

ZÁKLADY STATISTIKY

STUDIJNÍ OPORA PRO KOMBINOVANÉ STUDIUM

ZÁKLADY STATISTIKY

RNDr. Jiří Fišer, Ph.D.

© Moravská vysoká škola Olomouc, o. p. s.

Autoři: RNDr. Jiří FIŠER, Ph.D.

Olomouc 2024

Obsah

Úvod	8
1 Kombinatorika	11
1.1 Základní pojmy a vlastnosti	12
1.2 Variace	15
1.2.1 Variace bez opakování	15
1.2.2 Variace s opakováním	16
1.3 Permutace	17
1.3.1 Permutace bez opakování	17
1.3.2 Permutace s opakováním	18
1.4 Kombinace	19
1.4.1 Kombinace bez opakování	20
1.4.2 Kombinace s opakováním	22
1.4.3 Souhrnné příklady	23
2 Pravděpodobnost jevů	27
2.1 Základní pojmy	28
2.2 Klasická pravděpodobnost	29
2.3 Geometrická pravděpodobnost	34
2.4 Statistická pravděpodobnost	35
2.5 Podmíněná pravděpodobnost a nezávislé jevy	38
2.6 Úplná pravděpodobnost a Bayesova věta	41
2.7 Opakované pokusy	44
2.7.1 Nezávislé pokusy	44
2.7.2 Závislé pokusy	47
2.8 Souhrnné příklady	49
3 Náhodná veličina	53
3.1 Rozdělení pravděpodobnosti diskrétní náhodné veličiny	55
3.2 Rozdělení pravděpodobnosti spojitě náhodné veličiny	59
3.3 Číselné charakteristiky náhodné veličiny	62
3.4 Kvantilové charakteristiky náhodné veličiny	67
4 Základní typy rozdělení pravděpodobnosti diskrétní náhodné veličiny	71
4.1 Binomické rozdělení	72
4.2 Hypergeometrické rozdělení	73
4.3 Poissonovo rozdělení	75
4.4 Řešené příklady	76
5 Základní typy rozdělení pravděpodobnosti spojitě náhodné veličiny	80

5.1	Normální rozdělení	81
5.2	Rovnoměrné rozdělení	84
5.3	Exponenciální rozdělení	85
5.4	Řešené příklady	86
6	Náhodný vektor	91
6.1	Dvourozměrný náhodný vektor	92
6.2	Řešené příklady	94
7	Statistický soubor s jedním argumentem	103
7.1	Základní pojmy a vlastnosti	104
7.2	Rozložení četností	108
7.2.1	Grafické znázornění četností	111
7.3	Charakteristiky polohy a variability	113
7.3.1	Míry polohy	113
7.3.2	Míry variability	120
7.4	Míry tvaru rozdělení	122
7.5	Řešené příklady	123
8	Statistický soubor se dvěma argumenty	128
8.1	Základní pojmy	130
8.2	Tabulkové a grafické zobrazení dvourozměrných dat	130
8.3	Míry polohy a variability pro dvourozměrný soubor	132
8.3.1	Míry polohy	132
8.3.2	Míry variability a kovariance	133
8.4	Řešené příklady	134
8.5	Kontrolní otázky	136
9	Regresní a korelační analýza	137
9.1	Princip korelační analýzy	138
9.2	Princip lineární regrese	141
9.3	Řešené příklady	144
10	Časové řady	150
10.1	Základní pojmy časových řad	152
10.2	Typy časových řad	153
10.3	Analýza časových řad	154
10.4	Charakteristiky časových řad	155
10.5	Řešené příklady	156
10.6	Softwarová analýza časových řad	157
11	Induktivní statistika	162
11.1	Odhady v induktivní statistice	165
11.1.1	Bodový a intervalový odhad průměru (střední hodnoty)	166
11.1.2	Bodový a intervalový odhad rozptylu	168
11.2	Řešené příklady	169
12	Využití softwaru při řešení statistických úloh	173
12.1	Shrnutí práce s MS Excel	174
12.2	Představení Wolfram Alpha a R	177
12.2.1	Srovnání R a Wolfram Alpha	177

12.2.2	Základní příkazy ve Wolfram Alpha	177
12.2.3	Použití R pro statistické úlohy	179
12.3	Analýza dat z externích zdrojů	180
12.3.1	Excelovské nástroje pro analýzu akcií	183
12.3.2	Načítání externích statistických dat v R	185

Seznam literatury a použitých zdrojů	188
---	------------

Seznam obrázků	189
-----------------------	------------

Seznam tabulek	190
-----------------------	------------

Úvod

Vítejte ve světě statistiky

Vítejte ve studijní opoře pro předmět *Základy statistiky*, která je určena především pro studenty bakalářského studia. Skripta vás provedou základními teoretickými pojmy a koncepty statistiky, s důrazem na praktické aplikace, které jsou nezbytné pro analýzu a zpracování dat ve vaší budoucí praxi.

Tato opora se částečně překrývá s materiály pro navazující studium. Zatímco bakalářské studium klade větší důraz na řešení příkladů a pochopení základních principů, v navazujícím studiu dochází k rozšíření témat (do hloubky i do šířky) a rozvoji praktických dovedností pro pokročilejší aplikace statistiky.

Struktura skript

Struktura těchto skript je navržena tak, aby jednotlivé kapitoly na sebe logicky navazovaly a umožnily vám postupně prohlubovat vaše znalosti. Každá kapitola rozvíjí dovednosti, které jsou potřebné pro zvládnutí pokročilejších témat v následujících částech.

- **Kombinatorika** – V této kapitole se seznámíte se základními pojmy kombinatoriky, jako jsou variace, permutace a kombinace. Znalost těchto pojmů je klíčová pro pochopení dalších kapitol, zejména pravděpodobnosti.
- **Pravděpodobnost jevů** – Po úvodu do kombinatoriky se v této kapitole naučíte základní principy pravděpodobnosti, včetně klasické a geometrické pravděpodobnosti, podmíněné pravděpodobnosti a Bayesovy věty. Tyto znalosti jsou nezbytné pro pochopení následujících statistických metod.
- **Náhodná veličina a její rozdělení** – Tato kapitola vás uvede do pojmu náhodné veličiny a jejího rozdělení pravděpodobnosti. Seznámíte se s diskrétními a spojitými typy rozdělení, jejich charakteristikami a základními příklady.
- **Základní typy rozdělení pravděpodobnosti** – V této kapitole se podrobněji zaměříte na základní typy rozdělení pravděpodobnosti, včetně binomického, hypergeometrického, Poissonova a normálního rozdělení, které jsou běžně používány v praxi.
- **Náhodný vektor** – V této kapitole se seznámíte s pojmem náhodného vektoru, tedy soustavy více náhodných veličin, a s jeho rozdělením. Naučíte se pracovat s podmíněnými rozděleními a kovariancí, což je klíčové pro analýzu vztahů mezi více náhodnými veličinami.
- **Statistický soubor a jeho analýza** – Naučíte se, jak zpracovávat data z výběrových šetření, vytvářet tabulky četností, grafy a počítat charakteristiky polohy a variability.

- **Regresní a korelační analýza** – V této kapitole se naučíte techniky, které vám umožní analyzovat vztahy mezi dvěma nebo více proměnnými. Tyto metody jsou široce využívány v praxi, například při predikci a modelování.
- **Časové řady** – Naučíte se základní metody analýzy časových řad, které jsou nezbytné pro modelování vývoje veličin v čase, jako jsou ekonomické ukazatele nebo finanční data.
- **Induktivní statistika** – Zde se seznámíte s pokročilejšími metodami statistiky, jako jsou odhady parametrů, intervalové odhady a testování hypotéz. Naučíte se, jak aplikovat tyto metody na reálná data a jak z nich činit závěry o populaci.
- **Využití statistických softwarů** – Na závěr se naučíte používat moderní statistické softwary, jako jsou MS Excel, R a Wolfram Alpha, k analýze dat a modelování reálných problémů. Kapitola zahrnuje praktické návody a příklady, jak efektivně využívat tyto nástroje.

Každá kapitola je zaměřena na konkrétní téma a obsahuje jak teoretický výklad, tak i praktické příklady, které vám umožní lépe pochopit a procvičit danou látku. Tato struktura vám poskytne pevný základ pro další studium statistiky a jejích aplikací.

Co vás v kapitolách čeká

Každá kapitola začíná úvodní částí, která vás seznámí s tím, co bude v dané kapitole probíráno. V úvodu jsou vždy vytyčeny cíle, které byste měli po jejím prostudování zvládnout. Kapitoly dále obsahují:

- **Teoretický výklad** – Vysvětlíme vám podstatu jednotlivých statistických metod, postupů a jejich aplikace.
- **Řešené příklady** – Každá kapitola obsahuje praktické příklady, které vám pomohou pochopit a procvičit si danou látku.
- **Rámečky** – Důležité informace jsou zvýrazněny v rámečcích, které obsahují klíčové body, jež byste si měli zapamatovat.
- **Shrnutí** – Na konci každé kapitoly naleznete shrnutí hlavních bodů, které vám pomůže připomenout si probíranou látku.
- **Kontrolní otázky a příklady** – Otázky na závěr kapitoly jsou vhodné pro kontrolu pochopení látky, kterou jste se právě naučili. Odpovědi na ně najdete vdané kapitole. U příkladů jsou uvedeny výsledky v hranatých závorkách, což vám umožní ověřit si správnost výpočtů.

Praktická aplikace a význam softwaru

Statistika je nástroj, který je v praxi neocenitelný, a to jak při analýze ekonomických dat, tak při řešení manažerských problémů. Ve skriptech se budeme zaměřovat nejen na teoretické znalosti, ale i na jejich praktické využití. Proto klademe důraz na řešení praktických úloh a jejich výpočty, které vám umožní lépe pochopit jednotlivé metody.

V průběhu studia zjistíte, že statistický software jako Excel a další nástroje budou vašimi skvělými pomocníky. Excel vám umožní jednoduše a efektivně řešit většinu statistických úloh, což je neocenitelná dovednost v každodenní praxi.

Pokud zvládnete i práci s R, tak své schopnosti znásobíte (koeficientem větším než 1).

Motivace a podpora

Chceme, aby pro vás byla statistika zajímavá a přínosná. Neberte ji jako obtížný předmět, ale jako výzvu, která vám otevře dveře k lepšímu porozumění světu dat a informací. Každý příklad je tu proto, aby vás připravil na reálné situace, které vás mohou čekat v profesním životě. Naším cílem je, abyste si osvojili statistiku natolik, že ji budete schopni aplikovat s jistotou a bez obav.

Nebojte se chyb ani náročných úkolů, jsme tu proto, abychom vás podpořili na vaší cestě. Statistika není nepřekonatelná překážka, ale nástroj, který vám pomůže analyzovat svět kolem vás. Věříme, že tato skripta vám budou užitečným průvodcem a že se díky nim statistika stane nejen srozumitelnou, ale i zábavnou.

Kapitola 1

Kombinatorika



Po prostudování této kapitoly budete umět:

- rozlišovat mezi variacemi, kombinacemi a permutacemi, permutace (s opakováním a bez opakování),
- rozlišovat mezi situacemi s opakováním a bez opakování,
- řešit typové příklady zahrnující uvedené pojmy.



Klíčová slova:

Kombinatorika, faktoriál, kombinační číslo, variace bez opakování, variace s opakováním, kombinace bez opakování, kombinace s opakováním, permutace bez opakování, permutace s opakováním, pravidlo součinu, pravidlo součtu, princip inkluze a exkluze.

Náhled kapitoly

V této kapitole se zaměříme na základní principy kombinatoriky, tedy metody, jak uspořádat nebo vybrat prvky z dané množiny. Budeme probírat variace, permutace a kombinace, což jsou klíčové pojmy kombinatoriky. Zjistíme, kolika způsoby lze uspořádat nebo vybrat určité prvky a jaké jsou rozdíly mezi jednotlivými metodami. Uvedeme příklady situací, kdy záleží na pořadí a kdy naopak ne. Důraz bude kladen na řešení praktických příkladů, kde si studenti procvičí použití kombinatorických principů v reálných úlohách.

Cíle kapitoly

Po prostudování této kapitoly by studenti měli být schopni:

- rozlišovat mezi variacemi, kombinacemi a permutacemi a jejich praktickým využitím,
- rozlišovat mezi situacemi s opakováním a bez opakování,
- aplikovat uvedené pojmy na různé typové příklady a řešit úlohy z kombinatoriky,

a tím se nachystat na následující kapitolu o pravděpodobnosti.

Časová náročnost

Pro zvládnutí této kapitoly se doporučuje věnovat studiu přibližně 4 hodin, což zahrnuje přečtení teoretické části, procvičení na příkladech a samostatné řešení úloh. Tento časový odhad je zaměřen na získání dostatečné praktické dovednosti při řešení kombinatorických problémů.

1.1 Základní pojmy a vlastnosti

Co je to kombinatorika?

Definice 1.1. Kombinatorika je oblast matematiky, která se zabývá studiem uspořádání, výběru a počtu prvků v množinách. Hlavním cílem kombinatoriky je zjistit, kolika způsoby lze uspořádat nebo vybrat určité prvky z dané množiny, přičemž mohou být různé podmínky, jako například to, zda záleží na pořadí prvků nebo zda se prvky mohou opakovat.

Kombinatorika se nejčastěji zabývá třemi základními problémy:

- **Variace** – Uspořádání prvků, kde záleží na pořadí.
- **Permutace** – Speciální případ variací, kdy se uspořádává celá množina prvků.
- **Kombinace** – Výběr prvků, kde na pořadí nezáleží.

Kombinatorika nachází uplatnění v mnoha oblastech, jako je teorie pravděpodobnosti, statistika, informatika, optimalizace, kryptografie a další.

Kombinatorické pravidlo součinu

Definice 1.2. Kombinatorické pravidlo součinu říká, že pokud lze určitý proces rozdělit na k po sobě jdoucích kroků, kde první krok lze provést n_1 způsoby, druhý krok n_2 způsoby, ..., a k -tý krok n_k způsoby, potom celkový počet způsobů, jak proces provést, je dán vztahem:

$$n_1 \cdot n_2 \cdot \dots \cdot n_k.$$

Příklad 1.3. V obchodě jsou na výběr 3 druhy předkrmů, 4 druhy hlavních jídel a 2 druhy dezertů. Kolik různých jídelních kombinací lze sestavit?

Řešení: Podle pravidla součinu je celkový počet možných kombinací jídla dán součinem počtu možností pro každý chod: $3 \cdot 4 \cdot 2 = 24$. $\square$

Kombinatorické pravidlo součtu

Definice 1.4. Kombinatorické pravidlo součtu říká, že pokud lze vykonat proces buď jedním z n_1 způsobů, nebo druhým z n_2 způsobů, kde tyto způsoby jsou vzájemně neslučitelné, potom celkový počet způsobů, jak proces provést, je dán součtem:

$$n_1 + n_2.$$

Příklad 1.5. V knihovně máte na výběr 5 beletristických knih a 3 odborné knihy. Kolik různých knih si můžete vybrat, pokud si můžete vzít buď beletrii, nebo odbornou knihu?

Řešení: Podle pravidla součtu je celkový počet možností dán součtem počtu možností pro každý typ knihy: $5 + 3 = 8$. $\square$

Kombinatorický princip inkluze a exkluze

Definice 1.6. Kombinatorický princip inkluze a exkluze pro n množin vyjadřuje celkový počet prvků ve sjednocení množin $A_1, A_2, \dots, A_n$ následovně:

$$|A_1 \cup A_2 \cup \dots \cup A_n| = \sum_{i=1}^n |A_i| - \sum_{1 \leq i < j \leq n} |A_i \cap A_j| + \sum_{1 \leq i < j < k \leq n} |A_i \cap A_j \cap A_k| - \dots + (-1)^{n+1} |A_1 \cap A_2 \cap \dots \cap A_n|.$$

Tento vzorec postupně přičítá velikosti jednotlivých množin, odčítá jejich průniky, přičítá průniky tří množin, atd., až do průniku všech n množin.

Speciální případ pro $n = 2$

Definice 1.7. Pro dvě množiny A_1 a A_2 je vzorec jednodušší a vypadá následovně:

$$|A_1 \cup A_2| = |A_1| + |A_2| - |A_1 \cap A_2|.$$

Příklad 1.8. V třídě je 30 studentů. 15 studentů navštěvuje kurz matematiky, 10 studentů kurz fyziky a 5 studentů oba kurzy. Kolik studentů navštěvuje alespoň jeden z těchto kurzů?

Řešení: Aplikujeme princip inkluze a exkluze pro dvě množiny:

$$|M \cup F| = |M| + |F| - |M \cap F| = 15 + 10 - 5 = 20.$$

Alespoň jeden z kurzů navštěvuje 20 studentů. □

Speciální případ pro $n = 3$

Definice 1.9. Pro tři množiny A_1, A_2 a A_3 je vzorec následující:

$$|A_1 \cup A_2 \cup A_3| = |A_1| + |A_2| + |A_3| - |A_1 \cap A_2| - |A_1 \cap A_3| - |A_2 \cap A_3| + |A_1 \cap A_2 \cap A_3|.$$

Příklad 1.10. V knihovně, v oddělení matematiky, fyziky a informatiky, je určitý počet knih. 40 z nich obsahuje kapitoly o matematice, 25 o fyzice a 35 o informatice. Dále 10 z nich je současně o matematice i fyzice, 15 o matematice i informatice, 5 o fyzice i informatice. 3 knihy pokrývají všechny tři oblasti. Kolik knih tam tedy celkově je (pokud se v něm nenacházejí žádné jiné publikace)?

Řešení: Použijeme princip inkluze a exkluze pro tři množiny:

$$|M \cup F \cup I| = |M| + |F| + |I| - |M \cap F| - |M \cap I| - |F \cap I| + |M \cap F \cap I|.$$

Po dosazení hodnot:

$$|M \cup F \cup I| = 40 + 25 + 35 - 10 - 15 - 5 + 3 = 73.$$

V oddělení je 73 knih. □

Faktoriál

Definice 1.11. Faktoriál přirozeného čísla n , označovaný $n!$, je definován pro všechna nezáporná celá čísla.

Pro ta přirozená (tedy $n > 0$) jej definujeme jako součin všech přirozených čísel, která jsou $\leq n$:

$$n! = 1 \cdot 2 \cdot 3 \cdot \dots \cdot n.$$

Pro $n = 0$ definujeme:

$$0! = 1.$$

Příklad 1.12. $5! = 5 \cdot 4 \cdot 3 \cdot 2 \cdot 1 = 120$.

Faktoriál se využívá v různých oblastech matematiky, zejména v kombinatorice pro výpočet počtu permutací, variací a kombinací.

1.2 Variace

Variace jsou uspořádané výběry z dané množiny prvků. Existují dvě varianty: variace bez opakování a variace s opakováním.

1.2.1 Variace bez opakování

Příklad 1.13. Vypište všechny uspořádané dvojice ze základní množiny prvků $\{1, a, B\}$, pokud se prvky nemohou opakovat? Kolik jich je?

Řešení: Takovým uspořádaným dvojicím také říkáme odborně „variace druhé třídy ze tří prvků bez opakování“, ale můžeme použít i „2-prvkové variace ze tří prvků bez opakování“. Jednoduše vypíšeme všechny možnosti:

$$(1, a), (a, 1), (1, B), (B, 1), (a, B), (B, a).$$

Vidíme, že je jich celkově 6. □

Použít výpis k určení celkového počtu všech variací je při větším n a k přinejmenším nepraktické. Proto si budeme uvádět užitečné vzorce.

Definice 1.14. Variace bez opakování jsou uspořádané k -prvkové výběry z n prvků, přičemž každý prvek může být vybrán pouze jednou. Počet variací k -té třídy z n prvků je:

$$V_k(n) = \frac{n!}{(n-k)!} = \underbrace{n \cdot (n-1) \cdot \dots \cdot (n-k+1)}_{k \text{ činitelů (čísel)}}.$$

Příklad 1.15. Kolik různých uspořádaných trojic můžeme vybrat z množiny $\{1, 2, 3, 4, 5\}$, pokud se prvky nemohou opakovat?

Řešení: Jedná se o variace třetí třídy z pěti prvků bez opakování. Počet možností je

$$V_3(5) = \frac{5!}{(5-3)!} = \frac{5!}{2!} = \frac{120}{2} = 60 \quad \text{nebo} \quad V_3(5) = 5 \cdot 4 \cdot 3 = 60$$

□

Příklad 1.16. Kolika způsoby lze obsadit první tři místa v závodě s 10 účastníky, pokud se o umístění nelze dělit?

Řešení: Vytváříme variace třetí třídy z 10 prvků bez opakování:

$$V_3(10) = \frac{10!}{(10-3)!} = \frac{10 \cdot 9 \cdot 8 \cdot 7!}{7!} = \frac{10 \cdot 9 \cdot 8}{1} = \underbrace{10 \cdot 9 \cdot 8}_{k=3 \text{ čísla od } 10=n} = 720.$$

□

1.2.2 Variace s opakováním

Definice 1.17. Variace s opakováním jsou uspořádané k -prvkové výběry z n prvků, přičemž prvky se mohou opakovat (mohou být opakovaně vybrány). Počet variací k -té třídy z n prvků s opakováním je:

$$V_k^*(n) = n^k = \underbrace{n \cdot n \cdot \dots \cdot n}_{k \text{ činitelů } (n)}.$$

Příklad 1.18. Kolik různých trojčiferných čísel lze vytvořit pomocí cifer 1, 2, 3, 4, 5, pokud se cifry mohou opakovat?

Řešení: Jedná se o variace s opakováním, takže:

$$V_3^*(5) = 5^3 = 125.$$

□

Příklad 1.19. Kolik různých čtyřmístných PIN kódů lze vytvořit, pokud každé místo může obsahovat cifru od 0 do 9 a cifry se mohou opakovat?

Řešení: Jedná se o variace s opakováním, kde $n = 10$ a $k = 4$:

$$V_4^*(10) = 10^4 = 10000.$$

□

Příklad 1.20. Kolik různých značek lze vytvořit v Morseově abecedě, pokud se sestavují z teček a čárek do skupin po jedné až třech znacích?

Řešení: Použijeme kombinatorické pravidlo součtu, neboť si úlohu rozdělíme na tři nepřekrývající se případy skupin po jednom ($k = 1$), dvou ($k = 2$) a třech ($k = 3$) znacích.

Základní množina, ze které (opakovaně) vybíráme má dva znaky, tečku a čárku ($n = 2$).

Situaci zvládneme i přímo rozepsat:

- **Délka 1** (2 možnosti): $V_1^*(2) = 2^1 = 2$
·, –
- **Délka 2** (4 možnosti): $V_2^*(2) = 2^2 = 4$
··, ·–, –·, ––
- **Délka 3** (8 možností): $V_3^*(2) = 2^3 = 8$
···, ··–, ·–·, ·––, –··, –·–, ––·, –––

Celkový počet možností je tedy

$$V_1^*(2) + V_2^*(2) + V_3^*(2) = 2^1 + 2^2 + 2^3 = 2 + 4 + 8 = 14.$$

□

1.3 Permutace

Permutace jsou uspořádané výběry ze všech prvků dané množiny (speciální případ variací, kdy $k = n$). Opět rozlišujeme permutace bez opakování a permutace s opakováním.

1.3.1 Permutace bez opakování

Definice 1.21. Permutace bez opakování jsou uspořádání všech prvků dané množiny, kde každý prvek se vyskytuje pouze jednou. Pokud máme n prvků, počet jejich permutací bez opakování je dán vztahem:

$$P(n) = n!.$$

Příklad 1.22. Vypište všechny permutace základní množiny prvků $\{1, a, B\}$ (prvky jsou různé, tudíž se neopakují)? Odpovídá jejich počet vzorci?

Řešení: Jednoduše vypíšeme všechny možnosti:

$$(1, a, B), (a, 1, B), (1, B, a), (B, 1, a), (a, B, 1), (B, a, 1).$$

Vidíme, že je jich celkově 6, což odpovídá vzorci $P(3) = 3! = 6$. □

Příklad 1.23. Kolik různých způsobů lze uspořádat 6 knih na polici?

Řešení: Jedná se o permutace šesti prvků:

$$P(6) = 6! = 720.$$

□

1.3.2 Permutace s opakováním

Definice 1.24. Permutace s opakováním nastávají v situaci, kdy některé prvky základní množiny nejsou jedinečné, tedy se opakují. Pokud máme n prvků, kde se určitý prvek opakuje n_1 -krát, jiný prvek n_2 -krát a tak dále až po n_k -krát, pak počet všech možných uspořádání (permutací) těchto prvků je dán vzorcem:

$$P_{n_1, n_2, \dots, n_k}^*(n) = \frac{n!}{n_1! \cdot n_2! \cdot \dots \cdot n_k!},$$

kde $n = n_1 + n_2 + \dots + n_k$ je celkový počet prvků a $n_1, n_2, \dots, n_k$ jsou počty opakování jednotlivých prvků.

Tento vzorec zohledňuje, že přeuspořádání opakujících se prvků nevede k novým permutacím.

Příklad 1.25. Vypište všechny permutace základní množiny prvků $\{1, a, a\}$ (prvek a se opakuje, tudíž jde o permutace s opakováním)? Odpovídá jejich počet vzorci?

Řešení: Jednoduše vypíšeme všechny možnosti:

$$(1, a, a), (a, 1, a), (a, a, 1).$$

Vidíme, že jsou jen 3, což při označení $n_1 = 1$ (počet opakování prvku „1“), $n_2 = 2$ (počet opakování prvku „a“) a $n = n_1 + n_2 = 1 + 2 = 3$, odpovídá vzorci $P_{1,2}^*(3) = \frac{3!}{1! \cdot 2!} = \frac{6}{2} = 3$. □

Příklad 1.26. Kolik různých šesticiferných čísel lze vytvořit z číslic 1, 1, 2, 2, 2, 3?

Řešení: V této množině se číslice opakují, takže počet permutací je:

$$P_{2,3,1}^*(6) = \frac{6!}{2! \cdot 3! \cdot 1!} = \frac{720}{12} = 60.$$

□

Příklad 1.27 (Uspořádání písmen ve slově). Kolik různých uspořádání písmen lze vytvořit ze všech deseti písmen slova *STATISTIKA*?

Řešení: Slovo *STATISTIKA* má celkem 10 písmen, přičemž se některá písmena opakují:

$$S \text{ (2x)} \ n_1 = 2, \quad T \text{ (3x)} \ n_2 = 3, \quad A \text{ (2x)} \ n_3 = 2, \quad I \text{ (2x)} \ n_4 = 2, \quad K \text{ (1x)} \ n_5 = 1.$$

Počet všech možných uspořádání (permutací) je dán vzorcem pro permutace s opakováním:

$$P_{2,3,2,2,1}^*(10) = \frac{10!}{2! \cdot 3! \cdot 2! \cdot 2! \cdot 1!} = \frac{3\,628\,800}{2 \cdot 6 \cdot 2 \cdot 2 \cdot 1} = \frac{3\,628\,800}{48} = 75\,600.$$

Celkem lze vytvořit 75 600 různých uspořádání písmen. □

Příklad 1.28 (Tvorba šperků). Máme k dispozici 8 korálků, z nichž 4 jsou červené, 3 modré a 1 zelený. Kolik různých náhrdelníků lze vytvořit z těchto korálků, pokud nezáleží na pořadí, v jakém jsou jednotlivé korálky stejné barvy umístěny?

Řešení: Jedná se o permutace s opakováním, protože korálky stejné barvy jsou nerozlišitelné. Celkový počet korálků je 8, z toho 4 červené, 3 modré a 1 zelený. Počet možných uspořádání korálků je dán vzorcem:

$$P_{4,3,1}^*(8) = \frac{8!}{4! \cdot 3! \cdot 1!} = \frac{40\,320}{24 \cdot 6 \cdot 1} = \frac{40\,320}{144} = 280.$$

Lze tedy vytvořit 280 různých náhrdelníků. □

1.4 Kombinace

Kombinace jsou výběry prvků z dané množiny, při kterých nezáleží na pořadí. Rozlišujeme kombinace bez opakování a kombinace s opakováním.

Kombinační číslo

Pojem kombinačního čísla má dlouhou historii, která sahá až do starověké matematiky. Kombinační čísla byla poprvé popsána ve starověké Indii a Číně, kde se používala pro výpočty pravděpodobností a astrologických předpovědí. Ve středověké Evropě se kombinační čísla objevila v dílech matematiků, jako byl Blaise Pascal, který je studoval ve spojitosti se známým Pascalovým trojúhelníkem. Pascalův trojúhelník je geometrickým zobrazením kombinačních čísel a představuje jeden z nejznámějších způsobů, jak tato čísla zobrazit a použít v praxi.

V moderní matematice se kombinační čísla stala základem kombinatoriky, teorie pravděpodobnosti a statistiky.

Definice 1.29. Kombinační číslo, označované jako $\binom{n}{k}$, vyjadřuje počet možných způsobů, jak vybrat k prvků z množiny n prvků, pokud nezáleží na pořadí a každý prvek může být vybrán pouze jednou.

Vzorec pro výpočet kombinačního čísla je dán vztahem:

$$\binom{n}{k} = \frac{n!}{k!(n-k)!}$$

kde n je celkový počet prvků a k je počet vybraných prvků.

Příklad 1.30. Vypočítejte kombinační číslo $\binom{7}{3}$.

Řešení: Podle vzorce pro kombinační číslo:

$$\binom{7}{3} = \frac{7!}{3!(7-3)!} = \frac{7 \cdot 6 \cdot 5 \cdot 4!}{3!4!} = \frac{7 \cdot 6 \cdot 5}{3 \cdot 2 \cdot 1} = \frac{210}{6} = 35.$$

□

1.4.1 Kombinace bez opakování

Definice 1.31. Kombinace bez opakování je výběr k prvků z množiny n prvků, kde na pořadí nezáleží a každý prvek může být vybrán pouze jednou. Počet takových kombinací je dán vztahem:

$$C_k(n) = \binom{n}{k} = \frac{n!}{k!(n-k)!},$$

kde n je celkový počet prvků a k je počet vybraných prvků.

Příklad 1.32. Najděte všechny kombinace druhé třídy bez opakování z množiny $M = \{1, 2, 3, 4, 5\}$.

Řešení: Použijeme vzorec pro kombinace bez opakování. Počet kombinací druhé třídy bez opakování z 5 prvků je:

$$C_2(5) = \binom{5}{2} = \frac{5!}{2!(5-2)!} = \frac{5 \cdot 4}{2} = 10.$$

Vypíšeme všechny kombinace:

$$\{1, 2\}, \{1, 3\}, \{1, 4\}, \{1, 5\}, \{2, 3\}, \{2, 4\}, \{2, 5\}, \{3, 4\}, \{3, 5\}, \{4, 5\}.$$

Celkem tedy existuje 10 různých kombinací druhé třídy bez opakování.

□

Příklad 1.33. Kolik různých pětičlenných týmů lze vybrat ze skupiny 12 studentů?

Řešení: Jedná se o kombinace bez opakování, protože na pořadí členů týmu nezáleží a každý student může být vybrán pouze jednou. Počet kombinací je dán vztahem:

$$C_5(12) = \binom{12}{5} = \frac{12!}{5!(12-5)!} = \frac{12 \cdot 11 \cdot 10 \cdot 9 \cdot 8}{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1} = 792.$$

Celkově lze tedy vybrat 792 různých pětičlenných týmů. □

Příklad 1.34. Kolika různými způsoby lze vybrat 3 knihy z police, která obsahuje 7 různých knih?

Řešení: V tomto případě také pracujeme s kombinacemi bez opakování, protože pořadí vybraných knih není důležité. Počet kombinací je:

$$C_3(7) = \binom{7}{3} = \frac{7!}{3!(7-3)!} = \frac{7 \cdot 6 \cdot 5}{3 \cdot 2 \cdot 1} = 35.$$

Lze tedy vybrat 35 různých trojic knih. □

Příklad 1.35. Kolika způsoby lze sestavit výbor složený ze 4 mužů a 3 žen, pokud máme k dispozici 8 mužů a 5 žen?

Řešení: Nejdříve vybereme 4 muže z 8 mužů:

$$C_4(8) = \binom{8}{4} = \frac{8 \cdot 7 \cdot 6 \cdot 5}{4 \cdot 3 \cdot 2 \cdot 1} = 70.$$

Poté vybereme 3 ženy z 5 žen:

$$C_3(5) = \binom{5}{3} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = 10.$$

Celkový počet různých způsobů, jak sestavit výbor, je tedy:

$$C_4(8) \cdot C_3(5) = 70 \cdot 10 = 700.$$

□

1.4.2 Kombinace s opakováním

Definice 1.36. Kombinace s opakováním jsou výběry k prvků z n různých prvků, kde je dovoleno, aby se jednotlivé prvky opakovaly. Na rozdíl od kombinací bez opakování zde nezáleží na pořadí a zároveň se mohou prvky vyskytovat vícekrát.

Počet kombinací s opakováním k -té třídy z n prvků je dán vzorcem:

$$C_k^*(n) = \binom{n+k-1}{k} = \frac{(n+k-1)!}{k!(n-1)!}$$

Příklad 1.37. Najděte všechny kombinace druhé třídy s opakováním z množiny $M = \{1, 2, 3, 4, 5\}$.

Řešení: Použijeme vzorec pro kombinace s opakováním. Počet kombinací druhé třídy s opakováním z 5 prvků je:

$$C_2^*(5) = \binom{5+2-1}{2} = \binom{6}{2} = \frac{6 \cdot 5}{2} = 15.$$

Vypíšeme všechny kombinace: $\{1, 1\}, \{1, 2\}, \{1, 3\}, \{1, 4\}, \{1, 5\}, \{2, 2\}, \{2, 3\}, \{2, 4\}, \{2, 5\}, \{3, 3\}, \{3, 4\}, \{3, 5\}, \{4, 4\}, \{4, 5\}, \{5, 5\}$.

Celkem tedy existuje 15 různých kombinací druhé třídy s opakováním. □

Příklad 1.38. Kolika způsoby lze vybrat 4 bonbóny ze 3 různých druhů, pokud nezáleží na pořadí a mohou se opakovat?

Řešení: Jedná se o kombinace s opakováním, kde $n = 3$ a $k = 4$:

$$C_4^*(3) = \binom{3+4-1}{4} = \binom{6}{4} = 15.$$

□

Příklad 1.39. Kolika způsoby lze rozdělit 10 jablek mezi 3 děti, pokud každé dítě může dostat libovolný počet jablek?

Řešení: Jedná se o kombinace s opakováním, kde $n = 3$ a $k = 10$:

$$C_{10}^*(3) = \binom{3+10-1}{10} = \binom{12}{10} = 66.$$

□

Příklad 1.40. Kolika způsoby lze rozdělit 8 identických bonbónů mezi 4 děti?

Řešení: Jedná se o kombinace s opakováním, kde $n = 4$ a $k = 8$:

$$C_8^*(4) = \binom{4+8-1}{8} = \binom{11}{8} = 165.$$

□

Příklad 1.41. Kolika způsoby lze vybrat 6 květů z 5 druhů, pokud se mohou opakovat?

Řešení: Jedná se o kombinace s opakováním, kde $n = 5$ a $k = 6$:

$$C_6^*(5) = \binom{5+6-1}{6} = \binom{10}{6} = 210.$$

□

Příklad 1.42. Zjistěte, kolik existuje různých kvádrů, pro něž platí, že délka každé jejich hrany je přirozené číslo z intervalu $[2; 5]$, přičemž nezáleží na pořadí stran.

Řešení: Jedná se o kombinace s opakováním, protože nezáleží na pořadí délek stran kvádrů. Pro každou stranu lze vybrat délku z množiny $\{2, 3, 4, 5\}$, což je výběr z 4 různých hodnot.

Počet kombinací třetí třídy (tři strany kvádrů) z těchto čtyř prvků s opakováním je dán vzorcem pro kombinace s opakováním:

$$C_3^*(4) = \binom{3+4-1}{3} = \binom{6}{3} = \frac{6 \cdot 5 \cdot 4}{3 \cdot 2 \cdot 1} = 20.$$

Počet různých kvádrů, pro něž platí, že délka každé jejich hrany je přirozené číslo z intervalu $[2; 5]$, je tedy 20. □

1.4.3 Souhrnné příklady

Příklad 1.43. Jsou dány cifry 1, 2, 3, 4, 5. Cifry nelze opakovat. Kolik je možno vytvořit z těchto cifer čísel, která jsou:

- a) pětímístná, sudá,
- b) pětímístná, končící dvojčíslím 21,
- c) pětímístná, menší než 30 000,
- d) trojmístná lichá,
- e) čtyřmístná, větší než 2 000,
- f) dvojmístná nebo trojmístná.

Řešení: **ad a)** Sudá - to v tomto případě znamená, že číslo končí ciframi 2 nebo 4 (XXXX2, XXXX4) - tzn. dvě možnosti. Na zbývajících čtyřech pozicích permutují zbývajících čtyři cifry, takže výsledek:

$$2 \cdot P(4) = 48.$$

ad b) Máme číslo XXX21. Tedy na třech pozicích permutují tři cifry:

$$P(3) = 6.$$

ad c) Menší než 30 000, to jsou čísla začínající ciframi 1 nebo 2, tedy dvě možnosti. Na zbývajících čtyřech pozicích permutují zbývajících čtyři cifry:

$$2 \cdot P(4) = 48.$$

ad d) Lichá, tedy končí ciframi 1, 3, 5 - tři možnosti. Na zbývajících dvou pozicích se mohou vyskytovat některé ze zbývajících čtyř cifer, přičemž záleží na pořadí - jedná se o variace druhé třídy ze čtyř prvků:

$$3 \cdot V_2(4) = 36.$$

ad e) Obdobně jako u předchozích:

$$4 \cdot V_3(4) = 96.$$

ad f)

$$V_2(5) + V_3(5) = 80.$$

□

Příklad 1.44. Kolik různých státních poznávacích značek 4M9 XX-XX existuje s aspoň dvěma trojkami (na místě čtyř X mohou být jen číslice)?

Řešení: Aspoň dvě trojky, to jsou 2, 3 nebo 4 trojky. Začneme nejjednodušší možností:

4 trojky: Tzn. jediná možnost 4M9 33-33, takže:

$$x_4 = 1$$

3 trojky: Existují 4 možnosti, jak seskládat tři trojky na čtyřech pozicích (333X, 33X3, 3X33, X333). Obecně to lze vyjádřit jako počet permutací 4 prvků s opakováním, přičemž trojka se opakuje třikrát:

Dále existuje 9 možností (zbývajících devět cifer), které mohou být na čtvrté pozici. Obecně lze vyjádřit např. jako počet variací první třídy z devíti prvků:

$$V_1(9) = 9$$

Takže výsledný počet pro 3 trojky:

$$x_3 = P^*(4) \cdot V_1(9) = 4 \cdot 9 = 36$$

2 trojky: Existuje opět $P^*(4)$ možností, jak seskládat dvě trojky na čtyři pozice, přičemž tentokrát se trojka opakuje dvakrát a zbývající dvě pozice nerozlišujeme mezi sebou, takže se také dvakrát opakují (33XX, 3X3X, 3XX3, X33X, X3X3, XX33):

Na zbývajících dvou pozicích se může střídat zbývajících devět cifer, přičemž v dané dvojici záleží na pořadí cifer a cifry se mohou i opakovat. To se dá vyjádřit jako počet variací druhé třídy z devíti prvků s opakováním:

$$V_2^*(9) = 9^2 = 81$$

Takže výsledný počet pro 2 trojky:

$$x_2 = P^*(4) \cdot V_2^*(9) = 6 \cdot 81 = 486$$

Tzn., že počet státních poznávacích značek 4M9 XX-XX s aspoň dvěma trojkami je:

$$x = x_4 + x_3 + x_2 = 1 + 36 + 486 = 523$$

□

Σ

V této kapitole jsme se podrobně seznámili s kombinatorikou, což je oblast matematiky, která se zabývá výběrem a uspořádáním prvků v množinách. Probírali jsme různé druhy uspořádání a výběrů prvků: variace, permutace a kombinace. Dále jsme rozlišovali mezi situacemi, kdy se prvky mohou opakovat, a kdy se neopakují.

Hlavní kombinatorické techniky, které jsme se naučili, zahrnují:

- **Variace** – Uspořádané výběry prvků s ohledem na pořadí. Rozlišujeme variace s opakováním a bez opakování.
- **Permutace** – Uspořádání všech prvků množiny. Rozlišujeme permutace s opakováním a bez opakování.
- **Kombinace** – Výběry prvků, kde nezáleží na pořadí. Rozlišujeme kombinace s opakováním a bez opakování.
- **Kombinatorické pravidlo součinu** – Používáme, pokud je proces rozdělen na několik kroků.
- **Kombinatorické pravidlo součtu** – Používáme, pokud je výběr možný z více neslučitelných možností.
- **Princip inkluze a exkluze** – Používá se k výpočtu počtu prvků ve sjednocení několika množin, zohledňující průniky mezi množinami.



1. Státní poznávací značku tvoří dvě písmena, tři číslice a další dvě písmena (formát AAXXXAA, kde A je písmeno a X číslice). Kolik různých značek lze vytvořit, pokud můžeme vybírat z 25 písmen a 10 číslic? [390 625 000]
2. Kolik různých šestimístných čísel lze sestavit z cifer 1, 2 a 3, pokud se cifry mohou opakovat? [729]
3. Na MHD se kdysi používaly lístky s devíti čtverečky označenými čísly 1 až 9. Po nastoupení cestující zasunul lístek do strojku, který prodírkoval tři nebo čtyři z nich (specificky pro dané vozidlo a den). Kolik je různých způsobů prodírkování lístku? [210]
4. Kolika způsoby může sedět v kině sedm kamarádů (A, B, C, D, E, F, G) na sedadlech 1 až 7 tak, aby kamarád B seděl na sedadle č. 4 a kamarád G na sedadle č. 2? [120]
5. Do tanečního kroužku přišlo 24 chlapců a 15 dívek. Kolik různých párů lze vytvořit, pokud pár tvoří vždy dvojice chlapec-dívka? [360]
6. Ve třídě je 20 žáků. Kolika způsoby lze vybrat dvojici pro týdenní službu? [190]
7. Kolik hráčů se zúčastnilo turnaje ve stolním tenise, pokud se v dvouhře odehrálo 21 utkání a každý hráč hrál s každým právě jednou? [7]
8. Ve třídě je 20 dívek a 15 chlapců. Kolik různých pětičlenných hlídek na branné závody lze vytvořit, pokud v každé hlídce mají být 3 dívky a 2 chlapci? [119 700]
9. Hokejové družstvo má 20 hráčů: 13 útočníků, 5 obránců a 2 brankáře. Kolik různých sestav může trenér vytvořit, pokud sestava má obsahovat 3 útočníky, 2 obránce a 1 brankáře? [5 720]
10. Učitel má k dispozici 20 aritmetických a 30 geometrických úloh. Na písemné práci mají být dvě aritmetické a tři geometrické úlohy. Kolik má učitel možností k vytvoření písemné práce? [771 400]
11. Ze 7 mužů a 4 žen máme vytvořit 6člennou skupinu, ve které mají být 3 ženy. Kolika způsoby lze takovou skupinu vytvořit? [140]
12. Učitel má vybrat na recitační soutěž tři studenty ze třídy 3.A a dva studenty ze třídy 3.B. V 3.A je 22 studentů a v 3.B je 17 studentů. Kolik má učitel možností výběru? [209 440]
13. Kolik existuje způsobů, jak uspořádat sedadla pro kamarády A, B, C, D a E tak, aby kamarád A seděl vedle kamaráda C? [48]
14. Latinská abeceda má 26 písmen. Kolik různých 6písmenných „slov“ lze vytvořit, pokud písmena mohou být opakována? [308 915 776]
15. Státní poznávací značku tvoří 7 znaků. Na prvních třech pozicích může být číslice nebo písmeno, na zbývajících čtyřech jen číslice. Kolik různých značek lze vytvořit, pokud použijeme 28 písmen a 10 číslic? [548 720 000]
16. Na hodině tělesné výchovy stojí v řadě 5 dívek, z nichž dvě jsou sestry. Kolika způsoby lze rozestavit dívky tak, aby sestry stály vedle sebe? [48]



Literatura k tématu:

- [1] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [2] CALDA, E., DUPAČ, V. (2008). Matematika pro gymnázia: Kombinatorika, pravděpodobnost, statistika (5. vydání, dotisk 2011). Praha: Prometheus. ISBN 978-80-7196-365-3.

Kapitola 2

Pravděpodobnost jevů



Po prostudování této kapitoly budete umět:

- objasnit pojmy náhodný pokus, náhodný jev, operace s jevy a jejich aplikace,
- představit klasickou a geometrickou pravděpodobnost,
- řešit typové úlohy z oblasti pravděpodobnosti.



Klíčová slova:

Náhodný pokus, náhodný jev, klasická pravděpodobnost, geometrická pravděpodobnost, operace s jevy, podmíněná pravděpodobnost, nezávislé jevy, úplná pravděpodobnost, Bayesova věta.

Náhled kapitoly

V této kapitole se zaměříme na základní principy pravděpodobnosti, které tvoří jádro teorie pravděpodobnosti a slouží jako základ pro statistické analýzy. Probereme definice náhodných jevů, náhodného pokusu a klasické pravděpodobnosti. Budeme se věnovat také operacím s jevy, jako je sjednocení, průnik a doplněk. Dále si představíme podmíněnou pravděpodobnost a nezávislé jevy, což jsou klíčové koncepty při analýze složitějších náhodných událostí. Kapitola zahrnuje příklady z reálného světa, kde je třeba vypočítat pravděpodobnosti na základě známých jevů.

Cíle kapitoly

Po prostudování této kapitoly by studenti měli být schopni:

- rozlišovat mezi různými druhy náhodných jevů a aplikovat jejich definice,
- používat klasickou a geometrickou pravděpodobnost pro řešení praktických úloh,
- vypočítat podmíněnou pravděpodobnost a rozhodnout o nezávislosti jevů,
- řešit úlohy s použitím Bayesovy věty a úplné pravděpodobnosti.

Časová náročnost

Pro zvládnutí této kapitoly se doporučuje věnovat studiu přibližně 5 hodin, včetně procvičení praktických příkladů a samostatného řešení úloh.

2.1 Základní pojmy

Definice 2.1. Náhodný pokus je proces, jehož výsledek není jistý a může nabývat různých hodnot v závislosti na náhodě. Náhodný pokus lze opakovat za stejných podmínek, avšak jeho výsledek se může pokaždé lišit. Příkladem náhodného pokusu je hod kostkou, kde nevíme, jaké číslo padne, nebo losování míčku z osudí. Výsledky náhodného pokusu tvoří množinu *možných výsledků*, kterou nazýváme **prostor elementárních jevů**.

Definice 2.2. Náhodný jev je podmnožina prostoru elementárních jevů, která zahrnuje jeden nebo více možných výsledků náhodného pokusu. Náhodný jev tedy nastává, pokud výsledek náhodného pokusu spadá do této podmnožiny.

Například při hodu kostkou můžeme definovat náhodný jev A , že padne sudé číslo. V tomto případě je náhodný jev $A = \{2, 4, 6\}$, protože tyto výsledky odpovídají sudým číslům.

Druhy náhodných jevů

Definice 2.3. • **Jev jistý** – Jev, který nastane vždy, tj. obsahuje všechny možné výsledky náhodného pokusu. Jeho pravděpodobnost je 1. Například při hodu kostkou je jevem jistým, že padne číslo mezi 1 a 6.

$$P(J) = 1$$

- **Jev nemožný** – Jev, který nikdy nenastane, tj. neobsahuje žádný výsledek náhodného pokusu. Jeho pravděpodobnost je 0. Například při hodu klasickou kostkou je nemožným jevem, že padne číslo 7.

$$P(\emptyset) = 0$$

- **Jev elementární** – Jev, který obsahuje právě jeden možný výsledek náhodného pokusu. Například při hodu kostkou je elementárním jevem A , že padne číslo 3: $A = \{3\}$.
- **Jev složený** – Jev, který obsahuje více než jeden možný výsledek náhodného pokusu. Například při hodu kostkou může být složeným jevem B , že padne sudé číslo, což zahrnuje výsledky $B = \{2, 4, 6\}$.
- **Jev opačný (doplněk jevu)** – Jev, který nastane tehdy, když nenastane zadaný jev. Opačný jev k jevu A se označuje jako A^c . Například při hodu kostkou, pokud je jev A , že padne číslo 3, je jev A^c jevem, že padne jakékoli číslo jiné než 3, tedy $A^c = \{1, 2, 4, 5, 6\}$.
- **Neslučitelné (disjunktní) jevy** – Dva jevy jsou neslučitelné, pokud nemohou nastat současně. To znamená, že nemají žádný společný výsledek. Například při hodu kostkou jsou jevy A , že padne sudé číslo, a B , že padne liché číslo, neslučitelné: $A \cap B = \emptyset$.
- **Slučitelné jevy** – Dva jevy jsou slučitelné, pokud mohou nastat současně. To znamená, že mají alespoň jeden společný výsledek. Například při hodu kostkou jsou jevy A , že padne číslo menší než 4, a B , že padne sudé číslo, slučitelné, protože $A \cap B = \{2\}$.

2.2 Klasická pravděpodobnost

Definice 2.4. Při splnění níže uvedených předpokladů definujeme **klasickou pravděpodobnost** jako

$$P(A) = \frac{\text{Počet příznivých výsledků}}{\text{Celkový počet možných výsledků}}.$$

Předpoklady klasické pravděpodobnosti:

1. **Konečný počet možných výsledků:** Předpokládá se, že jev má konečný počet možných výsledků (elementárních jevů), které jsou všechny jasně definovány a lze je spočítat.
2. **Stejná pravděpodobnost všech výsledků:** Každý z možných výsledků je stejně pravděpodobný. To znamená, že žádný výsledek není preferován nebo diskriminován, což je klíčový předpoklad této definice. Například při hodu férovou kostkou má každá strana stejnou šanci padnout.
3. **Určitelnost jevů:** Všechny možné výsledky (elementární jevy) jsou dopředu známy a lze je spočítat. V praxi to znamená, že prostor elementárních jevů je jasně definovaný a každý výsledek je předem určitelný.
4. **Nezávislost pokusů:** Pokud klasickou pravděpodobnost aplikujeme na opakované pokusy (např. hody kostkou), předpokládá se, že jednotlivé pokusy jsou na sobě nezávislé – výsledek jednoho pokusu neovlivňuje výsledky dalších pokusů.

Tyto předpoklady omezují klasickou pravděpodobnost na situace, kde je možné zaručit stejné šance všech výsledků a kde je počet možných výsledků konečný a jasně definovaný.

Příklad 2.5. Klasickým příkladem náhodného pokusu je hod hrací kostkou. Budeme si na něm ilustrovat koncept náhodného pokusu a jevu.

Řešení: • Náhodný pokus: hod hrací kostkou

- Elementární jevy: „padne 1“ ... E_1 , „padne 2“ ... E_2 , ... „padne 6“ ... E_6
- Jevy $E_1, E_2, \dots, E_6$ vymezují základní prostor Ω . V tomto základním prostoru mohou být například následující jevy:
 - Náhodný jev A : „padne liché číslo“ ... $A = E_1 + E_3 + E_5$
 - Náhodný jev B : „padne číslo ≥ 4 “ ... $B = E_4 + E_5 + E_6$
 - Jev nemožný: „padne číslo > 6 “
 - Jev jistý: „padne číslo < 7 “
 - Neslučitelné jevy: „padne sudé číslo“ a „padne liché číslo“

□

Příklad 2.6. Při hodu kostkou určete pravděpodobnost jevů:

- a) jev A : „padne číslo 5“
- b) jev B : „padne číslo ≤ 2 “

Řešení: ad a) Pravděpodobnost jevu A :

$$P(A) = \frac{1}{6}.$$

ad b) Pravděpodobnost jevu B :

$$P(B) = \frac{2}{6} = \frac{1}{3}.$$

□

Příklad 2.7. S jakou pravděpodobností padne na dvou kostkách součet:

- a) šest,
- b) menší než 7?

Řešení: ad a) Šestka padne v následujících případech:

1. kostka	2. kostka
1	5
5	1
2	4
4	2
3	3

Tedy existuje 5 možností. Počet všech možností je $n = 6 \times 6 = 36$.

Pravděpodobnost:

$$P(\text{součet } 6) = \frac{5}{36}.$$

ad b) Součet menší než 7 může být:

Součet	Možnosti
5	(1, 4), (4, 1), (2, 3), (3, 2)
4	(1, 3), (3, 1), (2, 2)
3	(1, 2), (2, 1)
2	(1, 1)

Celkový počet možností je 15.

Pravděpodobnost:

$$P(\text{součet menší než } 7) = \frac{15}{36} = \frac{5}{12}.$$

□

Příklad 2.8. V cele předběžného zadržení sedí vedle sebe 10 podezřelých, z toho 3 ženy. Jaká je pravděpodobnost, že všechny tři ženy sedí vedle sebe?

Řešení: Počet možností, jak uspořádat 10 podezřelých, odpovídá počtu permutací z 10 prvků:

$$n = 10!.$$

Pokud všechny tři ženy sedí vedle sebe, můžeme je chápat jako jeden „blok“. Tento „blok“ lze umístit na 8 různých pozic (např. na pozice 1-2-3, 2-3-4, ..., 8-9-10). Uvnitř „bloku“ mohou být ženy uspořádány 3! způsoby. Zbývajících 7 podezřelých může být uspořádáno 7! způsoby.

Celkový počet příznivých uspořádání:

$$m = 8 \times 3! \times 7! = 8 \times 6 \times 7!.$$

Pravděpodobnost:

$$P = \frac{m}{n} = \frac{8 \times 6 \times 7!}{10!} = \frac{8 \times 6}{10 \times 9 \times 8} = \frac{1}{15}.$$

□

Příklad 2.9. Stanovte pravděpodobnost jevu, že z 10 náhodně vytažených bridžových karet budou alespoň 3 esa. (bridžové karty: 52 karet celkem, z toho 4 esa)

Řešení: Jev A – vybereme alespoň 3 esa znamená, že vybereme 3 nebo 4 esa. Tento jev se rozkládá na součet dvou navzájem disjunktních jevů:

$$A = A_1 + A_2,$$

kde

- A_1 : vybereme 3 esa,
- A_2 : vybereme 4 esa.

Pravděpodobnost:

$$P(A) = P(A_1) + P(A_2).$$

Výpočty jednotlivých pravděpodobností provedeme pomocí kombinací:

$$P(A_1) = \frac{\binom{4}{3} \times \binom{48}{7}}{\binom{52}{10}},$$

$$P(A_2) = \frac{\binom{4}{4} \times \binom{48}{6}}{\binom{52}{10}}.$$

Hledaná pravděpodobnost $P(A)$ je součtem těchto hodnot. □

Příklad 2.10. Při slosování sportky je z osudí postupně vylosováno 6 čísel ze 49. Po vylosování těchto čísel je ze zbývajících 43 čísel vylosováno dodatkové číslo. Při správném tipování:

- a) šesti čísel získává sázející výhru 1. pořadí,
- b) pěti čísel a dodatkového čísla ($5 + 1$) získává sázející výhru 2. pořadí,
- c) pěti čísel získává sázející výhru 3. pořadí,
- d) čtyř čísel získává sázející výhru 4. pořadí,
- e) tří čísel získává sázející výhru 5. pořadí.

Vypočítejte pravděpodobnost, se kterou při vsazeném jednom sloupci vyhrajete v 1. tahu výhry a) až e).

Řešení: ad a) Pravděpodobnost uhodnutí všech 6 čísel:

$$P(6 \text{ čísel}) = \frac{1}{\binom{49}{6}} = \frac{1}{13\,983\,816}.$$

ad b) Pravděpodobnost uhodnutí 5 čísel a dodatkového čísla:

$$P(5 + 1 \text{ číslo}) = \frac{\binom{6}{5} \times \binom{1}{1} \binom{42}{0}}{\binom{49}{6}} = \frac{6}{13\,983\,816}.$$

ad c) Pravděpodobnost uhodnutí 5 čísel:

$$P(5 \text{ čísel}) = \frac{\binom{6}{5} \times \binom{43}{1}}{\binom{49}{6}} = \frac{258}{13\,983\,816}.$$

ad d) Pravděpodobnost uhodnutí 4 čísel:

$$P(4 \text{ čísel}) = \frac{\binom{6}{4} \times \binom{43}{2}}{\binom{49}{6}}.$$

ad e) Pravděpodobnost uhodnutí 3 čísel:

$$P(3 \text{ čísel}) = \frac{\binom{6}{3} \times \binom{43}{3}}{\binom{49}{6}}.$$

□

2.3 Geometrická pravděpodobnost

Definice 2.11. Geometrická pravděpodobnost je pravděpodobnostní model, kde se pravděpodobnost určuje jako poměr dvou délek, ploch nebo objemů. Používá se v situacích, kdy náhodný pokus závisí na kontinuu, tedy na čase, délce nebo ploše.

Matematicky se geometrická pravděpodobnost počítá jako:

$$P(A) = \frac{\text{velikost příznivé oblasti}}{\text{velikost celkové oblasti}}$$

Kde:

- $P(A)$ je pravděpodobnost výskytu jevu A ,
- "příznivá oblast" je část celkové oblasti, kde nastane jev A ,
- "celková oblast" je celý prostor možných výsledků.

Geometrická pravděpodobnost se často používá v úlohách zahrnujících náhodné umístění bodu v oblasti, jako je například úsečka nebo kruh.

Příklad 2.12. Jak je pravděpodobné, že meteorit padne na pevninu, víme-li, že pevnina má rozlohu 149 milionů km^2 a moře 361 milionů km^2 ?

Řešení: Celková plocha povrchu Země je:

$$S = 149 + 361 = 510 \text{ milionů km}^2.$$

Pravděpodobnost, že meteorit padne na pevninu, je dána podílem rozlohy pevniny a celkové rozlohy povrchu Země:

$$P(\text{pevnina}) = \frac{149}{510} \approx 0.2922.$$

□

Příklad 2.13. Představte si kruh o poloměru 10 cm, ve kterém je vyznačena menší kruhová oblast s poloměrem 5 cm. Jaká je pravděpodobnost, že náhodně vybraný bod v kruhu spadne do této menší oblasti?

Řešení: Nejprve vypočítáme plochy obou kruhů. Plocha většího kruhu je

$$S_{\text{větší}} = \pi \times 10^2 = 100\pi \text{ cm}^2,$$

zatímco plocha menšího kruhu je

$$S_{\text{menší}} = \pi \times 5^2 = 25\pi \text{ cm}^2.$$

Pravděpodobnost, že náhodně vybraný bod spadne do menšího kruhu, je pak dána jako poměr ploch:

$$P(\text{menší kruh}) = \frac{S_{\text{menší}}}{S_{\text{větší}}} = \frac{25\pi}{100\pi} = 0,25.$$

□

Příklad 2.14. Dva známí se domluví, že se sejdou na určitém místě mezi 15. a 16. hodinou, přičemž doba čekání je 20 minut. Jaká je pravděpodobnost, že se při této dohodě setkají?

Řešení: Označme: - x jako čas po 15. hodině, kdy přijde první osoba, - y jako čas po 15. hodině, kdy přijde druhá osoba.

Podmínka pro setkání je $|x - y| \leq 20$ minut. Celkový časový interval je 60 minut.

Geometricky jde o výpočet obsahu příznivé oblasti v jednotkovém čtverci 60×60 (v minutách). Příznivá oblast je obdélník vymezený rovnicí $|x - y| \leq 20$.

Celková plocha čtverce:

$$|\Omega| = 60 \times 60 = 3600 \text{ minut}^2.$$

Příznivá plocha:

$$|A| = 3600 - (40 \times 40) = 2000 \text{ minut}^2.$$

Pravděpodobnost setkání je:

$$P(\text{setkání}) = \frac{|A|}{|\Omega|} = \frac{2000}{3600} \approx 0.5556.$$

□

2.4 Statistická pravděpodobnost

Definice 2.15. Statistickou pravděpodobnost definujeme jako relativní četnost, s jakou určitý jev nastává v dlouhodobém opakování experimentu. Její výpočet se odvozuje z pozorovaných dat a lze ji vyjádřit vztahem

$$P(A) = \lim_{n \rightarrow \infty} \frac{\text{Počet výskytů jevu } A}{\text{Celkový počet pokusů}}.$$

Předpoklady statistické pravděpodobnosti:

1. **Opakovatelnost experimentu:** Pokus, při kterém je zkoumán jev, lze opakovat za stejných podmínek mnohokrát.
2. **Stabilní výsledky při velkém počtu pokusů:** S narůstajícím počtem pokusů se relativní četnost výskytu daného jevu stabilizuje a blíží se určité hodnotě. Tato hodnota je považována za pravděpodobnost jevu.
3. **Nezávislost pokusů:** Jednotlivé pokusy jsou na sobě nezávislé, což znamená, že výsledek jednoho pokusu nemá vliv na výsledky dalších pokusů.
4. **Dostatečně velký počet pokusů:** Statistická pravděpodobnost má smysl pouze v situacích, kdy je k dispozici velký počet pokusů nebo měření. Relativní četnost se totiž stabilizuje až po dostatečně velkém počtu opakování.

Statistická pravděpodobnost je vhodná pro situace, kdy máme k dispozici data z opakovaných pokusů a můžeme na základě těchto dat odhadovat pravděpodobnost výskytu různých jevů.

Aplikace v různých situacích

Statistickou pravděpodobnost lze aplikovat jak v diskrétních, tak spojitých situacích, a to s určitými rozdíly:

- **Diskrétní konečná situace:** V případě konečného počtu možných výsledků (např. hod kostkou) lze statistickou pravděpodobnost odhadnout z relativních četností jednotlivých výsledků v řadě pokusů. Například pokud házíme kostkou 100krát, počet, kolikrát padne číslo 6, se může stabilizovat kolem hodnoty $\frac{1}{6}$.
- **Diskrétní nekonečná situace:** Pokud má náhodná veličina nekonečně mnoho možných hodnot, ale tyto hodnoty jsou diskrétní (např. počet zákazníků přicházejících do obchodu za den), pak se pravděpodobnostní model zaměřuje na odhad pravděpodobností jednotlivých hodnot nebo jejich intervalů pomocí četností. Zde může být například důležité určit, jak často během jednoho dne přijde do obchodu přesně 10 zákazníků, nebo třeba víc jak 50.
- **Spojitá situace:** U spojitých náhodných veličin (např. výška náhodně vybraného člověka) nelze přímo určit pravděpodobnost, že náhodná veličina nabude konkrétní hodnoty (např. přesně 170 cm), protože tato pravděpodobnost je prakticky nulová. Namísto toho se pracuje s pravděpodobností, že náhodná veličina spadne do určitého intervalu, např. že výška člověka bude mezi 170 a 175 cm. Pravděpodobnost se odhaduje na základě relativních četností hodnot spadajících do těchto intervalů a k modelování se používají hustoty pravděpodobnosti.

V závislosti na povaze náhodné veličiny a situace, ve které pracujeme, se způsob aplikace statistické pravděpodobnosti mění. Zatímco u diskrétních situací lze snadno spočítat četnosti jednotlivých hodnot, u spojitých situací musíme pracovat s intervaly hodnot a hustotami pravděpodobnosti.

Příklad 2.16 (spojitý případ). Sledujme dobu, po kterou se zákazníci zdržují v obchodě. Čas pobytu byl zaznamenán a rozdělen do intervalů o délce 5 minut. Data o četnostech pro jednotlivé intervaly jsou shrnuta v následující tabulce:

Tab. 1: Četnosti zdržení se zákazníků v obchodě (intervaly 5 minut)

Interval (min)	Četnost
0-5	77
5-10	83
10-15	25
15-20	15
Celkem	200

Určete jednotlivé statistické pravděpodobnosti.

Řešení: Z tabulky je zřejmé, že celkem bylo sledováno 200 zákazníků. Nyní spočítáme statistické pravděpodobnosti pro jednotlivé intervaly na základě relativních četností.

- $P(0-5 \text{ minut}) = \frac{77}{200} = 0,385,$
- $P(5-10 \text{ minut}) = \frac{83}{200} = 0,415,$
- $P(10-15 \text{ minut}) = \frac{25}{200} = 0,125,$
- $P(15-20 \text{ minut}) = \frac{15}{200} = 0,075.$

Rozdělení statistické pravděpodobnosti pro intervaly času zdržení se zákazníků v obchodě je tedy následující:

- Pravděpodobnost, že se zákazník zdrží v obchodě mezi 0 a 5 minutami, je 0,385.
- Pravděpodobnost, že se zákazník zdrží mezi 5 a 10 minutami, je 0,415.
- Pravděpodobnost, že se zákazník zdrží mezi 10 a 15 minutami, je 0,125.
- Pravděpodobnost, že se zákazník zdrží mezi 15 a 20 minutami, je 0,075.

Celkové rozdělení pravděpodobnosti je vytvořeno (odhadnuto) z relativních četností, které vyjadřují pravděpodobnosti pro jednotlivé intervaly. Toto rozdělení můžeme použít k modelování délky pobytu zákazníků v obchodě. $\square$

2.5 Podmíněná pravděpodobnost a nezávislé jevy

Podmíněná pravděpodobnost

Definice 2.17. Podmíněná pravděpodobnost je pravděpodobnost jevu A za předpokladu, že nastal jev B . Označuje se $P(A|B)$ a je definována jako:

$$P(A|B) = \frac{P(A \cap B)}{P(B)}, \quad \text{pokud } P(B) > 0.$$

Tento koncept je užitečný v mnoha praktických situacích, například při odhadu pravděpodobnosti úspěchu produktu na trhu, pokud víme, že byl úspěšný v podobném segmentu.

Nezávislé jevy

Definice 2.18. Nezávislé jevy jsou takové jevy, jejichž výskyt jeden druhého neovlivňuje. To znamená, že pravděpodobnost výskytu jednoho jevu neovlivňuje pravděpodobnost výskytu druhého jevu. Pokud jsou dva jevy A a B nezávislé, pak platí následující rovnost:

$$P(A \cap B) = P(A) \cdot P(B).$$

Tato rovnost říká, že pravděpodobnost současného výskytu jevů A a B (jejich průniku) je součinem pravděpodobností jednotlivých jevů. Nezávislost je důležitý koncept, který se často vyskytuje v reálných situacích, například při opakovaných náhodných pokusech, jako je házení kostkou nebo mincí. V těchto případech výsledek jednoho hodu neovlivňuje výsledek následujících hodů, a proto jsou tyto pokusy nezávislé.

Skupinově nezávislé jevy

Definice 2.19. Jevy A , B a C jsou **skupinově nezávislé**, jestliže platí následující podmínky:

- **Nezávislost po dvou:** Každá dvojice jevů musí být nezávislá, což znamená, že pro všechny dvojice jevů platí:

$$P(A \cap B) = P(A) \cdot P(B),$$

$$P(A \cap C) = P(A) \cdot P(C),$$

$$P(B \cap C) = P(B) \cdot P(C).$$

- **Nezávislost po třech:** Pro tři jevy zároveň musí platit, že průnik všech tří jevů odpovídá součinu jejich pravděpodobností:

$$P(A \cap B \cap C) = P(A) \cdot P(B) \cdot P(C).$$

Pokud jsou splněny všechny tyto podmínky, říkáme, že jevy A , B a C jsou skupinově nezávislé. Tato vlastnost je klíčová v situacích, kde analyzujeme souběh více nezávislých jevů, a je využívána v pravděpodobnostních modelech, jako je například rozklad nezávislých náhodných veličin.

Příklad 2.20. Házíme dvěma mincemi. Určete pravděpodobnost jevu:

- A : padne líc a rub,
- B : na první minci padne líc.

Určete pravděpodobnost jevu A za předpokladu, že nastal jev B .

Řešení: Možné výsledky hodu jsou:

1. mince	2. mince
LÍC	LÍC
LÍC	RUB
RUB	LÍC
RUB	RUB

Pravděpodobnost jevu A (líc a rub) za předpokladu, že na první minci padl líc (jev B):

Použijeme vzorec pro podmíněnou pravděpodobnost:

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

Jev $A \cap B$ nastane, pokud padne líc na první minci a rub na druhé minci, což je jedna možnost z celkových 4, tedy $P(A \cap B) = \frac{1}{4}$. Pravděpodobnost jevu B (líc na první minci) je $P(B) = \frac{1}{2}$.

Proto:

$$P(A | B) = \frac{\frac{1}{4}}{\frac{1}{2}} = \frac{1}{2}.$$

□

Příklad 2.21. Studenti při zkoušení mohou dostat tři otázky. První student je připraven pouze na první otázku, druhý umí pouze druhou otázku, třetí ovládá jen třetí otázku a čtvrtý je připraven na všechny tři otázky. Uvažujme nyní tyto jevy:

- A_1 : vyvolaný student dokáže zodpovědět první otázku,
- A_2 : vyvolaný student dokáže zodpovědět druhou otázku,
- A_3 : vyvolaný student dokáže zodpovědět třetí otázku.

Ukažte, že jevy A_1, A_2, A_3 jsou po dvou nezávislé, ale nejsou vzájemně nezávislé (jako trojice).

Řešení: Pravděpodobnosti jednotlivých jevů:

$$P(A_1) = P(A_2) = P(A_3) = \frac{2}{4} = 0,5.$$

Nyní uvažujme pravděpodobnosti průniků dvojic jevů:

$$P(A_1 \cap A_2) = P(A_1 \cap A_3) = P(A_2 \cap A_3) = \frac{1}{4} = 0,25.$$

Protože $P(A_i \cap A_j) = P(A_i) \times P(A_j) = 0,5 \times 0,5 = 0,25$ pro $i \neq j$, jsou jevy A_1, A_2, A_3 po dvou nezávislé.

Nicméně, pro vzájemnou nezávislost by muselo platit, že:

$$P(A_1 \cap A_2 \cap A_3) = P(A_1) \times P(A_2) \times P(A_3) = 0,5 \times 0,5 \times 0,5 = 0,125.$$

Ale ve skutečnosti:

$$P(A_1 \cap A_2 \cap A_3) = \frac{1}{4} = 0,25.$$

Proto nejsou jevy A_1, A_2, A_3 vzájemně nezávislé.

□

2.6 Úplná pravděpodobnost a Bayesova věta

Úplná pravděpodobnost

Definice 2.22. Zákon úplné pravděpodobnosti umožňuje vypočítat pravděpodobnost jevu na základě rozkladu prostoru jevů na několik disjunktních (vzájemně neslučitelných) událostí. Tento zákon využíváme zejména tehdy, když pravděpodobnost jevu závisí na několika různých scénářích (podmínkách), které tvoří úplný prostor možných výsledků.

Formálně lze úplnou pravděpodobnost jevu A vyjádřit jako:

$$P(A) = P(A \cap B_1) + P(A \cap B_2) + \cdots + P(A \cap B_n),$$

kde $B_1, B_2, \dots, B_n$ jsou vzájemně neslučitelné události, které tvoří úplný prostor (tedy $B_1 \cup B_2 \cup \cdots \cup B_n = \Omega$).

Použijeme-li pravidlo pro podmíněnou pravděpodobnost, můžeme tento vztah upravit:

$$P(A) = P(B_1) \cdot P(A | B_1) + P(B_2) \cdot P(A | B_2) + \cdots + P(B_n) \cdot P(A | B_n),$$

kde $P(A | B_i)$ je podmíněná pravděpodobnost jevu A za podmínky, že nastal jev B_i .

Zákon úplné pravděpodobnosti nám tedy umožňuje vypočítat pravděpodobnost složitých jevů tím, že je rozdělíme na dílčí podmíněné pravděpodobnosti.

Příklad 2.23. V obchodě jsou tři pokladny, na nichž dojde k chybě v účtování s pravděpodobnostmi 0,1, 0,05 a 0,2. Z hlediska umístění pokladen v obchodě jsou pravděpodobnosti odbavení pokladnami 0,3, 0,25 a 0,45. Jaká je pravděpodobnost, že osoba opouštějící obchod má chybný účet?

Řešení: Označme:

- A : jev, že došlo k chybě v účtování,
- H_i : jev, že zákazník byl obsloužen na i -té pokladně, kde $i = 1, 2, 3$.

Potom hledáme pravděpodobnost $P(A)$, kterou můžeme vyjádřit jako:

$$P(A) = P(A \cap H_1) + P(A \cap H_2) + P(A \cap H_3).$$

Protože jevy H_1 , H_2 a H_3 jsou vzájemně neslučitelné, platí:

$$P(A) = P(H_1) \cdot P(A | H_1) + P(H_2) \cdot P(A | H_2) + P(H_3) \cdot P(A | H_3).$$

Dosadíme:

$$P(A) = 0,3 \times 0,1 + 0,25 \times 0,05 + 0,45 \times 0,2.$$

Po výpočtu dostaneme:

$$P(A) = 0,03 + 0,0125 + 0,09 = 0,1325.$$

Pravděpodobnost, že zákazník má chybný účet, je tedy 0,1325. □

Bayesova věta

Definice 2.24. Bayesova věta je užitečný nástroj v pravděpodobnostní teorii, který umožňuje přepočítat podmíněnou pravděpodobnost jevu za předpokladu, že máme dodatečnou informaci. Vychází z pravidla pro výpočet podmíněné pravděpodobnosti a umožňuje nám přepočítat pravděpodobnost příčiny za předpokladu, že známe důsledek. Matematicky je Bayesova věta vyjádřena následovně:

$$P(B_i | A) = \frac{P(A | B_i) \cdot P(B_i)}{\sum_{j=1}^n P(A | B_j) \cdot P(B_j)},$$

kde $P(B_i | A)$ je pravděpodobnost jevu B_i za předpokladu, že nastal jev A , $P(A | B_i)$ je podmíněná pravděpodobnost jevu A , pokud nastal jev B_i , a $P(B_i)$ je pravděpodobnost jevu B_i . Jmenovatel představuje celkovou pravděpodobnost výskytu jevu A .

Bayesova věta se často používá v situacích, kde potřebujeme zpětně upravit pravděpodobnost určité příčiny na základě nových pozorování.

Příklad 2.25 (Bayesova věta). V obchodě jsou tři pokladny, přičemž pravděpodobnost chyby v účtování na pokladnách je následující: na první pokladně 0,1, na druhé 0,05 a na třetí 0,2. Pravděpodobnosti odbavení zákazníků jednotlivými pokladnami jsou 0,3, 0,25 a 0,45. Pokud dojde k chybě v účtování, jaká je pravděpodobnost, že k ní došlo na třetí pokladně?

Řešení: Použijeme Bayesovu větu. Označme:

- A — jev, že došlo k chybě,
- B_3 — jev, že zákazník byl obsloužen na třetí pokladně.

Chceme vypočítat $P(B_3 | A)$, tedy pravděpodobnost, že chyba nastala na třetí pokladně za předpokladu, že chyba nastala.

Podle Bayesovy věty:

$$P(B_3 | A) = \frac{P(A | B_3) \cdot P(B_3)}{P(A | B_1) \cdot P(B_1) + P(A | B_2) \cdot P(B_2) + P(A | B_3) \cdot P(B_3)}.$$

Dosadíme známé hodnoty:

$$P(B_3 | A) = \frac{0,2 \times 0,45}{0,1 \times 0,3 + 0,05 \times 0,25 + 0,2 \times 0,45}.$$

Vypočítáme:

$$P(B_3 | A) = \frac{0,09}{0,03 + 0,0125 + 0,09} = \frac{0,09}{0,1325} \approx 0,6792.$$

Výsledek: Pravděpodobnost, že chyba v účtování nastala na třetí pokladně, pokud víme, že chyba nastala, je přibližně 67,92%. $\square$

Poznámka 2.26. Tento příklad ukazuje, jak Bayesova věta umožňuje přepočítat pravděpodobnost příčiny (pokladna, kde došlo k chybě) na základě nového důkazu (chyba v účtování). Pomocí známých pravděpodobností chyby na jednotlivých pokladnách a pravděpodobností odbavení zákazníků lze zpětně vypočítat pravděpodobnost, že chyba nastala právě na třetí pokladně.

Příklad 2.27 (Pozitivní lékařský test). Prevalence výskytu AIDS v populaci je 0,6 %. Pro odhalení nemoci se používá test, který s pravděpodobností 99,9 % je pozitivní, je-li dotyčná osoba nakažená (tzv. senzitivita testu), a s pravděpodobností 99 % je negativní, je-li daná osoba zdravá (tzv. specifita testu). Jaká je pravděpodobnost, že osoba, která měla pozitivní test, má skutečně AIDS?

Řešení: Tento příklad řešíme pomocí **Bayesovy věty**, která nám umožňuje spočítat zpětnou pravděpodobnost, že osoba, která měla pozitivní test, je skutečně nakažená.

Označme:

- $P(A)$ - pravděpodobnost, že osoba má AIDS (prevalence v populaci): $P(A) = 0,006$,
- $P(\bar{A})$ - pravděpodobnost, že osoba nemá AIDS: $P(\bar{A}) = 1 - P(A) = 0,994$,
- $P(T^+|A)$ - pravděpodobnost pozitivního testu, pokud má osoba AIDS (senzitivita): $P(T^+|A) = 0,999$,
- $P(T^+|\bar{A})$ - pravděpodobnost pozitivního testu, pokud osoba nemá AIDS (chybovost, tedy $1 - \text{specifita}$): $P(T^+|\bar{A}) = 1 - 0,99 = 0,01$.

Bayesova věta nám umožňuje vypočítat pravděpodobnost, že osoba má AIDS za předpokladu, že měla pozitivní test, tedy $P(A|T^+)$. Tento vztah je dán vzorcem:

$$P(A|T^+) = \frac{P(T^+|A) \cdot P(A)}{P(T^+|A) \cdot P(A) + P(T^+|\bar{A}) \cdot P(\bar{A})}.$$

Dosadíme hodnoty:

$$P(A|T^+) = \frac{0,999 \times 0,006}{0,999 \times 0,006 + 0,01 \times 0,994}.$$

Vypočítáme jednotlivé členy:

$$P(A|T^+) = \frac{0,005994}{0,005994 + 0,00994} = \frac{0,005994}{0,015934} \approx 0,376.$$

Odpověď: Pravděpodobnost, že osoba, která měla pozitivní test, skutečně má AIDS, je přibližně 37,6 %. $\square$

2.7 Opakované pokusy

Definice 2.28. Opakované pokusy představují situace, kdy se experiment, při kterém sledujeme určitý jev, opakuje vícekrát za stejných podmínek. Při takových pokusech nás zajímá, jak se chovají pravděpodobnosti jednotlivých jevů v závislosti na počtu pokusů.

2.7.1 Nezávislé pokusy

Definice 2.29. Nezávislé opakované pokusy jsou takové, kde výsledek jednoho pokusu nemá žádný vliv na výsledky dalších pokusů. To znamená, že pravděpodobnost daného jevu zůstává ve všech pokusech stejná.

Klasickým příkladem je opakovaný hod mincí, kde pravděpodobnost líce či rubu zůstává konstantní. Nezávislé pokusy se často vyskytují v hazardních hrách (např. opakované hody kostkou, losování v loterii) nebo v testech spolehlivosti výrobků, kde zkoušíme nezávislé vzorky na stejné podmínky. Pokud máme například n nezávislých pokusů s pravděpodobností úspěchu p , celková pravděpodobnost, že jev nastane přesně k -krát, je dána binomickým rozdělením.

Definice 2.30 (Bernoulliho schéma). Mějme posloupnost n nezávislých dichotomických pokusů. V každém dílčím pokuse může nastat jev A (úspěch) s pravděpodobností p . Pravděpodobnost, že nastalo právě k úspěchů, je rovna:

$$P(A_k) = \binom{n}{k} p^k q^{n-k}, \quad k = 0, 1, 2, \dots, n,$$

kde $q = 1 - p$ je pravděpodobnost neúspěchu.

Nejpravděpodobnější počet úspěchů

Nejpravděpodobnější počet úspěchů k je takový, že splňuje nerovnici:

$$p \cdot (n + 1) - 1 \leq k \leq p \cdot (n + 1).$$

Příklad 2.31. Házíme šestkrát kostkou. Vypočítejte pravděpodobnost, že z těchto šesti hodů padne šestka právě dvakrát.

Řešení: Tato úloha spadá do oblasti binomického rozdělení. Označme:

- $p = \frac{1}{6}$: pravděpodobnost, že padne šestka při jednom hození,
- $k = 2$: počet úspěchů (padnutí šestky),
- $n = 6$: počet pokusů.

Pravděpodobnost $P(k)$, že padne šestka právě dvakrát, je dána vzorcem pro binomické rozdělení:

$$P(k) = \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k}.$$

Dosadíme:

$$P(2) = \binom{6}{2} \cdot \left(\frac{1}{6}\right)^2 \cdot \left(\frac{5}{6}\right)^4.$$

Po výpočtu dostaneme:

$$P(2) = 15 \cdot \frac{1}{36} \cdot \frac{625}{1296} \approx 0,0729.$$

Pravděpodobnost, že z šesti hodů padne šestka právě dvakrát, je přibližně 0,0729. □

Příklad 2.32. Sportovní střelec zasáhne cíl při každém výstřelu s pravděpodobností $p = 0,8$. Vypočítejte pravděpodobnost, že při 5 výstřelech budou v cíli:

1. právě 2 zásahy,
2. nejvýše jeden zásah,
3. alespoň 2 zásahy.

Řešení: 1. Pravděpodobnost právě 2 zásahů:

$$\begin{aligned} P(X = 2) &= \binom{5}{2} \cdot p^2 \cdot (1-p)^{5-2}, \\ P(X = 2) &= \binom{5}{2} \cdot (0,8)^2 \cdot (0,2)^3 \\ &= \frac{5 \cdot 4}{2 \cdot 1} \cdot 0,64 \cdot 0,008 \\ &= 10 \cdot 0,64 \cdot 0,008 = 0,0512. \end{aligned}$$

Odpověď: Pravděpodobnost právě 2 zásahů je 0,0512.

2. Pravděpodobnost nejvýše jednoho zásahu:

$$\begin{aligned} P(X \leq 1) &= P(X = 0) + P(X = 1), \\ P(X = 0) &= \binom{5}{0} \cdot (0,8)^0 \cdot (0,2)^5 = 1 \cdot 1 \cdot 0,00032 = 0,00032, \\ P(X = 1) &= \binom{5}{1} \cdot (0,8)^1 \cdot (0,2)^4 = 5 \cdot 0,8 \cdot 0,0016 = 0,0064, \\ P(X \leq 1) &= 0,00032 + 0,0064 = 0,00672. \end{aligned}$$

Odpověď: Pravděpodobnost nejvýše jednoho zásahu je 0,00672.

3. Pravděpodobnost alespoň dvou zásahů:

$$P(X \geq 2) = 1 - P(X \leq 1),$$

$$P(X \geq 2) = 1 - 0,00672 = 0,99328.$$

Odpověď: Pravděpodobnost alespoň dvou zásahů je 0,99328.

□

Příklad 2.33. Pravděpodobnost, že náhodně vybraný student bude znát učivo, je 0,05. Jaká je pravděpodobnost, že mezi dvaceti vybranými studenty bude:

- a) právě 5 znalých studentů,
- b) nejvýše 2 znalí studenti,
- c) alespoň jeden znalý student?

Řešení: Tato úloha opět spadá do oblasti binomického rozdělení. Označme:

- $p = 0,05$: pravděpodobnost, že náhodně vybraný student zná učivo,
- $n = 20$: počet pokusů (studentů).

a) Pravděpodobnost, že mezi 20 studenty bude právě 5 znalých:

$$P(5) = \binom{20}{5} \cdot (0,05)^5 \cdot (0,95)^{15},$$

$$P(5) = \frac{20!}{5!(20-5)!} \cdot (0,05)^5 \cdot (0,95)^{15},$$

$$P(5) = 15504 \cdot 0,0000003125 \cdot 0,46329 = 0,00225.$$

Pravděpodobnost, že mezi 20 studenty bude právě 5 znalých, je 0,00225.

b) Pravděpodobnost, že mezi 20 studenty budou nejvýše 2 znalí:

$$P(\text{nejvýše } 2) = P(0) + P(1) + P(2),$$

$$P(0) = \binom{20}{0} \cdot (0,05)^0 \cdot (0,95)^{20} = 1 \cdot 1 \cdot (0,95)^{20} = 0,35849,$$

$$P(1) = \binom{20}{1} \cdot (0,05)^1 \cdot (0,95)^{19} = 20 \cdot 0,05 \cdot 0,37735 = 0,37735,$$

$$P(2) = \binom{20}{2} \cdot (0,05)^2 \cdot (0,95)^{18} = \frac{20 \cdot 19}{2} \cdot 0,0025 \cdot 0,39759 = 0,18846,$$

$$P(\text{nejvýše } 2) = 0,35849 + 0,37735 + 0,18846 = 0,9243.$$

Pravděpodobnost, že mezi 20 studenty budou nejvýše 2 znalí, je 0,9243.

c) Pravděpodobnost, že mezi 20 studenty bude alespoň jeden znalý:

$$P(\text{alespoň } 1) = 1 - P(0),$$

$$P(\text{alespoň } 1) = 1 - 0,35849 = 0,64151.$$

Pravděpodobnost, že mezi 20 studenty bude alespoň jeden znalý, je 0,64151.

□

2.7.2 Závísle pokusy

Definice 2.34. Závísle opakované pokusy jsou takové, kde výsledek jednoho pokusu ovlivňuje pravděpodobnost výsledku dalších pokusů. To znamená, že pravděpodobnosti se mohou měnit v závislosti na předchozích výsledcích.

Příkladem může být výběr kuliček z urny bez vrácení, kde po každém výběru se mění počet kuliček a tím i pravděpodobnosti jednotlivých výsledků. Takové situace často nastávají v situacích, kde dochází k postupnému výběru bez nahrazování, například při losování cen, kontrolách kvality, či simulacích, kde jsou výsledky závislé na předchozích výběrech. V těchto situacích je důležité brát v úvahu změny v prostoru možných výsledků při každém dalším pokusu.

Definice 2.35 (Výběr bez vrácení). Mějme soubor N prvků, z nichž M má sledovanou vlastnost. Postupně vybereme bez vrácení n prvků. Pravděpodobnost, že vybereme k prvků, které mají sledovanou vlastnost, je rovna:

$$P(A_k) = \frac{\binom{M}{k} \binom{N-M}{n-k}}{\binom{N}{n}}, \quad k = 0, 1, \dots, n.$$

Příklad 2.36. V osudí jsou 2 bílé a 3 černé koule. Vypočítejte pravděpodobnost toho, že:

- a) vytáhneme naráz 3 koule a budou 2 černé a 1 bílá,
- b) vytáhneme po jedné bez vrácení 2 černé a 1 bílou.

Řešení: ad a) Pravděpodobnost vytáhnutí 2 černých a 1 bílé koule:

Použijeme kombinace:

$$P = \frac{\binom{3}{2} \times \binom{2}{1}}{\binom{5}{3}} = \frac{3 \times 2}{10} = \frac{6}{10} = 0,6.$$

ad b) Pravděpodobnost, že vytáhneme po jedné bez vrácení 2 černé a 1 bílou v pořadí ČBČ:

Možnosti jsou následující:

- ČBČ,
- ČČB,
- BČČ.

Každá z těchto možností má stejnou pravděpodobnost:

$$P(\check{C}B\check{C}) = \frac{3}{5} \times \frac{2}{4} \times \frac{2}{3} = \frac{1}{5}.$$

Celková pravděpodobnost pro všechny tři možnosti je:

$$P = 3 \times \frac{1}{5} = 0,6.$$

□

Příklad 2.37. Mezi 15 výrobky je 5 zmetků. Vybereme 3 výrobky. Jaká je pravděpodobnost, že jeden z nich je vadný, jestliže:

- a) vybereme všechny 3 najednou,
- b) vybíráme po jednom bez vracení.

Řešení: ad a) Pravděpodobnost, že 1 z 3 vybraných výrobků je vadný:

Použijeme kombinace:

$$P = \frac{\binom{5}{1} \times \binom{10}{2}}{\binom{15}{3}}.$$

ad b) Pravděpodobnost, že při postupném vybírání (bez vracení) bude 1 z 3 vybraných výrobků vadný:

Možnosti jsou následující:

- VDD,
- DVD,
- DDV.

Každá z těchto možností má vlastní pravděpodobnost:

$$P(\text{VDD}) = \frac{5}{15} \times \frac{10}{14} \times \frac{9}{13},$$

a podobně pro další dvě možnosti.

Celková pravděpodobnost:

$$P = P(\text{VDD}) + P(\text{DVD}) + P(\text{DDV}).$$

□

2.8 Souhrnné příklady

Příklad 2.38. Mějme pět vstupenek po 100 Kč, tři vstupenky po 300 Kč a dvě vstupenky po 500 Kč. Vyberme náhodně tři vstupenky. Určete pravděpodobnost toho, že:

- a) alespoň dvě z těchto vstupenek mají stejnou hodnotu,
- b) všechny tři vstupenky stojí dohromady 700 Kč.

Řešení: ad a) Budeme řešit pomocí opačného jevu. Opačný jev k „alespoň dvě mají stejnou hodnotu“ je „každá má jinou hodnotu“. Počet možností, jak vybrat tři vstupenky s různými hodnotami, je:

$$P(\text{žádné stejné hodnoty}) = \frac{\binom{5}{1} \times \binom{3}{1} \times \binom{2}{1}}{\binom{10}{3}}.$$

Pravděpodobnost opačného jevu:

$$P(\text{alespoň dvě stejné hodnoty}) = 1 - P(\text{žádné stejné hodnoty}).$$

ad b) Všechny tři vstupenky stojí dohromady 700 Kč. To může nastat v následujících případech:

1. Jedna vstupenka za 100 Kč a dvě vstupenky po 300 Kč.
2. Dvě vstupenky po 100 Kč a jedna za 500 Kč.

Pravděpodobnost je dána součtem pravděpodobností těchto dvou případů:

$$P(\text{celkem 700 Kč}) = \frac{\binom{5}{1} \times \binom{3}{2}}{\binom{10}{3}} + \frac{\binom{5}{2} \times \binom{2}{1}}{\binom{10}{3}}.$$

□

Příklad 2.39. Z celkové produkce závodu jsou 4 % zmetků a z dobrých výrobků je 75 % standardních. Určete pravděpodobnost, že náhodně vybraný výrobek je standardní.

Řešení: Označme:

- A : vybraný výrobek není zmetek,
- B : vybraný výrobek je standardní.

Víme, že:

$$P(A) = 1 - 0,04 = 0,96, \quad P(B | A) = 0,75.$$

Hledaná pravděpodobnost je:

$$P(A \cap B) = P(A) \times P(B | A) = 0,96 \times 0,75 = 0,72.$$

Pravděpodobnost, že náhodně vybraný výrobek je standardní, je tedy 0,72.

□

Příklad 2.40. Z výrobků určitého druhu dosahuje 95 % předepsanou kvalitu. V určitém závodě, který vyrábí 80 % celkové produkce, má předepsanou kvalitu 98 % výrobků. Mějme náhodně vybraný výrobek předepsané kvality. Jaká je pravděpodobnost, že byl vyroben ve výše uvedeném závodě?

Řešení: Označme:

- A : výrobek je vyroben ve zmíněném závodě,
- B : výrobek je předepsané kvality.

Hledáme $P(A | B)$. Použijeme Bayesovu větu:

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

Víme, že:

$$P(A) = 0,8, \quad P(B | A) = 0,98.$$

Dále musíme spočítat $P(B)$, tedy pravděpodobnost, že výrobek je předepsané kvality:

$$P(B) = P(B | A) \times P(A) + P(B | \bar{A}) \times P(\bar{A}),$$

kde $P(\bar{A}) = 0,2$ a $P(B | \bar{A}) = 0,95$. Dosadíme:

$$P(B) = 0,98 \times 0,8 + 0,95 \times 0,2 = 0,784 + 0,19 = 0,974.$$

Hledaná pravděpodobnost je tedy:

$$P(A | B) = \frac{0,98 \times 0,8}{0,974} \approx 0,805.$$

Pravděpodobnost, že výrobek předepsané kvality pochází ze zmíněného závodu, je přibližně 0,805. $\square$

Σ

V této kapitole jsme se seznámili se základními principy pravděpodobnosti a jejími aplikacemi na různé typy jevů. Hlavními pojmy, které jsme probírali, jsou:

- **Náhodný pokus** – Proces, jehož výsledek závisí na náhodě a nelze jej jednoznačně předpovědět. Například hod kostkou nebo slosování.
- **Náhodný jev** – Každý výsledek nebo skupina výsledků náhodného pokusu. Může jít o jednoduché jevy, jako například padnutí konkrétního čísla při hodu kostkou, nebo složené jevy, které zahrnují více možností.
- **Klasická pravděpodobnost** – Pravděpodobnost daného jevu se definuje jako podíl počtu příznivých případů k celkovému počtu možných případů, pokud jsou všechny stejně pravděpodobné. Například pravděpodobnost, že při hodu kostkou padne šestka, je $\frac{1}{6}$.

- **Geometrická pravděpodobnost** – Používá se v situacích, kdy náhodný pokus závisí na kontinuu (např. délka, plocha, objem). Pravděpodobnost se určuje jako poměr dvou délek, ploch nebo objemů.
- **Podmíněná pravděpodobnost** – Pravděpodobnost výskytu jevu za předpokladu, že jiný jev již nastal. Tento koncept se často používá v situacích, kdy výsledky jsou závislé na určitých podmínkách.
- **Nezávislost jevů** – Dva jevy jsou nezávislé, pokud výskyt jednoho jevu neovlivňuje pravděpodobnost výskytu druhého jevu.
- **Úplná pravděpodobnost a Bayesova věta** – Umožňují vypočítat pravděpodobnost jevů v situacích, kdy máme více možných scénářů a potřebujeme vzít v úvahu všechny možné cesty vedoucí k danému výsledku.

Kapitola zahrnovala také praktické příklady, kde jsme aplikovali výše uvedené koncepty. Naučili jsme se, jak řešit složitější problémy s využitím Bayesovy věty a podmíněné pravděpodobnosti. Tato kapitola poskytla důkladný úvod do teorie pravděpodobnosti a jejího praktického využití.



1. Máme 230 výrobků, mezi nimiž je 20 nekvalitních. Vybereme 15 výrobků, přičemž vybrané výrobky nevracíme zpět. Jaká je pravděpodobnost, že mezi 15 vybranými bude 10 dobrých? [0,00448]
2. Pacient se léčí doma a od 7 do 20 hod. je možné jej kontrolovat. Vycházky má od 13 do 15 hod. Jaká je pravděpodobnost, že mezi 7. a 20. hodinou bude doma k zastižení? [11/13]
3. Dva sportovní střelci nezávisle na sobě střílejí do jednoho terče. Každý po jednom výstřelu. Pravděpodobnost zásahu prvního střelce je 0,8, druhého 0,4. Při střelbě byl v terči jeden zásah. Jaká je pravděpodobnost, že terč zasáhl první střelec? [0,857]
4. Pravděpodobnost výhry hráče je 0,6. Určete, jaký je nejpravděpodobnější počet výher hráče v deseti odehraných partiích. [6]
5. Sérii 100 ks výrobků je třeba zkontrolovat náhodným výběrem. Celá je považována za špatnou, je-li aspoň jeden z pěti vybraných výrobků vadný. Vypočtete pravděpodobnost, že série je špatná, víme-li, že obsahuje 5 % vadných výrobků. [0,226]
6. V telefonním seznamu náhodně vybereme jedno šestimístné číslo (může začínat nulou) a předpokládáme, že v seznamu jsou použita všechna šestimístná čísla. Jaká je pravděpodobnost, že číslo:
 - a. neobsahuje 0? [0,53144]
 - b. obsahuje jednu 3? [0,4686]



Literatura k tématu:

- [1] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>

-
- [2] CALDA, E., DUPAČ, V. (2008). Matematika pro gymnázia: Kombinatorika, pravděpodobnost, statistika (5. vydání, dotisk 2011). Praha: Prometheus. ISBN 978-80-7196-365-3.
 - [3] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.

Kapitola 3

Náhodná veličina



Po prostudování této kapitoly budete umět:

- rozlišovat mezi diskrétními a spojitými náhodnými veličinami a jejich pravděpodobnostními funkcemi,
- vypočítat střední hodnotu, rozptyl a směrodatnou odchylku pro různá rozdělení náhodných veličin,
- chápat význam distribuční funkce a umět ji interpretovat pro různé typy náhodných veličin,
- vytvořit pravděpodobnostní a distribuční funkci pro diskrétní a spojitou náhodnou veličinu a graficky je znázornit.



Klíčová slova:

Diskrétní rozdělení, spojité rozdělení, pravděpodobnostní funkce, distribuční funkce, hustota pravděpodobnosti, střední hodnota, rozptyl, šikmost a špičatost.

Náhled kapitoly

Pro lepší pochopení toho, jak pravděpodobnost funguje, je důležité se seznámit s pojmy náhodného jevu a náhodné veličiny, které slouží k popisu náhodných procesů. Dále se podíváme, jak je možné pomocí rozdělení pravděpodobnosti určit pravděpodobnost výskytu různých hodnot náhodné veličiny v rámci určitého systému.

Kapitola se zaměřuje na klíčové koncepty, jako jsou pravděpodobnostní rozdělení, diskrétní a spojitá náhodná veličiny, a způsoby výpočtu střední hodnoty, rozptylu a směrodatné odchylky.

Cíle kapitoly

Cílem této kapitoly je zopakování (srovnání znalostí) základů teorie pravděpodobnosti a těch poznatků o náhodných veličinách a jejich rozděleních pravděpodobnosti, které budou potřeba v následujících kapitolách.

Odhad času potřebného ke studiu

Pro zvládnutí této kapitoly je doporučeno věnovat studiu přibližně 4 až 5 hodin. Tento čas zahrnuje čtení textu, pochopení základních pojmů a principů pravděpodobnosti, řešení příkladů a procvičení výpočtů základních pravděpodobnostních charakteristik.

Náhodný jev a náhodná veličina

Definice 3.1. Náhodný jev je událost, která může, ale nemusí nastat v rámci nějakého pokusu nebo procesu. Můžeme si ho představit jako výsledek experimentu, který závisí na náhodě. Pravděpodobnost je míra, která kvantifikuje možnost, že k danému náhodnému jevu dojde, a pohybuje se v rozmezí od 0 (jevu nelze dosáhnout) do 1 (jev nastane s jistotou). Například pravděpodobnost, že při hodu kostkou padne číslo 6, je $\frac{1}{6}$, protože existuje 6 možných výsledků a každý má stejnou šanci nastat.

Definice 3.2. Náhodná veličina je proměnná, která může nabývat různých (reálných) hodnot v závislosti na výsledku náhodného pokusu. Například při hodu kostkou může náhodná veličina X představující výsledek hodu nabývat hodnot 1, 2, 3, 4, 5 nebo 6. Každý z těchto výsledků je výsledek náhodného procesu.

Náhodné veličiny, které mohou nabývat různých hodnot v závislosti na výsledku náhodného jevu, se používají k popisu výsledků náhodných procesů.

Příklady náhodných veličin mohou být:

- Počet lvů při deseti hodech mincí.
- Počet zákazníků, kteří navštíví obchod v určitém dni.
- Výška náhodně vybraného člověka z populace.
- Doba, za kterou přijede autobus na zastávku.
- Výsledek hodu dvěma kostkami (součet bodů).
- Počet vadných kusů ve výrobní sérii 100 produktů.

Tyto příklady ukazují různé typy náhodných veličin – některé jsou *diskrétní* (počet hlav, počet zákazníků), jiné *spojité* (výška člověka, čas čekání).

Rozdělení pravděpodobnosti

Rozdělení pravděpodobnosti popisuje, jak jsou pravděpodobnosti jednotlivých možných výsledků náhodné veličiny rozloženy. Například u hodu (férovou) kostkou mají všechny výsledky (hodnoty 1 až 6) stejnou pravděpodobnost, tedy $\frac{1}{6}$. V praxi však ne vždy všechny výsledky mají stejnou pravděpodobnost. Rozdělení pravděpodobnosti tedy udává, s jakou pravděpodobností různé hodnoty náhodné veličiny nastanou.

Rozdělení pravděpodobnosti nám tedy poskytuje obraz o tom, jak často můžeme očekávat jednotlivé výsledky náhodného pokusu.

V závislosti na typu náhodné veličiny rozlišujeme dvě hlavní kategorie: **diskrétní** a **spojité** náhodné veličiny.

3.1 Rozdělení pravděpodobnosti diskrétní náhodné veličiny


Diskrétní náhodná veličina nabývá pouze konečného nebo spočetně nekonečného množství možných hodnot. Příkladem diskrétní náhodné veličiny je počet vadných výrobků v sérii nebo počet zákazníků přicházejících do obchodu za jeden den. Diskrétní náhodná veličina je jednoznačně určena posloupností reálných čísel $\{x_n\}$ a posloupností pravděpodobností $\{p_n = P(X = x_n)\}$.

Příklad 3.3. Diskrétní náhodná veličina X nabývá hodnot $M = \{1, 2, 4, 5\}$ s pravděpodobnostmi $p(k) = P[X = k]$, kde

$$p(1) = \frac{1}{3}, \quad p(2) = \frac{1}{4}, \quad p(4) = \frac{1}{6}, \quad p(5) = \frac{1}{4} \quad \text{a} \quad p(x) = 0 \text{ jinak.}$$

Zapisujeme také pomocí tabulky či obrázku:

k	1	2	4	5
$P(X = k)$	$\frac{1}{3}$	$\frac{1}{4}$	$\frac{1}{6}$	$\frac{1}{4}$



Definice 3.4. Diskrétní náhodné veličiny mají svou **pravděpodobnostní funkci**, která přiřazuje každé hodnotě náhodné veličiny určitou pravděpodobnost $P(X = x_i) = p_i$, $i = 1, \dots, m$, kde x_i je možná hodnota diskrétní náhodné veličiny X , a p_i je pravděpodobnost, že X nabude hodnoty x_i .

Vlastnosti pravděpodobnostní funkce:

- $p(x) \geq 0 \quad \forall x \in \mathbb{R}$,
- $\sum_{x \in M} p(x) = 1$,
- Výpočet pravděpodobnosti (jevu B)

$$P(X \in B) = \sum_{n: x_n \in B \cap M} P(X = x_n) = \sum_{n: x_n \in B \cap M} p(x_n)$$

(součet pravděpodobností všech čísel/výsledků, která patří do B ; jelikož nenulové pravděpodobnosti jsou jen v M , tak proto $B \cap M$.)

Definice 3.5 (Distribuční funkce). **Distribuční funkce** náhodné veličiny X je reálná funkce $F: \mathbb{R} \rightarrow \langle 0; 1 \rangle$ definovaná vztahem

$$F(x) = P(X \leq x), \quad x \in \mathbb{R}.$$

Příklad 3.6 (distribuční funkce diskrétní náhodné veličiny). Diskrétní náhodná veličina X nabývá hodnot $M = \{1, 2, 4, 5\}$ s pravděpodobnostmi $p(k) = P(X = k)$, kde $p(1) = \frac{1}{3}$, $p(2) = \frac{1}{4}$, $p(4) = \frac{1}{6}$, $p(5) = \frac{1}{4}$ a $p(x) = 0$ jinak.

Určete příslušnou distribuční funkci.

Řešení: Vycházíme z toho, že distribuční funkce je „zajímavá“ jen v bodech, kde je pravděpodobnostní funkce kladná. V těchto bodech dochází u distribuční funkce ke skokovému růstu

právě o hodnotu pravděpodobnostní funkce v tomto bodě. Mezi těmito body je konstantní. Praktické je tedy vypočítat hodnoty F v těchto bodech a připsat je do již známé tabulky pro pravděpodobnostní funkci:

k	1	2	4	5
$P(X = k)$	$\frac{1}{3}$	$\frac{1}{4}$	$\frac{1}{6}$	$\frac{1}{4}$
$F(k) = \sum_{k_i \leq k} P(X = k_i)$	$\frac{1}{3}$	$\frac{1}{3} + \frac{1}{4} = \frac{7}{12}$	$\frac{7}{12} + \frac{1}{6} = \frac{3}{4}$	$\frac{3}{4} + \frac{1}{4} = 1$


Dále F můžeme zapsat na jednotlivých intervalech, které nám pokryjí celé $\mathbb{R}$:

x	$(-\infty, 1)$	$\langle 1, 2)$	$\langle 2, 4)$	$\langle 4, 5)$	$\langle 5, \infty)$
$F(x)$	0	$\frac{1}{3}$	$\frac{7}{12}$	$\frac{3}{4}$	1

A nakonec i takto:

$$F(x) = \begin{cases} 0 & x < 1, \\ \frac{1}{3} & 1 \leq x < 2, \\ \frac{7}{12} & 2 \leq x < 4, \\ \frac{3}{4} & 4 \leq x < 5, \\ 1 & x \geq 5. \end{cases}$$

Nejnázornější stejně budou grafy na obrázku 1.



Obr. 1: Pravděpodobnostní a distribuční funkce k příkladu 3.6

□

Z příkladu 3.6 sice můžeme odpozorovat některé vlastnosti distribuční funkce, ale raději si je zde vypíšeme:

Vlastnosti distribuční funkce:

- $F(x) \in \langle 0, 1 \rangle$,
- F je neklesající,
- F je zprava spojitá,
- F je definovaná na $\mathbb{R}$,
- $\lim_{x \rightarrow -\infty} F(x) = 0$, $\lim_{x \rightarrow \infty} F(x) = 1$,
- $P(X = x_0) = F(x_0) - \lim_{x \rightarrow x_0^-} F(x)$ (výška skoku v bodě x_0).

Příklad 3.7. V osudí je 5 bílých a 7 červených míčků. Náhodná veličina X představuje počet bílých míčků mezi pěti vybranými. Vytvořte pravděpodobnostní a distribuční funkci této náhodné veličiny.

Řešení: Náhodná veličina X nabývá hodnot $\{0, 1, 2, 3, 4, 5\}$. Z teorie pravděpodobnosti víme, že se jedná o opakované závislé pokusy. Můžeme tedy sestavit pravděpodobnostní funkci pro jednotlivé hodnoty X :

$$P(X = x) = \frac{\binom{5}{x} \binom{7}{5-x}}{\binom{12}{5}}.$$

Na základě této funkce vytvoříme tabulku pravděpodobností:

x_i	0	1	2	3	4	5
p_i	$\frac{21}{792}$	$\frac{175}{792}$	$\frac{350}{792}$	$\frac{210}{792}$	$\frac{35}{792}$	$\frac{1}{792}$

Pravděpodobnostní funkce může být graficky znázorněna pomocí bodového grafu, úsečkového diagramu nebo histogramu.

Distribuční funkce $F(x)$ bude mít skoky v bodech 0, 1, 2, 3, 4, 5. Hodnoty funkce $F(x)$ jsou určeny jako součet všech předcházejících hodnot p_i :

$$F(x_i) = P(X \leq x_i).$$

Tabulka pro distribuční funkci:

x_i	0	1	2	3	4	5
$F(x_i)$	$\frac{21}{792}$	$\frac{196}{792}$	$\frac{546}{792}$	$\frac{756}{792}$	$\frac{791}{792}$	$\frac{792}{792}$

Graf distribuční funkce může být znázorněn jako spojitý schodovitý diagram. □

3.2 Rozdělení pravděpodobnosti spojitě náhodné veličiny

Spojitá náhodná veličina nabývá hodnot z nějakého intervalu reálných čísel. Příkladem může být výška náhodně vybraného člověka nebo doba, kterou zákazník stráví v obchodě. Spojité náhodné veličiny nemají konkrétní pravděpodobnosti pro jednotlivé hodnoty (pravděpodobnostní funkci), ale místo toho pracují s tzv. **hustotou pravděpodobnosti**, která určuje pravděpodobnost, že náhodná veličina nabyde hodnoty z určitého intervalu.

Definice 3.8. Náhodná veličina X s distribuční funkcí F se nazývá **spojitá**, jestliže existuje nezáporná funkce $f: \mathbb{R} \rightarrow \mathbb{R}$ taková, že

$$F(x) = \int_{-\infty}^x f(t) dt, \quad \forall x \in \mathbb{R}.$$

Funkce $f(x)$ se nazývá **hustota** (rozdělení pravděpodobností) náhodné veličiny X .


Vlastnosti hustoty:

- $f(x) \geq 0$,
- $\int_{-\infty}^{\infty} f(t) dt = 1 \Rightarrow$ plocha pod křivkou hustoty vyjadřuje pravděpodobnost,
- $f(x) = F'(x)$ v každém bodě x , kde F' existuje,
- $P(a \leq X \leq b) = F(b) - F(a) = \int_a^b f(t) dt$,
- $P(a \leq X \leq b) = P(a < X \leq b) = P(a \leq X < b) = P(a < X < b)$,
- $P(X \in B) = \int_B f(t) dt$.

Výpočet pravděpodobností pomocí $F(x)$ a $f(x)$ na nekonečném intervalu:

$$P(\xi < 0) = F(0) = \int_{-\infty}^0 f(t) dt.$$

Toto je znázorněno na obrázku 2.




Obr. 2: Výpočet pravděpodobností na nekonečném intervalu

Výpočet pravděpodobností pomocí $F(x)$ a $f(x)$ na konečném intervalu:

$$P(-2 < \xi < 0) = F(0) - F(-2) = \int_{-2}^0 f(t) dt.$$

Toto je znázorněno na obrázku 3.



Obr. 3: Výpočet pravděpodobností na konečném intervalu

Příklad 3.9. Náhodná veličina X je dána distribuční funkcí:

$$F(x) = \begin{cases} 0, & x < 0, \\ \frac{x^2}{4}, & 0 \leq x < 4, \\ 1, & x \geq 4. \end{cases}$$

Určete hustotu pravděpodobnosti $f(x)$, znázorněte graficky $F(x)$ a $f(x)$, a vypočtěte $P(0,4 \leq X < 1,6)$.

Řešení: Hustotu pravděpodobnosti $f(x)$ získáme derivací distribuční funkce $F(x)$:

$$f(x) = \begin{cases} 0, & x < 0, \\ \frac{d}{dx} \left(\frac{x^2}{4} \right) = \frac{x}{2}, & 0 \leq x < 4, \\ 0, & x \geq 4. \end{cases}$$

Graf distribuční funkce $F(x)$ a hustoty pravděpodobnosti $f(x)$ je následující:

- Distribuční funkce $F(x)$: Kvadratický nárůst od 0 do 1 v intervalu $0 \leq x < 4$.
- Hustota pravděpodobnosti $f(x)$: Lineární funkce $\frac{x}{2}$ v intervalu $0 \leq x < 4$.

Pravděpodobnost $P(0,4 \leq X < 1,6)$ vypočítáme jako:

$$P(0,4 \leq X < 1,6) = F(1,6) - F(0,4) = \frac{(1,6)^2}{4} - \frac{(0,4)^2}{4} = \frac{2,56}{4} - \frac{0,16}{4} = \frac{2,4}{4} = 0,6.$$

□

Příklad 3.10. Hustota pravděpodobnosti náhodné veličiny X má tvar:

$$f(x) = \begin{cases} a \cdot x, & 0 \leq x \leq 2, \\ 0, & \text{jinak.} \end{cases}$$

Určete koeficient a , distribuční funkci $F(x)$ a vypočtěte $P(0 \leq X \leq 1)$.

Řešení: Nejdříve určíme koeficient a . Platí, že integrál hustoty pravděpodobnosti přes celý definiční obor musí být roven 1:

$$\int_0^2 a \cdot x \, dx = 1.$$

Po integraci dostáváme:

$$a \cdot \int_0^2 x \, dx = a \cdot \left[\frac{x^2}{2} \right]_0^2 = a \cdot \frac{4}{2} = 2a.$$

Z toho plyne, že $2a = 1$, tedy $a = \frac{1}{2}$.

Distribuční funkci $F(x)$ získáme integrací hustoty pravděpodobnosti:

$$F(x) = \begin{cases} 0, & x < 0, \\ \int_0^x \frac{1}{2} \cdot t \, dt = \frac{1}{2} \cdot \frac{x^2}{2} = \frac{x^2}{4}, & 0 \leq x \leq 2, \\ 1, & x > 2. \end{cases}$$

Nyní vypočítáme pravděpodobnost $P(0 \leq X \leq 1)$:

$$P(0 \leq X \leq 1) = F(1) - F(0) = \frac{1^2}{4} - 0 = \frac{1}{4} = 0,25.$$

□

Příklad 3.11. Určete konstanty A a B tak, aby funkce $F(x) = A + B \cdot \arctan(x)$ definovaná pro všechna reálná čísla byla distribuční funkcí rozložení náhodné veličiny.

Řešení: Aby funkce $F(x)$ byla distribuční funkcí, musí splňovat následující podmínky:

1. $\lim_{x \rightarrow -\infty} F(x) = 0$,
2. $\lim_{x \rightarrow \infty} F(x) = 1$.

Z první podmínky plyne:

$$\lim_{x \rightarrow -\infty} (A + B \cdot \arctan(x)) = A + B \cdot \left(-\frac{\pi}{2}\right) = 0.$$

Z toho vyplývá, že $A = \frac{B\pi}{2}$.

Z druhé podmínky plyne:

$$\lim_{x \rightarrow \infty} (A + B \cdot \arctan(x)) = A + B \cdot \frac{\pi}{2} = 1.$$

Dosazením $A = \frac{B\pi}{2}$ dostáváme:

$$\frac{B\pi}{2} + B \cdot \frac{\pi}{2} = 1 \quad \Rightarrow \quad B\pi = 1 \quad \Rightarrow \quad B = \frac{1}{\pi}.$$

Tedy $A = \frac{1}{2}$.

Distribuční funkce má tedy tvar:

$$F(x) = \frac{1}{2} + \frac{1}{\pi} \cdot \arctan(x).$$

□

3.3 Číselné charakteristiky náhodné veličiny

Střední hodnota, rozptyl a směrodatná odchylka jsou klíčové charakteristiky, které popisují rozdělení náhodné veličiny.

Střední hodnota

Definice 3.12. Střední hodnota (očekávaná hodnota) diskrétní náhodné veličiny X se počítá jako vážený průměr všech možných hodnot náhodné veličiny:

$$E(X) = \sum_i x_i \cdot P(X = x_i) = \sum_i x_i \cdot p_i.$$

Definice 3.13. Střední hodnota spojité náhodné veličiny X je definována jako integrál z hodnot náhodné veličiny vážených hustotou pravděpodobnosti:

$$E(X) = \int_{-\infty}^{\infty} x \cdot f(x) dx.$$

Rozptyl

Definice 3.14. Rozptyl diskrétní náhodné veličiny měří, jak jsou jednotlivé hodnoty rozloženy kolem střední hodnoty:

$$D(X) = \text{Var}(X) = \sum_i (x_i - E(X))^2 \cdot P(X = x_i) = \sum_i (x_i - E(X))^2 \cdot p_i.$$

Definice 3.15. Rozptyl spojité náhodné veličiny je definován jako:

$$D(X) = \text{Var}(X) = \int_{-\infty}^{\infty} (x - E(X))^2 \cdot f(x) dx = E(X^2) - [E(X)]^2.$$

Směrodatná odchylka

Definice 3.16. Směrodatná odchylka je druhou odmocninou rozptylu: $\sigma(X) = \sqrt{D(X)}$.

Směrodatná odchylka nám poskytuje měřítko, jak daleko jsou hodnoty náhodné veličiny od její střední hodnoty.

Koeficient šikmosti a špičatosti

Koeficienty šikmosti a špičatosti popisují tvar křivky hustoty nebo pravděpodobnostní funkce.

Definice 3.17 (Koeficient šikmosti náhodné veličiny X).

$$\gamma_1 = \frac{E[(X - E(X))^3]}{(\sqrt{D(X)})^3}.$$

- $\gamma_1 = 0$: rozdělení je symetrické,
- $\gamma_1 > 0$: rozdělení je protáhlé napravo (např. mzdy),

- $\gamma_1 < 0$: rozdělení je protáhlé nalevo.

Vztah mezi koeficientem šikmosti, střední hodnotou, mediánem a modem:

$$\gamma_1 = 0 : E(X) = x_{0,5} = Mo(X),$$

$$\gamma_1 < 0 : E(X) \leq x_{0,5} \leq Mo(X),$$

$$\gamma_1 > 0 : Mo(X) \leq x_{0,5} \leq E(X).$$

Definice 3.18 (Koeficient špičatosti náhodné veličiny X).

$$\gamma_2 = \frac{E[(X - E(X))^4]}{(\sqrt{D(X)})^4} - 3.$$

- „Měří“ stupeň koncentrace hodnot okolo středu ve srovnání s ostatními hodnotami,
- veličina s nízkým koeficientem špičatosti ($\gamma_2 < 0$) obsahuje hodnoty velmi vzdálené od středu,
- čím špičatější rozdělení ($\gamma_2 > 0$), tím více jsou hodnoty soustředěné okolo středu.

Modus

Definice 3.19. Modus (nejčastější hodnota) je hodnota náhodné veličiny, která má nejvyšší pravděpodobnost výskytu. U diskrétní náhodné veličiny je to hodnota x , pro kterou $P(X = x)$ dosahuje maxima. U spojitě náhodné veličiny je to hodnota, kde hustota pravděpodobnosti $f(x)$ dosahuje svého vrcholu.

Příklad 3.20. Náhodná veličina X je dána tabulkou:

x_i	1	2	3	4
p_i	0,3	0,1	0,4	?

Určete její číselné charakteristiky.

Řešení: Nejprve zjistíme chybějící hodnotu pravděpodobnosti p_4 :

$$p_4 = 1 - (p_1 + p_2 + p_3) = 1 - (0,3 + 0,1 + 0,4) = 0,2.$$

Nyní vypočítáme jednotlivé číselné charakteristiky. Použijeme následující tabulku:

x_i	1	2	3	4	Σ
p_i	0,3	0,1	0,4	0,2	-
$x_i \cdot p_i$	0,3	0,2	1,2	0,8	2,5
$x_i^2 \cdot p_i$	0,3	0,4	3,6	3,2	7,5
$x_i^3 \cdot p_i$	0,3	0,8	10,8	12,8	24,7
$x_i^4 \cdot p_i$	0,3	1,6	32,4	51,2	85,5

- Střední hodnota (průměr): $E(X) = 2,5$
- Rozptyl: $D(X) = 7,5 - (2,5)^2 = 7,5 - 6,25 = 1,25$
- Směrodatná odchylka: $\sigma(X) = \sqrt{1,25} \approx 1,118$

□

Příklad 3.21. Náhodná veličina X má hustotu pravděpodobnosti:

$$f(x) = \begin{cases} 2x, & 0 \leq x \leq 1, \\ 0, & \text{jinak.} \end{cases}$$

Určete její číselné charakteristiky.

Řešení: Nejprve definujeme jednotlivé momenty:

$$\mu_k = \int_0^1 x^k \cdot f(x) dx = 2 \int_0^1 x^{k+1} dx.$$

Výpočet jednotlivých momentů:

1. První moment $\mu_1 = E(X)$ (střední hodnota):

$$\mu_1 = 2 \int_0^1 x^2 dx = 2 \left[\frac{x^3}{3} \right]_0^1 = \frac{2}{3}.$$

2. Druhý moment μ_2 (očekávaná hodnota X^2):

$$\mu_2 = 2 \int_0^1 x^3 dx = 2 \left[\frac{x^4}{4} \right]_0^1 = \frac{1}{2}.$$

3. Třetí moment μ_3 (očekávaná hodnota X^3):

$$\mu_3 = 2 \int_0^1 x^4 dx = 2 \left[\frac{x^5}{5} \right]_0^1 = \frac{2}{5}.$$

4. Čtvrtý moment μ_4 (očekávaná hodnota X^4):

$$\mu_4 = 2 \int_0^1 x^5 dx = 2 \left[\frac{x^6}{6} \right]_0^1 = \frac{1}{3}.$$

Výpočet rozptylu $D(X)$: Rozptyl se vypočítá jako:

$$D(X) = \mu_2 - (\mu_1)^2 = \frac{1}{2} - \left(\frac{2}{3}\right)^2 = \frac{1}{2} - \frac{4}{9} = \frac{9}{18} - \frac{8}{18} = \frac{1}{18}.$$

Výpočet šikmosti γ_1 : Šikmost (asymetrie) se vypočítá jako:

$$\gamma_1 = \frac{\mu_3 - 3\mu_1 \cdot D(X) - \mu_1^3}{(D(X))^{3/2}}.$$

Dosadíme hodnoty:

$$\gamma_1 = \frac{\frac{2}{5} - 3 \cdot \frac{2}{3} \cdot \frac{1}{18} - \left(\frac{2}{3}\right)^3}{\left(\frac{1}{18}\right)^{3/2}} = \frac{\frac{2}{5} - \frac{2}{9} - \frac{8}{27}}{\left(\frac{1}{18}\right)^{3/2}}.$$

Po zjednodušení:

$$\gamma_1 = \frac{\frac{54}{270} - \frac{60}{270}}{\left(\frac{1}{18}\right)^{3/2}} = \frac{-\frac{6}{270}}{\frac{1}{54}} = -\frac{6}{5}.$$

Výpočet špičatosti γ_2 : Špičatost (kurtóza) se vypočítá jako:

$$\gamma_2 = \frac{\mu_4}{(D(X))^2} = \frac{\frac{1}{3}}{\left(\frac{1}{18}\right)^2} = \frac{\frac{1}{3}}{\frac{1}{324}} = \frac{324}{3} = 108.$$

Výsledné číselné charakteristiky jsou:

- Střední hodnota: $E(X) = \frac{2}{3}$,
- Rozptyl: $D(X) = \frac{1}{18}$,
- Směrodatná odchylka: $\sigma(X) = \frac{1}{\sqrt{18}}$,
- Šikmost: $\gamma_1 = -\frac{6}{5}$,
- Špičatost: $\gamma_2 = 108$.

3.4 Kvantilové charakteristiky náhodné veličiny


Kvantily spojitých rozdělání

Definice

Definice 3.22. Kvantil spojitého rozdělání je hodnota (viz obrázek 4), která rozdělává oblast pod hustotou pravděpodobnosti na dvě části. Pro p -kvantil x_p platí, že plocha pod křivkou hustoty vlevo od x_p je rovna p , tj.

$$P(X \leq x_p) = F(x_p) = \int_{-\infty}^{x_p} f(x) dx = p,$$

kde $p \in (0, 1)$.



Obr. 4: Znázornění hustoty a p -kvantilu x_p pro spojitě rozdělání pravděpodobnosti (viz definici 3.22)

Speciální kvantily:

- **Medián** ($x_{0,5}$) je 50%-kvantil. Rozdělává rozdělání na dvě stejné části – jedna polovina hodnot leží pod mediánem, druhá polovina nad ním.
- **Kvartily** jsou kvantily, které rozdělávají data na čtvrtiny. První kvartil (Q_1) je 25%-kvantil, druhý kvartil je medián (Q_2) a třetí kvartil (Q_3) je 75%-kvantil.
- **Decily** rozdělávají rozdělání na desetiny. Například první decil (D_1) je 10%-kvantil, pátý decil (D_5) odpovídá mediánu, a devátý decil (D_9) je 90%-kvantil.
- **Percentily** rozdělávají rozdělání na 100 částí. Například první percentil (P_1) je 1%-kvantil, padesátý percentil (P_{50}) odpovídá mediánu a devadesátý devátý percentil (P_{99}) je 99%-kvantil.

Další běžně používané kvantily mohou zahrnovat **tercily** (dělí rozdělení na třetiny) a **kvintily** (dělí rozdělení na pětiny).

Speciálním případem kvantilu je **kritická hodnota**, používaná při statistických testech. Ta označuje mezní hodnotu, která odděluje zamítnutí a nezamítnutí nulové hypotézy (viz kapitolu *Testování statistických hypotéz*).

Určování kvantilů

Kvantily se určují z tabulek nebo se pohodlně počítají pomocí softwaru. My budeme většinou používat excelovské funkce, jako jsou:

- pro **normální rozdělení** funkce $\text{NORM.INV}(p; \mu; \sigma)$,
- pro **Studentovo rozdělení** funkce $\text{T.INV}(p; \nu)$ a
- pro **F-rozdělení** funkce $\text{F.INV}(p; \nu_1; \nu_2)$.

Všechny mají v názvu **INV**. Tím se poukazuje na to, že jde vlastně o inverzní funkci k distribuční funkci daného rozdělení:

$$F(x_p) = p \iff F^{-1}(p) = x_p,$$

tedy zatímco F k zadané hodnotě x_p na ose x vypočte pravděpodobnost p , tak F^{-1} (tedy inverze k F) vypočte k zadané pravděpodobnosti p hodnotu kvantilu x_p na ose x .

Příklad 3.23. Určete první decil $x_{0,1}$ a třetí kvartil $x_{0,75}$ pro náhodnou veličinu X s hustotou pravděpodobnosti:

$$f(x) = \begin{cases} \frac{1}{2}, & 0 \leq x \leq 1, \\ 0, & \text{jinak.} \end{cases}$$

Řešení: Hustota pravděpodobnosti $f(x)$ je konstantní v intervalu $0 \leq x \leq 1$. Distribuční funkce $F(x)$ je určena jako integrál hustoty:

$$F(x) = \begin{cases} 0, & x < 0, \\ \frac{x}{2}, & 0 \leq x \leq 1, \\ 1, & x > 1. \end{cases}$$

Decil $x_{0,1}$ je hodnota, pro kterou platí $F(x_{0,1}) = 0,1$. Hledáme tedy:

$$\frac{x_{0,1}}{2} = 0,1 \implies x_{0,1} = 0,2.$$

Třetí kvartil $x_{0,75}$ je hodnota, pro kterou platí $F(x_{0,75}) = 0,75$:

$$\frac{x_{0,75}}{2} = 0,75 \implies x_{0,75} = 1,5.$$

Výsledné hodnoty jsou:

- První decil: $x_{0,1} = 0,2$

- Třetí kvartil: $x_{0,75} = 1,5$

□

Příklad 3.24. Náhodná veličina X má hustotu pravděpodobnosti:

$$f(x) = \begin{cases} \frac{1}{2}x^2e^{-x}, & 0 < x < \infty, \\ 0, & \text{jinak.} \end{cases}$$

Určete modus.

Řešení: Modus je hodnota, ve které hustota pravděpodobnosti $f(x)$ dosahuje svého maxima. Nejprve spočítáme první derivaci funkce $f(x)$:

$$f'(x) = \frac{1}{2} \cdot (2xe^{-x} - x^2e^{-x}) = \frac{1}{2}xe^{-x} \cdot (2 - x).$$

Poté položíme derivaci rovnu nule:

$$\frac{1}{2}xe^{-x} \cdot (2 - x) = 0.$$

Tato rovnice má dvě řešení: $x = 0$ nebo $x = 2$. Jelikož $x = 0$ není v definičním oboru, jedná se o maximum v bodě $x = 2$. Ověříme, že se skutečně jedná o maximum tím, že vypočítáme druhou derivaci:

$$f''(x) = \frac{1}{2}e^{-x} \cdot [(2 - x) - x] = -\frac{1}{2}e^{-x}.$$

Protože druhá derivace je záporná pro $x = 2$, jedná se o maximum.

Výsledný modus je $M_o = 2$.

□

Σ

Tato kapitola se zaměřuje na **náhodné veličiny** a jejich základní charakteristiky. Náhodné veličiny jsou proměnné, které nabývají různých hodnot v závislosti na výsledku náhodného pokusu. Vysvětluje rozdíl mezi **diskrétními** a **spojitými** náhodnými veličinami, jejich **pravděpodobnostními funkcemi** a **distribučními funkcemi**.

Hlavními charakteristikami náhodných veličin jsou **střední hodnota** a **rozptyl**, které poskytují informace o průměrné hodnotě veličiny a o tom, jak moc se jednotlivé hodnoty od této průměrné hodnoty odchylují. V kapitole jsou vysvětleny i další charakteristiky, jako **šikmost** a **špičatost**, které popisují asymetrii a tvar rozdělení.

Pro **diskrétní náhodné veličiny** jsou uvedeny postupy výpočtu střední hodnoty a rozptylu na základě pravděpodobností jednotlivých hodnot. U **spojitých náhodných veličin** se používají **integrály** k určení těchto charakteristik. Kapitola se rovněž zabývá vztahem mezi pravděpodobnostní a distribuční funkcí, kdy distribuční funkce představuje kumulativní pravděpodobnost.



1. Co je to náhodná veličina?
2. Jaký je rozdíl mezi diskrétní a spojitou náhodnou veličinou?
3. Jakým způsobem se vyjadřuje pravděpodobnostní funkce pro diskrétní náhodnou veličinu?
4. Co je to distribuční funkce a jaký má význam?
5. Jak se počítá střední hodnota pro diskrétní náhodnou veličinu?
6. Jaký je vztah mezi pravděpodobnostní funkcí a distribuční funkcí?
7. Co je to rozptyl a jak se počítá pro náhodnou veličinu?
8. Jaký je význam charakteristik šikmosti a špičatosti pro popis náhodné veličiny?
9. Náhodná veličina X nabývá hodnot 1, 2, 3, 4 s pravděpodobnostmi 0,1; 0,2; 0,3; 0,4. Vypočítejte střední hodnotu a rozptyl veličiny X . [Střední hodnota: 3,0; Rozptyl: 1,0]
10. Pro spojitou náhodnou veličinu X je dána hustota pravděpodobnosti $f(x) = 2y^2$ pro $y \in [0, 1]$. Vypočítejte střední hodnotu a rozptyl této veličiny. [Střední hodnota: 0,5; Rozptyl: $\frac{1}{8}$]
11. Představte si hod kostkou, kde náhodná veličina X udává počet padlých bodů. Sestrojte pravděpodobnostní a distribuční funkci této náhodné veličiny. [Pravděpodobnostní funkce: $P(X = k) = \frac{1}{6}$ pro $k = 1, 2, 3, 4, 5, 6$; Distribuční funkce: $F(x) = 0$ pro $x < 1$, $F(x) = \frac{k}{6}$ pro $k \leq x < k + 1$ a $F(x) = 1$ pro $x \geq 6$]
12. Hustota pravděpodobnosti náhodné veličiny X má tvar:

$$f(x) = \begin{cases} 0, & \text{pro } x < 1, \\ x - \frac{1}{2}, & \text{pro } 1 \leq x < 2, \\ 0, & \text{pro } x \geq 2. \end{cases}$$

Určete distribuční funkci. [Distribuční funkce $F(x)$ je dána: $F(x) = 0$ pro $x < 1$, $F(x) = \frac{x^2}{2} - \frac{x}{2}$ pro $1 \leq x < 2$, $F(x) = 1$ pro $x \geq 2$]

13. Náhodná veličina X je určena tabulkou:


X	-2	0	2	4	6
p	0,1	?	0,2	0,3	0,2

Určete hodnotu pravděpodobnosti pro $X = 0$, distribuční funkci a pravděpodobnost jevu, že náhodná veličina nabude kladných hodnot. [Pravděpodobnost pro $X = 0$: 0,2; Pravděpodobnost kladných hodnot: 0,7]



Literatura k tématu:

- [1] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6. ISBN 978-80-867-3208-8.
- [2] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [3] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [4] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.



Kapitola 4

Základní typy rozdělení pravděpodobnosti diskrétní náhodné veličiny



Po prostudování této kapitoly budete umět:

- rozpoznat situace, kdy je vhodné k modelování použít binomické, Poissonovo nebo hypergeometrické rozdělení,
- vypočítat pravděpodobnosti a další charakteristiky u konkrétních diskrétních rozdělení,
- aplikovat poznatky na modelování situací z reálného života pomocí těchto rozdělení.
- pomocí excelovských funkcí vypočíst hodnoty pravděpodobnostních a distribučních funkcí.



Klíčová slova:

Diskrétní náhodná veličina, rozdělení pravděpodobnosti, pravděpodobnostní funkce, distribuční funkce.

Náhled kapitoly

V této kapitole se zaměříme na základní typy rozdělení pravděpodobnosti, které se používají u diskretních náhodných veličin. Probereme binomické, hypergeometrické a Poissonovo. Ukážeme si, jak každé z nich funguje a kdy se používá. Důraz bude kladen nejen na teorii, ale především na praktické příklady, které ukáží, jak tato rozdělení použít při řešení reálných i nereálných problémů. Tato rozdělení tvoří základ pro mnoho aplikací statistiky a pravděpodobnosti v praxi.

Cíle kapitoly

Cílem je pochopit různé typy rozdělení pravděpodobnosti u diskretních náhodných veličin s ohledem na jejich využití při modelování.

Časová náročnost

Na tuto kapitolu si vyhradte přibližně 3 hodiny. Tento čas zahrnuje jak studium teorie, tak procvičování příkladů a praktických aplikací, které vám pomohou lépe pochopit dané rozdělení.

4.1 Binomické rozdělení

Definice

Definice 4.1. Binomické rozdělení $\text{Bi}(n, p)$ modeluje počet úspěchů v pevně daném počtu nezávislých pokusů, kde každý pokus má dva možné výsledky (úspěch nebo neúspěch) a pravděpodobnost úspěchu je konstantní.

Pravděpodobnost k úspěchů z n pokusů je dána vzorcem:

$$P(X = k) = \binom{n}{k} p^k (1 - p)^{n-k},$$


kde n je počet pokusů, k je počet úspěchů, p je pravděpodobnost úspěchu v každém pokusu a $\binom{n}{k}$ je kombinační číslo.

Základní číselné charakteristiky

- **Střední hodnota:** $E(X) = np$,
- **Rozptyl:** $D(X) = np(1 - p)$.

Grafy pravděpodobnostní a distribuční funkce

Grafy pravděpodobnostní funkce (PDF) a distribuční funkce (CDF) pro binomické rozdělení s $n = 10$ a $p = 0,5$ jsou na obrázku 5.



Obr. 5: Pravděpodobnostní a distribuční funkce binomického rozdělení pro $n = 10$ a $p = 0,5$

Excelovské funkce

Pro práci s binomickým rozdělením lze v Excelu použít následující funkce:

- **Pravděpodobnostní funkce (PDF):** Funkce `BINOM.DIST(k; n; p; FALSE)` vrací pravděpodobnost přesně k úspěchů.
- **Distribuční funkce (CDF):** Funkce `BINOM.DIST(k; n; p; TRUE)` vrací pravděpodobnost nejvýše k úspěchů.

4.2 Hypergeometrické rozdělení

Definice

Definice 4.2. Hypergeometrické rozdělení $Hg(N, M, n)$ modeluje pravděpodobnost k úspěchů při náhodném výběru n objektů z populace N , kde M objektů z této populace jsou úspěchy. Výběr probíhá bez vracení.

Pravděpodobnost k úspěchů je dána vzorcem:

$$P(X = k) = \frac{\binom{M}{k} \binom{N-M}{n-k}}{\binom{N}{n}},$$


kde N je velikost populace, M je počet úspěšných objektů v populaci, n je počet vybraných objektů a k je počet úspěchů.

Základní číselné charakteristiky

- **Střední hodnota:** $E(X) = \frac{nM}{N}$,
- **Rozptyl:** $D(X) = n \frac{M}{N} \left(1 - \frac{M}{N}\right) \frac{N-n}{N-1}$.

Grafy pravděpodobnostní a distribuční funkce

Grafy pravděpodobnostní funkce (PDF) a distribuční funkce (CDF) pro hypergeometrické rozdělení s parametry $N = 50$, $M = 20$, $n = 10$ jsou na obrázku 6.



Obr. 6: Pravděpodobnostní a distribuční funkce hypergeometrického rozdělení pro $N = 50$, $M = 20$ a $n = 10$

Excelovské funkce

Pro práci s hypergeometrickým rozdělením lze v Excelu použít následující funkce:

- **Pravděpodobnostní funkce (PDF):** Funkce `HYPGEOM.DIST(k; n; M; N; FALSE)` vrací pravděpodobnost přesně k úspěchů.
- **Distribuční funkce (CDF):** Funkce `HYPGEOM.DIST(k; n; M; N; TRUE)` vrací pravděpodobnost nejvýše k úspěchů.

4.3 Poissonovo rozdělení

Definice

Definice 4.3. Poissonovo rozdělení $Po(\lambda)$ modeluje počet událostí, které nastanou v pevně daném čase nebo prostoru, za předpokladu, že tyto události nastávají nezávisle na sobě s konstantní střední intenzitou λ .

Pravděpodobnost, že v daném intervalu nastane právě k událostí, je dána vzorcem:

$$P(X = k) = \frac{\lambda^k e^{-\lambda}}{k!},$$


kde λ je očekávaný počet událostí v daném intervalu a k je počet událostí.

Základní číselné charakteristiky

- Střední hodnota: $E(X) = \lambda$,
- Rozptyl: $D(X) = \lambda$.

Grafy pravděpodobnostní a distribuční funkce

Grafy pravděpodobnostní funkce (PDF) a distribuční funkce (CDF) pro Poissonovo rozdělení s parametrem $\lambda = 3$ jsou na obrázku 7.



Obr. 7: Pravděpodobnostní a distribuční funkce Poissonova rozdělení pro $\lambda = 3$

Excelovské funkce

Pro práci s Poissonovým rozdělením lze v Excelu použít následující funkce:

- **Pravděpodobnostní funkce (PDF):** Funkce `POISSON.DIST(k; λ; FALSE)` vrací pravděpodobnost přesně k událostí.
- **Distribuční funkce (CDF):** Funkce `POISSON.DIST(k; λ; TRUE)` vrací pravděpodobnost nejvýše k událostí.

4.4 Řešené příklady

Některá další rozdělení

Příklad 4.4 (Alternativní rozdělení $Alt(p)$). V tomto příkladu si ukážeme alternativní rozdělení, které popisuje náhodný experiment s dvěma možnými výsledky. Uvažujme hod mincí, kde mohou nastat pouze dva výsledky: líc nebo rub. Tento experiment můžeme modelovat alternativním rozdělením $Alt(p)$, kde:

- Prostor možných výsledků je $\Omega = \{\text{líc}, \text{rub}\}$.
- Pravděpodobnost úspěchu (např. padnutí líce) je p , pravděpodobnost neúspěchu (padnutí rubu) je $1 - p$.

Výsledkem je náhodná veličina X , která nabývá hodnot 0 (neúspěch) nebo 1 (úspěch). Tedy: $M = \{0, 1\}$ a $X = \{0, 1\}$.

Jedná se o typické použití alternativního rozdělení.

Příklad 4.5 (Rovnoměrné rozdělení $R(n)$). Rovnoměrné rozdělení $R(n)$ popisuje situaci, kdy všechny možné výsledky mají stejnou pravděpodobnost. Uvažujme hod klasickou šestistěnnou kostkou, kde je pravděpodobnost každého čísla od 1 do 6 stejná:

- Prostor možných výsledků je $M = \{1, 2, 3, 4, 5, 6\}$.
- Každý z těchto výsledků má pravděpodobnost $\frac{1}{6}$.

V tomto případě se jedná o rovnoměrné rozdělení $R(6)$, které modeluje pravděpodobnostní chování při hodu kostkou.

Binomické rozdělení

Příklad 4.6 (Binomické rozdělení $Bi(n, p)$). Student má potíže s ranním vstáváním. Proto někdy zaspí a nestihne přednášku, která začíná již v 9 hodin. Pravděpodobnost, že zaspí, je 0,3. V semestru je 12 přednášek, což znamená 12 nezávislých pokusů dorazit na přednášku včas.

Nalezněte pravděpodobnost, že student nestihne přednášku v důsledku zaspání v polovině nebo více případů.

Jedná se o binomické rozdělení $Bi(n, p)$ s parametry $n = 12$ a $p = 0,3$. Hledaná pravděpodobnost je:

$$P(X \geq 6) = 1 - P(X < 6).$$

Tuto pravděpodobnost lze snadno vypočítat pomocí distribuční funkce binomického rozdělení, například pomocí funkce BINOMDIST v Excelu.

Příklad 4.7 (Binomické rozdělení $Bi(n, p)$). V obchodě probíhá reklamní akce, při které zákazníci losují ze 100 kupónů. Každý kupón může být výherní s pravděpodobností 0,05. Každý zákazník losuje jeden kupón a šance na výhru je pro každého stejná. Jaká je pravděpodobnost, že z 20 zákazníků alespoň 2 vyhrají?

Tento problém modelujeme jako binomické rozdělení $Bi(n, p)$ s parametry $n = 20$ a $p = 0,05$. Hledáme pravděpodobnost:

$$P(X \geq 2) = 1 - P(X < 2) = 1 - [P(X = 0) + P(X = 1)].$$

Pravděpodobnost $P(X = 0) = 0,3585$ a $P(X = 1) = 0,3773$. Proto:

$$P(X \geq 2) = 1 - (0,3585 + 0,3773) = 0,2642.$$

Tuto pravděpodobnost lze také spočítat pomocí funkce BINOMDIST v Excelu.

Poissonovo rozdělení

Příklad 4.8 (Poissonovo rozdělení $Po(\lambda)$). Předpokládejme, že realitní makléř jedná v průměru s pěti zákazníky za den. Zjistěte, jaká je pravděpodobnost, že počet zákazníků makléře za jeden den bude větší než 4.

Náhodná veličina X – počet zákazníků – splňuje kritéria pro Poissonovo rozdělení $Po(\lambda)$ s parametrem $\lambda = 5$. Hledáme:

$$P(X > 4) = 1 - P(X \leq 4).$$

Tuto pravděpodobnost lze vypočítat pomocí funkce POISSON v Excelu.

Příklad 4.9 (Poissonovo rozdělení $Po(\lambda)$). V průměru přistane na místním letišti během jedné hodiny 3 letadla. Jaká je pravděpodobnost, že během jedné hodiny přistanou přesně 2 letadla?

Náhodná veličina X – počet přistání – splňuje kritéria pro Poissonovo rozdělení $Po(\lambda)$ s parametrem $\lambda = 3$. Hledaná pravděpodobnost je:

$$P(X = 2) = \frac{3^2 e^{-3}}{2!} = 0,2240.$$

Tuto pravděpodobnost lze snadno vypočítat pomocí funkce POISSON v Excelu.

Hypergeometrické rozdělení

Příklad 4.10 (Hypergeometrické rozdělení $H(N, M, n)$). Mezi stovkou výrobků je 20 zmetků. Vybereme deset výrobků a sledujeme počet zmetků mezi vybranými.

V tomto případě má náhodná veličina X hypergeometrické rozdělení $H(100, 20, 10)$. Pravděpodobnostní funkce je dána vztahem:

$$P(X = k) = \frac{\binom{M}{k} \binom{N-M}{n-k}}{\binom{N}{n}},$$

kde $N = 100$, $M = 20$, $n = 10$ a k je počet zmetků mezi vybranými výrobky.

Například pravděpodobnost, že mezi deseti vybranými výrobky budou 3 zmetky, lze vypočítat jako $P(X = 3)$.

Příklad 4.11 (Hypergeometrické rozdělení $H(N, K, n)$). V krabici je 20 kuliček, z nichž 8 je červených a 12 modrých. Náhodně vybereme 5 kuliček bez vracení. Jaká je pravděpodobnost, že vybereme přesně 3 červené kuličky?

Tento problém modelujeme jako hypergeometrické rozdělení $H(N, K, n)$ s parametry:

$$N = 20, \quad K = 8, \quad n = 5.$$

Hledaná pravděpodobnost je:

$$P(X = 3) = \frac{\binom{8}{3} \binom{12}{2}}{\binom{20}{5}}.$$

Po dosazení hodnot dostáváme:

$$P(X = 3) = \frac{\binom{8}{3} \binom{12}{2}}{\binom{20}{5}} = \frac{56 \cdot 66}{15504} = 0,2386.$$

Tuto pravděpodobnost lze také vypočítat pomocí funkce `HYPGEOM.DIST` v Excelu.

Σ

V této kapitole byla představena základní diskretní rozdělení pravděpodobnosti, která se často vyskytují v praxi (některým jsme se věnovali podrobněji, dalším jen v praktických příkladech). Seznámili jsme se s charakteristikami a použitím těchto rozdělení:

- **Alternativní rozdělení** $A(p)$ – Popisuje náhodný experiment s dvěma možnými výsledky (např. úspěch/neúspěch). Využívá se např. při modelování hodu mincí.
- **Rovnoměrné rozdělení** $R(n)$ – Předpokládá, že všechny výsledky mají stejnou pravděpodobnost. Používá se např. při hodu kostkou, kde každé číslo má stejnou pravděpodobnost.
- **Binomické rozdělení** $Bi(n, p)$ – Popisuje počet úspěchů při pevně daném počtu nezávislých pokusů, kde každý pokus má stejnou pravděpodobnost úspěchu. Příkladem je situace, kdy se sleduje počet úspěchů při opakovaných pokusech, jako je např. ranní docházka studenta.
- **Poissonovo rozdělení** $Po(\lambda)$ – Používá se k modelování počtu výskytů události v pevném časovém nebo prostorovém intervalu. V praxi může jít např. o modelování počtu zákazníků přicházejících k realitnímu makléři.
- **Hypergeometrické rozdělení** $H(N, M, n)$ – Popisuje pravděpodobnost určitého počtu úspěchů při výběru bez vracení z konečné populace. Příkladem je sledování počtu vadných výrobků při náhodném výběru z výrobní dávky.




1. Jaké jsou základní číselné charakteristiky binomického rozdělení?
2. Jak vypadá pravděpodobnostní funkce binomického rozdělení pro $n = 10$ a $p = 0,5$?
3. Co modeluje Poissonovo rozdělení?
4. Jaký je vzorec pro pravděpodobnost, že Poissonova náhodná veličina X nabude hodnoty k , pokud má parametr λ ?
5. Jaký je vztah mezi střední hodnotou a rozptylem u Poissonova rozdělení?
6. Jaké typické aplikace má Poissonovo rozdělení v reálném světě?
7. Co modeluje hypergeometrické rozdělení?
8. Jaký je rozdíl mezi binomickým a hypergeometrickým rozdělením?
9. V dodávce 80 polotovarů je 8 (tj. 10 %) vadných. Náhodně vybereme (nejednou, tj. „bez vracení“) 5 kusů polotovarů k další kompletaci. Jaká je pravděpodobnost, že mezi vybranými prvky bude maximálně jeden vadný? [0,7248]
10. Ve skladišti závodu je 5 000 výrobků stejného typu. Pravděpodobnost toho, že daný výrobek nevydrží kontrolní zapojení, je 0,1 %. Najděte pravděpodobnost, že z výrobků na skladě více než dva nevydrží kontrolní zapojení. [0,0036]
11. Korektura 500 stránek obsahuje 500 nalezených tiskových chyb. Najděte pravděpodobnost toho, že na stránce jsou nejméně tři chyby. [0,0803]
12. Najděte pravděpodobnost toho, že mezi 200 výrobky se vyskytnou více než tři zmetky, když v průměru je zmetkovitost výroby těchto výrobků 1 %. [0,1423]



Literatura k tématu:

- [1] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6. ISBN 978-80-867-3208-8.
- [2] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [3] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [4] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.



Kapitola 5

Základní typy rozdělení pravděpodobnosti spojité náhodné veličiny



Po prostudování této kapitoly budete umět:

- vyjmenovat základní spojité rozdělení pravděpodobnosti i s jejich důležitými vlastnostmi,
- vypočítat základní charakteristiky daných typů rozdělení pravděpodobnosti,
- pomocí excelovských funkcí vypočíst hodnoty hustot a distribučních funkcí spojitých rozdělení,
- pomocí excelovských funkcí vypočíst kvantily spojitých rozdělení.



Klíčová slova:

Rozdělení pravděpodobnosti, hustota funkce, distribuční funkce, střední hodnota, rozptyl, kvantil.

Náhled kapitoly

Tato kapitola se zaměřuje na základní typy rozdělení pravděpodobnosti pro spojité náhodné veličiny. Seznámíme se s rozděleními, jako je normální, exponenciální a rovnoměrné rozdělení. Každé z těchto rozdělení má specifické vlastnosti a používá se v různých situacích při modelování náhodných jevů. Kromě teoretického popisu si také ukážeme, jak tato rozdělení aplikovat v praxi a jak vypočítat pravděpodobnosti a další charakteristiky. V kapitole jsou uvedeny příklady, které demonstrují užití spojitých rozdělení v reálných situacích.

Cíle kapitoly

Cílem je pochopit a rozlišovat základní typy rozdělení pravděpodobnosti pro spojité náhodné veličiny a aplikovat tyto poznatky při řešení úloh z praxe.

Časová náročnost

Pro tuto kapitolu doporučujeme vyčlenit přibližně 3 hodiny, které zahrnují jak studium teoretických částí, tak procvičování praktických příkladů a aplikací.

5.1 Normální rozdělení

Definice


Definice 5.1. Normální rozdělení $N(\mu, \sigma^2)$ je rozdělení pravděpodobnosti, které je symetrické kolem střední hodnoty μ a jeho tvar je zvonovitý. Je určeno dvěma parametry: střední hodnotou μ a směrodatnou odchylkou σ .

Hustota normálního rozdělení je dána vzorcem:

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right),$$

kde μ je střední hodnota a σ^2 je rozptyl.

Rozdělení $N(0; 1)$ se nazývá **normované** (nebo **standardizované**) **normální rozdělení** a je ve statistice velmi důležité.




Obr. 8: Jeden z hrdých otců normálního rozdělení (vytvořeno pomocí ChatGPT, openAI)

Základní číselné charakteristiky


- **Střední hodnota:** μ
- **Rozptyl:** σ^2
- **Symetrie:** Normální rozdělení je symetrické kolem střední hodnoty μ .

Grafy hustot a distribuční funkce

Grafy znázorňující hustoty a distribuční funkce normálního rozdělení pro různé hodnoty μ a σ jsou uvedeny na obrázcích 9 a 10.



Obr. 9: Grafy hustot a distribučních funkcí normálního rozdělení s různými rozptyly



Obr. 10: Grafy hustot a distribučních funkcí normálního rozdělení s různými středními hodnotami

Excelovské funkce

Pro práci s normálním rozdělením lze v Excelu použít následující funkce:

- **Hustota pravděpodobnosti (PDF):** Funkce `NORM.DIST(x; μ; σ; FALSE)` vrací hodnotu hustoty pravděpodobnosti.
- **Distribuční funkce (CDF):** Funkce `NORM.DIST(x; μ; σ; TRUE)` vrací hodnotu distribuční funkce.
- **Kvantilová funkce:** Funkce `NORM.INV(p; μ; σ)` vrací kvantil pro danou pravděpodobnost p , střední hodnotu μ a směrodatnou odchylku σ .

Pro práci s **normovaným normálním rozdělením** ($\mu = 0$, $\sigma = 1$) lze použít specializované funkce:

- **Hustota pravděpodobnosti (PDF):** Funkce `NORM.S.DIST(x; FALSE)` vrací hodnotu hustoty pravděpodobnosti.
- **Distribuční funkce (CDF):** Funkce `NORM.S.DIST(x; TRUE)` vrací hodnotu distribuční funkce.
- **Kvantilová funkce:** Funkce `NORM.S.INV(p)` vrací kvantil pro danou pravděpodobnost p .

5.2 Rovnoměrné rozdělení

Definice

Definice 5.2. Rovnoměrné rozdělení $U(a, b)$ je rozdělení pravděpodobnosti, kde každá hodnota z intervalu $[a, b]$ má stejnou pravděpodobnost. Je určeno dvěma parametry: dolní mezí a a horní mezí b .

Hustota rovnoměrného rozdělení je dána vzorcem:

$$f(x; a, b) = \frac{1}{b - a} \quad \text{pro } a \leq x \leq b.$$


Toto rozdělení se používá, pokud je každá hodnota v určitém rozsahu stejně pravděpodobná.

Základní číselné charakteristiky

- **Střední hodnota:** $\frac{a+b}{2}$
- **Rozptyl:** $\frac{(b-a)^2}{12}$
- **Symetrie:** Rovnoměrné rozdělení je symetrické kolem střední hodnoty.

Grafy hustoty a distribuční funkce

Grafy hustoty a distribuční funkce rovnoměrného rozdělení pro různé hodnoty a a b jsou uvedeny na obrázku 11.



Obr. 11: Grafy hustot a distribučních funkcí rovnoměrného rozdělení (různé parametry a a b)

Excelovské funkce

Pro práci s rovnoměrným rozdělením lze v Excelu použít následující funkce:

- **Hustota pravděpodobnosti (PDF):** Funkce `UNIFORM.DIST(x; a; b; FALSE)` vrací hodnotu hustoty pravděpodobnosti.
- **Distribuční funkce (CDF):** Funkce `UNIFORM.DIST(x; a; b; TRUE)` vrací hodnotu distribuční funkce.
- **Kvantilová funkce:** Funkce `UNIFORM.INV(p; a; b)` vrací kvantil pro danou pravděpodobnost p , dolní mez a a horní mez b .

5.3 Exponenciální rozdělení

Definice

Definice 5.3. Exponenciální rozdělení $Exp(\lambda)$ je rozdělení pravděpodobnosti, které modeluje dobu mezi nezávislými náhodnými událostmi, které se vyskytují s konstantní průměrnou mírou. Parametr λ představuje intenzitu událostí (průměrný počet výskytů za jednotku času).

Hustota exponenciálního rozdělení je dána vzorcem:

$$f(x; \lambda) = \lambda e^{-\lambda x} \quad \text{pro } x \geq 0,$$


kde $\lambda > 0$ je parametr udávající rychlost procesu. Tento typ rozdělení se používá pro modelování například doby čekání na příchod události.

Základní číselné charakteristiky

- **Střední hodnota:** $\frac{1}{\lambda}$
- **Rozptyl:** $\frac{1}{\lambda^2}$
- **Asymetrie:** Exponenciální rozdělení je asymetrické, má delší pravý chvost.

Grafy hustoty a distribuční funkce

Grafy hustoty a distribuční funkce exponenciálního rozdělení pro různé hodnoty λ jsou uvedeny na obrázku 12.

Obr. 12: Grafy hustot a distribučních funkcí exponenciálního rozdělení pro různé parametry λ

Excelovské funkce

Pro práci s exponenciálním rozdělením lze v Excelu použít následující funkce:

- **Hustota pravděpodobnosti (PDF):** Funkce `EXPON.DIST(x; λ; FALSE)` vrací hodnotu hustoty pravděpodobnosti.
- **Distribuční funkce (CDF):** Funkce `EXPON.DIST(x; λ; TRUE)` vrací hodnotu distribuční funkce.
- **Kvantilová funkce:** Funkce `EXPON.INV(p; λ)` vrací kvantil pro danou pravděpodobnost p a parametr λ .

5.4 Řešené příklady

Příklad 5.4 (Rovnoměrné rozdělení $R(a, b)$). Tramvajová linka číslo 8 odjíždí v dopoledních hodinách ze zastávky každých 10 minut. Vypočítejte pravděpodobnost, že na ni budete dopoledne čekat déle než 7 minut.

Doba čekání je náhodná veličina X , která má rovnoměrné rozdělení pravděpodobnosti – v našem případě $R(0, 10)$.

Řešení: Pro rovnoměrné rozdělení $R(a, b)$ platí:

$$f(x) = \begin{cases} \frac{1}{b-a}, & a \leq x \leq b, \\ 0, & \text{jinak.} \end{cases}$$

V našem případě $a = 0$ a $b = 10$, takže hustota pravděpodobnosti je:

$$f(x) = \begin{cases} \frac{1}{10}, & 0 \leq x \leq 10, \\ 0, & \text{jinak.} \end{cases}$$

Distribuční funkce $F(x)$ je:

$$F(x) = \begin{cases} 0, & x < 0, \\ \frac{x}{10}, & 0 \leq x \leq 10, \\ 1, & x > 10. \end{cases}$$

Pravděpodobnost, že budeme čekat déle než 7 minut, je:

$$P(X > 7) = 1 - F(7) = 1 - \frac{7}{10} = 0,3.$$

□

Příklad 5.5 (Exponenciální rozdělení $E(\lambda)$). Doba čekání hosta na pivo je v restauraci U Lva průměrně 5 minut. Určete:

1. hustotu pravděpodobnosti náhodné veličiny, která je dána dobou čekání na pivo,
2. pravděpodobnost, že budeme čekat na pivo déle než 12 minut,
3. dobu čekání, během které bude zákazník obsloužen s pravděpodobností 0,9.

Jedná se tedy o exponenciální rozdělení pravděpodobnosti.

Řešení: 1. Hustota pravděpodobnosti pro exponenciální rozdělení $E(\lambda)$ je dána vztahem:

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & x \geq 0, \\ 0, & x < 0. \end{cases}$$

V našem případě je střední doba čekání $\frac{1}{\lambda} = 5$, takže $\lambda = \frac{1}{5} = 0,2$. Hustota pravděpodobnosti tedy je:

$$f(x) = \begin{cases} 0,2e^{-0,2x}, & x \geq 0, \\ 0, & x < 0. \end{cases}$$

2. Distribuční funkce $F(x)$ je:

$$F(x) = \begin{cases} 0, & x < 0, \\ 1 - e^{-0,2x}, & x \geq 0. \end{cases}$$

Pravděpodobnost, že budeme čekat déle než 12 minut, je:

$$P(X > 12) = 1 - F(12) = 1 - (1 - e^{-0,2 \cdot 12}) = e^{-2,4} \approx 0,0907.$$

3. Hledáme dobu čekání t , při které bude zákazník obsloužen s pravděpodobností 0,9:

$$P(X \leq t) = 1 - e^{-0,2t} = 0,9.$$

Z toho plyne:

$$e^{-0,2t} = 0,1 \quad \Rightarrow \quad -0,2t = \ln(0,1) \quad \Rightarrow \quad t = \frac{\ln(0,1)}{-0,2} \approx 11,51.$$

Zákazník bude obsloužen s pravděpodobností 0,9 do 11,51 minut.

□

Příklad 5.6 (Normální rozdělení $N(\mu, \sigma^2)$). Jaká je pravděpodobnost, že náhodná veličina X , která má rozdělení $N(10, 9)$, nabude hodnoty:

1. menší než 16,
2. větší než 10,
3. v mezích od 7 do 22?

Řešení: 1. Hustota pravděpodobnosti pro normální rozdělení $N(\mu, \sigma^2)$ je dána vztahem:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

V našem případě $\mu = 10$ a $\sigma^2 = 9$, takže hustota pravděpodobnosti je:

$$f(x) = \frac{1}{3\sqrt{2\pi}} e^{-\frac{(x-10)^2}{18}}.$$

Distribuční funkce $F(x)$ je integrována z hustoty pravděpodobnosti:

$$F(x) = P(X \leq x) \quad \text{pro } x \in (-\infty, \infty).$$

Hodnoty distribuční funkce lze zjistit pomocí tabulek nebo např. v Excelu funkcí **NORMDIST**.

2. Pravděpodobnost, že $X < 16$, je:

$$P(X < 16) = F(16) \approx \text{NORMDIST}(16, 10, 3, 1) \approx 0,9772.$$

3. Pravděpodobnost, že $X > 10$, je:

$$P(X > 10) = 1 - F(10) = 1 - \text{NORMDIST}(10, 10, 3, 1) = 0,5.$$

4. Pravděpodobnost, že X nabude hodnoty v intervalu $7 < X < 22$, je:

$$P(7 < X < 22) = F(22) - F(7) \approx \text{NORMDIST}(22, 10, 3, 1) - \text{NORMDIST}(7, 10, 3, 1) \approx 0,8413.$$

□

Σ

V této kapitole jsme se zabývali základními spojitými rozděleními pravděpodobnosti, která se hojně používají v praxi. Seznámili jsme se s jejich vlastnostmi, praktickým použitím a s metodami výpočtu pravděpodobností a charakteristik.

- **Rovnoměrné rozdělení** $R(a, b)$ – Tento typ rozdělení se používá tehdy, když má náhodná veličina stejnou pravděpodobnost výskytu na každém bodě intervalu (a, b) . V této kapitole jsme si ukázali, jak vypočítat pravděpodobnosti a distribuční funkci rovnoměrně rozdělené náhodné veličiny a jaké jsou její základní charakteristiky (střední hodnota, rozptyl).

- **Exponenciální rozdělení** $E(\lambda)$ – Exponenciální rozdělení se používá při modelování času mezi událostmi v procesech, které se vyskytují s konstantní intenzitou. V praxi může jít například o dobu čekání na obsluhu. Zabývali jsme se výpočtem pravděpodobností, distribuční funkcí a časovými intervaly, v nichž nastanou určité události s danou pravděpodobností.
- **Normální rozdělení** $N(\mu, \sigma^2)$ – Toto rozdělení, často označované jako Gaussovo, je jedním z nejdůležitějších rozdělení v teorii pravděpodobnosti. Modeluje mnohé reálné procesy, jako jsou měření s chybami. V kapitole jsme si ukázali, jak pomocí normálního rozdělení odhadnout pravděpodobnosti pro různé intervaly hodnot, jak vypočítat hodnoty distribuční funkce a jak využít tabulky či software při výpočtech.

V této kapitole jsme se zaměřili také na aplikace těchto rozdělení ve formě řešených příkladů, které zahrnovaly výpočty pravděpodobností a interpretace získaných výsledků. Naučili jsme se rozlišovat situace, kdy je vhodné použít jednotlivé typy spojitých rozdělení, a získali jsme praktické dovednosti při jejich použití.

Kapitola poskytuje pevný základ pro pochopení spojitých náhodných veličin a jejich rozdělení, které jsou klíčové pro analýzu a modelování reálných dat v různých oblastech, od statistiky po strojové učení.

?


1. Jaké jsou hlavní rozdíly mezi spojitým a diskrétním rozdělením pravděpodobnosti? Uveďte příklady spojitých rozdělení.
2. Co je to distribuční funkce náhodné veličiny a jaký je její význam? Jaký tvar má distribuční funkce pro rovnoměrné rozdělení?
3. Vysvětlete, co rozumíme pod termínem hustota pravděpodobnosti. Jaká je hustota pravděpodobnosti pro exponenciální rozdělení?
4. Jaké jsou základní charakteristiky normálního rozdělení $N(\mu, \sigma^2)$? Proč je toto rozdělení tak důležité v teorii pravděpodobnosti a statistice?
5. Jaké jsou aplikace exponenciálního rozdělení v praxi? Vysvětlete, v jakých situacích je vhodné použít exponenciální rozdělení.
6. K čemu se používá rovnoměrné rozdělení? Jak se vypočítá střední hodnota a rozptyl rovnoměrně rozdělené náhodné veličiny?
7. Jakou roli hraje normální rozdělení při testování statistických hypotéz? Jaké vlastnosti musí mít data, aby bylo možné použít normální rozdělení pro analýzu?
8. Jaké jsou klíčové rozdíly mezi pravděpodobnostní funkcí a hustotou pravděpodobnosti? Jakou hodnotu má hustota pravděpodobnosti v konkrétním bodě pro normální rozdělení?
9. Co rozumíme pod pojmem střední hodnota náhodné veličiny? Jak se liší střední hodnota mezi rovnoměrným, exponenciálním a normálním rozdělením?
10. Jaký je vztah mezi intenzitou λ v exponenciálním rozdělení a střední dobou mezi událostmi?
11. Náhodná veličina X má rozdělení $N(0, 1)$. Určete:
 - a. $P(X < 2,31)$ [0,9896]
 - b. $P(X < -1,1)$ [0,1357]

- c. $P(-0,41 < X < 2,92)$ [0,6599]
12. Váha v uhelných skladech váží s chybou 30 kg, přičemž snižuje váhu. Náhodné chyby mají normální rozdělení pravděpodobnosti se $\sigma = 100$ kg. Jaká je pravděpodobnost, že chyba zjištěné váhy nepřekročí v absolutní hodnotě 90 kg? [0,6730]
13. Rovnoměrně rozdělená náhodná veličina X na intervalu $(2, 10)$. Vypočtěte:
- Střední hodnotu a rozptyl. [Střední hodnota: 6, Rozptyl: 5,33]
 - $P(X > 7)$ [0,375]
14. Čas mezi událostmi je modelován exponenciálním rozdělením s intenzitou $\lambda = 0,5$. Jaká je pravděpodobnost, že čas mezi dvěma událostmi bude menší než 3 minuty? [0,7769]



Literatura k tématu:

- [1] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6. ISBN 978-80-867-3208-8.
- [2] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [3] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [4] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.



Kapitola 6

Náhodný vektor



Po prostudování této kapitoly budete umět:

- určit hustotu pravděpodobnosti a distribuční funkci náhodného vektoru,
- vypočítat marginální funkce náhodného vektoru a charakteristiky náhodného vektoru – kovarianci a koeficient korelace.



Klíčová slova:

Náhodný vektor, hustota pravděpodobnosti, distribuční funkce, kovariance, koeficient korelace.

Náhled kapitoly

V této kapitole se zaměříme na pojem náhodného vektoru, což je rozšíření náhodné veličiny na případ dvou nebo více veličin současně. Probereme základní vlastnosti náhodného vektoru, společné a marginální rozdělení, a ukážeme si, jak lze analyzovat závislosti mezi jednotlivými složkami vektoru. Dále se budeme věnovat výpočtu číselných charakteristik, jako je střední hodnota, kovariance a koeficient korelace, a jejich významu při práci s náhodnými veličinami. Na praktických příkladech uvidíme, jak lze tyto pojmy využít.

Cíle kapitoly

Cílem je pochopit, proč je důležité pracovat s více náhodnými veličinami současně a jaký přínos to má pro analýzu dat.

Časová náročnost

Pro zvládnutí této kapitoly doporučujeme věnovat přibližně 3 hodiny studiu teorie, výpočtu charakteristik náhodného vektoru a řešení praktických příkladů, které vám pomohou lépe porozumět závislostem mezi náhodnými veličinami.

6.1 Dvourozměrný náhodný vektor

Náhodný vektor představuje rozšíření pojmu náhodné veličiny na případ dvou a více náhodných veličin současně. Popisuje pravděpodobnostní chování více veličin a umožňuje analyzovat jejich společnou distribuci a závislosti mezi nimi. V této kapitole se zaměříme na případ dvourozměrného náhodného vektoru.

Definice 6.1 (Náhodný vektor). Náhodný vektor (X, Y) je uspořádaná dvojice náhodných veličin. Pro popis jeho pravděpodobnostní struktury se využívá společná pravděpodobnostní funkce $p(x, y)$ u diskrétních veličin nebo hustota pravděpodobnosti $f(x, y)$ u spojitých veličin.

Definice 6.2 (Společná pravděpodobnostní funkce a hustota pravděpodobnosti). V případě diskrétních veličin je společná pravděpodobnostní funkce $p(x, y) = P(X = x, Y = y)$ definována jako pravděpodobnost, že $X = x$ a $Y = y$. U spojitých veličin je společná hustota pravděpodobnosti $f(x, y)$ definována tak, že:

$$P(X \in (x_1, x_2), Y \in (y_1, y_2)) = \int_{x_1}^{x_2} \int_{y_1}^{y_2} f(x, y) dy dx.$$

Definice 6.3 (Marginální rozdělení). Marginální rozdělení popisuje pravděpodobnostní chování jednotlivých složek náhodného vektoru. U diskrétních veličin získáme marginální pravděpodobnosti $p_1(x)$ a $p_2(y)$ jako:

$$p_1(x) = \sum_y p(x, y), \quad p_2(y) = \sum_x p(x, y).$$

Pro spojité veličiny získáme marginální hustoty $f_1(x)$ a $f_2(y)$ integrací:

$$f_1(x) = \int_{-\infty}^{\infty} f(x, y) dy, \quad f_2(y) = \int_{-\infty}^{\infty} f(x, y) dx.$$

Definice 6.4 (Distribuční funkce). Distribuční funkce náhodného vektoru $F(x, y)$ je definována jako:

$$F(x, y) = P(X \leq x, Y \leq y).$$

U spojitých veličin platí:

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y f(u, v) dv du.$$

Definice 6.5 (Podmíněné rozdělení). Podmíněná pravděpodobnost $p(x | y)$ je definována jako:

$$p(x | y) = \frac{p(x, y)}{p_2(y)} \quad \text{pro } p_2(y) > 0.$$

Pro spojité veličiny je podmíněná hustota definována obdobně:

$$f(x | y) = \frac{f(x, y)}{f_2(y)} \quad \text{pro } f_2(y) > 0.$$

Definice 6.6 (Číselné charakteristiky náhodného vektoru). Mezi základní charakteristiky náhodného vektoru (X, Y) patří střední hodnota, rozptyl a kovariance:

$$E[X] = \sum_x x \cdot p_1(x) \quad (\text{diskrétní}) \quad \text{nebo} \quad E[X] = \int_{-\infty}^{\infty} x \cdot f_1(x) dx \quad (\text{spojité}).$$

Kovariance $\text{Cov}(X, Y)$ se počítá jako:

$$\text{Cov}(X, Y) = E[(X - E[X])(Y - E[Y])] = E[XY] - E[X]E[Y].$$

Definice 6.7 (Koeficient korelace). Koeficient korelace $\rho(X, Y)$ vyjadřuje míru lineární závislosti mezi veličinami X a Y . Definice koeficientu korelace je:

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y},$$

kde σ_X a σ_Y jsou směrodatné odchylky veličin X a Y . Hodnota $\rho(X, Y)$ se pohybuje v intervalu $\langle -1, 1 \rangle$.

6.2 Řešené příklady

Příklad 6.8. Najděte konstantu c , tak aby funkce:

$$f(x, y) = \begin{cases} c \frac{x^2}{1+y^2}, & 2 \leq x \leq 3, 0 \leq y \leq 1, \\ 0, & \text{jinak.} \end{cases}$$

byla hustotou pravděpodobnosti nějakého náhodného vektoru (X, Y) .

Řešení: Aby byla $f(x, y)$ hustotou pravděpodobnosti, musí platit:

$$\int_0^1 \int_2^3 c \frac{x^2}{1+y^2} dx dy = 1.$$

Nejprve vypočítáme integrál:

$$\int_0^1 \int_2^3 \frac{x^2}{1+y^2} dx dy.$$

Integrál lze rozdělit na vnitřní a vnější:

$$\int_0^1 \int_2^3 \frac{x^2}{1+y^2} dx dy = \int_0^1 \frac{1}{1+y^2} \left(\int_2^3 x^2 dx \right) dy.$$

Vnitřní integrál je:

$$\int_2^3 x^2 dx = \left[\frac{x^3}{3} \right]_2^3 = \frac{27}{3} - \frac{8}{3} = \frac{19}{3}.$$

Vnější integrál je:

$$\int_0^1 \frac{1}{1+y^2} dy = [\arctan(y)]_0^1 = \arctan(1) - \arctan(0) = \frac{\pi}{4}.$$

Celkový integrál je tedy:

$$\int_0^1 \int_2^3 \frac{x^2}{1+y^2} dx dy = \frac{19}{3} \cdot \frac{\pi}{4} = \frac{19\pi}{12}.$$

Aby byla $f(x, y)$ hustotou pravděpodobnosti, musí platit:

$$c \cdot \frac{19\pi}{12} = 1.$$

Z toho plyne:

$$c = \frac{12}{19\pi}.$$

Hustota pravděpodobnosti je tedy:

$$f(x, y) = \begin{cases} \frac{12}{19\pi} \cdot \frac{x^2}{1+y^2}, & 2 \leq x \leq 3, 0 \leq y \leq 1, \\ 0, & \text{jinak.} \end{cases}$$

□

Příklad 6.9. Studenti z jedné studijní skupiny byli na zkoušce z matematiky a fyziky s těmito výsledky (první hodnota v uspořádané dvojici označuje výsledek studenta z matematiky, druhá z fyziky):

(1, 1), (1, 2), (1, 3), (2, 2), (2, 3), (2, 3), (3, 2), (3, 2), (3, 3), (3, 3), (3, 3), (3, 3), (3, 3),
(3, 4), (3, 4), (4, 3), (4, 3), (4, 4), (4, 4), (4, 4).

1. Vytvořte pravděpodobnostní tabulku náhodného vektoru, jehož složka X bude znamenat výsledky u zkoušky z matematiky a složka Y bude znamenat výsledky u zkoušky z fyziky.
2. Určete marginální pravděpodobnostní funkce $p_1(x)$ a $p_2(y)$.
3. Určete distribuční funkci $F(x, y)$.
4. Určete podmíněné pravděpodobnosti $p(x | y)$.

Řešení: Studentů je podle zadání 20 ($n = 20$).

ad 1. Vytvoříme **pravděpodobnostní tabulku** pro náhodný vektor (X, Y) :

$X \backslash Y$	1	2	3	4
1	0,05	0,05	0,05	0
2	0	0,05	0,10	0
3	0	0,10	0,25	0,10
4	0	0	0,10	0,15

Hodnoty v prvním řádku a prvním sloupci jsou hodnoty, kterých mohou nabývat náhodné veličiny X a Y . Ostatní čísla v tabulce znamenají pravděpodobnosti všech možných dvojic, například (hodnota v druhém řádku a druhém sloupci tabulky) $p(1, 1) = \frac{1}{20} = 0,05$, neboť hodnota $(1, 1)$ je jen jedna z dvaceti. Podobně třeba $p(3, 2) = \frac{2}{20} = 0,10$.

ad 2. **Marginální pravděpodobnostní funkce** $p_1(x)$ a $p_2(y)$:

$X \backslash Y$	1	2	3	4	$p_1(x)$
1	0,05	0,05	0,05	0	0,15
2	0	0,05	0,10	0	0,15
3	0	0,10	0,25	0,10	0,45
4	0	0	0,10	0,15	0,25
$p_2(y)$	0,05	0,20	0,50	0,25	1,00

Marginální pravděpodobnostní funkce $p_1(x)$ jsou dány součty pravděpodobností v řádcích, $p_2(y)$ jsou dány součty pravděpodobností ve sloupcích.

ad 3. **Distribuční funkce** $F(x, y)$:

Distribuční funkce $F(x, y)$ je součtem všech pravděpodobností, kde $X \leq x$ a $Y \leq y$.
Například:

$$F(3, 3) = P(X \leq 3, Y \leq 3) = 0,05 + 0,05 + 0,05 + 0,05 + 0,10 + 0,10 + 0,25 = 0,65.$$

Tabulka hodnot distribuční funkce $F(x, y)$ je následující:

$X \backslash Y$	1	2	3	4	$F(x, y)$
1	0,05	0,10	0,15	0,15	0,15
2	0,05	0,15	0,25	0,25	0,25
3	0,05	0,25	0,50	0,60	0,60
4	0,05	0,25	0,60	0,75	0,75

ad 4. **Podmíněné pravděpodobnosti** $p(x | y)$:

Podmíněné pravděpodobnosti $p(x | y)$ se vypočítají jako:

$$p(x | y) = \frac{p(x, y)}{p_2(y)}.$$

$$\text{Například } p(3 | 3) = \frac{0,25}{0,50} = 0,50.$$

Tabulka podmíněných pravděpodobností $p(x | y)$ je následující:

$X \setminus Y$	1	2	3	4
1	1,00	0,25	0,10	0,00
2	0,00	0,25	0,20	0,00
3	0,00	0,50	0,50	0,40
4	0,00	0,00	0,20	0,60

□

Příklad 6.10. Určete číselné charakteristiky náhodného vektoru (X, Y) , který je zadán tabulkou:

$Y \setminus X$	2	3	6
1	0,15	0,20	0,10
3	0,20	0,05	0,30

Řešení: Budeme postupovat podle následujících kroků:

1. Střední hodnota $E(X)$ a $E(Y)$:

Střední hodnoty se vypočítají jako vážený průměr hodnot X a Y s váhami odpovídajícími pravděpodobnostem:

$$E(X) = \sum_i \sum_j x_i \cdot p(x_i, y_j),$$

$$E(Y) = \sum_i \sum_j y_j \cdot p(x_i, y_j).$$

Pro výpočet $E(X)$:

$$E(X) = 2 \cdot (0,15 + 0,20) + 3 \cdot (0,20 + 0,05) + 6 \cdot (0,10 + 0,30) = 2 \cdot 0,35 + 3 \cdot 0,25 + 6 \cdot 0,40 = 0,70 + 0,75 + 2,40 = 3,85.$$

Pro výpočet $E(Y)$:

$$E(Y) = 1 \cdot (0,15 + 0,20 + 0,10) + 3 \cdot (0,20 + 0,05 + 0,30) = 1 \cdot 0,45 + 3 \cdot 0,55 = 0,45 + 1,65 = 2,10.$$

2. Rozptyl $D(X)$ a $D(Y)$:

Rozptyl se vypočítá jako:

$$D(X) = \sum_i \sum_j (x_i - E(X))^2 \cdot p(x_i, y_j),$$

$$D(Y) = \sum_i \sum_j (y_j - E(Y))^2 \cdot p(x_i, y_j).$$

Pro výpočet $D(X)$:

$$D(X) = (2 - 3,85)^2 \cdot (0,15 + 0,20) + (3 - 3,85)^2 \cdot (0,20 + 0,05) + (6 - 3,85)^2 \cdot (0,10 + 0,30).$$

$$D(X) = (-1,85)^2 \cdot 0,35 + (-0,85)^2 \cdot 0,25 + 2,15^2 \cdot 0,40 = 3,4225 \cdot 0,35 + 0,7225 \cdot 0,25 + 4,6225 \cdot 0,40.$$

$$D(X) = 1,198875 + 0,180625 + 1,849 = 3,2285.$$

Pro výpočet $D(Y)$:

$$D(Y) = (1 - 2,10)^2 \cdot (0,15 + 0,20 + 0,10) + (3 - 2,10)^2 \cdot (0,20 + 0,05 + 0,30).$$

$$D(Y) = (-1,10)^2 \cdot 0,45 + 0,90^2 \cdot 0,55 = 1,21 \cdot 0,45 + 0,81 \cdot 0,55 = 0,5445 + 0,4455 = 0,99.$$

3. Kovariance $\text{Cov}(X, Y)$:

Kovariance se vypočítá jako:

$$\text{Cov}(X, Y) = \sum_i \sum_j (x_i - E(X)) \cdot (y_j - E(Y)) \cdot p(x_i, y_j).$$

$$\text{Cov}(X, Y) = (2 - 3,85) \cdot (1 - 2,10) \cdot 0,15 + (2 - 3,85) \cdot (3 - 2,10) \cdot 0,20 + \dots$$

$$\text{Cov}(X, Y) = (-1,85) \cdot (-1,10) \cdot 0,15 + (-1,85) \cdot 0,90 \cdot 0,20 + \dots$$

$$\text{Cov}(X, Y) = 0,30525 - 0,333 + \dots$$

Počítáním všech členů dostaneme hodnotu kovariance přibližně $\text{Cov}(X, Y) \approx 0,465$.

4. Koeficient korelace $\rho(X, Y)$:

Koeficient korelace je dán vztahem:

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{D(X) \cdot D(Y)}}.$$

$$\rho(X, Y) = \frac{0,465}{\sqrt{3,2285 \cdot 0,99}} = \frac{0,465}{\sqrt{3,196}} = \frac{0,465}{1,787} \approx 0,26.$$

Jedná se tedy o slabou pozitivní lineární závislost mezi náhodnými veličinami X a Y . $\square$

Příklad 6.11. Vypočítejte střední hodnotu náhodné veličiny X náhodného vektoru, který je určen hustotou pravděpodobnosti:

$$f(x, y) = \begin{cases} \frac{1}{2} \sin(x + y), & 0 \leq x \leq \frac{\pi}{2}, 0 \leq y \leq \frac{\pi}{2}, \\ 0, & \text{jinak.} \end{cases}$$

Řešení: Střední hodnota náhodné veličiny X je dána vztahem:

$$E(X) = \int_0^{\frac{\pi}{2}} \int_0^{\frac{\pi}{2}} x \cdot \frac{1}{2} \sin(x + y) dx dy.$$

Nejprve vypočítáme vnitřní integrál podle proměnné x :

$$E(X) = \frac{1}{2} \int_0^{\frac{\pi}{2}} \int_0^{\frac{\pi}{2}} x \sin(x + y) dx dy.$$

Pro výpočet použijeme substituci $u = x + y$, což znamená $du = dx$ a u se mění od y do $y + \frac{\pi}{2}$. Poté máme:

$$E(X) = \frac{1}{2} \int_0^{\frac{\pi}{2}} \int_y^{y+\frac{\pi}{2}} (u - y) \sin(u) du dy.$$

Nyní rozdělíme integrál na dva:

$$E(X) = \frac{1}{2} \int_0^{\frac{\pi}{2}} \left(\int_y^{y+\frac{\pi}{2}} u \sin(u) du - y \int_y^{y+\frac{\pi}{2}} \sin(u) du \right) dy.$$

První integrál $\int u \sin(u) du$ je:

$$\int u \sin(u) du = -u \cos(u) + \sin(u).$$

Po dosazení mezi $u = y$ a $u = y + \frac{\pi}{2}$ dostaneme:

$$\int_y^{y+\frac{\pi}{2}} u \sin(u) du = -\left(y + \frac{\pi}{2}\right) \cos\left(y + \frac{\pi}{2}\right) + \sin\left(y + \frac{\pi}{2}\right) - (-y \cos(y) + \sin(y)).$$

Dále platí, že $\cos\left(y + \frac{\pi}{2}\right) = -\sin(y)$ a $\sin\left(y + \frac{\pi}{2}\right) = \cos(y)$, takže první část integrálu je:

$$\int_y^{y+\frac{\pi}{2}} u \sin(u) du = y \sin(y) + \frac{\pi}{2} \cos(y) + \cos(y) - y \cos(y).$$

Druhý integrál $\int_y^{y+\frac{\pi}{2}} \sin(u) du$ je:

$$\int \sin(u) du = -\cos(u),$$

takže po dosazení mezí dostaneme:

$$\int_y^{y+\frac{\pi}{2}} \sin(u) du = -\cos\left(y + \frac{\pi}{2}\right) + \cos(y) = \sin(y) + \cos(y).$$

Nakonec integrujeme vnější integrál podle y a dostaneme výslednou hodnotu střední hodnoty $E(X)$.

Po kompletním výpočtu zjistíme, že:

$$E(X) = \frac{\pi}{4}.$$

□

Σ

V této kapitole jsme se seznámili s konceptem náhodného vektoru, který představuje rozšíření pojmu náhodné veličiny na případ dvou a více náhodných veličin současně. Náhodný vektor popisuje pravděpodobnostní chování více veličin a umožňuje analyzovat jejich společnou distribuci a závislosti mezi nimi.

V této kapitole jsme rovněž řešili praktické příklady, ve kterých jsme aplikovali výše uvedené koncepty. Náhodný vektor je důležitým nástrojem při analýze dat, kde je třeba zkoumat více proměnných současně a jejich vzájemné vztahy. Tato kapitola poskytuje základní porozumění tomu, jak tyto závislosti modelovat a analyzovat.

- **Definice náhodného vektoru:** Náhodný vektor (X, Y) je uspořádaná dvojice náhodných veličin. Pro popis jeho pravděpodobnostní struktury se využívá společná pravděpodobnostní funkce (u diskrétních veličin) nebo hustota pravděpodobnosti (u spojitých veličin).
- **Společná pravděpodobnostní funkce a hustota pravděpodobnosti:** V případě diskrétních veličin (X, Y) je společná pravděpodobnostní funkce $p(x, y)$ definována jako pravděpodobnost, že $X = x$ a $Y = y$. U spojitých veličin je obdobně definována společná hustota pravděpodobnosti $f(x, y)$.
- **Marginální rozdělení:** Marginální rozdělení $p_1(x)$ a $p_2(y)$ popisuje pravděpodobnostní chování jednotlivých složek náhodného vektoru. Získává se součtem (u diskrétních veličin) nebo integrací (u spojitých veličin) přes všechny hodnoty druhé veličiny.
- **Distribuční funkce:** Distribuční funkce náhodného vektoru $F(x, y)$ je definována jako pravděpodobnost, že $X \leq x$ a $Y \leq y$.

- **Podmíněné rozdělení:** Podmíněné rozdělení $p(x | y)$ popisuje pravděpodobnost, že náhodná veličina X nabude hodnoty x , pokud je známo, že $Y = y$. Pro spojité veličiny se obdobně definuje podmíněná hustota pravděpodobnosti.
- **Číselné charakteristiky náhodného vektoru:** Mezi základní číselné charakteristiky patří střední hodnota, rozptyl, kovariance a koeficient korelace. Tyto charakteristiky umožňují popsat závislosti mezi složkami náhodného vektoru a míru jejich vzájemné závislosti.
- **Koeficient korelace:** Koeficient korelace $\rho(X, Y)$ udává míru lineární závislosti mezi veličinami X a Y . Hodnota ρ se pohybuje v intervalu $\langle -1, 1 \rangle$, kde hodnoty blízké 1 nebo -1 indikují silnou pozitivní, resp. negativní závislost, zatímco hodnoty blízké 0 indikují slabou nebo žádnou závislost.

?

1. Co je to dvourozměrný náhodný vektor a jak se liší od jednorozměrné náhodné veličiny?
2. Jak je definována společná pravděpodobnostní funkce dvou náhodných veličin X a Y ?
3. Vysvětlete rozdíl mezi marginálním a podmíněným rozdělením náhodného vektoru.
4. Jak se vypočítá marginální rozdělení z dvourozměrného náhodného vektoru?
5. Jaká je definice kovariance a co vyjadřuje o závislosti mezi náhodnými veličinami X a Y ?
6. Co vyjadřuje koeficient korelace a v jakém intervalu se jeho hodnota pohybuje?
7. Jaký je vztah mezi kovariancí a koeficientem korelace pro náhodný vektor (X, Y) ?
8. Uvedte příklad praktického využití dvourozměrného náhodného vektoru v ekonomii nebo managementu.
9. Náhodný vektor (X, Y) má pravděpodobnostní funkci zadanou tabulkou:

$X \backslash Y$	1	2	3
-1	0,15	0,05	0,10
0	0,10	0,10	0,15
1	0,05	0,10	0,20

Určete:

- a. $P(X = 0, Y = 3)$ $[0,15]$
 - b. $P(X < 0,5, Y < 2,5)$ $[0,40]$
 - c. $P(X > 0, Y > 2,5)$ $[0,20]$
 - d. marginální rozdělení $P(X)$ $[P(X = -1) = 0,30, P(X = 0) = 0,35, P(X = 1) = 0,35]$
 - e. marginální rozdělení $P(Y)$ $[P(Y = 1) = 0,30, P(Y = 2) = 0,25, P(Y = 3) = 0,45]$
10. Pro náhodný vektor daný následující tabulkou vypočtěte koeficient korelace:


$X \backslash Y$	1	0
1	0,05	0,01
0	0,02	0,92

[Koeficient korelace $\rho(X, Y) \approx 0,7558$]



Literatura k tématu:

- [1] ANDĚL, J. Statistické metody. 5. vyd. Praha: Matfyzpress, 2019. ISBN 978-80-7378-381-5.
- [2] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6. ISBN 978-80-867-3208-8.
- [3] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [4] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [5] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.



Kapitola 7

Statistický soubor s jedním argumentem



Po prostudování této kapitoly budete umět:

- určit základní popisné charakteristiky statistického souboru s jedním argumentem (viz klíčová slova),
- využít k těmto výpočtům statistický software (Excel).



Klíčová slova:

Základní soubor, statistická jednotka, četnosti, grafické znázornění četností, aritmetický průměr, modus, kvantily, medián, kvartily, decily, percentily, rozptyl, směrodatná odchylka.

Náhled kapitoly

V předchozích kapitolách jsme se věnovali spíše teoretickým modelům, zde se dostáváme k práci s daty. Tato kapitola se zaměřuje na základní popisné statistiky statistického souboru s jedním argumentem (s jednou proměnnou). Probereme různé druhy četností, jejich tabulkové a grafické znázorňování, dále různé míry polohy a variability dat. Prostě vše, co nám umožní mít ucelenější představu o rozložení dat. V následující kapitole tyto prostředky rozšíříme na dvourozměrný případ, kde nám k popisu jednotlivých proměnných přibude i jejich vzájemný vztah.

Cíle kapitoly

Cílem této kapitoly je získat základní potřebné dovednosti při práci s jednoduchými daty z pohledu popisné statistiky, tedy umět provádět potřebné výpočty a chápat jejich výsledky.

Časová náročnost

Pro tuto kapitolu doporučujeme vyčlenit přibližně 3 hodiny, které zahrnují jak studium teoretických částí, tak procvičování praktických příkladů a aplikací.

7.1 Základní pojmy a vlastnosti

Pravděpodobnost vs. statistika

Pravděpodobnost je matematický model reality. Jedná se o idealizovaný, abstraktní model, který pracuje s jednou nebo více náhodnými veličinami, jejichž rozdělení je známé. Z podstaty věci je tento model nepozorovatelný – představuje pouze naši abstrakci skutečnosti.

- Pravděpodobnost se zabývá náhodnými veličinami a jejich rozdělením.
- Jejím cílem je popsat, jak by se náhodné veličiny mohly chovat v určitém modelu.
- Pravděpodobnostní modely jsou používány v mnoha oblastech pro predikci nejistých jevů.

Statistika naopak vychází z pozorování (měření) hodnot konkrétních veličin. Statistika zkoumá jevy na rozsáhlém souboru dat a činí o nich závěry pomocí statistické indukce. Výsledky z malého vzorku jsou zobecňovány na rozsáhlejší populaci.

- Statistika používá odhady, protože žádný konečný výběr nemůže poskytovat úplnou informaci o rozdělení náhodných veličin v populaci.
- Statistika hledá pravidelnosti a souvislosti v datech a zobecňuje výsledky na širší soubor, než byl ten, ze kterého byly odvozeny.
- Vychází z reálných dat, na jejichž základě činí závěry o celkové populaci.

Příklady aplikací statistiky:

- Mají lidé, kteří pravidelně cvičí, lepší zdravotní ukazatele než ti, kteří necvičí?
- Je průměrná výše příjmů v určité oblasti závislá na vzdělání obyvatel?
- Jaká je pravděpodobnost, že nový produkt na trhu uspěje na základě výsledků z testovacího vzorku?

Data

Data představují klíčový prvek statistických analýz. Jedná se o pozorování, která provádíme za účelem zodpovězení položených otázek.

- **Matematicky:** data jsou realizací náhodné veličiny. Jedná se tedy o konkrétní hodnoty, které náhodná veličina může nabýt při experimentu nebo měření.
- **Datové tabulky:** Data jsou často organizována ve formě tabulek, kde řádky představují jednotlivá pozorování, zatímco sloupce odpovídají měřeným proměnným.
 - Řádky: Pozorování se týkají nezávislých subjektů náhodného výběru, jako jsou osoby, experimenty nebo jednotky sledování.
 - Sloupce: Každý sloupec odpovídá určité měřené veličině, například věk, pohlaví, výška, váha apod.
- **Software:** Pro správu a zpracování dat se používá řada softwarových nástrojů. Nejčastěji jsou využívány databázové systémy nebo tabulkové procesory, jako je Excel.
- **Statistický software:** K analýze dat se specializované statistické programy, jako jsou SAS, Statistica, SPSS, R nebo Python.

Ve statistice hraje správná organizace a správa dat zásadní roli, protože dobře strukturovaná data umožňují efektivnější analýzu a zajišťují správnost výsledků.

Popisná statistika

Popisná statistika představuje základní část statistické analýzy. Jejím cílem je sumarizovat a jednoduše popsat data, která máme k dispozici.

- **Pojmový aparát statistiky:** Zahrnuje základní statistické pojmy, jako jsou průměr, medián, rozptyl, směrodatná odchylka, kvartily a další.
- **Základní nástroj analýzy dat:** Pomocí popisných statistik můžeme rychle získat přehled o základních vlastnostech dat. Například průměr poskytuje informaci o střední hodnotě souboru, zatímco rozptyl nám řekne, jak jsou data rozložena kolem této hodnoty.
- **Prostředky pro prezentaci dat a výsledků:** Popisná statistika je často doprovázena vizuálními nástroji, jako jsou grafy, tabulky a diagramy, které umožňují efektivní prezentaci dat a usnadňují jejich interpretaci.

Příkladem aplikace popisné statistiky může být analýza průměrných platů v různých regionech, kde nás může zajímat nejen střední hodnota platu, ale také rozptyl a medián, abychom lépe porozuměli rozložení příjmů v dané populaci.

Základní pojmy ve statistice

Pro práci se statistickými daty je důležité nejprve pochopit několik základních pojmů:

Definice 7.1. Statistická jednotka je objekt, který chceme zkoumat. Může se jednat o osoby, domácnosti, firmy, organismy, obce, kraje, atd. Každá statistická jednotka je nositelem určité vlastnosti, která nás zajímá, a kterou zkoumáme.

Definice 7.2. Statistický soubor je množina statistických jednotek, které jsou předmětem našeho zkoumání:

- **Základní soubor:** Množina všech statistických jednotek, jejichž vlastnosti chceme poznat. Tento soubor zahrnuje veškeré objekty, které odpovídají naší studii, např. všechny domácnosti v určitém kraji.
- **Výběrový soubor:** Množina skutečně vyšetřovaných statistických jednotek, které jsou náhodně vybrány ze základního souboru. Tento výběr by měl být reprezentativní pro celou populaci.

Definice 7.3. Statistický znak je vlastnost, která je zjišťována na každé statistické jednotce. Tato vlastnost je v rámci statistiky považována za náhodnou veličinu. Mezi běžné statistické znaky patří např. pohlaví, věk, výška, hmotnost, počet dětí, barva očí, dopravní prostředek, počet úrazů, jméno.

Definice 7.4. Rozsah souboru (označován často jako n) představuje počet zkoumaných statistických jednotek v daném souboru.

Typy statistických znaků

Statistické znaky se dělí do několika kategorií podle svého charakteru:

- **Kvalitativní znaky** (někdy nazývané kategorické): Jedná se o slovní nebo kategoriální znaky, které nemohou být vyjádřeny numericky. Příkladem jsou pohlaví, barva očí, nebo dopravní prostředek, který statistická jednotka používá.
- **Kvantitativní znaky** (číslené, numerické):
 - **Spojité znaky**: Mohou nabývat jakékoli hodnoty na určitých intervalech, např. výška, hmotnost nebo věk. Tyto znaky mohou být měřeny s libovolnou přesností.
 - **Diskrétní znaky**: Nabývají pouze určitých konkrétních hodnot, např. počet dětí nebo počet úrazů. Tyto znaky mají omezený počet možných hodnot.
- **Alternativní znaky**: Tyto znaky mohou nabývat pouze dvou hodnot, např. zda osoba kouří či nikoli, nebo zda byl test úspěšný či neúspěšný.
- **Množné znaky**: Jedná se o znaky, které mohou nabývat tří a více hodnot, např. dopravní prostředek (auto, kolo, autobus).

Jednorozměrný statistický soubor

V jednorozměrném statistickém souboru se zabýváme pouze jedním statistickým znakem X a jeho hodnotami v rámci výběrového souboru.

Označení:

- $\{\varepsilon_1, \dots, \varepsilon_n\}$ výběrový soubor: Každá ε_i je statistická jednotka.
- X : statistický znak, který zkoumáme na každé statistické jednotce.
- x_j : hodnota znaku X na objektu ε_j , kde $j = 1, \dots, n$.
- $(x_1, \dots, x_n)$: datový soubor, který obsahuje hodnoty znaku X pro všechny jednotky.
- $(x_{(1)}, \dots, x_{(n)})$: uspořádaný datový soubor, tj. $x_{(1)} \leq \dots \leq x_{(n)}$.
- $(x_{[1]}, \dots, x_{[r]})$: vektor variant znaku X , tj. různé hodnoty, které znak X nabývá, kde $x_{[i]} \neq x_{[j]}$ pro $i \neq j$.

Jednorozměrný statistický soubor nám umožňuje analyzovat hodnoty určitého znaku v rámci výběrového souboru a zjišťovat jejich rozložení.

7.2 Rozložení četností

Rozložení četností slouží ke zpřehlednění datového souboru. Při této analýze sledujeme, kolikrát se jednotlivé hodnoty nebo intervaly hodnot vyskytují v našem výběrovém souboru.

- **Bodové rozložení četností:** Používá se pro diskrétní znaky s malým počtem variant, kdy četnost přiřazujeme jednotlivým variantám (hodnotám).
- **Intervalové rozložení četností:** Používá se pro diskrétní znaky s velkým počtem variant nebo pro spojité znaky, kdy četnost přiřazujeme třídícím intervalům.

Bodové rozložení četností

Bodové rozložení četností se vztahuje k jednotlivým hodnotám diskrétního znaku a zahrnuje následující typy četností:

Definice 7.5. (Absolutní) četnost varianty $x_{[j]}$: označována jako

$$n_j,$$

představuje počet výskytů hodnoty $x_{[j]}$ ve výběrovém souboru.

Definice 7.6. Relativní četnost varianty $x_{[j]}$: označována jako

$$p_j = \frac{n_j}{n},$$

kde n je celkový počet pozorování. Relativní četnost můžeme chápat jako empirickou pravděpodobnost.

Definice 7.7. (Absolutní) kumulativní četnost prvních j variant: označována jako

$$N_j = n_1 + \cdots + n_j,$$

představuje součet četností prvních j variant.

Definice 7.8. Relativní kumulativní četnost prvních j variant: označována jako

$$F_j = \frac{N_j}{n} = p_1 + \cdots + p_j,$$

představuje kumulativní relativní četnost, což je suma relativních četností až po j -tou variantu.

Definice 7.9. Empirická distribuční funkce pro bodové rozložení četností je definována následovně:

$$F(x) = \begin{cases} 0 & \text{pro } x < x_{[1]} \\ F_j & \text{pro } x_{[j]} \leq x < x_{[j+1]}, \quad j = 1, \dots, r-1 \\ 1 & \text{pro } x \geq x_{[r]} \end{cases}$$

Tato funkce zachycuje rozložení četností ve výběrovém souboru a zobrazuje kumulativní pravděpodobnost dosažení určité hodnoty.

Příklad 7.10 (Bodové rozložení četností). Při zápočtu ze statistiky se studenti podrobili testu, ve kterém mohli získat 0 až 15 bodů. Výsledky testu jsou následující:


5, 10, 6, 7, 0, 2, 2, 4, 8, 10, 12, 15, 0, 0, 4, 2, 7, 10, 15, 0, 6, 5, 5, 6, 9, 8, 7, 10, 12, 6, 0. Vytvořte tabulku rozložení bodových čeností (absolutních, relativních a kumulativních relativních) a nakreslete graf empirické distribuční funkce.

Řešení: Bodové rozložení četností je zobrazeno v tabulce 2 a graf empirické distribuční funkce na obrázku 13. □

Tento příklad ilustruje základní práci s bodovým rozložením četností, které umožňuje zjistit, kolik studentů dosáhlo určitého výsledku v testu a jak se tyto výsledky kumulují v rámci celého souboru.

Tab. 2: Bodové rozložení četností výsledků testu z příkladu 7.10

Body	n_j	p_j (%)	F_j (%)
0	5	16,7	16,7
2	3	10,0	26,7
4	2	6,7	33,4
5	2	6,7	40,1
6	4	13,3	53,4
7	3	10,0	63,4
8	2	6,7	70,1
9	1	3,3	73,4
10	4	13,3	86,7
12	2	6,7	93,4
15	2	6,7	100,0
Celkem	30	100,0	-



Obr. 13: Graf empirické distribuční funkce pro bodové rozložení četností z příkladu 7.10

Intervalové rozložení četností

Od bodového se liší tím, že na počátku celkový interval (rozsah) hodnot rozdělíme na menší podintervaly (rozsahy) a následně četnosti přiřazujeme celým těmto podintervalům. Po tomto kroku již vše funguje jako u bodových četností. Ukažme si to na následujícím příkladu.

Příklad 7.11 (Intervalové rozložení četností). U 70 žen byla změřena hladina hemoglobinu s přesností 0,1 g/100 ml. Výsledky jsou následující:

10,2; 13,7; 10,4; 14,9; 11,5; 12,0; 11,0; 13,3; 12,9; 12,1; 9,4; 13,2; 10,8; 11,7; 10,5; 13,7; 11,8; 14,1; 10,3; 13,6; 12,1; 12,9; 11,4; 12,7; 10,6; 11,4; 11,9; 9,3; 13,3; 14,6; 11,2; 11,7; 10,9; 10,4; 12,0; 12,9; 11,1; 10,2; 11,6; 12,5; 13,4; 12,1; 9,7; 11,3; 10,9; 14,7; 10,8; 13,3; 11,9; 11,4; 12,5; 13,0; 11,6; 13,4; 12,3; 11,0; 14,6; 11,1; 13,5; 10,9; 13,1; 11,8; 12,2.

Vytvořte tabulku rozložení intervalových četností (absolutních, relativních a kumulativních relativních).

Řešení: Intervalové rozložení četností je zobrazeno v tabulce 3. □

Tab. 3: Intervalové rozložení četností hladiny hemoglobinu u žen z příkladu 7.11

Hladina hemoglobinu v g/100 ml	n_j	p_j (%)	F_j (%)
8,0 – 8,9	1	1,4	1,4
9,0 – 9,9	3	4,3	5,7
10,0 – 10,9	14	20,0	25,7
11,0 – 11,9	19	27,1	52,9
12,0 – 12,9	14	20,0	72,9
13,0 – 13,9	13	18,6	91,4
14,0 – 14,9	5	7,1	98,6
15,0 – 15,9	1	1,4	100,0
Celkem	70	100,0	-


Tento příklad ilustruje základní práci s intervalovým rozložením četností, které nám umožňuje zjistit rozložení hodnot v rámci měřeného souboru a sledovat kumulativní četnosti pro jednotlivé intervaly.

7.2.1 Grafické znázornění četností

Znázorňujeme relativní a absolutní četnosti nebo relativní a absolutní kumulativní četnosti.

Koláčový graf


Koláčový graf se používá pro zobrazení absolutních i relativních četností, ale v obou případech vypadá stejně. Liší se jen popiskami (absolutními nebo relativními, ale mohou tam být i obě). Na obrázku 14 je příklad koláčového grafu, který zobrazuje rozložení prodeje různých kategorií produktů ve firmě.



Obr. 14: Koláčový graf rozložení prodeje produktů ve firmě


Histogram (sloupcový graf)

Histogram je sloupcový graf, který používáme pro znázornění rozložení četností. U bodového rozložení četností přiřadíme hodnotě $x_{[j]}$ obdélník, jehož výška je úměrná zjištěné četnosti. Na obrázku 15 je histogram výsledků testu ze statistiky z příkladu 7.10.



Obr. 15: Histogram absolutních četností výsledků testu ze statistiky z příkladu 7.10

Histogram pro hladinu hemoglobinu (v g/100 ml) z příkladu 7.11 je na obrázku 16. Každý sloupec pokrývá celý rozsah daného intervalu.



Obr. 16: Histogram relativních četností hladiny hemoglobinu z příkladu 7.11

7.3 Charakteristiky polohy a variability

Charakteristiky polohy a variability jsou základními nástroji pro popis rozložení dat.

Mezi **charakteristiky polohy** patří například aritmetický průměr, medián, modus a výběrové kvantily. Tyto charakteristiky poskytují informace o střední hodnotě dat a jejich umístění.

Charakteristiky variability zahrnují mj. rozptyl, směrodatnou odchylku, rozpětí a interkvartilové rozpětí. Tyto charakteristiky popisují, jak jsou data rozptýlena kolem střední hodnoty. Společně tyto charakteristiky umožňují komplexní popis a analýzu statistických dat.

7.3.1 Míry polohy

Míry polohy, nebo také charakteristiky centrální tendence, popisují střední hodnotu dat a poskytují přehled o tom, kde se data nejvíce koncentrují. Mezi nejdůležitější charakteristiky patří:

- **Aritmetický průměr** – Aritmetický průměr je nejběžnější charakteristika centrální tendence, která se počítá jako součet všech hodnot dělený jejich počtem:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i,$$

kde n je počet hodnot a x_i jsou jednotlivé hodnoty.

- **Medián** – Medián je střední hodnota uspořádaných dat. U lichého počtu hodnot je medián prostřední hodnota, u sudého počtu hodnot je medián průměr dvou prostředních hodnot. Medián je vhodný pro data s odlehlými hodnotami, protože není těmito extrémy ovlivněn.
- **Modus** – Modus je hodnota, která se v datech vyskytuje nejčastěji. V některých případech mohou data mít více než jeden modus, což se označuje jako multimodální rozdělení.
- **Harmonický průměr** – Harmonický průměr je vhodný pro průměrování veličin, které jsou podíly nebo kde jsou extrémy ve významu:

$$\bar{x}_{\text{harm}} = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}}.$$

- **Geometrický průměr** – Geometrický průměr je vhodný pro data, která se vztahují k růstu nebo procentním změnám:

$$\bar{x}_{\text{geom}} = \left(\prod_{i=1}^n x_i \right)^{\frac{1}{n}}.$$

- **Výběrové kvantily** – Výběrové kvantily jsou hodnoty, které dělí seřazený výběr do daného počtu stejně velkých částí. Nejčastěji používané kvantily jsou:
 - **První kvartil** (0,25 kvantil) – Hodnota, pod kterou leží 25% dat.
 - **Medián** (0,5 kvantil) – Hodnota, pod kterou leží 50% dat.
 - **Třetí kvartil** (0,75 kvantil) – Hodnota, pod kterou leží 75% dat.

Výběrové kvantily se určí z uspořádaných dat jako hodnoty, které odpovídají pozicím $\alpha(n+1)$, kde α je daný kvantil a n je počet pozorování. Pokud pozice není celé číslo, používá se lineární interpolace.

Tyto charakteristiky jsou klíčové pro popis rozložení dat a mají široké uplatnění v mnoha oblastech statistické analýzy, od popisu jednoduchých souborů dat po složitější ekonomické či demografické analýzy.

Aritmetický průměr

Pozorování $x_1, \dots, x_n$ jsou náhodné hodnoty z neseřazeného nebo seřazeného souboru. Aritmetický průměr je základní mírou polohy, která se počítá jako součet všech pozorování dělený jejich počtem.

Definice 7.12. Aritmetický průměr (neseřazeného) souboru:

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

Definice 7.13. Aritmetický průměr seřazeného souboru:

$$\bar{x} = \frac{x_{[1]}n_1 + \dots + x_{[r]}n_r}{n_1 + \dots + n_r} = \frac{1}{n} \sum_{i=1}^r x_{[i]}n_i$$

Definice 7.14 (Vážený aritmetický průměr). Pokud je soubor rozdělen do s dílčích souborů, které mají své vlastní průměry $\bar{x}_i$ a rozsahy n_i , můžeme vypočítat **vážený aritmetický průměr**:

$$\bar{x} = \frac{\sum_{i=1}^s \bar{x}_i n_i}{n_1 + \dots + n_s}$$

Tento vzorec se používá například při výpočtech, kdy jednotlivé části souboru mají různé váhy nebo velikosti, které je třeba zohlednit při výpočtu celkového průměru.

Vhodné a nevhodné využití aritmetického průměru

Aritmetický průměr je velmi užitečná míra centrální tendence v situacích, kdy jsou data rovnoměrně rozložena a nejsou ovlivněna extrémními hodnotami.

Vhodné využití:

- Aritmetický průměr je vhodný pro soubory dat, které mají symetrické rozdělení (například normální rozdělení), protože průměr zde dobře reprezentuje střed dat.
- Používá se ve statistikách výkonu, výzkumu nebo finanční analýze, kde jsou hodnoty vyvážené a nemají extrémní odchylky.

Nevhodné využití:

- Aritmetický průměr je nevhodný pro soubory dat, které mají výrazně asymetrické rozdělení nebo obsahují odlehlé (extrémní) hodnoty. V těchto případech může průměr zkreslovat skutečný střed dat. Například u příjmů, kde několik málo osob má velmi vysoké příjmy, bude aritmetický průměr vyšší než většina příjmů.
- Průměr také nemusí být reprezentativní v situacích, kde jsou data kategorizovaná nebo mají nominální povahu (například jména nebo pohlaví), kde není možné spočítat „průměr“.

V těchto případech je vhodnější použít jiné míry polohy, jako je medián nebo modus, které lépe popisují střední hodnoty asymetrických nebo kategoriálních dat.

Výběrové kvantily

Definice 7.15. Mějme setříděný soubor tedy hodnoty dat jsou uspořádané vzestupně: $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$, kde indexy označují pořadí hodnot v setříděném souboru.

Výběrový α -kvantil je hodnota, která rozděluje seřazený datový soubor na dvě části tak, že:

- alespoň 100α % všech dat je menších nebo rovných $\tilde{x}_\alpha$,
- alespoň $100(1 - \alpha)$ % všech dat je větších nebo rovných $\tilde{x}_\alpha$.

Určení výběrového α -kvantilu z dat

Postup určení výběrového α -kvantilu závisí na tom, zda hodnota αn (kde n je počet pozorování) je přirozené číslo nebo nikoliv:

- Pokud je $\alpha n = c$, kde c je přirozené číslo, pak výběrový α -kvantil je průměr hodnot na pozicích $x_{(c)}$ a $x_{(c+1)}$:

$$\tilde{x}_\alpha = \frac{x_{(c)} + x_{(c+1)}}{2}.$$

- Pokud αn není přirozené číslo, zaokrouhlujeme αn na nejbližší vyšší přirozené číslo c a položíme:

$$\tilde{x}_\alpha = x_{(c)}.$$

Pojmenované kvantily

Některé z kvantilů mají svá specifická jména:

- **Medián** (0,5 kvantil) – Hodnota, která dělí data na dvě stejně velké části, tedy 50% dat je menší nebo rovno této hodnotě a 50% je větší nebo rovno.
- **Kvantily** – Speciální kvantily, které dělí data na čtyři stejné části:
 - **První kvartil** (0,25 kvantil) – Hodnota, pod kterou leží 25% dat.
 - **Druhý kvartil** (0,5 kvantil) – Medián.
 - **Třetí kvartil** (0,75 kvantil) – Hodnota, pod kterou leží 75% dat.
- **Decily** – Kvantily, které dělí data na deset stejných částí:
 - **První decil** (0,1 kvantil) – Hodnota, pod kterou leží 10% dat.
 - **Druhý decil** (0,2 kvantil) – Hodnota, pod kterou leží 20% dat, atd.
 - **Devátý decil** (0,9 kvantil) – Hodnota, pod kterou leží 90% dat.
- **Percentily** – Kvantily, které dělí data na sto stejných částí:
 - **První percentil** (0,01 kvantil) – Hodnota, pod kterou leží 1% dat.
 - **Pátý percentil** (0,05 kvantil) – Hodnota, pod kterou leží 5% dat.
 - **Devadesátý pátý percentil** (0,95 kvantil) – Hodnota, pod kterou leží 95% dat.

Medián jako speciální případ výběrového kvantilu

Medián je speciálním případem výběrového kvantilu pro $\alpha = 0,5$. Tento kvantil rozdělí data na dvě stejně velké části.

Případ lichého n Pro lichý počet pozorování n , hodnota $n \times 0,5$ není přirozené číslo. Proto podle obecného postupu výpočtu kvantilu zaokrouhlíme $n \times 0,5$ nahoru na nejbližší celé číslo, což určí pořadí mediánu:

$$\tilde{x}_{0,5} = x_{\left(\frac{n+1}{2}\right)}.$$

Tento vzorec plyne z obecného pravidla zaokrouhlení kvantilu nahoru, kdy medián je hodnota na pozici $\frac{n+1}{2}$.

Příklad 7.16. Mějme soubor o lichém počtu hodnot $n = 7$, seřazených jako $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(7)}$. Medián bude hodnota na pozici $\frac{7+1}{2} = 4$, tedy $\tilde{x}_{0,5} = x_{(4)}$. $\square$

Případ sudého n Pro sudý počet pozorování n , hodnota $n \times 0,5$ je přirozené číslo. Proto medián, stejně jako obecný kvantil pro přirozené hodnoty $n \times \alpha$, bude průměrem dvou hodnot na pozicích:

$$\tilde{x}_{0,5} = \frac{x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)}}{2}.$$

Příklad 7.17. Pro soubor o sudém počtu hodnot $n = 8$ je $n \times 0,5 = 4$, takže medián je průměrem hodnot na 4. a 5. pozici:

$$\tilde{x}_{0,5} = \frac{x_{(4)} + x_{(5)}}{2}.$$

$\square$

Tímto způsobem medián vyplývá jako speciální případ obecného výpočtu výběrového kvantilu, kde pro liché n postupujeme zaokrouhlením nahoru a pro sudé n použijeme průměr dvou středních hodnot:

Definice 7.18. Mějme setříděný soubor. Potom **medián** definujeme takto:

$$\text{Med}(x) = \tilde{x}_{0,5} = \begin{cases} x_{\left(\frac{n+1}{2}\right)} & \text{pro liché } n, \\ \frac{x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)}}{2} & \text{pro sudé } n. \end{cases}$$

Příklad 7.19 (n sudé). Ve výrobě se v posledním půl roce v jednotlivých měsících vyskytl následující počet úrazů: 1, 3, 2, 4, 2, 4. Určete medián, dolní kvartil $\tilde{x}_{0,25}$ a horní kvartil $\tilde{x}_{0,75}$ počtu úrazů za měsíc.

Řešení: Počty uspořádáme vzestupně:

1, 2, 2, 3, 4, 4

- **Medián:**

$$\tilde{x}_{0,5} = \frac{x_{(3)} + x_{(4)}}{2} = \frac{2 + 3}{2} = 2,5$$

- **Dolní kvartil:** $\alpha n = 6 \cdot 0,25 = 1,5 \Rightarrow \tilde{x}_{0,25} = x_{(2)} = 2$

- **Horní kvartil:** $\alpha n = 6 \cdot 0,75 = 4,5 \Rightarrow \tilde{x}_{0,75} = x_{(5)} = 4$

□

Příklad 7.20 (n liché). Ve výrobě se v posledním půl roce v jednotlivých měsících vyskytl následující počet úrazů: 1, 3, 2, 4, 2, 4, 1. Určete medián, dolní a horní kvartil počtu úrazů za měsíc.

Řešení: Počty uspořádáme vzestupně:

$$1, 1, 2, 2, 3, 4, 4$$

- **Medián:**

$$\frac{n+1}{2} = \frac{7+1}{2} = 4 \Rightarrow \tilde{x}_{0,5} = x_{(4)} = 2$$

- **Dolní kvartil:** $\alpha n = 7 \cdot 0,25 = 1,75 \Rightarrow \tilde{x}_{0,25} = x_{(2)} = 1$

- **Horní kvartil:** $\alpha n = 7 \cdot 0,75 = 5,25 \Rightarrow \tilde{x}_{0,75} = x_{(6)} = 4$

□

Příklad 7.21. Uvažujme data x daná následující tabulkou

x_i	1	2	3	4
n_i	10	12	6	3

Určete první decil $\tilde{x}_{0,1}$, dolní kvartil a horní kvartil.

Řešení: Rozepíšeme si data podle jejich velikosti a četností:

- $x_{(1)} = \dots = x_{(10)} = 1,$
- $x_{(11)} = \dots = x_{(22)} = 2,$
- $x_{(23)} = \dots = x_{(28)} = 3,$
- $x_{(29)} = \dots = x_{(31)} = 4.$

Vidíme, že rozsah souboru je $n = 31$. Přejdeme k výpočtu jednotlivých kvantilů:

- **0,1 kvantil:** $\alpha n = 31 \cdot 0,1 = 3,1 \Rightarrow \tilde{x}_{0,1} = x_{(4)} = 1$
- **Dolní kvartil:** $\alpha n = 31 \cdot 0,25 = 7,75 \Rightarrow \tilde{x}_{0,25} = x_{(8)} = 1$
- **Horní kvartil:** $\alpha n = 31 \cdot 0,75 = 23,25 \Rightarrow \tilde{x}_{0,75} = x_{(24)} = 3$

□

Využití výběrových kvantilů

Výběrové kvantily mají široké využití v různých oborech statistiky a aplikovaných věd. Zde jsou uvedeny některé praktické příklady využití kvantilů:

- **Hladina cholesterolu v krvi** Jakou hladinu cholesterolu v krvi nepřekročí 90 % zdravé populace České republiky? Výběrový 90% kvantil by zde představoval referenční hodnotu pro stanovení diagnostických limitů, která se běžně využívá v klinické praxi. Podobně jsou stanoveny referenční hodnoty pro další ukazatele krevního obrazu, například hladinu cukru, triglyceridů nebo krevní tlak.
- **Délka lišek** Jakou délku nepřekročí 95 % lišek? Zde můžeme využít výběrového 5% a 95% kvantilu k určení rozmezí, ve kterém se nachází většina jedinců dané populace. Například, pokud délka lišek spadá do rozmezí 58–90 cm, můžeme říci, že pouze 5 % lišek je delších než 90 cm a pouze 5 % lišek je kratších než 58 cm. Tyto kvantily pomáhají určit, které jedince považujeme za „typické“ a které za extrémní.
- **Stoletá voda** Jak definovat pojem stoletá voda? Výběrový 99% kvantil se často používá v hydrologii k definici staleté vody, což je taková výše maximálního ročního průtoku, která je překročena pouze v 1 % případů. Tato hodnota je důležitá pro plánování protipovodňových opatření a pro stavbu infrastruktury v blízkosti vodních toků.
- **Požadavky na kapitál pojišťoven** Jakou výši kapitálu musí pojišťovny EU držet, aby snížily riziko platební neschopnosti? Pojišťovny jsou regulovány evropskou směrnicí Solvency II, která mimo jiné vyžaduje, aby pojišťovny držely kapitál na úrovni, která pokrývá 99,5 % možných finančních rizik v průběhu jednoho roku. Tento požadavek odpovídá výběrovému 99,5% kvantilu. Směrnice tedy stanovuje, že pouze v 0,5 % případů může nastat situace, kdy by pojišťovna nemohla splnit své závazky.
- **Testování pomocí SCIO testů** SCIO testy jsou jedním z nástrojů pro hodnocení úrovně znalostí žáků a studentů. Například při hodnocení výsledků SCIO testů z matematiky se často využívá kvantily pro stanovení referenčních hranic. Výběrový 25% kvantil určuje hranici pro čtvrtinu nejméně úspěšných studentů, zatímco výběrový 75% kvantil identifikuje hranici, nad kterou se nachází čtvrtina nejúspěšnějších studentů. Na základě těchto kvantilů mohou školy a zřizovatelé porovnávat výkonnost studentů mezi jednotlivými ročníky nebo regiony a stanovovat cíle pro zlepšení výuky.
- **Percentilové grafy** Kvantily se také často používají k tvorbě percentilových grafů, které poskytují přehled o rozložení dané populace. Percentilové grafy jsou běžně využívány například v pediatrii k porovnávání vývoje růstu dětí vůči standardním referenčním hodnotám.

Shrnutí

Výběrové kvantily jsou univerzálním nástrojem, který se využívá v mnoha oblastech lidské činnosti – od medicíny, přes hydrologii až po finance a pojišťovnictví. Pomáhají určit referenční hodnoty, identifikovat extrémní případy nebo poskytnout náhled na distribuci dat.

7.3.2 Míry variability

Míry absolutní variability

Míry absolutní variability popisují rozsah variability bez ohledu na střední hodnotu dat. Mezi tyto míry patří:

Definice 7.22. • **Variační obor** $\langle x_{(1)}, x_{(n)} \rangle$ – Interval mezi nejmenší a největší hodnotou v datech.

- **Variační rozpětí** $R = x_{(n)} - x_{(1)}$ – Rozdíl mezi největší a nejmenší hodnotou v datech.
- **Kvartilové rozpětí** $R_Q = \tilde{x}_{0.75} - \tilde{x}_{0.25}$ – Rozdíl mezi třetím a prvním kvantilem.
- **Kvartilová odchylka** $\frac{R_Q}{2}$ – Polovina kvartilového rozpětí.

Definice 7.23. Rozptyl – Střední kvadratická odchylka hodnot od průměru:

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

Pro seskupená data je rozptyl definován jako:

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^k (a_i - \bar{x})^2 n_i,$$

kde n_i je četnost hodnoty a_i .

Definice 7.24. Směrodatná odchylka – Druhá odmocnina rozptylu:

$$s_x = \sqrt{s_x^2}.$$

Míry relativní variability

Míry relativní variability se používají k porovnání variability mezi různými datovými soubory, které mohou mít rozdílné jednotky nebo měřítko:

Definice 7.25. Variační koeficient

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

je relativní míra variability vyjádřená jako podíl směrodatné odchylky a aritmetického průměru.

Relativní kvartilová odchylka

$$Q_r = \frac{\tilde{x}_{0.75} - \tilde{x}_{0.25}}{\tilde{x}_{0.75} + \tilde{x}_{0.25}}$$

je míra relativní variability založená na kvartilech.

Míry absolutní variability hodnotí rozptyl v datech přímo, zatímco míry relativní variability umožňují lépe srovnávat datové soubory s různými měřítky.

Příklad 7.26. Ve dvou firmách byly zkoumány měsíční platy zaměstnanců. Ve firmě A jsou platy následující (v tisících Kč): 25, 28, 30, 32, 35. Ve firmě B jsou platy (v tisících Kč): 20, 22, 24, 26, 80. Porovnejte variabilitu platů ve firmách A a B pomocí rozptylu a variačního koeficientu.

Řešení: Nejprve vypočteme aritmetický průměr pro obě firmy:

$$\begin{aligned}\bar{x}_A &= \frac{25 + 28 + 30 + 32 + 35}{5} = 30, \\ \bar{x}_B &= \frac{20 + 22 + 24 + 26 + 80}{5} = 34,4.\end{aligned}$$

Dále spočítáme rozptyl pro obě firmy:

Pro firmu A:

$$s_A^2 = \frac{1}{5-1} \left[(25-30)^2 + (28-30)^2 + (30-30)^2 + (32-30)^2 + (35-30)^2 \right] = \frac{1}{4} 44 = 11.$$

Pro firmu B:

$$\begin{aligned}s_B^2 &= \frac{1}{5-1} \left[(20-34,4)^2 + (22-34,4)^2 + (24-34,4)^2 + (26-34,4)^2 + (80-34,4)^2 \right] \\ &= \frac{1}{4} 3637,6 = 909,4.\end{aligned}$$

Nyní vypočítáme variační koeficienty pro obě firmy:

Pro firmu A:

$$V_A = \frac{s_A}{\bar{x}_A} = \frac{\sqrt{11}}{30} \approx 0,11.$$

Pro firmu B:

$$V_B = \frac{s_B}{\bar{x}_B} = \frac{\sqrt{909,4}}{34,4} \approx 0,87.$$

Závěr: Variabilita platů ve firmě A je výrazně nižší než ve firmě B. Variační koeficient ve firmě B je mnohem vyšší kvůli extrémně vysokému platu (80 tisíc Kč), který zvyšuje rozptyl a tedy i míru variability. $\square$

7.4 Míry tvaru rozdělení

Kromě charakteristik polohy a variability existují i charakteristiky, které popisují tvar rozdělení dat. Mezi hlavní charakteristiky tvaru rozdělení patří:

Definice 7.27. Výběrová šikmost (skewness) měří asymetrii rozdělení dat:

$$\gamma_1 = \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s_x} \right)^3.$$

Kladná hodnota značí pozitivní šikmost (ocas na pravé straně je delší), záporná hodnota značí negativní šikmost (ocas na levé straně je delší).

Definice 7.28. Výběrová špičatost (kurtosis) – Měří „ostrost“ vrcholu rozdělení dat:

$$\gamma_2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{n \cdot s_x^4} - 3,$$

nebo také korigovaná verze, která funguje i pro malé výběry:

$$\gamma_2 = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s_x} \right)^4 - \frac{3(n-1)^2}{(n-2)(n-3)}.$$

Hodnota vyšší než 0 značí rozdělení s vyšší špičatostí než normální rozdělení, hodnota nižší než 0 značí rozdělení s plošším tvarem.

Příklad 7.29. V následující tabulce jsou uvedeny hodnoty datového souboru: 2, 3, 5, 7, 8, 10. Spočítejte výběrovou šikmost a špičatost tohoto datového souboru.

Řešení: Nejprve vypočteme aritmetický průměr a směrodatnou odchylku:

$$\bar{x} = \frac{2 + 3 + 5 + 7 + 8 + 10}{6} = 5.83.$$

Směrodatná odchylka (výběrová) je:

$$s_x = \sqrt{\frac{1}{6-1} \sum_{i=1}^6 (x_i - \bar{x})^2} = \sqrt{\frac{1}{5} [(2 - 5.83)^2 + (3 - 5.83)^2 + \dots + (10 - 5.83)^2]} = 2.93.$$

Výběrová šikmost (skewness):

Výběrová šikmost se počítá podle vzorce:

$$\gamma_1 = \frac{6}{(6-1)(6-2)} \sum_{i=1}^6 \left(\frac{x_i - \bar{x}}{s_x} \right)^3.$$

Pro náš datový soubor po dosazení jednotlivých členů získáme:

$$\gamma_1 \approx 0,0465.$$

Tato hodnota znamená, že rozdělení má velmi malou pozitivní šikmost (ocas na pravé straně je nepatrně delší).

Výběrová špičatost (kurtosis):

Výběrová špičatost se počítá podle vzorce:

$$\gamma_2 = \frac{6(6+1)}{(6-1)(6-2)(6-3)} \sum_{i=1}^6 \left(\frac{x_i - \bar{x}}{s_x} \right)^4 - \frac{3(6-1)^2}{(6-2)(6-3)}.$$

Po dosazení členů a výpočtu získáme:

$$\gamma_2 \approx -1,4137.$$

Tato hodnota znamená, že rozdělení má plošší vrchol než normální rozdělení. □

7.5 Řešené příklady

Příklad 7.30. Určete relativní, kumulativní a relativní kumulativní četnosti dat z tabulky:

$x_{[i]}$	0	1	2	3	4
n_i	7	44	56	30	12

Řešení: Nejprve vypočítáme celkový počet prvků n :

$$n = \sum_{i=1}^5 n_i = 7 + 44 + 56 + 30 + 12 = 149.$$

Relativní četnosti $p_i = \frac{n_i}{n}$ se vypočítají jako podíl absolutní četnosti n_i a celkového počtu prvků n :

$x_{[i]}$	0	1	2	3	4	Σ
n_i	7	44	56	30	12	149
p_i	0,047	0,295	0,376	0,201	0,081	1

Nyní vypočítáme kumulativní četnosti N_i :

$$N_i = \sum_{j=1}^i n_j.$$

Například pro $x_{[2]} = 1$:

$$N_2 = 7 + 44 = 51.$$

Podobně pro další hodnoty:

$x_{[i]}$	0	1	2	3	4
N_i	7	51	107	137	149

Relativní kumulativní četnosti F_i se vypočítají jako podíl kumulativní četnosti N_i a celkového počtu prvků n :

$$F_i = \frac{N_i}{n}.$$

Například pro $x_{[3]} = 2$:

$$F_3 = \frac{107}{149} \approx 0,718.$$

Tabulka relativních kumulativních četností:

$x_{[i]}$	0	1	2	3	4
F_i	0,047	0,342	0,718	0,919	1

□

Příklad 7.31. Vypočtěte empirické charakteristiky: modus, kvartily, střední hodnotu, rozptyl, směrodatnou odchylku, šikmost a špičatost (exces) variační řady:

$x_{[i]}$	0	1	2	3	4
n_i	7	44	51	30	12

Řešení: Nejprve vypočítáme celkový počet prvků n :

$$n = \sum_{i=1}^5 n_i = 7 + 44 + 51 + 30 + 12 = 144.$$

1. Modus:

Modus je hodnota s nejvyšší četností:

$$Mo = 2.$$

2. Kvartily:

Pořadí kvartilů vypočítáme pomocí $\alpha \cdot n$, kde α je hodnota kvantilu:

$$\alpha = 0,25 : \quad \alpha \cdot n = 0,25 \cdot 144 = 36.$$

Kvartil $\tilde{x}_{0,25}$ je tedy průměr hodnot na pozicích 36 a 37 v uspořádaném souboru, což odpovídá hodnotě:

$$\tilde{x}_{0,25} = \frac{1 + 1}{2} = 1.$$

Podobně pro medián (druhý kvartil):

$$\alpha = 0,5 : \quad \alpha \cdot n = 0,5 \cdot 144 = 72.$$

Medián $\tilde{x}_{0,5}$ je tedy průměr hodnot na pozicích 72 a 73 v uspořádaném souboru, což odpovídá hodnotě:

$$\tilde{x}_{0,5} = \frac{2 + 2}{2} = 2.$$

A pro třetí kvartil:

$$\alpha = 0,75 : \quad \alpha \cdot n = 0,75 \cdot 144 = 108.$$

Třetí kvartil $\tilde{x}_{0,75}$ je tedy průměru hodnot na pozicích 108 a 109 v uspořádaném souboru, což odpovídá hodnotě:

$$\tilde{x}_{0,75} = \frac{3 + 3}{2} = 3.$$

3. Aritmetický průměr $\bar{x}$:

Aritmetický průměr se vypočítá takto:

$$\bar{x} = \frac{\sum_{i=1}^5 x_{[i]} \cdot n_i}{\sum_{i=1}^5 n_i} = \frac{0 \cdot 7 + 1 \cdot 44 + 2 \cdot 51 + 3 \cdot 30 + 4 \cdot 12}{144} = \frac{284}{144} \approx 1,97.$$

4. Rozptyl s_x^2 :

Rozptyl se vypočítá jako:

$$\begin{aligned} s_x^2 &= \frac{\sum_{i=1}^5 (x_{[i]} - \bar{x})^2 \cdot n_i}{\sum_{i=1}^5 n_i} \\ &= \frac{(0 - 1,97)^2 \cdot 7 + (1 - 1,97)^2 \cdot 44 + (2 - 1,97)^2 \cdot 51 + (3 - 1,97)^2 \cdot 30 + (4 - 1,97)^2 \cdot 12}{144} \\ &\approx 0,872. \end{aligned}$$

5. Směrodatná odchylka s_x :

Směrodatná odchylka je odmocnina rozptylu:

$$s_x = \sqrt{s_x^2} \approx \sqrt{0,872} \approx 0,934.$$

6. Šikmost γ_1 :

Šikmost se vypočítá jako:

$$\gamma_1 = \frac{\sum_{i=1}^5 (x_{[i]} - \bar{x})^3 \cdot n_i}{\sum_{i=1}^5 n_i \cdot s_x^3}.$$

Po dosazení získáme hodnotu přibližně:

$$\gamma_1 \approx -0,11.$$

Hodnota blízká 0 naznačuje, že rozdělení je téměř symetrické.

7. Špičatost γ_2 :

Špičatost se vypočítá jako:

$$\gamma_2 = \frac{\sum_{i=1}^5 (x_{[i]} - \bar{x})^4 \cdot n_i}{\sum_{i=1}^5 n_i \cdot s_x^4} - 3.$$

Po dosazení získáme hodnotu přibližně:

$$\gamma_2 \approx -0,57.$$

Záporná hodnota naznačuje ploché rozdělení.

□

 Σ

V této kapitole jsme prozkoumali základní charakteristiky jednorozměrného statistického souboru. Zaměřili jsme se na popisné statistiky jako průměr, medián, modus, rozptyl, směrodatnou odchylku, šikmost a špičatost.

- **Aritmetický průměr** popisuje „průměrnou“ hodnotu v souboru.
- **Medián** rozděluje soubor na dvě stejně velké části a je méně citlivý na extrémní hodnoty než průměr.
- **Modus** je nejčastěji se vyskytující hodnota.
- **Rozptyl a směrodatná odchylka** udávají, jak moc se hodnoty liší od průměru.
- **Šikmost** hodnotí asymetrii rozložení, **špičatost** popisuje tvar vrcholu rozložení.

Ukázali jsme si, jak tyto charakteristiky vypočítat a interpretovat. Jsou klíčové pro analýzu dat v různých oblastech výzkumu a praxe.




1. Co je to aritmetický průměr a jak se vypočítá?
2. Jaký je rozdíl mezi mediánem a aritmetickým průměrem?
3. Kdy je vhodnější použít medián místo průměru?
4. Co vyjadřuje rozptyl a jaký má vztah ke směrodatné odchylce?
5. Jaký význam má šikmost a špičatost (exces) při analýze rozložení dat?
6. Jak se vypočítá relativní četnost a kumulativní relativní četnost?
7. Co jsou to kvartily, jaký je jejich vztah ke kvantilům?
8. Určete medián a průměr měsíční spotřeby elektrické energie (kWh) v bytech z následujících údajů: 169, 108, 26, 43, 114, 68, 35, 183, 103, 266, 74, 205, 62, 230, 85, 487, 120, 148, 91, 18, 58, 96, 295, 42, 137. [103, 151,64]
9. Zkoušky životnosti žárovek daly následující výsledky (v hodinách): 606, 1249, 267, 44, 510, 340, 109, 1957, 463, 801, 1082, 169, 233, 1734, 1458, 80, 1023, 2736, 917, 459.
Určete průměrnou dobu životnosti žárovek a jejich rozptyl. [938,35, 757,9]



Literatura k tématu:

- [1] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6. ISBN 978-80-867-3208-8.
- [2] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [3] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [4] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.



Kapitola 8

Statistický soubor se dvěma argumenty



Po prostudování této kapitoly budete umět:

- určit základní charakteristiky dvourozměrného statistického souboru,
- vypočítat střední hodnotu, rozptyl a kovarianci pro dvourozměrný soubor,
- využít vhodné grafické nástroje pro vizualizaci dvourozměrných dat,
- interpretovat výsledky analýzy závislosti mezi dvěma znaky.



Klíčová slova:

Dvourozměrný soubor, aritmetický průměr, kovariance, rozptyl, směrodatná odchylka, kontingenční tabulka, bodový graf.

Tab. 4: Ukázka dvourozměrného statistického souboru

Statistická jednotka	Znak X (Výška v cm)	Znak Y (Hmotnost v kg)
1	170	65
2	165	70
3	180	80
4	175	75
5	160	60

Náhled kapitoly

Zde přímo navazujeme na předchozí kapitolu, její látku rozšíříme na případ dvou proměnných. Novinkou budou pojmy specifické pro tento dvojrozměrný případ, například kontingenční tabulky, bodové grafy a kovariance, které popisují vztahy dvojice proměnných. Pokročilejší metody, jako jsou regrese a korelace, si necháme až na další kapitoly.

Cíle kapitoly

Cílem této kapitoly je získat povědomí o rozdílu mezi jednorozměrným a dvojrozměrným případem a nachystat si pojem kovariance pro další kapitolu.

Časová náročnost

Pro tuto kapitolu doporučujeme vyčlenit přibližně 2 hodiny, které zahrnují jak studium teoretických částí, tak procvičování praktických příkladů a aplikací.

Úvod

Dvourozměrný statistický soubor se skládá z dvojic hodnot (argumentů), kde každý argument představuje hodnotu jiného statistického znaku měřeného na stejných statistických jednotkách. Tento typ souboru je používán k analýze vztahů mezi dvěma různými proměnnými, například výškou a hmotností osob, věkem a platem zaměstnanců, apod.

Každá statistická jednotka je tedy charakterizována dvojicí hodnot, které spolu mohou nebo nemusí být nějakým způsobem závislé. Dvourozměrný statistický soubor nám umožňuje analyzovat nejen vlastnosti jednotlivých znaků samostatně, ale i vztah mezi nimi.

Příklad dvourozměrného statistického souboru je v tabulce 4:

V tomto příkladu je znak X výška v centimetrech a znak Y hmotnost v kilogramech. Každý řádek představuje jednu statistickou jednotku (například jednu osobu), na které jsou měřeny oba znaky současně.

8.1 Základní pojmy

- **Statistická jednotka:** Objekt, na kterém jsou měřeny oba znaky. Může to být osoba, firma, stroj apod. Každá statistická jednotka má přiřazenou dvojici hodnot – jednu pro každý znak.
- **Znak X :** První proměnná, která je měřena na všech statistických jednotkách. Například výška osob nebo věk zaměstnanců.
- **Znak Y :** Druhá proměnná, která je rovněž měřena na stejných statistických jednotkách jako znak X . Například hmotnost osob nebo plat zaměstnanců.
- **Dvojice hodnot:** Každá statistická jednotka má přiřazenou dvojici hodnot (x_i, y_i) , kde x_i je hodnota znaku X a y_i je hodnota znaku Y pro i -tou statistickou jednotku.
- **Statistický soubor:** Množina všech dvojic hodnot $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, kde n je počet statistických jednotek.
- **Rozsah souboru:** Počet statistických jednotek v souboru, označovaný jako n . V dvourozměrném souboru je rozsah stejný pro oba znaky, protože oba znaky jsou měřeny na stejných jednotkách.

Můžeme se vrátit k tabulce 4, kde jsou statistickými jednotkami jednotlivé osoby, znakem X je výška a znakem Y je hmotnost. Rozsah souboru $n = 5$.

8.2 Tabulkové a grafické zobrazení dvourozměrných dat

Při práci s dvourozměrným statistickým souborem je důležité umět data správně zobrazit. Existují různé způsoby, jak data vizualizovat a interpretovat. Mezi nejběžnější metody patří kontingenční tabulky a bodové grafy.

Kontingenční tabulky

Kontingenční tabulky se používají pro dvourozměrné soubory s diskrétními znaky. Tabulka obsahuje četnosti výskytu jednotlivých kombinací hodnot znaků X a Y . Tyto tabulky poskytují přehled o tom, jak často se různé kombinace hodnot vyskytují ve statistickém souboru.

- **Řádky tabulky** představují jednotlivé kategorie znaku X .
- **Sloupce tabulky** představují jednotlivé kategorie znaku Y .
- **Buňky tabulky** obsahují absolutní četnosti kombinací hodnot X a Y .

Tab. 5: Ukázka kontingenční tabulky


	Y_1	Y_2	Y_3
X_1	5	7	3
X_2	8	12	4
X_3	6	2	9

Příklad kontingenční tabulky je v tabulce 5, kde jsou zobrazeny četnosti kombinací hodnot X a Y . Například hodnota 5 znamená, že kombinace X_1 a Y_1 se vyskytuje pětkrát.

Kontingenční tabulky jsou užitečné pro analýzu závislosti mezi dvěma diskrétními znaky. Mohou být základem pro další metody analýzy, jako je například výpočet podmíněných pravděpodobností nebo chi-kvadrát test závislosti.

Bodové grafy

Bodové grafy (scatter plots) se používají pro dvourozměrné soubory, kde oba znaky nabývají spojitých hodnot. Na ose x je vynášen znak X a na ose y znak Y . Každá dvojice hodnot (x_i, y_i) se zobrazuje jako bod v rovině.



Obr. 17: Ukázka bodového grafu

Příklad bodového grafu je na obrázku 17. Každý bod v grafu představuje jednu statistickou jednotku a její hodnoty znaků X a Y . Například bod na souřadnicích $(160, 60)$ odpovídá jednotce s výškou 160 cm a hmotností 60 kg.

Bodové grafy umožňují vizuálně analyzovat vztah mezi dvěma znaky. Pokud jsou body uspořádány podél určité linie nebo křivky, může to naznačovat nějaký druh závislosti mezi znaky X a Y . Tyto grafy jsou základním nástrojem pro identifikaci vzorů a závislostí v datech.

Interpretace grafických zobrazení

Grafická zobrazení nám pomáhají lépe pochopit vztah mezi dvěma znaky. V případě bodového grafu může například kladná korelace znamenat, že vyšší hodnoty znaku X jsou často doprovázeny vyššími hodnotami znaku Y . Naopak záporná korelace by znamenala, že vyšší hodnoty jednoho znaku jsou spojeny s nižšími hodnotami druhého.

Kontingenční tabulky nám umožňují odhalit závislosti mezi kategoriemi dvou znaků. Pokud se některé kombinace kategorií vyskytují mnohem častěji než jiné, může to naznačovat silnou závislost mezi znaky.

Tabulkové a grafické metody jsou důležité nástroje pro první krok analýzy dvourozměrných statistických souborů, protože poskytují vizuální a kvantitativní přehled o datech.

8.3 Míry polohy a variability pro dvourozměrný soubor

8.3.1 Míry polohy

Podobně jako u jednorozměrného statistického souboru, můžeme i u dvourozměrného souboru vypočítat míry polohy pro oba znaky X a Y . Tyto míry zahrnují aritmetický průměr, medián a modus.

Aritmetický průměr

Pro každý znak zvlášť můžeme vypočítat aritmetický průměr, který udává střední hodnotu daného znaku v souboru.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i.$$

Zde $\bar{X}$ je průměrná hodnota znaku X a $\bar{Y}$ je průměrná hodnota znaku Y . Výpočty probíhají stejným způsobem jako v jednorozměrném souboru.

Příklad 8.1. Pro dvourozměrný statistický soubor z předchozího příkladu (výška a hmotnost osob) bychom vypočítali průměrnou výšku a hmotnost následovně:

$$\bar{x} = \frac{170 + 165 + 180 + 175 + 160}{5} = 170 \text{ cm},$$

$$\bar{y} = \frac{65 + 70 + 80 + 75 + 60}{5} = 70 \text{ kg.}$$

Podobným způsobem by se vypočítaly mediány a modus pro oba znaky. □

8.3.2 Míry variability a kovariance

Míry variability pro dvourozměrný statistický soubor jsou obdobné jako u jednorozměrného souboru, přičemž jsou vypočítávány zvlášť pro každý znak X a Y .

Rozptyl a směrodatná odchylka

Rozptyl a směrodatná odchylka se pro dvourozměrný soubor počítají obdobně jako v jednorozměrném případě, zvlášť pro každý znak:

$$s_X^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2, \quad s_Y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2.$$

Směrodatná odchylka je druhá odmocnina rozptylu:

$$s_X = \sqrt{s_X^2}, \quad s_Y = \sqrt{s_Y^2}.$$

Podrobnosti o rozptylu a směrodatné odchylce byly probrány v předchozí kapitole o jednorozměrném statistickém souboru.

Kovariance

Kovariance měří míru vzájemné závislosti mezi dvěma znaky X a Y . Je-li kovariance kladná, znamená to, že se vysoké hodnoty znaku X pojí s vysokými hodnotami znaku Y . Záporná kovariance naopak naznačuje, že vyšší hodnoty jednoho znaku se pojí s nižšími hodnotami druhého znaku.

Definice 8.2. Kovariance se vypočítá podle vzorce:

$$\text{Cov}(X, Y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

Pokud jsou hodnoty X a Y nezávislé, je jejich kovariance blízká nule.

Příklad 8.3. Uvažujme opět dvourozměrný statistický soubor (výška a hmotnost osob) (tabulka 4). Vypočteme kovarianci.

Řešení: Nejprve vypočítáme průměry:

$$\bar{x} = 170, \quad \bar{y} = 70.$$

Poté vypočítáme kovarianci:

$$\text{Cov}(X, Y) = \frac{1}{5-1}[(170-170)(65-70) + (165-170)(70-70) + \dots + (160-170)(60-70)] = 50.$$

Tato kladná hodnota kovariance naznačuje, že mezi výškou a hmotností existuje pozitivní vztah — vyšší osoby mají obecně vyšší hmotnost. $\square$

8.4 Řešené příklady

Příklad 8.4. Vypočítejte základní číselné charakteristiky dvourozměrného statistického souboru. Tabulka uvádí hodnoty X a Y pro jednotlivá pozorování:

$x \backslash y$	20	30	40	50	60	70	80
250	19	5					
350	23	116	11				
450	1	41	98	9			
550		4	32	65	7		
650		1	4	21	46	3	
750			1	2	11	13	1
850					1	3	2

Řešení: Pro řešení vypočítáme:

1. Průměry:

$$\bar{x} = \frac{1}{540} \cdot 259800 \approx 481,1, \quad \bar{y} = \frac{1}{540} \cdot 22030 \approx 40,8.$$

2. Rozptyly:

$$s_X^2 = \frac{1}{540} \cdot 134490000 - 481,1^2 \approx 17587,65, \quad s_Y^2 = \frac{1}{540} \cdot 989900 - 40,8^2 \approx 168,81.$$

3. Směrodatné odchylky:

$$s_X \approx 132,62, \quad s_Y \approx 12,99.$$

4. Kovariance:

$$\text{Cov}(X, Y) = \frac{1}{540} \cdot 11427500 - 481,1 \cdot 40,8 \approx 1534,49.$$

$\square$

Příklad 8.5. Vypočítejte číselné charakteristiky dvourozměrného statistického souboru, který je zadán tabulkou:

x	27	31	87	93	114	124	190	193	250	254	264	272	308	324
y	28	21	71	36	30	43	54	54	59	25	82	22	38	22

371	372	440	442	502	503	506	522	556	620	624
56	63	46	24	33	40	41	28	53	38	66

Řešení: Výpočty provedeme pomocí Excelu:

1. Průměry:

$$\bar{x} = \frac{7989}{25} \approx 319,56, \quad \bar{y} = \frac{1073}{25} \approx 42,92.$$

2. Rozptyly:

$$s_X^2 = \frac{3371599}{25} - 319,56^2 \approx 32745,37, \quad s_Y^2 = \frac{52945}{25} - 42,92^2 \approx 275,67.$$

3. Směrodatné odchylky:

$$s_X \approx 180,96, \quad s_Y \approx 16,60.$$

4. Kovariance:

$$\text{Cov}(X, Y) = \frac{349250}{25} - 319,56 \cdot 42,92 \approx 254,48.$$

□

Σ

V této kapitole jsme se seznámili s dvourozměrným statistickým souborem, který analyzuje dvojice hodnot (x_i, y_i) pro každou statistickou jednotku. Pro oba znaky jsme vypočítali základní míry polohy (průměr, medián, modus) a variability (rozptyl, směrodatná odchylka).

Představili jsme kovarianci jako nástroj k měření závislosti mezi dvěma znaky, kde kladná kovariance ukazuje na pozitivní vztah a záporná na negativní.

Kromě výpočtů jsme se věnovali kontingenčním tabulkám pro diskrétní znaky a bodovým grafům pro spojité znaky, které umožňují vizuální analýzu vztahů mezi znaky.

Tato kapitola připravuje základ pro další analýzy závislostí mezi dvěma znaky, které budou následovat v příštích kapitolách.

8.5 Kontrolní otázky

?

1. Jaký je rozdíl mezi jednorozměrným a dvourozměrným statistickým souborem?
2. Jak vypočítáme aritmetický průměr pro dvourozměrný statistický soubor?
3. Co znamená kovariance a jaký má význam při analýze dvourozměrného souboru?
4. Jaká je interpretace kladné a záporné hodnoty kovariance?
5. Jaký grafický nástroj lze použít pro vizualizaci dvourozměrného statistického souboru, kde oba znaky jsou spojité?
6. Jak funguje kontingenční tabulka a kdy ji použijeme?
7. Jaký je vztah mezi rozptylem a směrodatnou odchylkou pro jednotlivé znaky v dvourozměrném statistickém souboru?
8. Proč používáme bodový graf (scatter plot) při analýze dvourozměrných dat a co nám ukazuje o závislosti mezi znaky X a Y ?
9. U 130 zákrsků bylo zjištěno stáří stromu v letech (argument X) a sklizeň v jistém roce v kg (argument Y). Podle údajů v tabulce určete kovarianci.


$X \backslash Y$	4	5	6	7	8	9	10	11
3	6	0	0	0	0	0	0	0
4	0	5	10	2	0	0	0	0
5	0	0	0	2	8	3	0	0
6	0	0	0	0	0	12	10	0
7	0	0	0	0	0	8	15	4
8	0	0	0	0	4	16	8	0
9	0	3	12	2	0	0	0	0

$$[\text{Cov}(X, Y) \approx 1,12]$$



Literatura k tématu:

- [1] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6. ISBN 978-80-867-3208-8.
- [2] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [3] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [4] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.



Kapitola 9

Regresní a korelační analýza



Po prostudování této kapitoly budete umět:

- vysvětlit, co korelační koeficient popisuje a jaké jsou jeho varianty,
- vypočítat Pearsonův korelační koeficient na základě zadaných dat.
- interpretovat výsledky korelační analýzy,
- používat Excel nebo jiný statistický software k výpočtu korelačních koeficientů,
- odhadovat parametry lineárního regresního modelu,
- aplikovat lineární regresi na reálná data,
- používat Excel a modul **Analýza dat – Regrese** pro výpočty.



Klíčová slova:

Korelační koeficient, statistická závislost, lineární vztah, lineární regrese, regresní analýza, regresní koeficienty, Excel, modul Analýza dat.

Náhled kapitoly

V této kapitole navážeme na předchozí kapitolu, kde jsme zkoumali vztah dvou statistických znaků. Zde se seznámíme s dvěma pokročilejšími metodami analýzy těchto závislostí.

Korelační analýza slouží k měření síly a směru lineárního vztahu mezi dvěma proměnnými. Probereme různé varianty korelačních koeficientů a jejich využití v praxi, zejména Pearsonův korelační koeficient, který je nejčastěji používán. Ukážeme si také omezení tohoto koeficientu a situace, kdy je vhodné použít alternativní metody.

Metoda **lineární regrese** umožňuje odhadnout vztah mezi závislou a nezávislou proměnnou pomocí přímky (případně i jiné křivky).

Obě metody se naučíme provádět i v Excelu.

Cíle kapitoly

Cílem této kapitoly je praktické seznámení s dvěma metodami, korelační a regresní analýzou, které nám umožňují studovat vztah (závislost) dvou statistických znaků.

Odhad času potřebného ke studiu

Odhaduje se, že studium této kapitoly zabere přibližně 3 hodiny. Tento čas zahrnuje čtení textu, pochopení teoretických konceptů a řešení příkladů (i v Excelu).

9.1 Princip korelační analýzy

Co je to korelační koeficient?

Korelační koeficient je statistická míra, která určuje sílu a směr vztahu mezi dvěma proměnnými. Pearsonův korelační koeficient, označovaný jako r , měří lineární vztah mezi dvěma spojitými proměnnými a nabývá hodnot mezi -1 a 1. Pokud je $r = 1$, jedná se o perfektní pozitivní lineární vztah, pokud $r = -1$, jedná se o perfektní negativní lineární vztah, a pokud $r = 0$, neexistuje žádná lineární závislost mezi proměnnými.

Výpočet korelačního koeficientu

Definice 9.1. Pearsonův korelační koeficient je definován vztahem:

$$r = \frac{\text{Cov}(X, Y)}{s_X s_Y} = \frac{\sum (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \cdot \sum (y_i - \bar{y})^2}}$$

kde x_i a y_i jsou jednotlivé hodnoty obou proměnných, a $\bar{x}$ a $\bar{y}$ jsou jejich průměry.

Řešené příklady

Příklad 9.2. Mějme data o prodeji produktů ve dvou různých regionech. Vypočítejte Pearsonův korelační koeficient a určete, zda mezi těmito proměnnými existuje lineární vztah.

Prodeje (Region 1)	10	15	20	25	30
Prodeje (Region 2)	12	18	25	24	28

Řešení: Nejprve vypočítáme průměry $\bar{x} = 20$ a $\bar{y} = 21.4$. Poté provedeme výpočet Pearsonova korelačního koeficientu podle výše uvedeného vzorce. Korelační koeficient $r \approx 0.88$, což ukazuje na silnou pozitivní lineární závislost mezi prodeji v obou regionech.

Excel: Korelační koeficient lze spočítat pomocí funkce `CORREL(array1, array2)` v Excelu.

Příklad 9.3. Mějme data o počtu zákazníků navštěvujících obchod a průměrné denní tržby. Vypočítejte korelační koeficient a určete, zda existuje lineární závislost.

Počet zákazníků	50	60	70	80	90
Denní tržby (v tis. Kč)	20	25	30	28	35

Řešení: Vypočítáme průměry $\bar{x} = 70$ a $\bar{y} = 27.6$. Pomocí vzorce pro korelační koeficient získáme $r \approx 0.91$, což značí velmi silnou pozitivní lineární závislost mezi počtem zákazníků a tržbami.

Excel: Pomocí funkce `CORREL(array1, array2)` lze získat stejný výsledek. □

Příklad 9.4. Zde jsou data pro prodej dvou produktů v různých týdnech. Určete, zda mezi prodejem těchto produktů existuje lineární vztah.

Prodeje produktu A	100	105	110	95	115	90	120	85	125	80
Prodeje produktu B	200	180	205	185	190	185	190	195	200	190

Řešení: Průměry pro produkt A a produkt B jsou $\bar{x} = 102.5$ a $\bar{y} = 192$. Po výpočtu korelačního koeficientu dostaneme $r \approx 0.08$, což naznačuje velmi slabou nebo žádnou lineární závislost mezi prodeji těchto produktů.

Excel: Výpočet pomocí `CORREL(array1, array2)` v Excelu také ukazuje, že korelace je blízka nule, tedy nevýznamná. □

Historie a varianty korelačních koeficientů

Historie korelačních koeficientů sahá až do 19. století, kdy Francis Galton poprvé navrhl metody pro kvantifikaci statistických vztahů mezi proměnnými. Na jeho práci navázal Karl Pearson, který formalizoval a popularizoval Pearsonův korelační koeficient.

V průběhu času byly vyvinuty další varianty korelačních koeficientů pro specifické účely:

- Spearmanův korelační koeficient (Spearman's rho): Používá se, pokud data nejsou normálně rozložena nebo vykazují monotónní, nikoli lineární vztah.
- Kendallův tau: Měří sílu vztahu mezi pořadím hodnot a používá se zejména u malých souborů dat.
- Point-biserial correlation: Využívá se pro měření korelace mezi spojitou a binární proměnnou.

Každý z těchto korelačních koeficientů má své specifické aplikace a závisí na typu dat, které jsou analyzovány. Korelační analýza našla využití v mnoha oblastech, včetně psychologie, ekonomie, marketingu a biostatistiky.

Kdy je korelační koeficient vhodný?

Korelační koeficient popisuje sílu a směr lineárního vztahu mezi dvěma spojitými proměnnými. Jeho použití je vhodné, pokud jsou splněny následující podmínky:

- Obě proměnné mají přibližně normální rozložení.
- Vztah mezi proměnnými je lineární.
- Nejsou přítomny výrazné odlehlé hodnoty, které by ovlivnily výsledek.

Použití Pearsonova korelačního koeficientu je nevhodné, pokud vztah mezi proměnnými není lineární nebo pokud se jedná o ordinální data, u nichž je vhodnější použít Spearmanův korelační koeficient nebo Kendallův tau.

Praktické cvičení

Mějte následující data pro dva produkty a určete, zda existuje lineární závislost mezi jejich prodeji:

Prodeje produktu A	5	10	15	20	25
Prodeje produktu B	8	12	17	22	24

Spočítejte korelační koeficient pomocí výše uvedeného vzorce nebo pomocí Excelu (`CORREL(array1, array2)`). Na základě výsledku určete, zda mezi těmito proměnnými existuje lineární závislost.

9.2 Princip lineární regrese

Úvodní příklad

Představte si, že jste ekonomický analytik ve společnosti, která chce předpovědět tržby na základě výdajů na reklamu. Máte k dispozici následující data z posledních 10 měsíců (tabulka 6).

Tab. 6: Ukázková data pro lineární regresi

Měsíc	1	2	3	4	5	6	7	8	9	10
Reklama (tis. Kč)	20	25	30	35	40	45	50	55	60	65
Tržby (tis. Kč)	200	220	250	280	310	330	360	390	420	450

Cílem je zjistit, jak silný je vztah mezi výdaji na reklamu a tržbami, a vytvořit model, který umožní předpovědět tržby při různých úrovních výdajů na reklamu.

Formulace problému

- **Závislá proměnná (Y):** Tržby (tis. Kč).
- **Nezávislá proměnná (X):** Výdaje na reklamu (tis. Kč).

Cíl analýzy

Pomocí lineární regrese odhadnout vztah mezi výdaji na reklamu a tržbami a posoudit, zda je tento vztah statisticky významný.

Co je to lineární regrese?

Lineární regrese je statistická metoda používaná k modelování vztahu mezi závislou proměnnou a jednou nebo více nezávislými proměnnými. V případě jednoduché lineární regrese se jedná o vztah mezi dvěma proměnnými, který je modelován pomocí přímky.

Regresní model

Lineární regresní model lze vyjádřit rovnicí:

$$Y = \beta_0 + \beta_1 X + \varepsilon,$$

kde:

- Y je závislá proměnná,
- X je nezávislá proměnná,
- β_0 je absolutní člen (intercept),
- β_1 je směrnice přímky (sklon),
- ε je náhodná chyba (reziduální složka).

Metoda nejmenších čtverců

Parametry β_0 a β_1 jsou odhadnuty pomocí *metody nejmenších čtverců*, která minimalizuje součet čtverců odchylek mezi skutečnými hodnotami Y a predikovanými hodnotami $\hat{Y}$:

$$\min_{\beta_0, \beta_1} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \min_{\beta_0, \beta_1} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2.$$

Odhady parametrů

Odhady parametrů $\hat{\beta}_0$ a $\hat{\beta}_1$ lze vypočítat pomocí vzorců:

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x},$$

kde $\bar{x}$ a $\bar{y}$ jsou průměry X a Y .

Předpoklady lineární regrese

Aby byly odhady parametrů platné, musí být splněny následující předpoklady:

- **Linearita:** Vztah mezi X a Y je lineární.
- **Homoskedasticita:** Rozptyl náhodné složky ε je konstantní pro všechna X .
- **Nezávislost:** Hodnoty náhodné složky ε jsou nezávislé.
- **Normalita:** Náhodná složka ε je normálně rozložena.

Historické poznámky

Metoda lineární regrese byla poprvé formálně představena anglickým statistikem **Sir Francis Galtonem** v 19. století při studiu dědičnosti výšky mezi rodiči a dětmi. Termín *regrese* pochází z Galtonova pozorování, že extrémní hodnoty mají tendenci “regresovat” k průměru v následující generaci.

Později **Karl Pearson** a **Ronald A. Fisher** rozvinuli matematické základy regresní analýzy a metodu nejmenších čtverců, která je dnes standardním nástrojem v statistice a ekonometrice.

Odhad parametrů a interpretace

Výpočet odhadů

Pomocí výše uvedených vzorců lze spočítat odhady $\hat{\beta}_0$ a $\hat{\beta}_1$ na základě dostupných dat.

Interpretace parametrů

- **Směrnice přímky ($\hat{\beta}_1$):** Udává změnu v závislé proměnné Y při jednotkové změně nezávislé proměnné X .
- **Absolutní člen ($\hat{\beta}_0$):** Hodnota závislé proměnné Y , když nezávislá proměnná X je nulová.


9.3 Řešené příklady

Příklad 9.5. Vyrovnajte data v tabulce regresní přímkou:

x	5	15	25	35	45	55	65
y	3,5	5,2	5,5	6,1	5,9	6,4	7,8


Řešení: Ukážeme, jak by se tato úloha řešila v Excelu:

1. Nejdříve označíme data a klikneme na *Vložit Graf*, přičemž vybereme typ grafu *XY bodový* (obrázek 18).




Obr. 18: Vložení bodového grafu

2. Máme-li aktivní okno grafu, v nabídce + vybereme možnost *Spojnice trendu* (obrázek 19).



Obr. 19: Přidání spojnice trendu

3. V rámci volby můžete volit i jiné křivky než přímku, a také vložit rovnici přímky přímo do grafu (obrázek 20):



Obr. 20: Nastavení lineární regrese

4. Výsledkem je rovnice regrese $y = 0,0561 \cdot x + 3,8089$. Z grafu vidíme, že rovnice dobře vystihuje závislost proměnných.

Řešení bez použití Excelu:

Pro výpočet regresní přímky použijeme vzorce:

$$y = \hat{\beta}_1 \cdot x + \hat{\beta}_0,$$

kde:

$$\hat{\beta}_1 = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{n \sum x_i^2 - (\sum x_i)^2},$$

$$\hat{\beta}_0 = \frac{\sum y_i - \hat{\beta}_1 \sum x_i}{n}.$$

Pro naše data:

$$\sum x_i = 5 + 15 + 25 + 35 + 45 + 55 + 65 = 245,$$

$$\sum y_i = 3,5 + 5,2 + 5,5 + 6,1 + 5,9 + 6,4 + 7,8 = 40,4,$$

$$\sum x_i^2 = 5^2 + 15^2 + 25^2 + 35^2 + 45^2 + 55^2 + 65^2 = 8575,$$

$$\sum x_i y_i = 5 \cdot 3,5 + 15 \cdot 5,2 + 25 \cdot 5,5 + 35 \cdot 6,1 + 45 \cdot 5,9 + 55 \cdot 6,4 + 65 \cdot 7,8 = 1601,5.$$

Dosadíme do vzorců:

$$\hat{\beta}_1 = \frac{7 \cdot 1601,5 - 245 \cdot 40,4}{7 \cdot 8575 - 245^2} = 0,0561,$$

$$\hat{\beta}_0 = \frac{40,4 - 0,0561 \cdot 245}{7} = 3,8089.$$

Rovnice regresní přímky je tedy:

$$y = 0,0561 \cdot x + 3,8089.$$

□

Příklad 9.6. Použijte data z úvodního příkladu (tabulka 6) a odhadněte lineární regresní model pro vztah mezi výdaji na reklamu a tržbami. Určete odhady parametrů $\hat{\beta}_0$ a $\hat{\beta}_1$.

Řešení: **Krok 1: Výpočet průměrů**

$$\bar{x} = \frac{\sum_{i=1}^{10} x_i}{10} = \frac{20 + 25 + \dots + 65}{10} = 42,5,$$

$$\bar{y} = \frac{\sum_{i=1}^{10} y_i}{10} = \frac{200 + 220 + \dots + 450}{10} = 321.$$

Krok 2: Výpočet odhadu $\hat{\beta}_1$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^{10} (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^{10} (x_i - \bar{x})^2}.$$

Spočítáme jednotlivé sumy:

$$\begin{aligned} \sum (x_i - \bar{x})(y_i - \bar{y}) &= \sum (x_i y_i) - n \bar{x} \bar{y}, \\ \sum (x_i - \bar{x})^2 &= \sum x_i^2 - n \bar{x}^2. \end{aligned}$$

Výpočty:

Vytvoříme tabulku pro výpočty (část výpočtů):

i	X_i	Y_i	$X_i Y_i$	X_i^2
1	20	200	4 000	400
2	25	220	5 500	625
3	30	250	7 500	900
4	35	280	9 800	1 225
5	40	310	12 400	1 600
6	45	330	14 850	2 025
7	50	360	18 000	2 500
8	55	390	21 450	3 025
9	60	420	25 200	3 600
10	65	450	29 250	4 225
Σ	425	3 210	147 950	20 125

A tedy

$$\hat{\beta}_1 = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2} = \frac{147\,950 - 10 \cdot 42,5 \cdot 321}{20\,125 - 10 \cdot (42,5)^2} \approx 5,5882.$$

Výpočet $\hat{\beta}_0$:

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} = 321 - 5,5882 \cdot 42,5 = 321 - 237,5 = 83,5.$$

Regresní rovnice:

$$\hat{Y} = 5,5882X + 83,5.$$

Výpočty v Excelu: Kromě postupu přímo v Excelu, jak jsme si to předvedli v předchozím příkladu, můžeme použít i pokročilejší modul **Analýza dat - Regrese**:

Postup:

1. Vložíme data do dvou sloupců: X (Reklama) a Y (Tržby).
2. Spustíme *Analýza dat* a vybereme *Regrese*.
3. Nastavíme vstupní rozsahy pro závislou a nezávislou proměnnou.
4. Zvolíme výstupní oblast a případně další možnosti (např. reziduální grafy).

Výstupem bude tabulka s odhady parametrů, ale také jejich směrodatnými chybami, hodnotami t -statistik a P -hodnotami.

Interpretace výsledků z Excelu:

Výsledky mohou vypadat například takto:

Parametr	Odhad	Směr. chyba	t	P -hodnota
$\hat{\beta}_0$	83,5	5,0	16,7	0,0000
$\hat{\beta}_1$	5,5882	0,2	27,9	0,0000

Rozhodnutí:

Protože P -hodnota pro $\hat{\beta}_1$ je mnohem menší než $\alpha = 0,05$, zamítáme nulovou hypotézu $H_0 : \beta_1 = 0$. Regresní koeficient $\hat{\beta}_1$ je tedy statisticky významný.

□



V této kapitole jsme se zabývali korelační a regresní analýzou, která slouží k analýze závislostí mezi dvěma kvantitativními znaky. Korelace hodnotí sílu a směr lineárního vztahu mezi dvěma proměnnými pomocí korelačního koeficientu r_{XY} . Pozitivní korelace značí, že s růstem jedné proměnné roste i druhá, zatímco negativní korelace ukazuje opačný vztah.

Regresní analýza pak umožňuje vyjádřit tento vztah pomocí matematického modelu. Nejčastěji se používá lineární regresní model, který popisuje vztah mezi závisle proměnnou

Y a nezávislou proměnnou X pomocí přímky. Parametry modelu, jako je směrnice a průsečík, jsou odhadovány metodou nejmenších čtverců.

V rámci kapitoly jsme si ukázali, jak tyto metody aplikovat na konkrétní data, jak interpretovat výsledky korelace a regrese. Důležitou součástí byla také vizualizace dat pomocí bodových grafů a regresních přímk.

?

1. Co je korelační koeficient a jaká je jeho interpretace?
2. Jaký je rozdíl mezi korelační a regresní analýzou?
3. Jak se vypočítá koeficient korelace r_{XY} mezi dvěma proměnnými?
4. Co znamená hodnota korelačního koeficientu blízká 1, 0 nebo -1 ?
5. Co je to lineární regrese a k čemu slouží?
6. Jak se odhadují parametry lineárního regresního modelu?
7. Co vyjadřuje směrnice a průsečík regresní přímky?
8. Jaké grafické nástroje se používají k vizualizaci výsledků korelační a regresní analýzy?
9. Uvažujme následující data, která představují počet hodin fyzického cvičení za týden a spotřebu kalorií (v tisících) pěti osob:

Osoba	Hodiny cvičení za týden (X)	Spotřeba kalorií (Y, v tisících)
1	3	2,2
2	5	2,8
3	7	3,1
4	8	3,5
5	10	4,0

Vypočítejte korelační koeficient mezi počtem hodin cvičení a spotřebou kalorií a interpretnete výsledek. [$r = 0,98$]


10. V následující tabulce jsou uvedeny hodnoty proměnných X a Y , kde X představuje počet hodin studia a Y dosažené skóre v testu:

Osoba	Hodiny studia (X)	Skóre (Y)
1	2	50
2	3	55
3	4	60
4	5	60
5	6	70

Určete parametry lineární regresní přímky pro závislost skóre na počtu hodin studia (vztah mezi X a Y) a napište rovnici regresní přímky. [$Y = 2X + 51$]

**Literatura k tématu:**

- [1] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6. ISBN 978-80-867-3208-8.
- [2] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [3] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [4] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.



Kapitola 10

Časové řady



Po prostudování této kapitoly budete umět:

- definovat a vysvětlit základní pojmy časových řad,
- popsat klíčové složky časových řad, jako jsou trend, sezónnost a náhodná složka,
- rozlišit mezi stacionárními a nestacionárními časovými řadami,
- interpretovat grafickou analýzu časových řad.



Klíčová slova:

Časová řada, trend, sezónnost, cykličnost, stacionarita, grafická analýza.

Náhled kapitoly

V této kapitole se seznámíme s konceptem časových řad a jejich základními charakteristikami. Časové řady představují posloupnost hodnot sledovaných (většinou) v pravidelných časových intervalech. Tyto řady se používají k analýze dat v mnoha oblastech, jako jsou ekonomie, finance a další disciplíny. Probereme základní složky časových řad, jako jsou trend, sezónnost, cyklické jevy a náhodné výkyvy. Naučíme se, jak tyto složky rozlišit a interpretovat pomocí grafických metod.

Cíle kapitoly

Cílem této kapitoly je představit časové řady jako důležitý nástroj pro analýzu dat sledovaných v čase. Studenti se naučí rozpoznávat základní složky časových řad, pochopí rozdíl mezi stacionárními a nestacionárními řadami a budou schopni provést základní grafickou analýzu.

Odhad času potřebného ke studiu

Odhaduje se, že studium této kapitoly zabere přibližně 2 hodiny. Tento čas zahrnuje čtení textu, pochopení teoretických konceptů a interpretaci grafických analýz časových řad.

Úvod

Definice 10.1. Časové řady představují posloupnost hodnot, které jsou zaznamenávány v pravidelných nebo nepravidelných časových intervalech. Každá hodnota časové řady odpovídá určitému okamžiku nebo časovému úseku. Tento typ dat umožňuje analyzovat změny proměnné v čase a může odhalit různé vzorce chování proměny dat, jako jsou trendy (růst nebo pokles ve větším časovém měřítku) nebo sezónní výkyvy.

Příkladem časové řady může být vývoj ceny akcií na burze, počet prodaných výrobků v obchodě za jednotlivé měsíce nebo denní teplota zaznamenaná meteorologickou stanicí.

Kde se časové řady využívají?

Časové řady se využívají v mnoha oblastech, kde je třeba analyzovat a předvídat vývoj veličin v čase. Mezi nejčastější aplikace patří:

- *Ekonomie a finance:* Analýza vývoje cen akcií, kurzů měn, inflace nebo nezaměstnanosti.
- *Marketing:* Předpovědi poptávky, prodejních trendů, či sezónních výkyvů v tržbách.
- *Meteorologie:* Analýza teplotních změn, srážkových úhrnů nebo předpovědi počasí na základě historických dat.
- *Výrobní procesy:* Monitoring a analýza výkonnosti výrobních zařízení v čase, sledování kvality nebo optimalizace výrobních kapacit.

Díky těmto aplikacím je možné provádět analýzy, které pomáhají organizacím předvídat budoucí vývoj a lépe plánovat své aktivity.

10.1 Základní pojmy časových řad

Pozorování a časová osa

Časová řada je posloupnost hodnot určité veličiny, které jsou měřeny nebo zaznamenávány v nějakých (většinou pravidelných) časových intervalech.

Definice 10.2. Každá časová řada má dvě klíčové složky:

- *Časová osa:* Zahrnuje jednotlivé časové body (např. dny, měsíce, roky), ve kterých jsou hodnoty proměnné zaznamenány.
- *Hodnoty proměnné:* Reprezentují sledovanou veličinu (např. teplotu, cenu akcií, prodeje).

Časové řady jsou důležité pro zkoumání změn a trendů v průběhu času, což nám potenciálně umožňuje predikovat budoucí hodnoty na základě předchozích dat.

Trend, sezónnost, cykličnost a náhodná složka

Definice 10.3. Časovou řadu můžeme rozložit na několik základních složek:

- *Trend:* Dlouhodobý směr vývoje časové řady, který může být vzestupný, sestupný nebo konstantní. Představuje systematickou změnu hodnot v čase.
- *Sezónnost:* Krátkodobé pravidelné fluktuace, které se opakují v určitém časovém období (např. roční období, měsíční prodeje).
- *Cykličnost:* Dlouhodobé nepravidelné výkyvy, které nejsou striktně periodické, ale mohou souviset s ekonomickými nebo jinými cykly.
- *Náhodná složka:* Nepravidelné, nepředvídatelné výkyvy, které nelze vysvětlit trendem, sezónností ani cykličností. Tato složka představuje vlivy, které nejsou systematické a mohou být způsobeny různými náhodnými faktory.

Rozklad časové řady na tyto složky nám umožňuje lépe pochopit její strukturu a provádět analýzy, které jsou užitečné například při modelování a predikci.

10.2 Typy časových řad

Deterministické a stochastické časové řady

Definice 10.4. Časové řady můžeme rozdělit do dvou základních kategorií:

- *Deterministické časové řady:* U těchto řad je budoucí vývoj plně určen předchozími hodnotami. Neobsahují žádnou náhodnou složku a jsou často popsány jednoduchými matematickými funkcemi, například lineárním nebo exponenciálním trendem.
- *Stochastické časové řady:* Tyto řady obsahují náhodnou složku, což znamená, že jejich budoucí vývoj není zcela předvídatelný. Příkladem je fluktuace na finančních trzích, kde se vývoj ceny akcie v čase nedá přesně určit.

Rozlišení mezi deterministickými a stochastickými řadami je klíčové pro výběr vhodných metod analýzy a předpovědí.

Stacionární a nestacionární časové řady

Definice 10.5. Další důležité dělení časových řad je na stacionární a nestacionární:

- *Stacionární časové řady:* Časová řada je stacionární, pokud její statistické vlastnosti (např. průměr a rozptyl) zůstávají v čase konstantní. To znamená, že v průběhu času nepozorujeme žádný výrazný trend ani změny v kolísání hodnot. Stacionární časové řady jsou často jednodušší na analýzu a modelování.
- *Nestacionární časové řady:* V těchto řadách dochází ke změnám v čase, například k růstu nebo poklesu průměru, změnám v rozptylu nebo výskytu sezónních výkyvů. Pro analýzu nestacionárních časových řad je obvykle nutné aplikovat metody, které tyto změny zohlední, například diferenciaci.

Stacionarita je důležitý koncept, protože mnoho statistických metod předpokládá, že časová řada je stacionární. Pokud není, je třeba použít vhodné transformace, které pomohou dosáhnout stacionarity.

10.3 Analýza časových řad

Grafická analýza časových řad

Jedním z prvních kroků při analýze časové řady je vizuální zkoumání jejích vlastností pomocí grafů. Grafická analýza časových řad nám umožňuje identifikovat základní složky časové řady, jako jsou trend, sezónnost nebo náhodné výkyvy.

Definice 10.6. Mezi nejčastěji používané grafické nástroje patří:

- *Časový graf*: Zobrazuje hodnoty časové řady na vertikální ose a časové body na horizontální ose. Tento graf je ideální pro identifikaci dlouhodobých trendů a sezónních výkyvů.
- *Sezónní diagram*: Používá se k vizualizaci opakujících se sezónních vzorců. Umožňuje snadno rozpoznat, zda má časová řada pravidelné sezónní fluktuace v průběhu jednotlivých období (například různé měsíce nebo roční období).
- *Bodový diagram (scatter plot)*: Může být použit ke zkoumání závislosti mezi hodnotami časové řady v různých časových intervalech. Tento graf může odhalit autokorelaci (závislost mezi hodnotami v různých časech).

Grafická analýza poskytuje rychlý přehled o struktuře časové řady a je často prvním krokem před aplikací pokročilejších analytických metod.

Rozklad časové řady

Pro lepší pochopení struktury časové řady je často užitečné rozložit ji na jednotlivé složky: trend, sezónnost a náhodnou složku. Tento rozklad umožňuje oddělit systematické vlivy od náhodných výkyvů, což usnadňuje interpretaci a předpovědi.

Definice 10.7. Rozklad časové řady lze provést pomocí několika metod, například:

- *Additivní model*: Předpokládá, že časová řada je součtem trendu, sezónnosti a náhodné složky. Tento model je vhodný, pokud amplituda sezónních výkyvů zůstává konstantní v čase.
- *Multiplikativní model*: Předpokládá, že časová řada je součinem trendu, sezónnosti a náhodné složky. Tento model je vhodný, pokud se amplituda sezónních výkyvů mění s velikostí časové řady (například větší pro vyšší hodnoty časové řady).

Rozklad časové řady nám umožňuje lépe porozumět jejím jednotlivým složkám a případně predikovat budoucí hodnoty na základě trendů a sezónních vzorců.

10.4 Charakteristiky časových řad

Charakteristiky časových řad

Při analýze časových řad se používají základní charakteristiky růstu, které nám umožňují kvantifikovat změny hodnot mezi jednotlivými časovými body.

Definice 10.8. Mezi hlavní charakteristiky patří:

- *Absolutní přírůstky* (difference): Rozdíl mezi hodnotami časové řady ve dvou po sobě jdoucích obdobích. Absolutní přírůstek Δx_t pro období t je dán vztahem:

$$\Delta x_t = x_t - x_{t-1},$$

kde x_t je hodnota časové řady v období t a x_{t-1} je hodnota v předchozím období.

- *Koeficienty růstu*: Poměr mezi hodnotou časové řady v období t a hodnotou v předchozím období $t - 1$. Koeficient růstu k_t je dán vztahem:

$$k_t = \frac{x_t}{x_{t-1}}.$$

Tento koeficient nám ukazuje relativní změnu hodnot mezi dvěma obdobími.

Průměrné charakteristiky

Pro získání obecnějšího obrazu o vývoji časové řady v delším období používáme

Definice 10.9. průměrné charakteristiky:

- *Průměrný absolutní přírůstek*: Jedná se o průměr všech absolutních přírůstků časové řady a vypočítá se jako:

$$\text{Průměrný přírůstek} = \frac{\sum_{t=2}^n \Delta x_t}{n - 1}$$

kde n je počet období.

- *Průměrný koeficient růstu*: Tento koeficient vyjadřuje průměrnou relativní změnu časové řady v průběhu několika období. Vypočítá se jako geometrický průměr koeficientů růstu:

$$\text{Průměrný koeficient růstu} = \left(\prod_{t=2}^n k_t \right)^{\frac{1}{n-1}}$$

Tyto průměrné charakteristiky poskytují přehled o celkovém trendu časové řady.

Aplikace v praxi

Charakteristiky růstu lze využít k analýze změn v různých oblastech, jako je produkce, prodej nebo zásoby. Například pomocí průměrného absolutního přírůstku lze sledovat, jak se postupně mění objem výroby v továrně, a průměrný koeficient růstu nám může ukázat, zda růst prodeje vykazuje stabilní tempo nebo kolísá mezi obdobími.

10.5 Řešené příklady


Příklad 10.10. Mějme následující časovou řadu, která představuje počet prodaných kusů určitého produktu v obchodě za posledních 10 měsíců:

(120, 150, 130, 170, 160, 180, 200, 190, 210, 230)

Vaším úkolem je:

1. Vykreslit časový graf této časové řady.
2. Identifikovat, zda časová řada obsahuje trend.

Řešení: 1. Pro vykreslení časového grafu použijeme hodnoty z časové řady na vertikální ose a čas (v měsících) na horizontální ose. Graf ukazuje, jak se počet prodaných kusů mění v čase.



2. Z časového grafu můžeme vidět, že počet prodaných kusů má obecně rostoucí trend. Ne v každém měsíci se počet prodaných kusů zvyšuje, ale celkově je jasný pozitivní růst. Tato časová řada tedy obsahuje trend.

Příklad 10.11. Určete elementární charakteristiky růstu časové řady sledující výrobu plynu v letech 1980 - 1985.

rok	1980	1981	1982	1983	1984	1985
výroba (m ³)	1286	1363	1393	1495	1571	1610

Řešení: Řešení:

rok	výroba (m ³) y_t	absolutní přírůstky	koefficienty růstu
1980	1286		
1981	1363	77	1,060
1982	1393	30	1,022
1983	1495	102	1,073
1984	1571	76	1,051
1985	1610	39	1,025

Průměrný absolutní přírůstek:

$$\bar{\Delta} = \frac{\sum \Delta y_t}{n-1} = \frac{(y_2 - y_1) + (y_3 - y_2) + \dots + (y_n - y_{n-1})}{n-1} = \frac{y_n - y_1}{n-1} = \frac{1610 - 1286}{5} = 64,8$$

Průměrný koeficient růstu:

$$\bar{k} = \sqrt[n-1]{k_1 \cdot k_2 \cdot \dots \cdot k_{n-1}} = \sqrt[5]{\frac{y_2}{y_1} \cdot \frac{y_3}{y_2} \cdot \frac{y_4}{y_3} \cdot \dots \cdot \frac{y_n}{y_{n-1}}} = \sqrt[5]{\frac{1610}{1286}} \approx 1,046$$

□

10.6 Softwarová analýza časových řad

V předchozích dvou příkladech jsme si předvedli jen velmi základní výpočty.

Pro pokročilejší analýzu časových řad lze využít různé softwarové nástroje, které nabízejí specializované funkce a metody:

- *Excel*: Excel umožňuje provádět základní analýzu časových řad, jako je vykreslování časových grafů nebo výpočet klouzavých průměrů. Pro pokročilejší analýzy je možné použít doplněk **Analýza dat**, který zahrnuje funkce pro regresní analýzu nebo sezónní dekompozici.
- *R*: Ve statistické softwaru R jsou k dispozici speciální balíčky, jako například **forecast** nebo **tseries**, které poskytují nástroje pro modelování časových řad, jako jsou ARIMA modely, exponenciální vyrovnávání a testy stacionarity. R je velmi flexibilní a široce využívaný pro komplexní analýzy.
- *Wolfram Alpha*: Wolfram Alpha je interaktivní nástroj, který umožňuje provádět základní analýzu časových řad, jako je vykreslení grafů nebo výpočet trendů. Méně se hodí pro komplexní statistické modely, ale je užitečný pro rychlé vizualizace a základní výpočty.

Použití konkrétního softwaru závisí na potřebách analýzy – Excel je vhodný pro jednodušší úlohy a rychlou vizualizaci, zatímco R poskytuje nástroje pro pokročilé statistické modely, a Wolfram Alpha nabízí snadno přístupnou platformu pro základní výpočty.

Příklad 10.12. Ukázka grafických výstupů při analýze časové řady počtu cestujících. Data jsou součástí instalace softwaru R.

Řešení: Nejprve uvedeme programový kód, který nám v R, mimo jiné, vytvoří zmíněné grafické výstupy:

```
# Načtení datasetu AirPassengers
data("AirPassengers")
# Základní informace o datasetu
summary(AirPassengers)
plot(AirPassengers, main="Počet cestujících v letecké dopravě (1949–1960)",
      ylab="Počet cestujících", xlab="Rok", col="blue")
# Decompose časové řady (rozklad na trend, sezónnost a náhodnou složku)
decomposed <- decompose(AirPassengers)
plot(decomposed, col="darkred")
# Autokorelační graf
acf(AirPassengers, main="Autokorelační funkce pro AirPassengers")
# ARIMA model pro předpověď
library(forecast)
model <- auto.arima(AirPassengers)
forecasted <- forecast(model, h=24)
# Graf předpovědi
plot(forecasted, main="Předpověď počtu cestujících na příští 2 roky", col="green")
# Výstup modelu
summary(model)
```

Pokračujeme ukázkou grafů.

- Na obrázku 21 na straně 160 je znázorněna časová řada počtu cestujících.
- Na obrázku 22 na straně 160 je provedena tzv. dekompozice (rozklad) časové řady na trendovou, sezónní a náhodnou složku.
- Na obrázku 23 na straně 160 je ukázka předpovědi.

□

Σ

V této kapitole jsme se věnovali časovým řadám, které popisují vývoj veličin v čase. Hlavní body zahrnují:

- **Základní pojmy:** Probrali jsme časovou osu, hodnoty proměnných a základní složky časové řady, jako jsou trend, sezónnost a náhodné výkyvy.
- **Typy časových řad:** Rozdělili jsme časové řady na deterministické a stochastické, stacionární a nestacionární.
- **Charakteristiky růstu:** Představili jsme absolutní přírůstky, koeficienty růstu a jejich průměrné hodnoty jako nástroje pro kvantifikaci změn časové řady.


Kapitola poskytuje jen velmi základní nástroje pro analýzu časových řad v různých oborech.

?


1. Jaké jsou základní složky časové řady? Uveďte příklady každé z nich.
2. Jaký je rozdíl mezi stacionární a nestacionární časovou řadou?
3. Jaký je význam průměrného absolutního přírůstku a průměrného koeficientu růstu v analýze časových řad?
4. V jakých situacích byste použili multiplicative model namísto aditivního modelu pro rozklad časové řady?
5. Vysvětlete, jak lze využít Excel, R nebo Wolfram Alpha pro analýzu časových řad. Jaké jsou hlavní rozdíly mezi těmito nástroji?
6. Majitel prodejny evidoval čtvrtletně objem prodeje ovocných kompotů a jejich zásoby na počátku čtvrtletí.

čtvrtletí	prodej ks	zásoby ks
I.	560	220
II.	480	210
III.	520	215
IV.	550	200


Na konci 4. čtvrtletí bylo v zásobě 150 ovocných kompotů. Vypočtete průměrný čtvrtletní prodej a průměrnou čtvrtletní zásobu ovocných kompotů. [527,5, 199]



Obr. 21: Graf časové řady z příkladu 10.12



Obr. 22: Dekompozice časové řady z příkladu 10.12



Obr. 23: Graf předpovědi časové řady z příkladu 10.12

7. Časová řada následujících hodnot představuje počet prodaných kusů elektroniky v obchodě za posledních 12 měsíců:

(120, 130, 110, 150, 140, 160, 170, 165, 180, 175, 190, 185)

- Vypočtete absolutní přírůstky pro každý měsíc.
- Vypočtete koeficient růstu pro každý měsíc.
- Určete průměrný absolutní přírůstek a průměrný koeficient růstu.

[..., ..., 7,27, 1,0217]



Literatura k tématu:

- [1] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6. ISBN 978-80-867-3208-8.
- [2] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [3] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [4] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.

Kapitola 11

Induktivní statistika



Po prostudování této kapitoly budete umět:

- určit bodový odhad zvolených parametrů,
- určit intervalový odhad (interval spolehlivosti) střední hodnoty a rozptylu při zvolené hladině spolehlivosti,
- použít nástroje Excelu a R pro výpočty bodových a intervalových odhadů v praktických příkladech.



Klíčová slova:

Bodový odhad, intervalový odhad, střední hodnota, rozptyl, Excel, R.

Náhled kapitoly

V této kapitole se budeme věnovat základním nástrojům indukční statistiky, kterými jsou bodové a intervalové odhady. Tyto odhady umožňují na základě výběrových dat vyvodit závěry o základním souboru, což je klíčová součást statistické analýzy. Naučíme se, jak vypočítat bodový a intervalový odhad střední hodnoty (průměru) a rozptylu, a to jak teoreticky, tak i prakticky s využitím programů Excel a R.

Cíle kapitoly

Cílem této kapitoly je pochopit hlavní myšlenku indukční statistiky a naučit se odhadovat parametry základního souboru pomocí bodových a intervalových odhadů.

Odhad času potřebného ke studiu

Studium této kapitoly by mělo zabrat přibližně 2 hodiny. Tento čas zahrnuje prostudování teorie, porozumění odhadovým metodám a zvládnutí praktických výpočtů v Excelu a R.

Úvod

Zopakujme si, že statistika je obor, který se zabývá sběrem, analýzou a interpretací hromadných pozorování a výsledků opakovaných pokusů. Je rozdělena na dva hlavní typy:

- **Deskriptivní (popisná) statistika:** Zaměřuje se na uspořádání datových souborů, jejich popis a účelnou sumarizaci.
- **Induktivní statistika:** Pomocí empirických poznatků umožňuje vytvářet vědecky odůvodněné obecné závěry. Tento přístup je založen na teorii pravděpodobnosti.

Stejně jako statistika, i lidské myšlení lze rozdělit na různé typy podle způsobu uvažování. Mezi nejvýznamnější typy patří:

Deduktivní myšlení

Deduktivní myšlení je proces, při kterém vyvozujeme závěry z obecných zákonitostí nebo pravidel. Z obecných principů vytváříme specifické závěry, které se uplatňují v jednotlivých případech. Deduktivní myšlení zajišťuje přesné a logické usuzování.

Příklad: Všichni lidé jsou smrtelní. Sokrates je člověk. Tudíž Sokrates je smrtelný.

Induktivní myšlení

Induktivní myšlení vychází z konkrétních pozorování jednotlivých případů a zobecňuje je do obecných závěrů. Na rozdíl od dedukce, indukce často pracuje s nejistotou, protože závěry jsou ovlivněny subjektivními postoji a mají omezenou platnost.

Příklad: Každé ráno, kdy jsem pozoroval východ slunce, slunce skutečně vyšlo. Proto mohu induktivně usoudit, že slunce vyjde i zítra ráno.

Další typy myšlení

- **Abduktivní myšlení:** Vyvozování nejpravděpodobnějšího vysvětlení na základě dostupných informací. Často se používá při řešení neúplných problémů, kde se snažíme najít nejlepší hypotézu.

Příklad: „Zem je mokrá, pravděpodobně pršelo.“

- **Kreativní myšlení:** Schopnost generovat nové a originální nápady nebo řešení. Zaměřuje se na netradiční přístupy k řešení problémů.

Příklad: „Namísto tradičního reklamačního procesu navrhneme zcela nový způsob zákaznického servisu pomocí umělé inteligence.“

- **Kritické myšlení:** Proces systematického hodnocení a zkoumání informací, argumentů a důkazů. Cílem je dospět ke správným závěrům založeným na logice a důkazech.

Příklad: „Tento článek tvrdí, že určité potraviny jsou škodlivé, ale podívejme se na důkazy a ověřme, zda to podporují i jiné studie.“

Statistická indukce je proces, při kterém pomocí statistických metod dokážeme vytvářet obecné závěry z dostupných dat. Jejich spolehlivost lze kvantifikovat pomocí pravděpodobnosti. Základem statistické indukce je práce s **výběrem** a **základním souborem**.

Základní soubor (populace)

Základní soubor, někdy označován jako populace, je množina všech prvků, které jsou předmětem zkoumání. Tento soubor může být:

- **Konečný:** Např. počet obyvatel v určité zemi.
- **Nekonečný:** Hypotetický soubor, který je ideální a v realitě neexistuje.

Prvky základního souboru mají různé vlastnosti, nazývané **znaky**. Tyto znaky dělíme na:

- **Kvalitativní:**

- *Nominální*: Vlastnosti, které lze pouze pojmenovat (např. barva očí).
- *Ordinální*: Vlastnosti, které lze uspořádat (např. spokojenost zákazníků na škále 1 až 5).

- **Kvantitativní:**

- *Diskrétní*: Hodnoty mohou nabývat pouze určitých hodnot (např. počet dětí v rodině).
- *Spojitě*: Hodnoty mohou nabývat jakékoliv hodnoty v daném intervalu (např. výška člověka).

Výběr

Výběr je část základního souboru, kterou zkoumáme a na základě které usuzujeme na celou populaci. Aby byl výběr reprezentativní, musí odpovídat vlastnostem celého základního souboru. Pokud není výběr reprezentativní, jedná se o selektivní výběr.

Metody výběru:

- **Náhodný výběr**: Prvky vybíráme náhodně, například losováním nebo pomocí tabulek náhodných čísel.
- **Mechanický (systematický) výběr**: Prvky vybíráme podle pevně stanoveného pravidla (např. každý třetí prvek).
- **Oblastní (stratifikovaný) výběr**: Základní soubor je rozdělen na homogenní oblasti, ze kterých jsou prvky vybírány náhodně.
- **Skupinový výběr**: Používá se pro velké populace, kdy vybíráme celé skupiny prvků (např. domácnosti nebo rodiny).
- **Vícestupňový výběr**: Prvky jsou vybírány postupně z různých úrovní hierarchie (např. město – domácnost – osoba).

11.1

Odhady v indukční statistice

V oblasti indukční statistiky se nejčastěji zaměřujeme na odhadování parametrů základního souboru na základě výběrových dat. Mezi hlavní parametry, které odhadujeme, patří:

- **Průměr (střední hodnota):** Odhadujeme střední hodnotu populace na základě průměru ve výběru.
- **Rozptyl:** Odhadujeme rozptyl populace na základě výběrového rozptylu.
- **Proporce:** Odhady podílů určité charakteristiky v populaci (např. podíl lidí s určitým názorem).

Zde se konkrétně zaměříme na **bodový** a **intervalový** odhad průměru (střední hodnoty) a rozptylu.

11.1.1 Bodový a intervalový odhad průměru (střední hodnoty)

Bodový odhad průměru

Definice 11.1. Bodový odhad průměru vyjadřuje nejlepší odhad skutečné střední hodnoty populace na základě výběrového průměru. Bodový odhad střední hodnoty μ se vypočítá jako:

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i,$$

kde x_i jsou jednotlivé hodnoty z výběru a n je počet pozorování.

Praktický výpočet v Excelu:

V Excelu můžete bodový odhad průměru vypočítat pomocí funkce PRŮMĚR:

`=PRŮMĚR(A1:A10),`

kde rozsah buněk A1:A10 obsahuje hodnoty výběru.

Praktický výpočet v R:

V R můžete bodový odhad průměru spočítat funkcí `mean()`:

`mean(data),`

kde `data` je vektor obsahující hodnoty výběru.

Intervalový odhad průměru

Definice 11.2. Intervalový odhad poskytuje rozsah hodnot, ve kterém se s určitou pravděpodobností nachází skutečný průměr populace. Intervalový odhad pro střední hodnotu μ s danou hladinou spolehlivosti $1 - \alpha$ se vypočítá jako:

$$\left\langle \hat{\mu} - u_{1-\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}, \hat{\mu} + u_{1-\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \right\rangle,$$

kde $u_{1-\alpha/2}$ je kvantil normálního rozdělení pro zvolenou hladinu spolehlivosti, σ je směrodatná odchylka populace (případně odhad ze vzorku) a n je velikost výběru.

Praktický výpočet v Excelu:

Intervalový odhad průměru lze v Excelu vypočítat pomocí následujícího postupu:

1. Výpočet průměru: `=PRŮMĚR(A1:A10)`
2. Výpočet směrodatné odchylky: `=SMODCH.VÝBĚR.S(A1:A10)`
3. Výpočet velikosti výběru: `=POČET(A1:A10)`
4. K výpočtu kvantilu normálního rozdělení použijeme funkci `NORM.INV` nebo `NORM.S.INV`, např. pro hladinu spolehlivosti 95%: `=NORM.S.INV(0,975)`
5. Intervalový odhad pak získáme jako průměr $\pm u_{1-\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}$.

Praktický výpočet v R:

V R můžeme intervalový odhad průměru vypočítat pomocí kombinace funkcí:

```
mean(data) + c(-1, 1) * qnorm(0.975) * sd(data)/sqrt(length(data))
```

11.1.2 Bodový a intervalový odhad rozptylu

Bodový odhad rozptylu

Definice 11.3. Bodový odhad rozptylu vyjadřuje nejlepší odhad skutečného rozptylu populace na základě výběrového rozptylu. Bodový odhad rozptylu σ^2 se vypočítá jako:

$$\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \hat{\mu})^2,$$

kde $\hat{\mu}$ je průměr výběru a x_i jsou jednotlivé hodnoty z výběru.

Praktický výpočet v Excelu:

V Excelu můžete bodový odhad rozptylu vypočítat pomocí funkce `VAR.S`:

`=VAR.S(A1:A10)`

Praktický výpočet v R:

V R můžete bodový odhad rozptylu vypočítat funkcí `var()`:

`var(data)`

Intervalový odhad rozptylu

Definice 11.4. Intervalový odhad rozptylu lze vypočítat s využitím χ^2 rozdělení, které se používá pro odhady rozptylu. Intervalový odhad rozptylu s hladinou spolehlivosti $1 - \alpha$ se vypočítá jako:

$$\left\langle \frac{(n-1) \cdot \hat{\sigma}^2}{\chi_{1-\alpha/2, n-1}^2}, \frac{(n-1) \cdot \hat{\sigma}^2}{\chi_{\alpha/2, n-1}^2} \right\rangle,$$

kde $\chi_{\alpha/2, n-1}^2$ je kvantil χ^2 rozdělení.

Praktický výpočet v Excelu:

Intervalový odhad rozptylu můžete vypočítat pomocí následujících kroků:

1. Výpočet rozptylu: `=VAR.S(A1:A10)`
2. Výpočet velikosti výběru: `=POČET(A1:A10)`
3. K výpočtu kvantilu χ^2 rozdělení použijte funkci `CHISQ.INV`, např.: `=CHISQ.INV(0,975;n-1)`
4. Intervalový odhad rozptylu pak získáme dosazením o vzorce pro interval.

Praktický výpočet v R:

V R můžeme intervalový odhad rozptylu vypočítat pomocí následujícího kódu:

```
n <- length(data)

var(data) * (n-1) / qchisq(c(0.975, 0.025), n-1)
```

Tento výpočet nám poskytne dolní a horní hranici intervalového odhadu rozptylu.

11.2 Řešené příklady

Příklad 11.5. Při měření průměru vačkového hřídele na 250 součástkách bylo zjištěno, že výběrový průměr činí $\bar{x}_p = 995,6$ a výběrová disperze $s^2 = 134,7$. Předpokládáme, že soubor má normální rozdělení. Určete interval spolehlivosti pro střední hodnotu základního souboru při hladině významnosti $\alpha = 0,05$.

Řešení: Pro odhad střední hodnoty základního souboru μ na základě výběrových dat se používá interval spolehlivosti ve tvaru:

$$\langle \bar{x}_p - \Delta; \bar{x}_p + \Delta \rangle,$$

kde $\bar{x}_p$ je výběrový průměr, Δ je tzv. mezní chyba odhadu a určuje se podle vztahu:

$$\Delta = \frac{s}{\sqrt{n}} \cdot u_{1-\frac{\alpha}{2}}.$$

V tomto výrazu:

- s je směrodatná odchylka výběru,
- n je počet pozorování (v našem případě $n = 250$),

- $u_{1-\frac{\alpha}{2}}$ je kritická hodnota normálního rozdělení odpovídající zvolené hladině významnosti α .

Pro hladinu významnosti $\alpha = 0,05$ je hodnota $u_{1-\frac{\alpha}{2}} = \text{NORM.S.INV}(0,975) \approx 1,96$.

Nyní vypočítáme mezní chybu odhadu Δ :

$$\Delta = \frac{\sqrt{134,7}}{\sqrt{250}} \cdot 1,96 \approx 1,441558.$$

Intervalový odhad střední hodnoty μ je tedy:

$$\langle \bar{x}_p - \Delta; \bar{x}_p + \Delta \rangle = \langle 995,6 - 1,441558; 995,6 + 1,441558 \rangle = \langle 994,1584; 997,0416 \rangle.$$

Z toho plyne, že s 95 % spolehlivostí lze tvrdit, že skutečná střední hodnota průměru vačkového hřídele leží v intervalu $\langle 994,1584; 997,0416 \rangle$. $\square$

Příklad 11.6. Určete oboustranný konfidenční interval rozptylu normálně rozloženého základního souboru pro hladiny spolehlivosti 0,90, 0,95 a 0,99, když u výběru s rozsahem $n = 12$ byl zjištěn rozptyl $s^2 = 0,64$. Posuďte získané výsledky.

Řešení: Pro výpočet konfidenčního intervalu pro rozptyl σ^2 normálně rozloženého základního souboru použijeme vztah:

$$\frac{n \cdot s^2}{\chi_{1-\frac{\alpha}{2}}^2(n-1)} \leq \sigma^2 \leq \frac{n \cdot s^2}{\chi_{\frac{\alpha}{2}}^2(n-1)},$$

kde

- $n = 12$ je rozsah výběru,
- $s^2 = 0,64$ je výběrový rozptyl,
- $\chi_{1-\frac{\alpha}{2}}^2(n-1)$ a $\chi_{\frac{\alpha}{2}}^2(n-1)$ jsou kritické hodnoty Pearsonova rozdělení s $n-1 = 11$ stupni volnosti.

1. Příklad: Hladina spolehlivosti 0,90

Pro hladinu spolehlivosti $1 - \alpha = 0,90$ je $\alpha = 0,10$. Kritické hodnoty jsou:

$$\chi_{0,05}^2(11) = \text{CHIINV}(0,05; 11) \approx 19,675,$$

$$\chi_{0,95}^2(11) = \text{CHIINV}(0,95; 11) \approx 4,575.$$

Dosazením do vztahu:

$$\frac{12 \cdot 0,64}{19,675} \leq \sigma^2 \leq \frac{12 \cdot 0,64}{4,575},$$

$$0,390 \leq \sigma^2 \leq 1,678.$$

2. Příklad: Hladina spolehlivosti 0,95

Pro hladinu spolehlivosti $1 - \alpha = 0,95$ je $\alpha = 0,05$. Kritické hodnoty jsou:

$$\chi_{0,025}^2(11) = \text{CHIINV}(0,025; 11) \approx 22,362,$$

$$\chi_{0,975}^2(11) = \text{CHIINV}(0,975; 11) \approx 3,816.$$

Dosazením do vztahu:

$$\frac{12 \cdot 0,64}{22,362} \leq \sigma^2 \leq \frac{12 \cdot 0,64}{3,816},$$

$$0,343 \leq \sigma^2 \leq 2,012.$$

3. Příklad: Hladina spolehlivosti 0,99

Pro hladinu spolehlivosti $1 - \alpha = 0,99$ je $\alpha = 0,01$. Kritické hodnoty jsou:

$$\chi_{0,005}^2(11) = \text{CHIINV}(0,005; 11) \approx 26,757,$$

$$\chi_{0,995}^2(11) = \text{CHIINV}(0,995; 11) \approx 2,603.$$

Dosazením do vztahu:

$$\frac{12 \cdot 0,64}{26,757} \leq \sigma^2 \leq \frac{12 \cdot 0,64}{2,603},$$

$$0,287 \leq \sigma^2 \leq 2,952.$$

Z výsledků vidíme, že s rostoucí hladinou spolehlivosti se konfidenční interval rozšiřuje. $\square$

Σ

V této kapitole jsme se věnovali základním metodám induktivní statistiky, zejména bodovým a intervalovým odhadům, které jsou klíčovými nástroji pro usuzování o parametrech základního souboru na základě výběrových dat.

V kapitole byl kladen důraz na praktické využití těchto metod v Excelu a R, kde byly představeny konkrétní funkce pro výpočet bodových a intervalových odhadů, jako např. `PRŮMĚR`, `SMODCH.VÝBĚR`, `NORM.S.INV` a `CHISQ.INV` v Excelu a `mean()`, `var()`, `qnorm()` a `qchisq()` v R.

?


1. Vysvětlete, co je bodový odhad a jak se liší od intervalového odhadu.
2. Jaké jsou hlavní složky při výpočtu intervalového odhadu pro střední hodnotu? Vysvětlete, co znamená hladina spolehlivosti.
3. Kdy použijete pro intervalový odhad průměru normální rozdělení a kdy Studentovo t -rozdělení?
4. Jaký je rozdíl mezi intervalovým odhadem pro střední hodnotu a intervalovým odhadem pro rozptyl? Uveďte vzorce a vysvětlete jednotlivé členy.
5. Co znamená, že intervalový odhad má hladinu spolehlivosti 95 %? Může být tento odhad vždy správný?
6. Jaký je význam kritické hodnoty v kontextu intervalových odhadů? Jak se liší kritické hodnoty pro různé hladiny spolehlivosti?
7. Jakou roli hraje velikost výběru při výpočtu intervalových odhadů? Jak se mění šířka intervalu s rostoucím počtem pozorování?

8. Byla měřena délka trvání určitého procesu. Z 12 měření byla zjištěna střední doba trvání procesu 44 s a směrodatná odchylka 4 s. Sestrojte 90 % a 95 % interval spolehlivosti pro očekávanou délku procesu za předpokladu normálního rozdělení. [90 % CI: (42,02; 45,98), 95 % CI: (41,45; 46,55)]
9. Při měření kapacity sady kondenzátorů bylo provedeno 10 měření s výsledky: 152, 156, 148, 153, 150, 156, 140, 155, 145, 148. Odhadněte interval spolehlivosti pro kapacitu těchto kondenzátorů se spolehlivostí a) 90 %, b) 95 %. [90 % CI: (146,41; 154,19), 95 % CI: (145,58; 155,02)]
10. Určete intervalový odhad s 90 % spolehlivostí střední hodnoty a směrodatné odchylky pro následující hodnoty: 606, 1249, 267, 44, 510, 340, 109, 1957, 463, 801, 1086, 169, 233, 1734, 1458, 80, 1023, 2736, 917, 459. [90 % CI: (487,87; 1224,73)]
11. Vzorek 20 studentů měl průměrnou dobu studia na zkoušku 5,6 hodiny se směrodatnou odchylkou 1,2 hodiny. Určete 95 % interval spolehlivosti pro průměrnou dobu studia celé populace studentů, pokud předpokládáme, že délka studia má normální rozdělení. [95 % CI: (5,00; 6,20)]
12. Po změření výšky 30 osob bylo zjištěno, že průměrná výška je 172 cm a směrodatná odchylka je 5 cm. Sestrojte 99 % interval spolehlivosti pro průměrnou výšku celé populace. [99 % CI: (169,49; 174,51)]
13. Při experimentu s délkou životnosti určitého druhu baterie bylo zaznamenáno 15 hodnot. Výběrový průměr životnosti je 500 hodin a směrodatná odchylka je 40 hodin. Určete 90 % interval spolehlivosti pro očekávanou délku životnosti baterií. [90 % CI: (481,80; 518,20)]
14. Vzorek 25 produktů měl výběrový rozptyl 0,36. Určete interval spolehlivosti pro rozptyl populace na hladině významnosti 0,05. [95 % CI: (0,219; 0,693)]



Literatura k tématu:

- [1] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6. ISBN 978-80-867-3208-8.
- [2] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [3] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4. Dostupné z: <https://home1.vsb.cz/~oti73/cdpast1/>
- [4] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.



Kapitola 12

Využití softwaru při řešení statistických úloh



Po prostudování této kapitoly budete umět:

- využít software pro řešení vybraných statistických úloh,
- načíst data z externích zdrojů do Excelu,
- analyzovat rozsáhlejší data v Excelu.



Klíčová slova:

MS Excel, Wolfram Alpha, R, statistické úlohy, data z internetu, analýza dat.

Náhled kapitoly

Tato kapitola se zaměřuje na využití softwarových nástrojů pro řešení statistických úloh. Nejprve shrneme hlavní funkce a možnosti Excelu, který jsme používali v předchozích kapitolách. Dále se podíváme na Wolfram Alpha, což je výkonný výpočetní nástroj, vhodný pro rychlé teoretické výpočty, ale méně vhodný pro práci s rozsáhlými datovými sadami. Nakonec se informativně seznámíme s R, jehož hlavní výhoda spočívá v pokročilých analýzách dat, které však vyžadují instalaci softwaru a základní znalost programování. Kapitulu zakončíme praktickými příklady s reálnými daty z internetu.

Cíle kapitoly

Cílem této kapitoly je naučit studenty využívat různé nástroje pro statistické výpočty. Studenti si zopakují základní funkce Excelu, naučí se používat Wolfram Alpha k řešení menších úloh a získají základní povědomí o možnostech softwaru R. Důraz bude kladen na praktické aplikace těchto nástrojů při analýze aktuálních dat dostupných na internetu.

Odhad času potřebného ke studiu

Studium této kapitoly zabere přibližně 3 hodiny, včetně času na procvičování. Tento čas zahrnuje shrnutí práce s Excelem, seznámení s Wolfram Alpha, informativní přehled o R a řešení praktických příkladů.

Úvod

V této kapitole se budeme věnovat třem hlavním nástrojům pro řešení statistických úloh: MS Excel, Wolfram Alpha a R. Každý z nich má své výhody i omezení. Excel je široce dostupný a praktický nástroj, Wolfram Alpha umožňuje rychlé teoretické výpočty a R je silný nástroj pro pokročilé analýzy, ale vyžaduje určité programovací dovednosti. Zaměříme se především na Excel a Wolfram Alpha, zatímco R bude představen spíše informativně.

Excel jsme již používali v předchozích kapitolách, proto zde shrneme jeho hlavní funkce a ukážeme, jak je aplikovat na aktuální data. Wolfram Alpha bude vysvětlen více od začátku, jelikož jsme s ním zatím moc nepracovali. U složitějších analýz, jako je regresní analýza nebo práce s rozsáhlými daty, doporučujeme používat R, které však vyžaduje programování.

V této kapitole se také podíváme, jak stáhnout aktuální data z veřejně dostupných zdrojů, například z ČNB, a jak tato data analyzovat pomocí Excelu.

12.1 Shrnutí práce s MS Excel

V této sekci si shrneme hlavní statistické funkce a možnosti, které jsme v Excelu již používali v předchozích kapitolách. Excel je nástroj široce dostupný a je ideální pro základní statistické úlohy, zejména pro práci s menšími datovými soubory a pro vizualizaci dat.

Základní statistické funkce v Excelu

- **PRŮMĚR** – slouží k výpočtu průměrné hodnoty datové sady.
=PRŮMĚR(A1:A10)
- **SMODCH.VÝBĚR.S** – vypočítá směrodatnou odchylku výběru.
=SMODCH.VÝBĚR.S(A1:A10)
- **VAR.S** – slouží k výpočtu výběrového rozptylu dat.
=VAR.S(A1:A10)
- **COVARIANCE.P** – vypočítá kovarianci mezi dvěma datovými sadami.
=COVARIANCE.P(A1:A10;B1:B10)
- **CORREL** – slouží k výpočtu korelačního koeficientu mezi dvěma proměnnými.
=CORREL(A1:A10;B1:B10)


Modul Analýza dat

Excel obsahuje modul **Analýza dat**, který poskytuje více pokročilých statistických nástrojů:

- **Popisná statistika** – zobrazí základní souhrnné statistiky jako je průměr, medián, směrodatná odchylka a rozptyl.
- **Histogram** – vizualizace dat v podobě rozdělení četností. Ukázka je na obrázku 24.
- **Regresní analýza** – nástroj pro výpočet regresních koeficientů a analýzu vztahu mezi proměnnými.
- **Korelační matice** – výpočet korelačních koeficientů mezi více proměnnými.

Postup pro použití modulu Analýza dat:

1. Aktivujte modul **Analýza dat** (Pokud není modul aktivní, přidejte jej přes Možnosti Excelu → Doplnky → Analytické nástroje).
2. Zvolte požadovanou metodu analýzy, např. **Popisná statistika**.
3. Vyberte oblast dat, na kterých chcete analýzu provést, a potvrďte volbu.
4. Výsledky se zobrazí v novém listu nebo ve zvoleném rozsahu buněk.



Obr. 24: Ukázka histogramu (četnosti a kumulativní relativní četnosti) z modulu Analýza dat

Tento modul je velmi užitečný pro provádění rychlých analýz a statistických výpočtů, které by jinak vyžadovaly více manuálních kroků.

Grafické zpracování dat

Excel také poskytuje nástroje pro vytváření vizuálních reprezentací dat:

- **Sloupcové grafy** – vhodné pro vizualizaci kategoriálních dat.
- **Spojnicové grafy** – ideální pro znázornění časových řad.
- **Bodové grafy** – často používané při regresní a korelační analýze.
- **Histogram** – pro znázornění rozdělení četností.

Všechny tyto grafy lze snadno vytvořit prostřednictvím nástroje **Vložit → Grafy**. Vizualizace dat je důležitou součástí analýzy, protože poskytuje okamžitý náhled na strukturu a rozdělení dat.

Ilustrativní příklad

Příklad 12.1. Máme následující data o výnosech akcií za poslední 10 dnů: 3, 5, 2, 7, 6, 8, 4, 7, 9, 5. Pomocí Excelu vypočítejte průměr, směrodatnou odchylku a vytvořte histogram těchto dat.

Řešení: V Excelu použijeme následující funkce:

- Průměr: $\text{=PRŮMĚR}(A1:A10) = 5,6$.
- Směrodatná odchylka (výběrová): $\text{=SMODCH.VÝBĚR.S}(A1:A10) = 2,059$.
- Histogram vytvoříme pomocí modulu **Analýza dat → Histogram**, kde zvolíme intervaly a četnosti.

12.2 Představení Wolfram Alpha a R

V minulé sekci jsme shrnuli základní práci s excelovskými funkcemi a moduly. V této části se podíváme na další softwarové nástroje, konkrétně Wolfram Alpha a R.

12.2.1 Srovnání R a Wolfram Alpha

1) Licencování:

- **R:** Otevřený software, zdarma, licencován pod GPL. Komunita neustále přidává nové balíčky. Je nutné ho nainstalovat na lokální počítač, ale existují i některé online služby pro běh R.
- **Wolfram Alpha:** Komerční produkt. Základní verze je zdarma, pokročilé funkce vyžadují předplatné Wolfram Alpha Pro. Dostupný interaktivně online, bez potřeby instalace.

2) Použití pro statistické výpočty:

- **R:** Pokrývá širokou škálu statistických výpočtů, od základních po pokročilé metody (na co si člověk vzpomene).
- **Wolfram Alpha:** Umožňuje základní statistické výpočty, rychlé a snadné použití, vhodné pro rychlé dotazy.

3) Šířka záběru:

- **R:** Zaměřeno hlavně na statistiku a analýzu dat. Lze rozšířit o balíčky pro různé oblasti (text mining, geografická data, strojové učení).
- **Wolfram Alpha:** Pokrývá širokou škálu oborů (matematika, další vědy, ekonomie), ale s omezenými možnostmi pro pokročilé statistické analýzy.

12.2.2 Základní příkazy ve Wolfram Alpha

Wolfram Alpha umožňuje provádět různé typy výpočtů, jako je výpočet průměru, směrodatné odchylky, rozptylu a mnoho dalších. Zde jsou některé základní příkazy, které lze zadat přímo

do vyhledávacího pole Wolfram Alpha:

- **Mean of {data}** – vypočítá průměr datové sady.

$$\text{Mean of } \{3, 5, 2, 7, 6, 8, 4, 7, 9, 5\} \rightarrow 5.6$$

- **Standard deviation of {data}** – vypočítá směrodatnou odchylku datové sady.

$$\text{Standard deviation of } \{3, 5, 2, 7, 6, 8, 4, 7, 9, 5\} \rightarrow 2.059$$

- **Variance of {data}** – vypočítá rozptyl datové sady.

$$\text{Variance of } \{3, 5, 2, 7, 6, 8, 4, 7, 9, 5\} \rightarrow 4.24$$

- **Correlation between {data1} and {data2}** – vypočítá korelační koeficient mezi dvěma sadami dat.

$$\text{Correlation between } \{3, 5, 2\} \text{ and } \{7, 8, 4\} \rightarrow 0.866$$

Po zadání do vyhledávače Wolfram Alpha systém automaticky provede výpočet. Výsledky jsou doplněny o další související informace, jako jsou grafy nebo dodatečné statistické hodnoty.

Ilustrativní příklady

Příklad 12.2 (Regresní analýza ve Wolfram Alpha). Zadejte `linear regression of {(1,2), (2,3), (3,5)}`.

Řešení: Po zadání Wolfram Alpha vypočítá regresní přímku ve tvaru $y = ax + b$, kde a je směrnice a b průsečík.

Výstup: $y = 1.5x + 0.5$

Wolfram Alpha rovněž poskytne graf a hodnotu koeficientu determinace (R^2), což je užitečné pro hodnocení kvality modelu. $\square$

Příklad 12.3. Vyzkoušejte ve Wolfram Alpha následující příkazy a prozkoumejte jejich výstupy:

- `{10, 12, 8, 14, 11, 9, 15, 13}`
- `five number summary {20, 25, 18, 30, 22, 19, 28, 30, 24}`
- `variance {20, 25, 18, 30, 22, 19, 28, 30, 24}`
- `median {20, 25, 18, 30, 22, 19, 28, 30, 24}`
- `poisson distribution`
- `normal distribution, mean=0, sd=2`

- Student t, 17 degrees of freedom

Wolfram Alpha nám poskytuje okamžité výsledky, které lze použít pro další analýzu nebo kontrolu správnosti našich výpočtů. V následující sekci se podíváme na informativní přehled o využití softwaru R.

12.2.3 Použití R pro statistické úlohy

R je volně dostupný programovací jazyk zaměřený na statistické výpočty a datovou analýzu. I když jeho využití není v tomto kurzu klíčové, stojí za to jej zmínit jako výkonný nástroj pro složitější úlohy, které mohou být mimo možnosti Excelu nebo Wolfram Alpha. V této části si ukážeme několik základních funkcí v R, které se používají pro statistické úlohy, a to spíše informativně, bez nutnosti provádět výpočty během výuky.

Základní příkazy v R pro statistické výpočty

R nabízí širokou škálu funkcí, které jsou velmi užitečné při řešení statistických úloh. Zde je přehled některých základních příkazů:

- `mean()` – vypočítá průměr zadaných dat.

```
mean(c(3, 5, 2, 7, 6, 8, 4, 7, 9, 5)) → 5,6.
```

- `sd()` – vypočítá výběrovou směrodatnou odchylku zadaných dat.

```
sd(c(3, 5, 2, 7, 6, 8, 4, 7, 9, 5)) → 2,22.
```

- `var()` – vypočítá výběrový rozptyl zadaných dat.

```
var(c(3, 5, 2, 7, 6, 8, 4, 7, 9, 5)) → 4,93.
```

- `cor()` – vypočítá korelační koeficient mezi dvěma sadami dat.

```
cor(c(3, 5, 2), c(7, 8, 4)) → 0,891.
```

- `lm()` – provádí lineární regresi.

```
lm(y ~x, data = dataframe)
```

Tato funkce provede lineární regresní analýzu mezi proměnnými `x` a `y` v datovém rámci `dataframe`.

Výhody a nevýhody R

Výhody:

- R je zdarma a otevřený software, který je snadno dostupný.
- Nabízí širokou škálu funkcí a knihoven pro různé statistické metody, od jednoduchých výpočtů po složité modelování.
- Je vhodný pro analýzu velkých datových sad, které by byly v Excelu obtížně zpracovatelné.
- Možnost vytvářet pokročilé vizualizace a grafy přímo z dat (pomocí programového kódu).

Nevýhody:

- R vyžaduje určitou znalost programování, což může být pro začínající studenty obtížné. Ovšem tuto nevýhodu lze do značné míry potlačit s asistencí AI.
- Pro mnoho uživatelů je Excel jednodušší a intuitivnější, zejména pro menší a jednodušší úlohy.

Ilustrativní příklad

Příklad 12.4. Zvažte následující data o cenách produktů v obchodech: {10, 12, 8, 14, 11, 9, 15, 13}. Pomocí R vypočítejte průměr, směrodatnou odchylku a rozptyl. Napište příkazy a uveďte, co každý z nich dělá.

- Řešení:*
- Průměr: `mean(c(10, 12, 8, 14, 11, 9, 15, 13)) = 11,5`.
 - Směrodatná odchylka (výběrová): `sd(c(10, 12, 8, 14, 11, 9, 15, 13)) = 2,44`.
 - Rozptyl (výběrový): `var(c(10, 12, 8, 14, 11, 9, 15, 13)) = 6`.

□

12.3 Analýza dat z externích zdrojů


V této sekci se zaměříme na příklady rozsáhlejších statistických úloh, které zahrnují stahování dat z internetu, jejich zpracování v Excelu, grafické znázornění a následné výpočty popisných statistik a korelace. Zaměříme se na reálná data z ČNB (kurzy měn) a akciových trhů.

Kde hledat statistická data na internetu?

Existuje mnoho dostupných zdrojů, ze kterých lze stahovat reálná statistická data. Klasicky ve formě souborů, například ve formátu csv, nebo přímým napojením. Mezi ty české patří například Český statistický úřad (czso.cz) a ČNB (cnb.cz). Z těch zahraničních například Eurostat (ec.europa.eu/eurostat) a Světová banka (data.worldbank.org), případně Yahoo Finance (finance.yahoo.com) a Google Finance (google.com/finance).

Načítání dat z vnějších zdrojů do Excelu

V Excelu existuje několik možností, jak načítat a transformovat data z různých externích zdrojů. Tyto možnosti umožňují zpracovávat data nejen ze souborů na lokálním disku, ale také z online zdrojů s aktuálními informacemi. Mezi základní možnosti patří (viz obrázek 25):



Obr. 25: Excel: Skupina Načíst a transformovat data na kartě Data

- **Načítání z Text/CSV**

Pomocí této funkce lze načíst data z textových souborů (.txt) nebo souborů CSV (.csv). Jedná se o jednoduchý způsob, jak dostat strukturovaná data do Excelu.

- **Načítání z webu**

Tato možnost umožňuje přímé načtení dat z webové stránky. Excel si z webu stáhne tabulková data a umožní je dále zpracovávat. To je zvláště užitečné pro načítání kurzů měn, cen akcií nebo jiných finančních dat, která se pravidelně aktualizují.

- **Načítání z tabulky nebo oblasti**

Tento nástroj umožňuje načítat data přímo z jiných tabulek v Excelu nebo z definovaných oblastí buněk. Hodí se při práci s velkými datovými sadami rozdělenými do více souborů.

- **Načítání z obrázku**

Excel dokáže načítat data přímo z obrázků, což je užitečné pro digitalizaci dat v tištěných tabulkách nebo grafech. Stačí nahrát obrázek a Excel rozpozná strukturu dat.

- **Načítání z webových API a online zdrojů**

Excel umožňuje načítání dat z online zdrojů pomocí webových API. Tato funkce je klíčová pro práci s aktuálními daty, například z finančních trhů, online databází nebo jiných služeb poskytujících aktualizované informace. Pomocí rozhraní API lze získat přístup k datům, která se pravidelně aktualizují, což je ideální pro tvorbu reportů nebo analýz založených na živých datech.

- **Poslední zdroje**

V této části Excelu je možné rychle znovu načíst data z posledních použitých zdrojů. To usnadňuje opakované aktualizace dat z těchto zdrojů.


- **Existující připojení**

Tato funkce umožňuje správu a opětovné využití dříve nastavených připojení k datovým zdrojům, jako jsou databáze, webové služby nebo další Excelové soubory.

Načítání dat z online zdrojů je pro analýzy v Excelu zásadní, zejména pokud pracujeme s dynamickými daty, která se často mění. Pomocí těchto nástrojů je možné zajistit, že naše tabulky budou obsahovat aktuální a relevantní informace pro daný účel.


Ilustrativní příklad

Příklad 12.5 (Načtení a analýza tabulky kurzů měn z ČNB). 1. Na stránkách ČNB najdete údaje „Kurzy devizového trhu - roční historie“ a vyberte rok 2024 (obrázek 26)¹.



Obr. 26: ČNB: Kurzy devizového trhu - roční historie – zadání roku 2024

2. Zkopírujte odkaz a použijte jej v Excelu -> Data -> (Načíst a transformovat data) Z webu (obrázek 27).



Obr. 27: Načtení dat z ČNB do Excelu pomocí volby Data -> Z webu

- Pomocí volby **Analýza dat -> Popisná statistika** vypočítejte popisné statistiky pro všechny měny (na zvláštní list).
- Pomocí volby **Analýza dat -> Korelace** vypočítejte korelační koeficienty pro všechny dvojice měn (na zvláštní list).
- Pomocí podmíněného formátování korelační koeficienty obarvte podle velikosti. Zvlášť zvýrazněte hodnoty větší než 0,9. (obrázek 28).
- Jak si vysvětlujete tak vysokou pozitivní lineární korelaci?
- Vyberte jednu dvojici z předchozího bodu a vytvořte pro ni bodový graf.

¹AUD – Australský dolar, BGN – Bulharské leva, BRL – Brazilský real, CAD – Kanadský dolar, CHF – Švýcarský frank, CNY – Čínský jüan, DKK – Dánská koruna, EUR – Euro, GBP – Britská libra, HKD – Hongkongský dolar, HUF – Maďarský forint (kurz za 100 jednotek), IDR – Indonéská rupie (kurz za 1000 jednotek), ILS – Izraelský nový šekel, INR – Indická rupie (kurz za 100 jednotek), ISK – Islandská koruna (kurz za 100 jednotek), JPY – Japonský jen (kurz za 100 jednotek), KRW – Jihokorejský won (kurz za 100 jednotek), MXN – Mexické peso, MYR – Malajsijský ringgit, NOK – Norská koruna, NZD – Novozélandský dolar, PHP – Filipínské peso (kurz za 100 jednotek), PLN – Polský zlotý, RON – Rumunský lei, SEK – Švédská koruna, SGD – Singapurský dolar, THB – Thajský baht (kurz za 100 jednotek), TRY – Turecká lira (kurz za 100 jednotek), USD – Americký dolar, XDR – Speciální práva čerpání (měna používaná MMF), ZAR – Jihoafrický rand.

	A	B	C	D	E	F	
1		1 AUD	1 BGN	1 BRL	1 CAD	1 CHF	1
2	1 AUD	1					
3	1 BGN	0,56662	1				
4	1 BRL	-0,26862	-0,03034	1			
5	1 CAD	0,27497	0,54962	0,70436	1		
6	1 CHF	0,1362	0,47057	-0,2287	0,11274	1	
7	1 CNY	0,489	0,83009	0,20362	0,71783	0,42913	
8	1 DKK	0,56791	0,99647	-0,00012	0,57281	0,46649	
9	1 EUR	0,57007	0,99703	-0,02245	0,55534	0,4615	
10	1 GBP	0,74454	0,80486	-0,45514	0,15803	0,49149	
11	1 HKD	0,45092	0,67855	0,30423	0,7807	0,02264	

Obr. 28: Podmíněné formát tabulky korelačních koeficientů

12.3.1 Excelovské nástroje pro analýzu akcií

Využití datového typu Akcie v Excelu

Datový typ **Akcie** umožňuje získávat aktuální finanční údaje o veřejně obchodovaných společnostech. Pro jeho použití stačí zadat **název společnosti** nebo její **ticker** (např. "AAPL" pro Apple) do buňky, následně zvolit z karty *Data* možnost *Akcie*. Excel poté poskytne aktuální údaje jako *cena*, *tržní kapitalizace*, *P/E ratio* atd., ale i samotný ticker. Tyto údaje se automaticky aktualizují (minimálně při každém otevření souboru).

Získaný ticker lze následně využít ve funkci **STOCKHISTORY** pro načtení historických dat obchodování dané akcie.

Použití funkce STOCKHISTORY

Syntaxe je následující:

```
=STOCKHISTORY("ticker"; "start_date"; "end_date"; [interval]; [headers]; [property0]; [property1]; ...)
```

Příklad použití pro načtení denních uzavíracích cen akcií Microsoftu za září 2024:

```
=STOCKHISTORY("MSFT"; "2024-09-01"; "2024-09-30"; 0; 1; 0; 5)
```

Tento vzorec vrátí tabulku obsahující data a uzavírací ceny pro každý obchodní den v uvedeném období. Funkce **STOCKHISTORY** je vhodná pro analýzu historických finančních dat a sledování časových řad.

Ilustrativní příklady

Příklad 12.6 (Analýza uzavíracích cen akcií firem NVIDIA a Intel). Pomocí datového typu **Akcie** zjistěte tickery firem **NVIDIA** a **Intel**.

Pomocí funkce **STOCKHISTORY** načtěte uzavírací denní ceny jejich akcií v období od 1. srpna 2024 do 30. září 2024.

Tyto dvě časové řady graficky znázorněte, vypočtěte pro ně základní popisné statistiky a proveďte jejich korelační analýzu.

Řešení: 1. Tickery

Nejprve získáme tickery společností NVIDIA a Intel pomocí datového typu **Akcie**:

- Do buněk vložíme názvy společností (NVIDIA, Intel).
- Označíme buňky s názvy a na kartě *Data* zvolíme možnost **Akcie**. Excel automaticky přiřadí k názvům společností jejich tickery.
- NVIDIA má ticker **NVDA**, Intel **INTC**.

2. Zisk historických uzavíracích cen

Pro získání denních uzavíracích cen akcií obou společností v období od 1. srpna 2024 do 30. září 2024 použijeme následující funkce:

```
=STOCKHISTORY("NVDA"; "2024-08-01"; "2024-09-30"; 0; 1; 0; 1)
=STOCKHISTORY("INTC"; "2024-08-01"; "2024-09-30"; 0; 1; 0; 1)
```

Experimentujte s tímto zápisem tak, abyste získali tabulku o třech sloupcích: datum, ceny NVIDIA, ceny Intel. Tato funkce načte uzavírací ceny pro každý obchodní den v uvedeném období. Získané datové řady budou použity pro další analýzu.

3. Grafické znázornění časových řad

Po získání uzavíracích cen vytvoříme spojnicový graf, který vizuálně znázorní vývoj uzavíracích cen akcií NVIDIA a Intel:


- Označíme sloupce s daty (datum, uzavírací ceny NVIDIA a Intel).
- Na kartě *Vložení* zvolíme typ grafu **Spojnicový graf**.
- Excel vygeneruje graf, který zobrazí vývoj cen akcií obou společností v průběhu sledovaného období.

4. Korelační analýza

Pro určení míry lineární závislosti mezi cenami akcií NVIDIA a Intel použijeme funkci **CORREL**. Vzorec pro výpočet korelačního koeficientu mezi dvěma časovými řadami uzavíracích cen je následující:

```
=CORREL(B2:B45, C2:C45)\approx 0{,}249.
```

Funkce vrátila korelační koeficient o hodnotě 0,249, který popisujeme jako slabou pozitivní korelaci. Mějme ale na paměti, že korelační koeficient popisuje jen lineární závislost, a tak je vždy užitečné si celkový obraz doplnit obrázkem. V tomto případě je bodový graf na obrázku 29. Můžeme na něm zaznamenat jednu odlehlou hodnotu (v takovém případě bychom měli prověřit, zda nejde o chybnou hodnotu, resp. zjistit, jak mohla nastat). Na obrázku je znatelný drobný nárůst vertikálních hodnot (souřadnic) při růstu horizontálních hodnot. Uvědomme si také, že v tomto typu grafu není zachycena časová složka dat.



Obr. 29: Bodový graf cen akcií NVIDIA (horizontální osa) a Intel (vertikální osa) z příkladu 12.6

□

Příklad 12.7 (Analýza maximálního rozdílu mezi maximálními a minimálními denními cenami). Zvolte si tři firmy. Získejte jejich tickery a maximální a minimální denní ceny za jedno roční období, končící na konci předminulého měsíce (vzhledem ke dni, kdy příklad počítáte).

Následně pro každou akcii vypočítejte denní rozdíly mezi maximální a minimální cenou. Poté najděte pro každou firmu nejvyšší hodnotu těchto denních rozdílů (tzv. maximální denní rozpětí) a tyto tři hodnoty porovnejte.

Protože ceny akcií mohou být velmi rozdílné, je nutné výsledky porovnávat relativně. Nejprve pro každou akcii spočítejte tzv. *průměrnou denní cenu* jako průměr maximální a minimální ceny pro každý den. Z těchto průměrů vypočítejte jejich průměrnou hodnotu za celé období.

Nakonec relativně porovnejte maximální denní rozpětí s touto průměrnou cenou (v procentech). Toto procentuální vyjádření vám umožní porovnat, která akcie vykazuje největší cenové výkyvy vzhledem ke své průměrné ceně.

12.3.2 Načítání externích statistických dat v R

Ač Exel lze dobře použít pro import aktuálních finančních a dalších statistických dat, tak ten, kdo ovládá práci v R má situaci mnohem pohodlnější.

R nabízí několik balíčků, které usnadňují přímé načítání aktuálních statistických a finančních dat z externích zdrojů. Mezi nejpoužívanější patří

- **quantmod**, který umožňuje získávat data o cenách akcií, měnových kurzech a dalších finančních údajích z Yahoo Finance a FRED.
- Balíček **wbstats** poskytuje přístup k datům Světové banky, včetně ukazatelů inflace, HDP a dalších makroekonomických dat.
- Pro evropská data lze použít balíček **eurostat**, který umožňuje stahovat data o ekonomických a sociálních ukazatelích v rámci členských států EU.
- Kromě toho balíček **fredr** poskytuje přístup k bohaté databázi ekonomických ukazatelů FRED.

Tyto nástroje v R umožňují rychlé a efektivní načítání aktuálních dat pro další analýzu. Samozřejmě, samostatná data nestačí, je třeba nejprve nastudovat jejich strukturu, označení a význam.



Σ

V této kapitole jsme se věnovali statistické analýze z pohledu použitého softwaru, přirozeně s největším důrazem na MS Excel, ale prošli jsme i možnosti Wolfram Alpha a R. Zaměřili jsme se na výpočty základních statistik, korelační analýzu a tvorbu grafických výstupů. Ukázali jsme také, jakým způsobem lze data načítat do Excelu z externích zdrojů a jak je následně zpracovat.

Wolfram Alpha byl představen jako jednoduchý nástroj pro rychlé výpočty pravděpodobností a dalších základních statistických úloh, kdy není třeba složitého programování.

R bylo popsáno jako pokročilý nástroj pro statistickou analýzu, který je vhodný pro práci s rozsáhlými datovými soubory, jejich vizualizaci a modelování, a umožňuje přímé načítání externích dat z různých statistických zdrojů, jako jsou například Světová banka nebo Eurostat.



?

1. Jaké zdroje lze využít pro stahování statistických dat z internetu?
2. Jaké jsou základní kroky pro načtení externích dat do Excelu?
3. Popište postup pro vytvoření grafu časových řad v Excelu.
4. Jaké funkce v Excelu použijete pro výpočet průměru, mediánu a směrodatné odchylky?
5. Co je Pearsonův korelační koeficient a jak se v Excelu vypočítá?
6. Kdy je vhodné použít Wolfram Alpha pro statistické výpočty? Uveďte příklady.
7. Jakým způsobem lze analyzovat a znázornit data z akciových trhů?

8. Stáhněte data o inflaci z webu Českého statistického úřadu (<https://www.czso.cz>) za posledních 10 let. Načtěte tato data do Excelu, analyzujte je pomocí grafu časové řady a vypočítejte základní statistiky (průměr, medián, směrodatná odchylka, minimum, maximum).
9. Získejte data o cenách akcií tří ropných společností za tři roky (začátek a konec si zvolte sami) pomocí funkce STOCKHISTORY. Vypočtěte jejich popisné statistiky. Vytvořte graf s těmito třemi časovými řadami. Proveďte jejich korelační analýzu včetně bodových grafů. Komentujte výsledky (největší podobnosti a rozdíly).



Literatura k tématu:

- [1] PRAŽSKÁ BURZA CENNÝCH PAPÍRŮ. Dostupné z: <https://www.pse.cz/>.
- [2] YAHOO FINANCE. Dostupné z: <https://finance.yahoo.com/>.
- [3] MICROSOFT EXCEL. Podpora pro statistické funkce. Dostupné z: <https://support.microsoft.com/excel>.
- [4] WOLFRAM ALPHA. Online nástroj pro výpočty. Dostupné z: <https://www.wolframalpha.com/>.
- [5] R CORE TEAM. (2023). R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. Dostupné z: <https://cran.r-project.org/manuals.html>.
- [6] ČESKÁ NÁRODNÍ BANKA (ČNB) - Data. Česká národní banka. (2023). Data a statistiky. Dostupné z: <https://www.cnb.cz/cs/statistika/>.
- [7] EUROSTAT. Statistika Evropské unie. Dostupné z: <https://ec.europa.eu/eurostat>.
- [8] SVĚTOVÁ BANKA. (2023). Data Světové banky. Dostupné z: <https://data.worldbank.org/>.
- [9] ČESKÝ STATISTICKÝ ÚŘAD (ČSÚ). Data a statistiky České republiky. Dostupné z: <https://www.czso.cz/>.

Seznam literatury a použitých zdrojů

- [1] ANDĚL, J. Statistické metody. 5. vyd. Praha: Matfyzpress, 2019. ISBN 978-80-7378-381-5.
- [2] CALDA, E., DUPAČ, V. (2008). Matematika pro gymnázia: Kombinatorika, pravděpodobnost, statistika (5. vydání, dotisk 2011). Praha: Prometheus. ISBN 978-80-7196-365-3.
- [3] HANSEN, B. Probability and Statistics for Economists. Princeton University Press, 2022. ISBN 9780691236148.
- [4] HENDL, J. Základy matematiky, logiky a statistiky pro sociologii a ostatní společenské vědy v příkladech. 3. vyd., Karolinum, 2023. ISBN 978-80-246-5400-3.
- [5] HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-869-4643-6.
- [6] HONG, Y. Probability and Statistics for Economists. World Scientific, 2017. ISBN 9789813228818.
- [7] JANÁČEK, J. Statistika jednoduše. Grada, 2022. ISBN 978-80-271-1738-3.
- [8] KELLER, G. Statistics for Management and Economics. 12th ed., Cengage Learning, 2022. ISBN 9780357714393.
- [9] MAREK, L. Statistika v příkladech. 2. vyd. Praha: Kamil Mařík – Professional Publishing, 2015. ISBN 978-80-743-1153-6.
- [10] NEUBAUER, J. a SEDLAČÍK, M. Základy statistiky: Aplikace v technických a ekonomických oborech - 3., rozšířené vydání. Grada, 2021. ISBN 978-80-271-3421-2.
- [11] OPENAI. Asistovaná příprava studijní opory pomocí ChatGPT. OpenAI. Dostupné na <https://chat.openai.com>, 2024.
- [12] OTIPKA, P., ŠMAJSTRLA, V. Pravděpodobnost a statistika [online]. 1. vydání. Ostrava: VŠB-TU Ostrava, 2007 [cit. 2024-09-09]. ISBN 80-248-1194-4.
- [13] ŘEZANKOVÁ, H. a kol. Úvod do statistiky. 2. dotisk 1. vyd., Oeconomica, nakladatelství VŠE, 2019. ISBN 9788024523019.
- [14] ZVÁRA, K. a ŠTĚPÁN, J. Pravděpodobnost a matematická statistika. Matfyzpress, 2019. ISBN 978-80-7378-388-4.

Seznam obrázků

1	Pravděpodobnostní a distribuční funkce k příkladu 3.6	57
2	Výpočet pravděpodobností na nekonečném intervalu	60
3	Výpočet pravděpodobností na konečném intervalu	60
4	Znázornění hustoty a p -kvantilu x_p pro spojité rozdělení pravděpodobnosti (viz definici 3.22)	67
5	Pravděpodobnostní a distribuční funkce binomického rozdělení pro $n = 10$ a $p = 0,5$	73
6	Pravděpodobnostní a distribuční funkce hypergeometrického rozdělení pro $N = 50$, $M = 20$ a $n = 10$	74
7	Pravděpodobnostní a distribuční funkce Poissonova rozdělení pro $\lambda = 3$	75
8	Jeden z hrdých otců normálního rozdělení (vytvořeno pomocí ChatGPT, openAI)	82
9	Grafy hustot a distribučních funkcí normálního rozdělení s různými rozptyly . .	82
10	Grafy hustot a distribučních funkcí normálního rozdělení s různými středními hodnotami	83
11	Grafy hustot a distribučních funkcí rovnoměrného rozdělení (různé parametry a a b)	84
12	Grafy hustot a distribučních funkcí exponenciálního rozdělení pro různé parametry λ	86
13	Graf empirické distribuční funkce pro bodové rozložení četností z příkladu 7.10 .	110
14	Koláčový graf rozložení prodeje produktů ve firmě	112
15	Histogram absolutních četností výsledků testu ze statistiky z příkladu 7.10 . . .	112
16	Histogram relativních četností hladiny hemoglobinu z příkladu 7.11	113
17	Ukázka bodového grafu	131
18	Vložení bodového grafu	144
19	Přidání spojnice trendu	144
20	Nastavení lineární regrese	145
21	Graf časové řady z příkladu 10.12	160
22	Dekompozice časové řady z příkladu 10.12	160
23	Graf předpovědi časové řady z příkladu 10.12	160
24	Ukázka histogramu (četnosti a kumulativní relativní četnosti) z modulu Analýza dat	176
25	Excel: Skupina Načíst a transformovat data na kartě Data	181
26	ČNB: Kurzy devizového trhu - roční historie – zadání roku 2024	182
27	Načtení dat z ČNB do Excelu pomocí volby Data -> Z webu	182
28	Podmíněné formát tabulky korelačních koeficientů	183
29	Bodový graf cen akcií NVIDIA (horizontální osa) a Intel (vertikální osa) z příkladu 12.6	185

Seznam tabulek

1	Četnosti zdržení se zákazníků v obchodě (intervaly 5 minut)	37
2	Bodové rozložení četností výsledků testu z příkladu 7.10	110
3	Intervalové rozložení četností hladiny hemoglobinu u žen z příkladu 7.11	111
4	Ukázka dvourozměrného statistického souboru	129
5	Ukázka kontingenční tabulky	131
6	Ukázková data pro lineární regresi	141