

Popisná statistika

- grafy
 - z-skóry


 - pravděpodobnost
(jako příprava pro úvod do indukční statistiky)
-

Grafy

- ❑ pouze základní typy
 - ❑ pro kategoriální data - sloupcový diagram, výsečový graf
 - ❑ pro intervalová data - histogram, frekvenční polygon, krabicový diagram, stromkový diagram
 - ❑ grafy je možno znázornit v kategorizované formě - pro jednotlivé kategorie další proměnné (např. pro muže a ženy)
 - ❑ grafy pro vztah dvou a více proměnných budou probrány později
-

Výsečový graf

- koláčový diagram, pie chart – užívá se více v populárních publikacích než v odborných




Výsečový graf

- každá výseč by měla být označena % a uveden celkový počet případů
 - ideální pro 3-7 kategorií
 - **výhody**: srozumitelný
 - **nevýhody**: jen pro kategoriální data; neukazuje přesné údaje (pokud nejsou vyznačeny); srovnání více skupin osob problematické
-

Sloupcový diagram

□ bar chart



Sloupcový diagram

- ❑ pro kategoriální data, může být orientován horizontálně či vertikálně
 - ❑ jednotlivé sloupce odděleny mezerou
 - ❑ **výhody**: srozumitelný, je možno v jednom grafu porovnat četnosti pro více skupin osob
-

Histogram

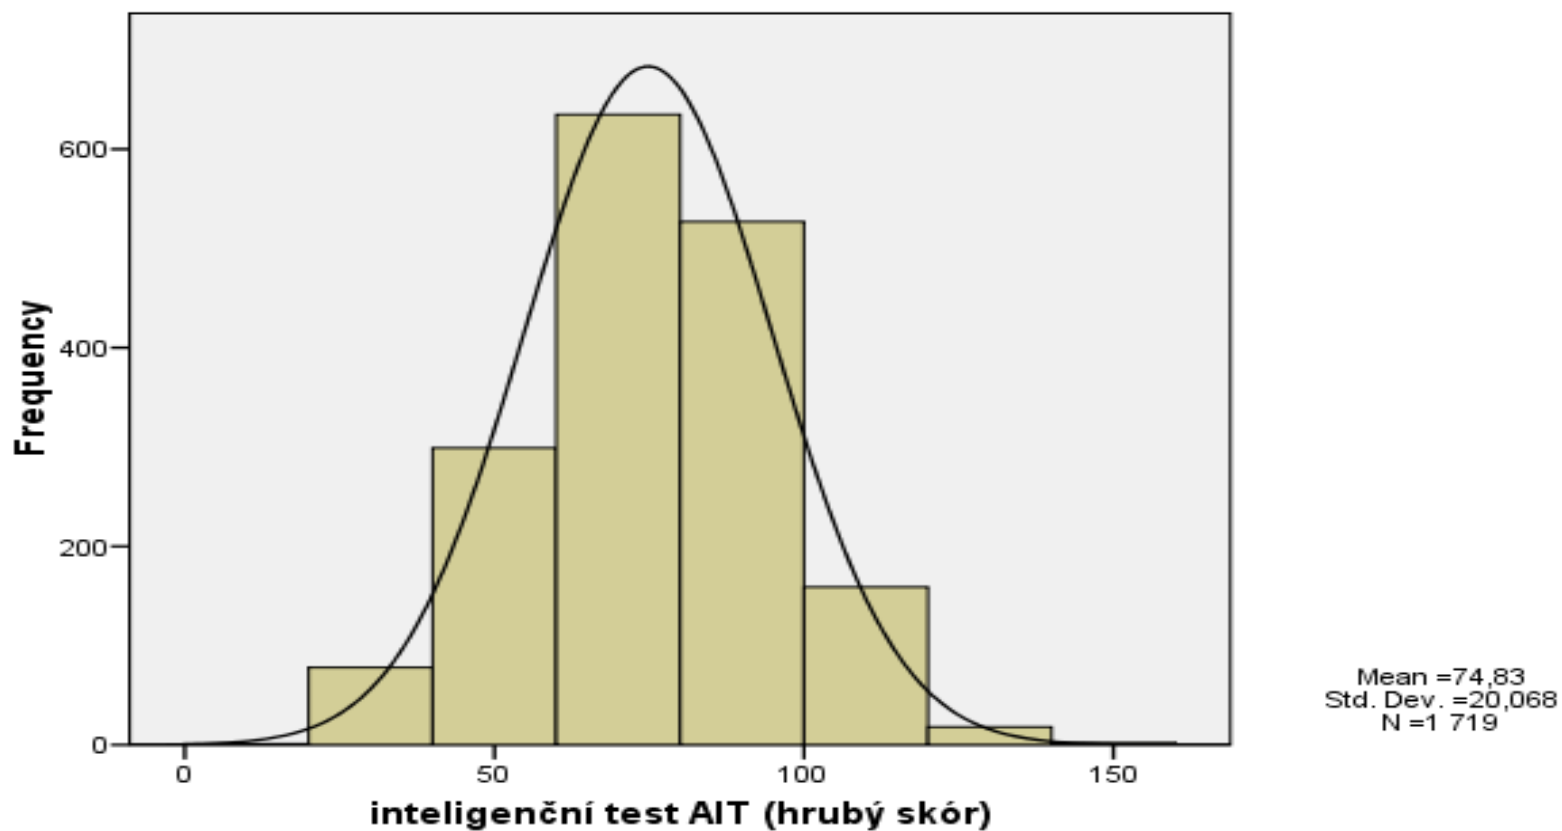
- ❑ často užívaný
 - ❑ podobný sloupcovému diagramu, ale je pro intervalová data
 - ❑ jednotlivé sloupce reprezentují nikoliv jednotlivé kategorie, ale intervaly hodnot (sloupce jsou bez mezer)
 - ❑ tvar histogramu závisí také na šířce intervalů
-

Histogram

- **výhody:** umožňuje detekovat odlehlá pozorování, srovnání s normálním rozdělením
 - **nevýhody:** nezjistíte přesné hodnoty jednotlivých případů, obvykle se nezobrazují data pro více skupin případů
-


Histogram

Histogram



Grafy

- **frekvenční polygon** – konstruován podobně jako histogram, jen místo sloupců jsou tečky spojené čarou



Stromkový diagram

- ❑ stem-and-leaf plot; stonek a list – podobný histogramu (naležato), ale obsahuje informace o každém případě
 - ❑ konstrukce diagramu – hodnoty jsou rozděleny např. na desítky (stonek) a jednotky (list)
 - ❑ např. hodnota $85 = 8 \times 10 + 5 \times 1$
 - ❑ pokud je hodnota pro některé desítky více, rozdělí se na další stonky
-

Stromkový diagram

Frequency	Stem & Leaf
3,00	1 . 468
7,00	2 . 0225588
9,00	3 . 011234449
10,00	4 . 3455567799
3,00	5 . 344
7,00	6 . 0111389
4,00	7 . 1234
2,00	8 . 34
1,00	9 . 1

Stem width: 10,00
Each leaf: 1 case(s)

Stromkový diagram

Frequency	Stem & Leaf
,00	3 .
6,00	3 . 667777
8,00	3 . 88889999
9,00	4 . 000001111
5,00	4 . 22333
5,00	4 . 44455
3,00	4 . 667
1,00	4 . 9
1,00	Extremes (>=55)

Stem width: 10
Each leaf: 1 case(s)


Stromkový diagram

- **výhody:** ukazuje údaje pro každý případ; je možné snadno identifikovat minimum, maximum, shluky případů, odlehlá pozorování; můžeme porovnat dvě skupiny případů zobrazením dvou přilehlých diagramů
 - **nevýhody:** nevypadá zajímavě; vhodnější spíše pro menší datové soubory ($N < 100$)
-

Krabicový diagram

- ❑ boxplot, vousatá krabička
 - ❑ poskytuje bohaté zobrazení důležitých aspektů rozdělení hodnot
 - ❑ délka krabice odpovídá interkvartilové odchylce; uvnitř krabice je vyznačen medián
 - ❑ v některých variantách grafu jde např. o směrodatnou odchylku a průměr
 - ❑ „vousy“ je ohraničeno rozmezí hodnot
-

Krabicový diagram



Odlehlá pozorování

- zvlášť jsou u boxplotu vyznačena tzv. **odlehlá pozorování** (outliers – obvykle hodnoty vzdálené více než 1.5 mezikvartilové odchyly od hodnoty kvartilů – v grafu kolečka) a extrémní pozorování (obvykle více než 3x mezikvartilové odchyly – v grafu hvězdičky)
 - odlehlá pozorování mohou zkreslit výsledky některých statistik a statistických testů
-

Odlehlá pozorování

- je proto důležité je v datech hledat; pokud je najdeme, musíme se rozhodnout, zda se jedná o ojedinělý výskyt (který by se v jiném vzorku nevyskytl) nebo výsledek chyby měření; nebo zda je tak reprezentována určitá část populace
 - pokud jde o ojedinělý výskyt, je možno je z další analýzy vyloučit
 - jinak je nutno se rozhodnout mezi dvěma možnostmi: buď je vyloučit s vědomím, že výsledky budou jejich nepřítomností zkresleny, nebo použít neparametrický test (vhodnější přístup)
-

Krabicový diagram

- **výhody:** užitečný pro detekci odlehlých pozorování, šikmosti rozdělení; vhodný pro porovnání více skupin případů
 - **nevýhody:** složitější
-

Grafy – obecná doporučení

- ❑ každý graf by měl mít stručný a výstižný **název**
 - ❑ obě **osy** grafu by měly být označeny názvy proměnných a jednotkami měření (závislá proměnná je obvykle na svislé ose)
 - ❑ **počátek os** by měl být v nule – pokud není, je třeba to vyznačit
 - ❑ **velikost** grafu a **rozsah** os by měl být takový, aby většina dat zabírala celý graf
-

Z-skóry


- umožňují najít a popsat **pozici každé hodnoty** v rámci rozdělení hodnot
 - a také **srovnávání hodnot** pocházejících z měření **na rozdílných stupnicích**
 - hrubé skóry jsou převedeny na **standardizovanou stupnici** (jednotkou je směrodatná odchylka)
-

Z-skóry - příklad

- např. skóry ze dvou testů – biologie a psychologie
 - student získal 26 bodů z biologie a 620 z psychologie. Ve kterém předmětu byl lepší?
-


Z-skóry - příklad

biologie



$$18 = \mu$$
$$6 = \sigma$$

psychologie



$$500 = \mu$$
$$100 = \sigma$$

Z-skóry

- přímé porovnání není snadné – skóry z obou testů mají rozdílné průměry i směrodatné odchylky
 - z skór = odchylka skóru od průměru vzhledem k velikosti směrodatné odchylky
 - $z = \text{odch. od průměru} / \text{směr. odch.}$
-

Z-skóry - příklad


- skór z biologie: $(26-18)/6 = 1,33$
 - skór psychologie: $(620-500)/100=1,2$
 - v biologii byl student lepší – 1,33
směrodatné odchytky nad průměrem
-

Z-skóry

- ❑ z-skór přesně udává pozici každé hodnoty vzhledem k ostatním hodnotám
 - ❑ znaménko (+ nebo -) ukazuje, zda je hodnota nad nebo pod průměrem rozdělení
 - ❑ hodnota z-skóru upřesňuje, kolik směrodatných odchylek byla hodnota od průměru vzdálena
-

Z-skóry

- průměr rozdělení z-skórů je vždy 0
- směrodatná odchylka je 1



Z-skóry

vzorec pro výpočet z-skóru hodnoty X

□ u populace: $z = (X - \mu) / \sigma$

□ u vzorku: $z = (X - m) / s$

Z-skóry

- podobně můžeme i z-skór převést na hrubý skór, známe-li průměr a směrodatnou odchylku
-

Z-skóry

- např. u stupnice IQ
 - $\mu = 100, \sigma = 15$
 - pro osobu se $z = -3$ (3 směrodatné odchylky pod průměrem) bude IQ ?
-

Z-skóry

- např. u stupnice IQ $\mu = 100, \sigma = 15$
- pro osobu se $z = -3$ (3 směrodatné odchytky pod průměrem) bude IQ

$$X = Z \cdot \sigma + \mu$$

$$X = -3 \cdot 15 + 100$$

$$X = 55$$

Rozdělení z-skórů

- **tvar** rozdělení z-skórů je **stejný** jako tvar původního rozdělení hrubých skórů
 - průměr je 0, směrodatná odchylka 1
 - transformace změní jen označení hodnot na ose X
-

Pravděpodobnost

- postupy indukční statistiky vycházejí z teorie pravděpodobnosti
- **pravděpodobnost**, že nastane určitý výsledek, **definujeme** jako podíl

$$P(A) = \frac{\text{počet pokusů, kdy nastal jev } A}{\text{celkový počet jevů}}$$

Pravděpodobnost - příklady

- jaká je pravděpodobnost, že si z balíčku 52 karet vytáhneme určitou kartu (např. pikovou dámu) ?
-

Pravděpodobnost - příklady

- jaká je pravděpodobnost, že si z balíčku 52 karet vytáhneme určitou kartu (např. pikovou dámu) ?

$$P(\text{piková dáma}) = f/N = 1/52 = 0,019 = 1,9\%$$

Pravděpodobnost - příklady

- jaká je pravděpodobnost, že při hodu kostkou padne trojka nebo šestka ?

Pravděpodobnost - příklady

- jaká je pravděpodobnost, že při hodu kostkou padne trojka nebo šestka ?

$$P(3 \text{ n. } 6) = f/N = 2/6 = 0,333 = 33,3\%$$

Pravděpodobnost

- pravděpodobnost bývá uváděna nejčastěji jako **podíl** (0,33), **zlomek** ($1/3$) nebo **procento** (33,3%)
 - pravděpodobnost určitého jevu nebo třídy jevů můžeme odhadnout z rozdělení hodnot (četností)
-


Pravděpodobnost - příklady

- představme si, že máme krabici se 40 očíslovanými žetony s čísly 1 – 5
 - v tabulce jsou uvedeny absolutní i relativní četnosti jednotlivých čísel žetonů
-

Pravděpodobnost

X	f	p
5	2	0,05
4	10	0,25
3	16	0,40
2	8	0,20
1	4	0,10

Pravděpodobnost



Pravděpodobnost - příklady

- vaším úkolem je vytáhnout 1 žeton
 - **jaká je pravděpodobnost, že vytáhnete žeton s číslem 3?**
-

Pravděpodobnost

X	f	p
5	2	0,05
4	10	0,25
3	16	0,40
2	8	0,20
1	4	0,10

Pravděpodobnost

- vaším úkolem je vytáhnout 1 žeton
 - jaká je pravděpodobnost, že vytáhnete žeton s číslem 3?
 - **$p(3) = f/N = 16/40 = 0,40$**
nebo $2/5$ či 40%
-

Pravděpodobnost

- Jaká je pravděpodobnost, že vytáhnete žeton s číslem vyšším než 2?**
-

Pravděpodobnost


X	f	p
5	2	0,05
4	10	0,25
3	16	0,40
2	8	0,20
1	4	0,10

Pravděpodobnost

- Jaká je pravděpodobnost, že vytáhnete žeton s číslem vyšším než 2?

$$p(X > 2) = ?$$

$$0,05 + 0,25 + 0,40 = \mathbf{0,70}$$



Pravděpodobnost

- Jaká je pravděpodobnost, že vytáhnete žeton s číslem nižším než 5?**
-

Pravděpodobnost


X	f	p
5	2	0,05
4	10	0,25
3	16	0,40
2	8	0,20
1	4	0,10

Pravděpodobnost

- Jaká je pravděpodobnost, že vytáhnete žeton s číslem nižším než 5?

$$p(X < 5) = ?$$

$$0,10 + 0,20 + 0,40 + 0,25 = \mathbf{0,95}$$



Pravděpodobnost

- Jaká je pravděpodobnost, že vytáhnete žeton s číslem nižším než 4 a vyšším než 1?**
-

Pravděpodobnost

X	f	p
5	2	0,05
4	10	0,25
3	16	0,40
2	8	0,20
1	4	0,10


Pravděpodobnost

- Jaká je pravděpodobnost, že vytáhnete žeton s číslem nižším než 4 a vyšším než 1?

$$p(4 > X > 1) = ?$$

$$0,20 + 0,40 =$$

$$\mathbf{0,60}$$



Pravděpodobnost

- pravděpodobnost odpovídá hustotě **oblasti pod křivkou** pro daný interval
-

Kontrolní otázky

- základní typy grafů, výhody/nevýhody
 - odlehlá pozorování
 - výpočet a interpretace z-skóru
-

Doplňující literatura

- Wainer, H., & Velleman, PF (2001). **Statistical graphics: Mapping the pathways of science.** Annual Review of Psychology, 52, 305-335.
-