů: (a) vyšetřit, zda daná konkrétní posloupnost náhodných veličin splňuje silný (slabý) zákon velkých čísel a co nám tento zákon velkých čísel dává; (b) využití CLV na řešení různých slovních úloh.

## 8. Cramérova-Sluckého věta.

- (a) Formulace věty (bez důkazu).
- (b) Použití při konstrukci asymptotických intervalů spolehlivosti a asymptotických testů založených na CLV a konzistentním odhadu neznámého rozptylu, resp. neznámých rozptylů (asymptotická varianta t-testu, ...).

## 3.2 Základy matematické statistiky

### 1. Náhodný výběr, uspořádaný náhodný výběr.

- (a) Definice náhodného výběru.
- (b) Použití náhodného výběru jakožto pravděpodobnostního modelu pro data.
- (c) Definice uspořádaného náhodného výběru, odvození rozdělení (distribuční funkce, případně hustota) první a poslední pořádkové statistiky (minimum, maximum).
- (d) Výběrové kvantily.

### 2. Bodové a intervalové odhady, nestrannost a konsistence odhadů.

- (a) Definice parametrické třídy rozdělení.
- (b) Definice bodového a intervalového odhadu, jednostranné intervaly spolehlivosti.
- (c) Schopnost srozumitelně vysvětlit, co si představit pod pojmem „interval spolehlivosti se spolehlivostí  $(1 - \alpha)$  %“, chápat náhodnost mezi intervalu spolehlivosti, umět vysvětlit, odkud se tato náhodnost bere.
- (d) Definice nestrannosti, konzistence odhadu a vysvětlení smyslu těchto definic.
- (e) Definice asymptotické nestrannosti odhadu, resp. asymptotického intervalu spolehlivosti.
- (f) Důkaz nestrannosti zadaného odhadu.
- (g) Důkaz konzistence zadaného odhadu, zejména je-li možné využít zákona velkých čísel.
- (h) Směrodatná odchylka (směrodatná chyba) odhadu a její význam a použití při konstrukci asymptotických intervalů spolehlivosti.
- (i) Vlastnosti výběrového průměru a výběrového rozptylu v náhodném výběru z normálního rozdělení: nestrannost a konzistence včetně důkazu, normální rozdělení výběrového průměru včetně důkazu. Informativně: nezávislost výběrového průměru a výběrového rozptylu,  $\chi^2$  rozdělení výběrového rozptylu (po přenásobení vhodnou konstantou).
- (j) Bodový a intervalový odhad střední hodnoty a rozptylu v náhodném výběru z normálního rozdělení  $\mathcal{N}(\mu, \sigma^2)$  včetně odvození. Schopnost vysvětlit, z čeho plyne Studentovo t-rozdělení statistiky  $\frac{\bar{X}_n - \mu}{\frac{S_n}{\sqrt{n}}}$ . Podmínky, za jakých lze odvozený intervalový odhad střední hodnoty použít v případě, že je porušena normalita výběru.
- (k) Bodový a intervalový odhad rozdílu středních hodnot dvou nezávislých náhodných výběrů z normálních rozdělení s neznámým shodným rozptylem včetně odvození. Podmínky, za jakých lze intervalový odhad rozdílu středních hodnot použít v případě, že je porušena normalita jednoho nebo druhého výběru.
- (l) Bodový a intervalový odhad podílu rozptylů, resp. směrodatných odchylek dvou nezávislých náhodných výběrů z normálních rozdělení včetně odvození.
- (m) Bodový a intervalový odhad střední hodnoty (pravděpodobnosti „úspěchu“) v náhodném výběru z alternativního rozdělení založený na CLV a Cramérově-Sluckého větě včetně odvození.
- (n) Bodový a intervalový odhad rozdílu středních hodnot (pravděpodobností „úspěchu“) dvou nezávislých náhodných výběrů z alternativních rozdělení založený na CLV a Cramérově-Sluckého větě včetně odvození.
- (o) Bodový a intervalový odhad střední hodnoty ve výběru z Poissonova rozdělení založený na CLV a Cramérově-Sluckého větě včetně odvození.
- (p) Bodový a intervalový odhad střední hodnoty ve výběru z exponenciálního rozdělení založený na CLV a Cramérově-Sluckého větě včetně odvození.

### 3. Empirická distribuční funkce.

- (a) Empirická distribuční funkce (edf) a její vlastnosti: nestrannost a konzistence včetně důkazu.
- (b) Idea využití edf při konstrukci Kolmogorovova-Smirnovova testu.
- (c) Použití Kolmogorovova-Smirnovova testu pro řešení prakticky zadaného problému.

#### 4. Principy testování hypotéz, Neymanovo-Pearsonovo lemma.

- (a) Formulace problému testování hypotéz, vysvětlení základních pojmů: nulová a alternativní hypotéza, chyba prvního a druhého druhu, hladina testu, síla testu, p-hodnota.
- (b) Vysvětlení, proč nelze statistickým testem prokázat platnost nulové hypotézy. Obvyklý postup formulace hypotéz v praktické situaci: tvrzení, jehož platnost chceme prokázat  $\rightarrow$  alternativní hypotéza, následně formulace nulové hypotézy, výjimka: testy dobré shody.
- (c) Vysvětlení principu odvození testu: a) testová statistika, která nějakým způsobem odráží (ne)shodu dat s nulovou hypotézou, resp. (ne)podporu alternativní hypotézy, b) rozdělení testové statistiky při nulové hypotéze (proč je potřeba ho znát při nulové a nikoliv při alternativní hypotéze), vysvětlení, odkud se bere náhodnost testové statistiky, když data jsou v konkrétní situaci pouze jedna, c) kritický obor, d) p-hodnota, e) souvislost kritického oboru s výpočtem p-hodnoty.
- (d) Souvislost mezi testováním hypotéz a intervaly spolehlivosti (v případě parametrických testů). Odvození intervalu spolehlivosti „invertováním“ testové statistiky souvisejícího testu.
- (e) Formulace Neymanova-Pearsonova lemmatu v případě jednoduché hypotézy i alternativy. Praktické použití při odvození testu v zadaném příkladě (test o pravděpodobnosti úspěchu v alternativním rozdělení, test o střední hodnotě v Poissonově rozdělení, test o střední hodnotě v exponenciálním rozdělení, test o rozptylu v normálním rozdělení, ...).

#### 5. Fisherova informace, Rao-Cramérova věta, odhady metodou maximální věrohodnosti, asymptotické testy založené na maximální věrohodnosti.

- (a) Věrohodnost náhodného výběru z rozdělení z parametrické třídy rozdělení. Logaritmická věrohodnost, skórová funkce, Fisherova informace (pozorovaná a očekávaná).
- (b) Princip odhadu metodou maximální věrohodnosti (ML).
- (c) Formulace vět o konzistenci ML odhadu, o asymptotické normalitě skórové funkce a ML odhadu (bez důkazu). Není nutné znát do detailu všechny podmínky regularity.
- (d) Vysvětlení principů, na jejichž základě fungují testy založené na asymptotické teorii maximální věrohodnosti (Waldův test, skórový test, test poměrem věrohodností).
- (e) Princip odvození asymptotických intervalů spolehlivosti založených na Waldově a skórovém testu, resp. testu poměrem věrohodností. Význam směrodatné odchylky (směrodatné chyby) odhadu pro konstrukci Waldova intervalu spolehlivosti.
- (f) Odvození maximálně věrohodného odhadu, jeho asymptotického rozptylu, souvisejících asymptotických testů a intervalů spolehlivosti pro zadaný problém (např. odhad parametru  $\lambda$  ve výběru z Poissonova rozdělení se střední hodnotou  $\lambda$ ).
- (g) Formulace Rao-Cramérové věty (bez důkazu). Vysvětlení vztahu mezi Rao-Cramérovou větou a teorií maximální věrohodnosti.

#### 6. Jednovýběrový, dvouvýběrový, párový t-test.

- (a) Podmínky, za jakých je možné použít jednotlivé testy i bez platnosti předpokládaného normálního rozdělení.
- (b) Význam párování při eliminaci výběrové variability.

(c) Viz též společné poznámky pro okruhy **6** a **7** níže.

## 7. Jednovýběrové a dvouvýběrové testy pro vybrané parametrické problémy, test dobré shody na multinomické rozdělení, testy nezávislosti v dvourozměrných kontingenčních tabulkách.

- (a) Jednovýběrový test o rozptylu normálního rozdělení.
- (b) Dvouvýběrový test o shodě rozptylů dvou nezávislých výběrů z normálního rozdělení.
- (c) Test o střední hodnotě (pravděpodobnosti „úspěchu“) alternativního rozdělení založený na CLV.
- (d) Test o střední hodnotě rozdělení splňujícího podmínky pro platnost CLV (Poissonovo, exponenciální, ...) založený na CLV a případně Cramérově-Sluckého větě.
- (e) Test o shodě středních hodnot (pravděpodobností „úspěchu“) dvou nezávislých výběrů z alternativního rozdělení založený na CLV a Cramérově-Sluckého větě. Souvislost s  $\chi^2$ -testem nezávislosti v kontingenční tabulce  $2 \times 2$ .
- (f)  $\chi^2$ -test dobré shody na multinomické rozdělení, umět napsat tvar testové statistiky a vysvětlit její princip, znát asymptotické rozdělení této statistiky za nulové hypotézy ( $\chi^2$  včetně stupňů volnosti), není však nutné toto umět dokázat.
- (g)  $\chi^2$ -test nezávislosti, umět napsat tvar testové statistiky a vysvětlit její princip, znát asymptotické rozdělení této statistiky za nulové hypotézy ( $\chi^2$  včetně stupňů volnosti), není však nutné toto umět dokázat. Souvislost  $\chi^2$ -test nezávislosti s testem homogenity několika multinomických rozdělení.
- (h) Viz též společné poznámky pro okruhy **6** a **7** níže.

### 3.2.1 Společné poznámky pro okruhy **6** a **7**

Zadávané otázky odvozené z těchto okruhů budou vesměs spočívat v popisu „reálného“ problému a požadavku navrhnout řešení tohoto problému.

**Příklad.** *Mezi náhodně oslovenými návštěvníky obchodního domu Máj bylo zaznamenáno jejich pohlaví a odpověď na otázku, zda preferují na chlebu namazaný margarín nebo máslo. Zformulujte pravděpodobnostní model a na jeho základě odvoďte statistický test, pomocí něhož lze zjistit, zda preference másla/margarínu mezi návštěvníky obchodního domu Máj závisí na pohlaví.*

V rámci odpovědi se očekává následující (případně podmnožina následujícího):

- ✧ Formulace vhodného pravděpodobnostního modelu.
- ✧ Formulace testovaných hypotéz.
- ✧ Návrh testové statistiky, odvození (důkaz) jejího (asymptotického) rozdělení za nulové hypotézy. Podrobné odůvodnění rozdělení testové statistiky se nevyžaduje u  $\chi^2$  testů dobré shody a nezávislosti (viz výše).
- ✧ Návrh kritického oboru a důkaz, že odpovídá testu na zadané hladině  $\alpha$ .
- ✧ Způsob výpočtu p-hodnoty testu.
- ✧ Jedná-li se o parametrický test, odvození souvisejícího intervalu spolehlivosti.

Obdobným způsobem mohou být zadány taktéž některé otázky směřující k vysvětlení či konstrukci intervalových odhadů (okruhy **2j**, **2k**, **2l**, **2m**, **2n**, **2o**, **2p**).