

Elektronický učební materiál

**Počítačová podpora cvičení z předmětu
M7521 Pravděpodobnost a statistika 1
s využitím programového systému STATISTICA**

Autoři: Marie Budíková, Štěpán Mikoláš
Pracoviště: Katedra aplikované matematiky PřF MU v Brně

Základní informace o programovém systému STATISTICA 6

Systém má modulární stavbu. V multilicenci pro Masarykovu univerzitu jsou k dispozici moduly: Basic Statistics/Tables, Multiple Regression, ANOVA, Nonparametrics, Distribution Fitting, Advanced Linear / Nonlinear Models, Multivariate Exploratory Techniques, Industrial Statistics & Six Sigma.

Velké množství informací o systému STATISTICA lze najít na webové stránce společnosti StatSoft, která je jejím distributorem v České republice (www.statsoft.cz). Z této stránky vede rovněž odkaz na elektronickou učebnici statistiky.

STATISTICA 6 má několik typů oken:

- **spreadsheet** (datové okno, má příponu sta, jeho obsah však lze exportovat i v jiných formátech). Do datového okna lze načítat datové soubory nejrůznějších typů (např. z tabulkových procesorů, databázové soubory, ASCII soubory).
- **workbook** (má příponu stw). Do workbooku ukládají výstupy, tj. tabulky a grafy. Skládá se ze dvou oken, v levém okně je znázorněna stromová struktura výstupů, v pravém jsou samotné výstupy. V levém okně se lze pohybovat myší nebo kurzorem, mazat, přesouvat, editovat apod. Výstupy mohou sloužit jako vstupy pro další analýzy a grafy.
- **report** (má příponu str, lze ho uložit i ve formátu rtf, txt či htm). Pokud požadujeme, aby se výstupy ukládaly nejen do workbooku, ale i do reportu, postupujeme takto: Tools – Options – Output Manager – zaškrtneme Also send to Report Window – OK. Report se podobně jako workbook skládá ze dvou oken. Do reportu můžeme vkládat vlastní text, vysvětlující komentáře, poznámky apod. Tabulky a grafy lze v reportu i workbooku dále upravovat.
- **okno grafů** (přípona stg, lze ho uložit i jako bmp, jpg, png a wmf). Získá se tak, že ve workbooku klikneme pravým tlačítkem na graf a vybereme Clone Graph.
- **programovací okno** (přípona svb). Slouží pro zápis programů v jazyku STATISTICA Visual Basic.

Mezi jednotlivými typy oken se přepínáme pomocí položky Window v hlavním menu.

Téma 1: Bodové zpracování četnosti

Vzorový příklad: U 20 studentů 1. ročníku byly zjištěny známky z matematiky, angličtiny a údaje o pohlaví (viz skripta Popisná statistika, příklad 2.4). Příslušný datový soubor se jmenuje **znamky.sta**. Provedte bodové zpracování četnosti.

Postup ve STATISTICE:

1. Do programu STATISTICA načtěte datový soubor **znamky.sta**.
2. Znaky nazvěte X, Y, Z, vytvořte jím návěstí (X - známka z matematiky, Y - známka z angličtiny, Z - pohlaví studenta) a popište, co znamenají jednotlivé varianty (u znaků X a Y: 1 - výborně, 2 - velmi dobře, 3 - dobře, 4 - neprospěl, u znaku Z: 0 - žena, 1 - muž). Soubor uložte.
Návod: Kurzor nastavíme na Var1 – 2x klikneme myší – Name X – Long Name známka z matematiky, Text label – výborně, Numeric – 1, velmi dobře, Numeric - 2, dobře, Numeric – 3, neprospěl, Numeric – 4, OK. U proměnné Y lze text label okopírovat z proměnné X – v Text Labels Editor zvolíme Copy from variable X.
(Přepínání mezi číselnými hodnotami a jejich textovým popisem se děje pomocí tlačítka s obrázkem štítku.)
3. U znaků X a Y vypočtěte absolutní četnosti, relativní četnosti a relativní kumulativní četnosti.
Návod: Statistics - Basic Statistics/Tables – Frequency tables – OK – Variables X, Y, OK – Summary.
(Obě tabulky se uloží do workbooku a listovat v nich můžeme pomocí stromové struktury v levém okně.)

Řešení:

Category	Frequency table: X: známka z matematiky (zr)			
	Count	Cumulative Count	Percent	Cumulative Percent
výborně:	7	7	35,00000	35,0000
velmi dobře:	3	10	15,00000	50,0000
dobře	2	12	10,00000	60,0000
neprospěl:	8	20	40,00000	100,0000
Missing	0	20	0,00000	100,0000


Category	Frequency table: Y: známka z angličtiny (zna)			
	Count	Cumulative Count	Percent	Cumulative Percent
výborně:	4	4	20,00000	20,0000
velmi dobře:	4	8	20,00000	40,0000
dobře	7	15	35,00000	75,0000
neprospěl:	5	20	25,00000	100,0000
Missing	0	20	0,00000	100,0000

4. Vytvořte sloupkový diagram absolutních četností znaků X a Y.
Návod: Graphs – Histograms – Variables X, Y – OK – vypneme Normal fit – Advanced – zaškrtneme Breaks between Columns, OK.
Vytvořte výsečový diagram absolutních četností znaků X a Y.
Návod: Graphs – 2D Graphs – Pie Charts – Variables X, Y – OK – Advanced – Pie legend Text and Percent (nebo Text and Value) – OK.

Vytvořte polygon absolutních četností znaků X a Y.

Návod: ve workbooku vstoupíme do tabulky rozložení četností proměnné X. Pomocí Edit – Delete - Cases vymažeme řádek označený Missing. Nastavíme se kurzorem na Count a kliknutím pravého tlačítka vstupíme do menu Line Plot: Entire Columns. Vykreslí se polygon četnosti.

Řešení:




5. Vytvořte graf empirické distribuční funkce znaku X.

Návod: Při tvorbě histogramu zadáme v Advanced volbu Showing Type Cumulative, Y axis % - 2x klikneme myší na pozadí grafu – otevře se okno All Options – vybereme Plot: Bars – Type Rectangles.

Vytvořte graf četnostní funkce znaku X.

Návod: Při tvorbě histogramu zadáme v Advanced Y axis % - 2x klikneme myší na pozadí grafu – vybereme Plot General – zaškrtneme Markers – vybereme Plot: Bars – Type Lines.

Řešení:



6. Z datového souboru vyberte pouze ženy (pouze muže) a úkol 3 proveděte pro ženy (pro muže).

Návod: Statistics - Basic Statistics/Tables – Frequency tables – OK – Variables X, Y, OK – Select Cases – zaškrtneme Selection Conditions – Include cases – zaškrtneme Specific, selected by $Z = 0$, OK.

Řešení:

Variační řady známk z matematiky a angličtiny pro ženy.

Category	Frequency table: X: známka z matematiky			
	Count	Cumulative Count	Percent	Cumulative Percent
výborně:	5	5	50,00000	50,0000
velmi dobře:	2	7	20,00000	70,0000
dobře	1	8	10,00000	80,0000
neprospěl:	2	10	20,00000	100,0000
Missing	0	10	0,00000	100,0000

Category	Frequency table: Y: známka z angličtiny			
	Count	Cumulative Count	Percent	Cumulative Percent
výborně:	4	4	40,00000	40,0000
velmi dobře:	2	6	20,00000	60,0000
dobře	1	7	10,00000	70,0000
neprospěl:	3	10	30,00000	100,0000
Missing	0	10	0,00000	100,0000

Variační řady známek z matematiky a z angličtiny pro muže.

Category	Frequency table: X: známka z matematiky			
	Count	Cumulative Count	Percent	Cumulative Percent
výborně:	2	2	20,00000	20,00000
velmi dobře:	1	3	10,00000	30,00000
dobře	1	4	10,00000	40,00000
neprospěl:	6	10	60,00000	100,00000
Missing	0	10	0,00000	100,00000

Category	Frequency table: Y: známka z angličtiny			
	Count	Cumulative Count	Percent	Cumulative Percent
velmi dobře:	2	2	20,00000	20,00000
dobře	6	8	60,00000	80,00000
neprospěl:	2	10	20,00000	100,00000
Missing	0	10	0,00000	100,00000

7. Nadále pracujte s celým datovým souborem. Vytvořte kontingenční tabulkou absolutních četností znaků X a Y a graf simultánní četností funkce.

Návod: Statistics - Basic Statistics/Tables – Tables and banners – OK – Select cases – All – OK – Specify tables - List 1 X, List 2 Y, OK, Summary.

Vytvoření grafu simultánní četnostní funkce: Návrat do Crosstabulation Tables Result – 3D histograms – vybereme Axis Scaling – Mode Manual – Minimum 0 (a totéž provedeme pro Axis Y) – dále vybereme Graph Layout – Type – Spikes – OK. Graf lze natáčet pomocí Point of View.

Vytvořte kontingenční tabulkou sloupcově a řádkově podmíněných relativních četností znaků X a Y.


Návod: Návrat do Crosstabulation Tables Result – Options - zaškrtneme ve sloupci Compute tables volbu Percentages of column counts (resp. Percentages of row counts).

Řešení:

Kontingenční tabulka absolutních četností známek z matematiky a z angličtiny.

Summary Frequency Table (znamky)					
Marked cells have counts > 10					
(Marginal summaries are not marked)					
X	Y výborně	Y velmi dobře	Y dobře	Y neprospěl	Row Totals
výborně	4	1	2	0	7
velmi dobře	0	2	1	0	3
dobře	0	0	1	1	2
neprospěl	0	1	3	4	8
All Grps	4	4	7	5	20

Simultánní četnostní funkce.



Kontingenční tabulka sloupcově a řádkově podmíněných relativních četností.

Summary Frequency Table (znamky)						
	X	Y výborně	Y velmi dobře	Y dobře	Y neprospěl	Row Totals
Count	výborně	4	1	2	0	7
Column Percent		100,00%	25,00%	28,57%	0,00%	
Row Percent		57,14%	14,29%	28,57%	0,00%	
Count	velmi dobře	0	2	1	0	3
Column Percent		0,00%	50,00%	14,29%	0,00%	
Row Percent		0,00%	66,67%	33,33%	0,00%	
Count	dobře	0	0	1	1	2
Column Percent		0,00%	0,00%	14,29%	20,00%	
Row Percent		0,00%	0,00%	50,00%	50,00%	
Count	neprospěl	0	1	3	4	8
Column Percent		0,00%	25,00%	42,86%	80,00%	
Row Percent		0,00%	12,50%	37,50%	50,00%	

Téma 2: Intervalové zpracování četnosti

Vzorový příklad: U 60 vzorků oceli byly zjištovány hodnoty meze plasticity a meze pevnosti v kpcm^{-2} (viz skripta Popisná statistika, př. 2.5). Datový soubor se jmenuje **ocel.sta**. Proveďte intervalové zpracování četnosti.

Postup ve STATISTICE:

1. Načtěte soubor **ocel.sta**. Proměnným X a Y vytvořte návěstí „mez plasticity“ a „mez pevnosti“.
2. Pro X a Y použijeme intervalové zpracování četnosti. Podle Sturgesova pravidla je optimální počet třídicích intervalů 7. Musíme zjistit minimum a maximum, abychom vhodně stanovili třídicí intervaly.
Návod: Statistics – Basic Statistics/Tables – Descriptive statistics - Variables X,Y – zaškrtneme Minimum&maximum – Summary. (Pro X je minimum 33 a maximum 160, tedy vhodná volba třídicích intervalů je $(30,50>$, $(50,70>$, ..., $(150,170>$, pro Y je minimum 52 a maximum 189, tedy třídicí intervaly zvolíme $(50,70>$, $(70,90>$, ..., $(170,190>$)

Řešení:

Variable	Descriptive Statistics (c)	
	Minimum	Maximum
X	33,00000	160,00000
Y	52,00000	189,00000

U znaku X volíme dolní mez prvního třídicího intervalu 30, horní mez posledního třídicího intervalu 170. U znaku Y volíme dolní mez prvního třídicího intervalu 50, horní mez posledního třídicího intervalu 190.

Celkem tedy třídicí intervaly znak X budou:

$(30,50>$, $(50,70>$, $(70,90>$, $(90,110>$, $(110,130>$, $(130,150>$, $(150,170>$


a pro znak Y:

$(50,70>$, $(70,90>$, $(90,110>$, $(110,130>$, $(130,150>$, $(150,170>$, $(170,190>$.

3. Vytvořte histogram pro X a pro Y.

Návod: Graphs – Histograms – Variables X – vypneme Normal fit – Advanced – zaškrtneme Boundaries – Specify Boundaries – 50 70 90 110 130 150 170 OK – Y Axis %. Po vykreslení histogramu lze 2 x klepnout na pozadí grafu a ve volbě All Options měnit různé vlastnosti grafu.

Řešení:





4. Proveďte zakódování hodnot proměnných X a Y do příslušných třídicích intervalů.
Návod: Insert – Add Variables – 2 – After Y – OK – přejmenujeme je na RX a RY.
Nastavíme se kurzorem na RX – Data – Recode - vyplníme podmínky pro všechn 7 kategorií.
(Pozor – podmínky se musí psát ve tvaru $X > 30$ and $X \leq 50$ atd.). Pak klepneme na OK.
Analogicky pro Y.

5. Vytvořte graf intervalové empirické distribuční funkce pro X.
Návod: Vytvoříme Frequency table pro RX. Před 1. případ vložíme řádek, kde do Category napíšeme 0 a do Cumulative Percent také 0. Nastavíme se kurzorem na Cumulative Percent – Graphs – Graphs of Block Data – Custom Graph from Block by Column – Line Plots (Variables) – OK.

Řešení:

Kategorie	Tabulka četností:RX (ocel)			
	Četnost	Kumulativní četnost	Rel.četnost	Kumulativní rel.četnost
0				0,0000
1	8	8	13,33333	13,3333
2	4	12	6,66667	20,0000
3	13	25	21,66667	41,6667
4	15	40	25,00000	66,6667
5	9	49	15,00000	81,6667
6	7	56	11,66667	93,3333
7	4	60	6,66667	100,0000
ChD	0	60	0,00000	100,0000

Kategorie	Tabulka četností:RY (ocel)			
	Četnost	Kumulativní četnost	Rel.četnost	Kumulativní rel.četnost
0				0,0000
1	5	5	8,33333	8,3333
2	10	15	16,66667	25,0000
3	14	29	23,33333	48,3333
4	13	42	21,66667	70,0000
5	9	51	15,00000	85,0000
6	6	57	10,00000	95,0000
7	3	60	5,00000	100,0000
ChD	0	60	0,00000	100,0000



6. Sestavte kontingenční tabulky absolutních četností (relativních četností, sloupcově a řádkově podmíněných relativních četností) dvourozměrných třídicích intervalů pro (X,Y).
- Návod:** Viz úkol č. 7 v tématu 1, kde budeme pracovat s proměnnými RX a RY.

Řešení:

Kontingenční tabulky absolutních a relativních četností.

	Summary Frequency Table (ocel) Table: RX(7) x RY(7)								
	RX	RY (50,70>	RY (70,90>	RY (90,110>	RY 110,130	RY 130,150	RY 150,170	RY 70,190	Row Totals
Count	(30,50>	5	3	0	0	0	0	0	8
Total Percent		8,33%	5,00%	0,00%	0,00%	0,00%	0,00%	0,00%	13,33%
Count	(50,70>	0	3	1	0	0	0	0	4
Total Percent		0,00%	5,00%	1,67%	0,00%	0,00%	0,00%	0,00%	6,67%
Count	(70,90>	0	4	7	1	1	0	0	13
Total Percent		0,00%	6,67%	11,67%	1,67%	1,67%	0,00%	0,00%	21,67%
Count	(90,110>	0	0	6	8	1	0	0	15
Total Percent		0,00%	0,00%	10,00%	13,33%	1,67%	0,00%	0,00%	25,00%
Count	110,130:	0	0	0	4	5	0	0	9
Total Percent		0,00%	0,00%	0,00%	6,67%	8,33%	0,00%	0,00%	15,00%
Count	(130,150	0	0	0	0	2	5	0	7
Total Percent		0,00%	0,00%	0,00%	0,00%	3,33%	8,33%	0,00%	11,67%
Count	(150,170	0	0	0	0	0	1	3	4
Total Percent		0,00%	0,00%	0,00%	0,00%	0,00%	1,67%	5,00%	6,67%
Count	All Grps	5	10	14	13	9	6	3	60
Total Percent		8,33%	16,67%	23,33%	21,67%	15,00%	10,00%	5,00%	

Kontingenční tabulky řádkově a sloupcově podmíněných relativních četností.

	Summary Frequency Table (ocel) Table: RX(7) x RY(7)								
	RX	RY 1	RY 2	RY 3	RY 4	RY 5	RY 6	RY 7	Row Totals
Count	1	5	3	0	0	0	0	0	8
Row Percent		62,50%	37,50%	0,00%	0,00%	0,00%	0,00%	0,00%	
Count	2	0	3	1	0	0	0	0	4
Row Percent		0,00%	75,00%	25,00%	0,00%	0,00%	0,00%	0,00%	
Count	3	0	4	7	1	1	0	0	13
Row Percent		0,00%	30,77%	53,85%	7,69%	7,69%	0,00%	0,00%	
Count	4	0	0	6	8	1	0	0	15
Row Percent		0,00%	0,00%	40,00%	53,33%	6,67%	0,00%	0,00%	
Count	5	0	0	0	4	5	0	0	9
Row Percent		0,00%	0,00%	0,00%	44,44%	55,56%	0,00%	0,00%	
Count	6	0	0	0	0	2	5	0	7
Row Percent		0,00%	0,00%	0,00%	0,00%	28,57%	71,43%	0,00%	
Count	7	0	0	0	0	0	1	3	4
Row Percent		0,00%	0,00%	0,00%	0,00%	0,00%	25,00%	75,00%	
Count	All Grps	5	10	14	13	9	6	3	60


	Summary Frequency Table (ocel) Table: RX(7) x RY(7)								
	RX	RY 1	RY 2	RY 3	RY 4	RY 5	RY 6	RY 7	Row Totals
Count	1	5	3	0	0	0	0	0	8
Column Percent		100,00%	30,00%	0,00%	0,00%	0,00%	0,00%	0,00%	
Count	2	0	3	1	0	0	0	0	4
Column Percent		0,00%	30,00%	7,14%	0,00%	0,00%	0,00%	0,00%	
Count	3	0	4	7	1	1	0	0	13
Column Percent		0,00%	40,00%	50,00%	7,69%	11,11%	0,00%	0,00%	
Count	4	0	0	6	8	1	0	0	15
Column Percent		0,00%	0,00%	42,86%	61,54%	11,11%	0,00%	0,00%	
Count	5	0	0	0	4	5	0	0	9
Column Percent		0,00%	0,00%	0,00%	30,77%	55,56%	0,00%	0,00%	
Count	6	0	0	0	0	2	5	0	7
Column Percent		0,00%	0,00%	0,00%	0,00%	22,22%	83,33%	0,00%	
Count	7	0	0	0	0	0	1	3	4
Column Percent		0,00%	0,00%	0,00%	0,00%	0,00%	16,67%	100,00%	
Count	All Grps	5	10	14	13	9	6	3	60

7. Vytvořte stereogram pro (RX,RY).

Návod: V tabulce Crosstabulation Tables Result zaškrtneme 3D histograms. Ve volbě Axis Scaling (pro RX i pro RY) změníme Mode na Manual – Minimum 0.

Řešení:

Stereogram: RY x RX




8. Nakreslete dvourozměrný tečkový diagram pro (X,Y).

Návod: Graphs – Scatterplots – Variables X,Y – OK vypneme Linear fit – OK.

Řešení:

Dvourozměrný tečkový diagram.



Téma 3: Výpočet číselných charakteristik jednorozměrného datového souboru

Vzorový příklad: Pro následující datové soubory vypočtěte číselné charakteristiky.

Postup ve STATISTICE:

- Načtěte soubor **znamky.sta**. Pro známky z matematiky a angličtiny vypočtěte medián, dolní a horní kvartil a kvartilovou odchylku. Výsledky porovnejte s údaji ve skriptech Popisná statistika (viz str. 28).
Návod: Stastistics – Basic Statistics/Tables – Descriptive Statistics – OK - Variables X, Y, OK – zaškrtneme Median, Lower & upper quartiles, Quartile range – Summary.

Řešení:

Variable	Descriptive Statistics (znamky)			
	Median	Lower Quartile	Upper Quartile	Quartile Range
X	2,500000	1,000000	4,000000	3,000000
Y	3,000000	2,000000	3,500000	1,500000

- Načtěte soubor **ocel.sta**. Pro mez plasticity a mez pevnosti vypočtěte aritmetické průměry, směrodatné odchylky a rozptyly. Výsledky porovnejte s údaji ve skriptech Popisná statistika (viz str. 30).

Návod: Stastistics – Basic Statistics/Tables – Descriptive Statistics – OK - Variables X, Y, OK – zaškrtneme Mean, Standard Deviation, Variance – Summary.

Vysvětlení: Rozptyl a směrodatná odchylka vyjdou ve STATISTICE jinak než ve skriptech, protože STATISTICA ve vzorci pro výpočet rozptylu nepoužívá $1/n$, ale $1/(n-1)$.

Řešení:

Variable	Descriptive Statistics (ocel)		
	Mean	Variance	Std.Dev.
X	95,8833	1070,240	32,71453
Y	114,4000	1075,125	32,78911

- Je třeba si uvědomit, že průměr a rozptyl nepopisují rozložení četností jednoznačně. Existují datové soubory, které mají shodný průměr i rozptyl, ale přesto se jejich rozložení četností velmi liší. Tuto skutečnost dobře ilustruje následující příklad: Tři skupiny studentů o počtech 149, 69 a 11 odpovídaly při testu na 10 otázek. Znak X je počet správně zodpovězených otázek. Známe absolutní četnosti znaku X ve všech třech skupinách.

č. sk.	X										
	0	1	2	3	4	5	6	7	8	9	10
1	2	5	15	20	25	15	25	20	15	5	2
2	4	3	2	1	0	49	0	1	2	3	4
3	1	0	0	0	0	9	0	0	0	0	1

Vypočtěte průměr (mean), rozptyl (variance), šikmost (skewness) a špičatost (kurtosis) počtu správně zodpovězených otázek ve všech třech skupinách. Nakreslete sloupkové diagramy absolutních četností.

Návod: Při zadávání dat do STATISTIKY utvořte čtyři proměnné a 11 případů. V 1. sloupci budou varianty znaku X (tj. 0 až 10), v dalších sloupcích pak absolutní četnosti. Proměnné pojmenujeme X, SK1, SK2, SK3. V tabulce Descriptive Statistics zadáme Variable X a klepneme na tlačítko W, abychom program upozornili, že budeme pracovat s daty zadanými pomocí absolutních četností. Zadáme Weight variable SK1, zaškrtneme Status On, OK – zaškrtneme Mean, Variance, Skewness, Kurtosis – Summary. Dále pro znak X nakreslíme sloupkový diagram – viz úkol č. 4 v tématu „Bodové rozložení četností“. Tytéž úkoly provedeme s Weight variable SK2 a SK3.

Řešení:

1. skupina (X weightet by SK1)


Variable	Descriptive Statistics			
	Mean	Variance	Skewness	Kurtosis
X	5,000000	5,000000	-0,000000	-0,759500

2. skupina (X weightet by SK2)


Variable	Descriptive Statistics			
	Mean	Variance	Skewness	Kurtosis
X	5,000000	5,000000	-0,000000	1,291133

3. skupina (X weightet by SK3)

Variable	Descriptive Statistics (cischar)			
	Mean	Variance	Skewness	Kurtosis
X	5,000000	5,000000	-0,000000	5,000000



Sloupkový diagram.



Interpretace: Všechny tři skupiny mají týž průměr, rozptyl a šíkmost, liší se pouze ve špičatosti. Rozložení četností počtu správně zodpovězených otázek je ovšem velmi rozdílné.

Téma 4: Korelace a regrese

Vzorový příklad: Pro následující datové soubory provedte korelační, resp. regresní analýzu.

Postup ve STATISTICE:

- Načtěte soubor **znamky.sta**. Vypočtěte Spearmanův korelační koeficient známek z matematiky a angličtiny pro všechny studenty, pak zvlášť pro muže a zvlášť pro ženy. Získané výsledky interpretujte.

(Spearmanův korelační koeficient měří těsnost lineární závislosti dvou ordinálních proměnných x, y a počítá se podle vzorce:

$$r_s = 1 - \frac{6}{n(n^2 - 1)} \sum_{i=1}^n (R_i - Q_i)^2,$$

kde R_i je pořadí x_i - tj. počet těch hodnot x_1, \dots, x_n , které jsou $\leq x_i$ a Q_i je pořadí y_i .)

Návod: Po načtení souboru zvolíme Statistics – Nonparametrics – Correlations – OK – Variables First variable list X, Second variable list Y – OK – Spearman R. Počítáme-li r_s pro muže, vybereme v tabulce tabulce Nonparametric Correlation tlačítko Select Cases – Specific, select by Z=1.

Řešení:

Pro všechny

Pair of Variables	Spearman Rank Order Correlations (zna MD pairwise deleted Marked correlations are significant at p <			
	Valid N	Spearman R	t(N-2)	p-level
	X & Y	20	0,688442	4,027090

Pro muže (if Z=1)

Pair of Variables	Spearman Rank Order Correlations (zna MD pairwise deleted Marked correlations are significant at p <			
	Valid N	Spearman R	t(N-2)	p-level
	X & Y	10	0,373544	1,138990

Pro ženy (if Z=0)

Pair of Variables	Spearman Rank Order Correlations (zna MD pairwise deleted Marked correlations are significant at p <			
	Valid N	Spearman R	t(N-2)	p-level
	X & Y	10	0,860314	4,773446

- Vysvětlení významu Pearsonova korelačního koeficientu: Načtěte soubor **korkoef.sta**, který obsahuje proměnné X,Y1,Y2,Y3,Y4, X4. Vypočtěte Pearsonovy korelační koeficienty dvojic proměnných (X,Y1), (X,Y2), (X,Y3), (X4,Y4) a pro každou z uvedených dvojic proměnných

nakreslete dvouozměrný tečkový diagram. Pro které dvojice proměnných se hodí Pearsonův korelační koeficient jako vhodná míra těsnosti lineární závislosti?

Návod: Statistics – Basis Statistics/Tables – Correlation matrices – OK – One variable list X, Y1 – OK – Summary: Correlation matrix – Návrat do Product-Moment and Partial Correlations – Advanced/plot – 2D Scatterplots – OK – First X, Second Y1 – OK. Analogicky pro ostatní dvojice proměnných.





Řešení:

Variable	Correlations (korkoe)	
	X	Y1
X	1,000000	0,816421
Y1	0,816421	1,000000

Variable	Correlations (korkoe)	
	X	Y2
X	1,000000	0,816237
Y2	0,816237	1,000000

Variable	Correlations (korkoe)	
	X	Y3
X	1,000000	0,816287
Y3	0,816287	1,000000

Variable	Correlations (korkoe)	
	X4	Y4
X4	1,000000	0,816521
Y4	0,816521	1,000000



- Načtěte do STATISTIKY soubor **ocel.sta**. Vypočtěte kovarianci a Pearsonův koeficient korelace meze plasticity a meze pevnosti. Porovnejte s výsledky ve skriptech Popisná statistika (str. 30).

Návod: Po načtení souboru zvolíme Statistics - Multiple Regression - Variables Independent X, Dependent Y – OK – OK – Residuals/assumption-prediction – Descriptive statistics – Covariances. Pro získání korelačního koeficientu zvolíme Correlation místo Covariances.

Vysvětlení: Kovariance vyjde ve STATISTICE jinak než ve skriptech, protože ve STATISTICE se ve vzorci pro výpočet kovariance nepoužívá $1/n$, ale $1/(n-1)$.

Řešení:

Variable	Correlations (ocel)	
	X	Y
X	1,000000	0,934548
Y	0,934548	1,000000

Variable	Covariances (ocel)	
	X	Y
X	1070,240	1002,471
Y	1002,471	1075,125

4. Určete koeficienty regresní přímky meze pevnosti na mez plasticity a stanovte index determinace. Určete regresní odhad meze pevnosti, je-li mez plasticity 110. Nakreslete regresní přímku do dvouzměrného tečkového diagramu.

Návod: V tabulce Multiple Regression zvolíme Variables Independent X, Dependent Y – OK – Summary:Regression results. Ve výstupní tabulce najdeme koeficient b_0 ve sloupci B na řádku označeném Intercept, koeficient b_1 ve sloupci B na řádku označeném X, index determinace pod označením R2.

Pro výpočet predikované hodnoty zvolíme Residuals/assumption/prediction Predict dependent variable X:110 - OK. Ve výstupní tabulce je hledaná hodnota označena jako Predicted.


Nakreslení regresní přímky: Návrat do Multiple Regression – Residuals / assumption / prediction – Perform residuals analysis – Scatterplots – Bivariate correlation – X, Y – OK. Jiný způsob: Do dvouzměrného tečkového diagramu nakreslíme regresní přímku tak, že v tabulce 2D Scatterplots zvolíme Fit Linear, OK.

Řešení:

Statistic	Summary
	Value
Multiple R	0,9345
Multiple R2	0,8734
Adjusted R2	0,8712
F(1,58)	400,0641
p	0,0000
Std.Err. of Estimate	11,7677

Variable	Predicting Values for (ocel) variable:Y		
	B-Weight	Value	B-Weight * Value
X	0,936679	110,0000	103,0346
Intercept			24,5881
Predicted			127,6228
-95,0%CL			124,3063
+95,0%CL			130,9392

N=60	Regression Summary for Dependent Variable:Y (ocel) R= ,93454811 R2= ,87338017 Adjusted R2= ,87119707 F(1,58)=400,06 p<0,0000 Std.Error of estimate: 11,768					
	Beta	Std.Err. of Beta	B	Std.Err. of B	t(58)	p-level
Intercept			24,58814	4,740272	5,18707	0,000003
X	0,934548	0,046724	0,93668	0,046830	20,00160	0,000000



5. U sedmi náhodně vybraných strojů v určitém podniku se zjišťovalo stáří stroje v letech (proměnná x) a týdenní náklady v Kč na údržbu stroje (proměnná y). Data: (1,35), (1,52), (3,81), (3,105), (5,100), (6,125), (7, 120)

Data znázorněte graficky. Vyzkoušejte následující čtyři modely:

$y = \beta_0 + \beta_1 x$, $y = \beta_0 + \beta_1 \sqrt{x}$, $y = \beta_0 + \beta_1 \log_{10} x$, $y = \beta_0 + \beta_1 1/x$. Vyberte ten model, který poskytuje nejvyšší index determinace. Určete regresní odhad týdenních nákladů pro stroj starý čtyři roky.

Návod: Datový soubor s proměnnými X a Y doplňte o proměnné SQRTX, LOGX a INVX. Hodnoty proměnné SQRTX získáte tak, že do Long Name napíšete =sqrt(x). (Analogicky pro ostatní proměnné.) Regresní analýzu provedete tak, že roli nezávisle proměnné bude hrát proměnná X, pak SQRTX, LOGX a nakonec INVX.


Řešení:

Model s proměnnou X

Statistic	Summary
	Value
Multiple R	0,91004
Multiple R2	0,82817
Adjusted R2	0,79381
F(1,5)	24,09909
p	0,00444
Std.Err. of Estimate	15,48711

Variable	Predicting Values for (stroje) variable: Y		
	B-Weight	Value	B-Weight * Value
X	13,14957	4,000000	52,5983
Intercept			39,4444
Predicted			92,0427
-95,0%CL			76,8676
+95,0%CL			107,2179

N=7	Regression Summary for Dependent Variable: Y (stroje)					
	Beta	Std.Err. of Beta	B	Std.Err. of B	t(5)	p-level
Intercept			39,44444	11,54341	3,417054	0,018898
X	0,910040	0,185379	13,14957	2,67862	4,909082	0,004439




Model s odmocninou

Statistic	Summary
	Value
Multiple R	0,93924
Multiple R ²	0,88217
Adjusted R ²	0,85860
F(1,5)	37,43261
p	0,00169
Std.Err. of Estimate	12,82508

Variable	Predicting Values for (stroje) variable: Y		
	B-Weight	Value	B-Weight * Value
SQRTX	48,55972	2,000000	97,1194
Intercept			-0,4774
Predicted			96,6421
-95,0%CL			83,6962
+95,0%CL			109,5880

N=7	Regression Summary for Dependent Variable: Y (stroje) R= ,93923698 R ² = ,88216611 Adjusted R ² = ,85859933 F(1,5)=37,433 p<,00169 Std.Error of estimate: 12,825					
	Beta	Std.Err. of Beta	B	Std.Err. of B	t(5)	p-level
Intercept			-0,47736	15,29638	-0,031207	0,976312
SQRTX	0,939237	0,153515	48,55972	7,93690	6,118220	0,001691




Model s převrácenou hodnotou

Statistic	Summary
	Value
Multiple R	0,94282
Multiple R2	0,88891
Adjusted R2	0,86670
F(1,5)	40,01016
p	0,00146
Std.Err. of Estimate	12,45245

Variable	Predicting Values for (stroje) variable: Y		
	B-Weight	Value	B-Weight * Value
INVX	-84,4832	0,250000	-21,1208
Intercept			126,6192
Predicted			105,4984
-95,0%CL			91,5231
+95,0%CL			119,4738

N=7	Regression Summary for Dependent Variable: Y (stroje) R= ,94282234 R2= ,88891396 Adjusted R2= ,86669676 F(1,5)=40,010 p<,00146 Std.Error of estimate: 12,452					
	Beta	Std.Err. of Beta	B	Std.Err. of B	t(5)	p-level
Intercept			126,6192	7,67327	16,50134	0,000015
INVX	-0,942822	0,149054	-84,4832	13,35627	-6,32536	0,001456




Model s logaritmem

Statistic	Summary
	Value
Multiple R	0,95349
Multiple R2	0,90915
Adjusted R2	0,89097
F(1,5)	50,03321
p	0,00087
Std.Err. of Estimate	11,26153


Variable	Predicting Values for (stroje) variable: Y		
	B-Weight	Value	B-Weight * Value
LOGX	93,23472	0,602060	56,1329
Intercept			44,6457
Predicted			100,7786
-95,0%CL			88,9325
+95,0%CL			112,6247

N=7	Regression Summary for Dependent Variable: Y (stroje) R= ,95349135 R2= ,90914576 Adjusted R2= ,89097491 F(1,5)=50,033 p<,00087 Std.Error of estimate: 11,262					
	Beta	Std.Err. of Beta	B	Std.Err. of B	t(5)	p-level
Intercept			44,64571	7,49541	5,956407	0,001907
LOGX	0,953491	0,134799	93,23472	13,18100	7,073415	0,000874



Nejvyšší hodnotu indexu determinace vykazuje model s logaritmem.

Výsledky všech čtyř modelů:



Téma 5: Výpočty pravděpodobností pomocí distribuční funkce binomického rozložení

STATISTICA poskytuje hodnoty distribučních funkcí mnoha rozložení. Omezíme se na binomické rozložení (funkce $\text{IBinom}(x,p,n)$, kde x ... počet úspěchů, p ... pravděpodobnost úspěchu v jednom pokusu, n ... celkový počet pokusů).

Vzorový příklad na binomické rozložení: Pojišťovna zjistila, že 12% pojistných událostí je způsobeno vloupáním. Jaká je pravděpodobnost, že mezi 30 náhodně vybranými pojistnými událostmi bude způsobeno vloupáním

- a) nejvýše 6,
- b) aspoň 6,
- c) právě 6,
- d) od dvou do pěti?

Řešení:

Náhodná veličina X udává počet pojistných událostí způsobených vloupáním, $X \sim \text{Bi}(30; 0,12)$.

- ad a) $P(X \leq 6) = \Phi(6) = 0,9393$,
- ad b) $P(X \geq 6) = 1 - P(X \leq 5) = 1 - \Phi(5) = 0,1431$,
- ad c) $P(X=6) = \Phi(6) - \Phi(5) = 0,0825$,
- ad d) $P(2 \leq X \leq 5) = \Phi(5) - \Phi(1) = 0,7469$.

Postup ve STATISTICE:

Otevřeme nový datový soubor se čtyřmi proměnnými a o jednom případu.

Řešení:

Do Long Name 1. proměnné napišeme $=\text{IBinom}(6;0,12;30)$.

Do Long Name 2. proměnné napišeme $=1-\text{IBinom}(5;0,12;30)$.

Do Long Name 3. proměnné napišeme $=\text{IBinom}(6;0,12;30)-\text{IBinom}(5;0,12;30)$.

Do Long Name 3. proměnné napišeme $=\text{IBinom}(5;0,12;30)-\text{IBinom}(1;0,12;30)$.

- a) $P(X \leq 6) = \Phi(6) = \text{IBinom}(6;0,12;30) = 0,939393$
- b) $P(X \geq 6) = 1 - P(X \leq 5) = 1 - \Phi(5) = 1 - \text{IBinom}(5;0,12;30) = 0,143077$
- c) $P(X=6) = P(X \leq 6) - P(X \leq 5) = \text{IBinom}(6;0,12;30) - \text{IBinom}(5;0,12;30) = 0,082470$
- d) $P(2 \leq X \leq 5) = P(1 < X \leq 5) = \Phi(5) - \Phi(1) = \text{IBinom}(5;0,12;30) - \text{IBinom}(1;0,12;30) = 0,746953$

Příklady ze skript Teorie pravděpodobnosti a matematická statistika, kapitola 4:

Příklad 4.10.

$n = 10$, úspěch = narození chlapce, pravděpodobnost úspěchu $\vartheta = 0,5$

X udává počet narozených chlapců

Řešení:

- a) $P(X=5) = P(X \leq 5) - P(X \leq 4) = \Phi(5) - \Phi(4) = \text{IBinom}(5;0,5;10) - \text{IBinom}(4;0,5;10) = 0,246094$
- b) $P(3 \leq X \leq 8) = P(2 < X \leq 8) = \Phi(8) - \Phi(2) = \text{IBinom}(8;0,5;10) - \text{IBinom}(2;0,5;10) = 0,934570$

Příklad 4.11.

$n = 7$, úspěch = potkání dvou vlaků během 24 hodin, pravděpodobnost úspěchu $\vartheta = 0,2$
 X udává počet potkání dvou vlaků během týdne

Řešení:

$$\begin{aligned} P(X=3) &= P(X \leq 3) - P(X \leq 2) = \Phi(3) - \Phi(2) = \text{IBinom}(3;0,2;7) - \text{IBinom}(2;0,2;7) = 0,11468 \\ P(X \leq 3) &= \text{IBinom}(3;0,2;7) = 0,966656 \\ P(X \geq 3) &= 1 - P(X < 3) = 1 - P(X \leq 2) = 1 - \Phi(2) = 1 - \text{IBinom}(2;0,2;7) = 0,148032 \end{aligned}$$

Příklad 4.12.

Úspěch je výhra partie se stejně silným soupeřem, když remíza je vyloučena

Pravděpodobnost úspěchu $\vartheta = 0,5$, X udává počet úspěchů

- a) $n = 4$
- b) $n = 8$

Řešení:

$$\begin{aligned} \text{ad a)} \quad P(X=3) &= P(X \leq 3) - P(X \leq 2) = \Phi(3) - \Phi(2) = \text{IBinom}(3;0,5;4) - \text{IBinom}(2;0,5;4) = \\ &= 0,250000 \\ \text{ad b)} \quad P(X=5) &= P(X \leq 5) - P(X \leq 4) = \Phi(5) - \Phi(4) = \text{IBinom}(5;0,5;8) - \text{IBinom}(4;0,5;8) = \\ &= 0,218750 \end{aligned}$$

Příklad 4.13.

$n = 20$, úspěch je padnutí tří líců při hodu třemi mincemi, $\vartheta = 1/8 = 0,125$,
 X udává počet úspěchů

Řešení:

$$P(X \geq 1) = 1 - P(X < 1) = 1 - P(X \leq 0) = 1 - \text{IBinom}(0;0,125;20) = 0,930791$$

Příklad 4.14.

$n = 5$, úspěch je padnutí tří jedniček při hodu třemi kostkami, $\vartheta = 1/6^3 = 1/216$,
 X udává počet úspěchů

Řešení:

$$P(X=2) = P(X \leq 2) - P(X \leq 1) = \Phi(2) - \Phi(1) = \text{IBinom}(2;1/216;5) - \text{IBinom}(1;1/216;5) = 0,000211$$


Téma 6: Kreslení grafů distribuční funkce a pravděpodobnostní funkce binomického rozložení









Vzorový příklad: Nakreslete graf distribuční funkce a pravděpodobnostní funkce náhodné veličiny $X \sim Bi(12; 0,3)$


Postup ve STATISTICE: Vytvoříme nový datový soubor o 3 proměnných a 13 případech. První proměnnou nazveme X a uložíme do ní hodnoty 0, 1, ..., 12 (do Long Name napišeme =v0-1). Druhou proměnnou nazveme DF a uložíme do ní hodnoty distribuční funkce (do Long Name napišeme příkaz =IBinom(x;0,3;12)). Třetí proměnnou nazveme PF a uložíme do ní hodnoty pravděpodobnostní funkce (do Long Name napišeme příkaz =Binom(x;0,3;12)). Graf distribuční funkce: Graphs – Scatterplots – Variables X, DF – OK – vypneme Linear fit – OK – 2x klikneme na pozadí grafu – Plot:General – zaškrtneme Line – Line Type: Step – OK. Graf pravděpodobnostní funkce: Graphs – Scatterplots – Variables X, PF – OK – vypneme Linear fit - OK.

Podle tohoto návodu nakreslete grafy distribučních a pravděpodobnostních funkcí binomického rozložení pro různá n a p, např. n=5, p=0,5 (resp. 0,75) apod. Sledujte vliv parametrů na vzhled grafů.

Řešení:







Téma 7: Výpočet střední hodnoty, rozptylu, kovariance a koeficientu korelace u diskrétních náhodných veličin.

Vzorový příklad 1. Postupně se zkouší spolehlivost čtyř přístrojů. Další se zkouší jen tehdy, když předchozí je spolehlivý. Každý z přístrojů vydrží zkoušku s pravděpodobností 0,8. Náhodná veličina X udává počet zkoušených přístrojů. Vypočtěte střední hodnotu a rozptyl náhodné veličiny X.

Řešení:

X nabývá hodnot 1, 2, 3, 4 a její pravděpodobnostní funkce je $\pi(1) = 0,2$, $\pi(2) = 0,8 \cdot 0,2 = 0,16$, $\pi(3) = 0,8^2 \cdot 0,2 = 0,128$, $\pi(4) = 0,8^3 \cdot 0,2 + 0,8^4 = 0,512$, $\pi(0) = 0$ jinak

$$E(X) = 1 \cdot 0,2 + 2 \cdot 0,16 + 3 \cdot 0,128 + 4 \cdot 0,512 = 2,952$$

$$D(X) = 1^2 \cdot 0,2 + 2^2 \cdot 0,16 + 3^2 \cdot 0,128 + 4^2 \cdot 0,512 - 2,952^2 = 1,4697$$

Postup ve STATISTICE:

Otevřeme nový datový soubor o čtyřech případech a pěti proměnných, které nazveme $x, pi(x), x*pi(x), xkvadrat, xkvadrat*pi(x)$. První proměnnou naplníme hodnotami náhodné veličiny X, druhou hodnotami její pravděpodobnostní funkce. Do třetí proměnné uložíme součin $x\pi(x)$ (do Long name napišeme =v1*v2), do čtvrté x^2 (do Long name napišeme =v1^2), do páté součin $x^2\pi(x)$ (do Long name napišeme v4*v2).

x	pi(x)	x*pi(x)	xkvadrat	xkvadrat*pi(x)
1	0,2	0,2	1	0,2
2	0,16	0,32	4	0,64
3	0,128	0,384	9	1,152
4	0,512	2,048	16	8,192

Výpočty E(X) a D(X) provedeme takto:

Statistics – Basic Statistics/Tables – Descriptive Statistics – Variables x*pi(x), xkvadrat*pi(x) – OK, zaškrtneme Sum - Summary

Proměnnou Sum ve workbooku transponujeme: Data – Transpose – File. Proměnnou x*pi(x) přejmenujeme na E(X) (vidíme, že $E(X) = 2,952$). Přidáme (ve workbooku) proměnnou D(X) a do jejího Long name napišeme =v2-v1^2. Vidíme, že $D(X) = 1,4697$.

Variable	Descriptiv
	Sum
x*pi(x)	2,95200
xkvadrat*pi(x)	10,18400

Vzorový příklad 2. Náhodná veličina X udává příjem manžela (v tisících dolarů) a náhodná veličina Y příjem manželky (v tisících dolarů). Je známa simultánní pravděpodobnostní funkce $\pi(x,y)$ diskrétního náhodného vektoru (X,Y): $\pi(10,10) = 0,2$, $\pi(10,20) = 0,04$, $\pi(10,30) = 0,01$, $\pi(10,40) = 0$, $\pi(20,10) = 0,1$, $\pi(20,20) = 0,36$, $\pi(20,30) = 0,09$, $\pi(20,40) = 0$, $\pi(30,10) = 0$, $\pi(30,20) = 0$

$= 0,05$, $\pi(30,30) = 0,1$, $\pi(30,40) = 0$, $\pi(40,10) = 0$, $\pi(40,20) = 0$, $\pi(40,30) = 0$, $\pi(40,40) = 0,05$, $\pi(x,y) = 0$ jinak. Vypočtěte koeficient korelace příjmů manžela a manželky.

Řešení:

Náhodná veličina X i náhodná veličina Y nabývají hodnot 10, 20, 30, 40. Stanovíme hodnoty marginálních pravděpodobnostních funkcí: $\pi_1(10) = 0,25$, $\pi_1(20) = 0,55$, $\pi_1(30) = 0,15$, $\pi_1(40) = 0,05$, $\pi_1(x) = 0$ jinak, $\pi_2(10) = 0,3$, $\pi_2(20) = 0,45$, $\pi_2(30) = 0,2$, $\pi_2(40) = 0,05$, $\pi_2(y) = 0$ jinak. Spočteme $E(X) = 20$, $E(Y) = 20$, $D(X) = 60$, $D(Y) = 70$. Dosazením do vzorce pro výpočet kovariance zjistíme, že $C(X,Y) = 49$, tedy koeficient korelace $R(X,Y) = 49/\sqrt{60}\sqrt{70} = 0,76$.

Postup ve STATISTICE:

Budeme potřebovat dva nové soubory. První pro výpočet středních hodnot a rozptylů, druhý pro výpočet kovariance a koeficientu korelace.

První soubor bude mít 4 případy a 10 proměnných.

Zde jsou pro výpočet středních hodnot a rozptylů použity dva soubory vzhledem k přílišné délce tabulky pro obě náhodné veličiny.

x	pi(x)	x*pi(x)	xkvadrat	xkvadrat*pi(x)
10	0,25	2,5	100	25
20	0,55	11	400	220
30	0,15	4,5	900	135
40	0,05	2	1600	80

Variable	Descriptiv
	Sum
x*pi(x)	20,0000
xkvadrat*pi(x)	460,0000

y	pi(y)	y*pi(y)	ykvadrat	ykvadrat*pi(y)
10	0,3	3	100	30
20	0,45	9	400	180
30	0,2	6	900	180
40	0,05	2	1600	80

Variable	Descriptiv
	Sum
y*pi(y)	20,0000
ykvadrat*pi(y)	470,0000

Nyní vytvoříme nový datový soubor o 16 případech a 4 proměnných, které nazveme $x, y, pi(x,y)$, a $x*y*pi(x,y)$. Do první proměnné napíšeme 10, 10, 10, 10, 20, 20, 20, 20, 30, 30, 30, 30, 40, 40, 40 a do druhé proměnné 10, 20, 30, 40, 10, 20, 30, 40, 10, 20, 30, 40, 10, 20, 30, 40.

Do třetí proměnné zapíšeme hodnoty simultánní pravděpodobnostní funkce $\pi(x,y)$ a do čtvrté proměnné uložíme součin $xy\pi(x,y)$ (do Long name napíšeme =v1*v2*v3).

x	y	pi(x,y)	x*y*pi(x,y)
10	10	0,2	20
10	20	0,04	8
10	30	0,01	3
10	40	0	0
20	10	0,1	20
20	20	0,36	144
20	30	0,09	54
20	40	0	0
30	10	0	0
30	20	0,05	30
30	30	0,1	90
30	40	0	0
40	10	0	0
40	20	0	0
40	30	0	0
40	40	0,05	80

Statistics – Basic Statistics/Tables – Variables x*y*pi(x,y) – OK , zaškrtneme Sum – Summary.

Variable	Descriptiv
	Sum
x*y*pi(x,y)	449,0000

Proměnnou Sum ve workbooku přejmenujeme na E(X,Y) a přidáme k ní 6 nových proměnných E(X), E(Y), D(X), D(Y), C(X,Y), R(X,Y). Do proměnných E(X), E(Y), D(X), D(Y) napíšeme vypočtené střední hodnoty a rozptyly. Do Long name proměnné C(X,Y) napíšeme =v1-vv2*v3 a do Long name proměnné R(X,Y) napíšeme =v6/sqrt(v4*v5).

	E(X,Y)	E(X)	E(Y)	D(X)	D(Y)	C(X,Y)	R(X,Y)
x*y*pi(x,y)	449	20	20	60	70	49	0,756086

Vzorový příklad 3. Náhodná veličina X udává počet ok při hodu kostkou. Vypočtěte její střední hodnotu a rozptyl.

Řešení:

Náhodná veličina X nabývá hodnot 1, 2, 3, 4, 5, 6. Její pravděpodobnostní funkce je $\pi(1) = 1/6$, $\pi(2) = 1/6$, $\pi(3) = 1/6$, $\pi(4) = 1/6$, $\pi(5) = 1/6$, $\pi(6) = 1/6$, $\pi(x) = 0$ jinak

$$E(X) = (1/6)(1+2+3+4+5+6) = 21/6 = 3,5$$

$$E(X^2) = (1/6)(1+4+9+16+25+36) = 91/6$$

$$D(X) = E(X^2) - [E(X)]^2 = 91/6 - 49/4 = 35/12$$

Postup ve STATISTICE:

Otevřeme nový datový soubor o čtyřech případech a pěti proměnných, které nazveme x, pi(x), x*pi(x), xkvadrat, xkvadrat*pi(x). První proměnnou naplníme hodnotami náhodné

veličiny X, druhou hodnotami její pravděpodobnostní funkce (do Long name napíšeme =1/6).

Do třetí proměnné uložíme součin x*pi(x) (do Long name napíšeme =v1*v2), do čtvrté x^2 (do

Long name napíšeme =v1^2), do páté součin $x^2 \pi(x)$ (do Long name napíšeme v4*v2).

x	$\pi(x)$	$x^*\pi(x)$	x^2	$x^2\pi(x)$
1	0,166666667	0,166666667	1	0,166666667
2	0,166666667	0,333333333	4	0,666666667
3	0,166666667	0,5	9	1,5
4	0,166666667	0,666666667	16	2,666666667
5	0,166666667	0,833333333	25	4,166666667
6	0,166666667	1	36	6

Výpočty E(X) a D(X) provedeme takto:

Statistics – Basic Statistics/Tables – Descriptive Statistics –Variables $x^*\pi(x)$, $x^2\pi(x)$ – OK, zaškrtneme Sum – Summary

Proměnnou Sum ve workbooku transponujeme: Data – Transpose – File.

Proměnnou $x^*\pi(x)$ přejmenujeme na E(X) (vidíme, že $E(X) = 2,952$). Přidáme (ve workbooku) proměnnou D(X) a do jejího Long name napíšeme = v2-v1^2.

Vidíme, že $D(X) = 1,4697$.

Variable	Descriptiv
	Sum
$x^*\pi(x)$	3,50000
$x^2\pi(x)$	15,16667

Vzorový příklad 4. Diskrétní náhodný vektor (X_1, X_2) má simultánní pravděpodobnostní funkci s hodnotami $\pi(0,-1) = c$, $\pi(0,0) = \pi(0,1) = \pi(1,-1) = \pi(2,-1) = 0$, $\pi(1,0) = \pi(1,1) = \pi(2,1) = 2c$, $\pi(2,0) = 3c$, $\pi(x,y) = 0$ jinak. Určete konstantu c a vypočtěte $R(X_1, X_2)$.

Řešení:

Náhodná veličina X_1 nabývá hodnot 0, 1, 2, náhodná veličina X_2 nabývá hodnot -1, 0, 1. Součet hodnot simultánní pravděpodobnostní funkce musí být roven jedné a odtud $10c = 1$, tedy $c = 0,1$.

Stanovíme hodnoty marginálních pravděpodobnostních funkcí: $\pi_1(0) = 0,1$, $\pi_1(1) = 0,4$, $\pi_1(2) = 0,5$, $\pi_1(x) = 0$ jinak, $\pi_2(-1) = 0,1$, $\pi_2(0) = 0,5$, $\pi_2(1) = 0,4$, $\pi_2(y) = 0$ jinak.

Spočteme $E(X) = 20$, $E(Y) = 20$, $D(X) = 60$, $D(Y) = 70$. Dosazením do vzorce pro výpočet kovariance zjistíme, že $C(X,Y) = 49$, tedy koeficient korelace $R(X,Y) = 49/\sqrt{60}\sqrt{70} = 0,76$.

Postup ve STATISTICE:

Budeme potřebovat tři nové soubory. První dva pro výpočet středních hodnot a rozptylů, třetí pro výpočet kovariance a koeficientu korelace.

První dva soubory bude mít po 3 případy a 5 proměnných.

x1	$\pi(x1)$	$x1^*\pi(x1)$	$x1^2$	$x1^2\pi(x1)$
0	0,1	0	0	0
1	0,4	0,4	1	0,4
2	0,5	1	4	2

Variable	Descriptiv
	Sum
x1*pi(x1)	1,400000
x1kvadrat*pi(x1)	2,400000

x2	pi(x2)	x2*pi(x2)	x2kvadrat	x2kvadrat*pi(x2)
-1	0,1	-0,1	1	0,1
0	0,5	0	0	0
1	0,4	0,4	1	0,4

Variable	Descriptiv
	Sum
x2*pi(x2)	0,300000
x2kvadrat*pi(x2)	0,500000

Nyní vytvoříme nový datový soubor o 9 případech a 4 proměnných, které nazveme $x_1, x_2, \pi(x_1, x_2), x_1 \cdot x_2 \cdot \pi(x_1, x_2)$. Do první proměnné napišeme 0, 0, 0, 1, 1, 1, 2, 2, 2 a do druhé proměnné -1, 0, 1, -1, 0, 1, -1, 0, 1. Do třetí proměnné zapišeme hodnoty simultánní pravděpodobnostní funkce $\pi(x_1, x_2)$ a do čtvrté proměnné uložíme součin $x_1 x_2 \pi(x_1, x_2)$ (do Long name napišeme =v1*v2*v3)).

x1	x2	pi(x1,x2)	x1*x2*pi(x1,x2)
0	-1	0,1	0
0	0	0	0
0	1	0	0
1	-1	0	0
1	0	0,2	0
1	1	0,2	0,2
2	-1	0	0
2	0	0,3	0
2	1	0,2	0,4

Statistics – Basic Statistics/Tables – Variables x1*x2*pi(x1,x2) – OK , zaškrtneme Sum – Summary.

Variable	Descriptiv
	Sum
x1*x2*pi(x1,x2)	0,600000

Proměnnou Sum ve workbooku přejmenujeme na E(X1*X2) a přidáme k ní 6 nových proměnných E(X1), E(X2), D(X1), D(X2), C(X1,X2), R(X1,X2). Do proměnných E(X1), E(X2), D(X1), D(X2) napišeme vypočtené střední hodnoty a rozptyly. Do Long name proměnné C(X,Y) napišeme =v1-v2*v3 a do Long name proměnné R(X,Y) napišeme =v6/sqrt(v4*v5).

	E(X1*X2)	E(X1)	E(X2)	D(X1)	D(X2)	C(X1,X2)	R(X1,X2)
x1*x2*pi(x1,x2)	0,600000	1,4	0,3	0,44	0,41	0,18	0,42379

Téma 8: Ilustrace empirického zákona velkých čísel

Empirický zákon velkých čísel: Se vzrůstajícím počtem pokusů se relativní četnost úspěchu ustaluje kolem pravděpodobnosti úspěchu.

Modelová situace: Provádíme n nezávislých hodů mincí. Padnutí líce považujeme za úspěch. Tento pokus budeme simulovat pomocí programu STATISTICA a budeme sledovat závislost relativní četnosti úspěchu na počtu pokusů. (Počet pokusů volíme 2, 5, 10, 20, 50, 100, 200, 500, 1000, 2000.)

Postup: Vygenerujeme n náhodných čísel mezi 0 a 1. Nabude-li náhodné číslo hodnotu z intervalu $<0,5; 1>$, pokus považujeme za úspěšný - tzn., že padl líc. Zjistíme relativní četnost úspěchu. Postup opakujeme pro různá n a nakonec znázorníme graficky závislost relativní četnosti úspěchu na počtu pokusů.

Návod: File – New – Number of variables 2, Number of cases 2000 – OK. 1. proměnnou přejmenujeme na NC, do Long Name napíšeme =Rnd(1), OK. (Funkce Rnd(1) vygeneruje náhodné číslo mezi 0 a 1.) 2. proměnnou přejmenujeme na POCET. Data – Recode - Category 1: Include If NC $\geq 0,5$, Category 2: Include If NC $< 0,5$, New Value 2, value 0, OK. (Proměnná POCET indikuje, zda nastal úspěch nebo neúspěch.) Vypočítáme průměr proměnné POCET (tj. relativní četnost úspěchu). Poznamenáme si počet pokusů n a relativní četnost úspěchu p. Nyní vymažeme posledních 1000 případů. Edit – Delete – Cases - From Case 1001 To Case 2000, OK. Znovu naplníme proměnné NC a POCET a spočteme průměr proměnné POCET. Postup opakujeme, až nám zbudou jen dva případy. Pak vytvoříme nový datový soubor o dvou proměnných n a p a 10 případech, kam zapíšeme hodnoty n a p. Nakonec nakreslíme dvourozměrný tečkový diagram závislosti p na n.

Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	1005	1005	50,25000	50,2500
1	995	2000	49,75000	100,0000
Missing	0	2000	0,00000	100,0000

Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	510	510	51,00000	51,0000
1	490	1000	49,00000	100,0000
Missing	0	1000	0,00000	100,0000

Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	256	256	51,20000	51,2000
1	244	500	48,80000	100,0000
Missing	0	500	0,00000	100,0000

Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	100	100	50,00000	50,0000
1	100	200	50,00000	100,0000
Missing	0	200	0,00000	100,0000

Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	42	42	42,00000	42,0000
1	58	100	58,00000	100,0000
Missing	0	100	0,00000	100,0000

Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	23	23	46,00000	46,0000
1	27	50	54,00000	100,0000
Missing	0	50	0,00000	100,0000

Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	8	8	40,00000	40,0000
1	12	20	60,00000	100,0000
Missing	0	20	0,00000	100,0000


Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	6	6	60,00000	60,0000
1	4	10	40,00000	100,0000
Missing	0	10	0,00000	100,0000

Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	1	1	50,00000	50,0000
1	1	2	50,00000	100,0000
Missing	0	2	0,00000	100,0000

Category	Frequency table: POCET (Ezvc)			
	Count	Cumulative Count	Percent	Cumulative Percent
0	4	4	80,00000	80,0000
1	1	5	20,00000	100,0000
Missing	0	5	0,00000	100,0000

n	2000	1000	500	200	100	50	20	10	5	2
p	0,4975	0,4900	0,4880	0,5000	0,5800	0,5400	0,6000	0,4000	0,2000	0,5000

Dvouroz měrný tečkový diagram.
Závislost relativní četnosti úspěchu na počtu pokusů.



Téma 9: Centrální limitní věta

Ilustrace centrální limitní věty

Vygenerujeme 12×1000 realizací náhodných veličin X_1, \dots, X_{12} , $X_i \sim \text{Rs}(0,1)$, $i=1, \dots, 12$. Podle centrální limitní věty má náhodná veličina $X = X_1 + \dots + X_{12} - 6$ přibližně rozložení $N(0,1)$.


Návod: Vytvoříme nový datový soubor o 13 proměnných a 1000 případech. Otevřeme programovací okno STATISTICA VISUAL BASIC (File – New – Macro (SVB) Program – Name clv – OK) a do okna napišeme příkazy:

```
Dim s As Spreadsheet
Set s = ActiveSpreadsheet
For i = 1 To 12
    s.Variable(i).FillRandomValues
    ' do proměnných v1 až v12 se uloží náhodná čísla
    ' z intervalu(0,1)
Next i
s.VariableLongName(13) = "=Sum(v1:v12)-6"
' do proměnné v13 se uloží součet proměnných v1 až v12
' zmenšený o 6
s.Recalculate
```

Znázorníme histogramy proměnných v1 a v13 a porovnáme jejich vzhled s tvarem hustot rozložení $\text{Rs}(0,1)$, $N(0,1)$.

Dále spočteme průměry a rozptyly proměnných v1 a v13 a porovnáme je s teoretickou střední hodnotou a rozptylem náhodné veličiny s rozložením $\text{Rs}(0,1)$ ($E(X)=0,5$, $D(X)=1/12=0,833$) a náhodné veličiny s rozložením $N(0,1)$ ($E(X)=0$, $D(X)=1$).


Řešení:



Jedná se o 1000 náhodných čísel vygenerovaných z intervalu $(0,1)$.

Jejich aritmetický průměr je $m = 0,497491$ a rozptyl $s^2 = 0,082374$.

Střední hodnota $\text{Rs}(0,1)$ je $E(X) = 0,5$ a rozptyl $D(X) = 1/12 = 0,08333$.



Variable	Descriptive Statistics	
	Mean	Variance
v1	0,497471	0,082374
v13	0,039656	1,009721

Jedná se o náhodnou veličinu $v13 = v1+v2+\dots+v12 - 6$, která podle centrální limitní věty má rozložení $N(0,1)$. (přesněji řečeno, posloupnost standardizovaných součtů konverguje v distribuci ke standardizované normální náhodné veličině.) Aritmetický průměr $v13$ vyšel $m = 0,039656$, rozptyl $s^2 = 1,009721$.

Střední hodnota $X \sim N(0,1)$ je $E(X) = 0$, rozptyl $D(X) = 1$.

Aplikace Moivreovy - Laplaceovy integrální věty

Pomocí STATISTIKY spočteme př. 11.2. ze skript Teorie pravděpodobnosti a matematická statistika:

Y_{100} – počet úspěchů v posloupnosti $n = 100$ opakovaných nezávislých pokusů, pravděpodobnost úspěchu $\vartheta = 0,3$, $Y_{100} \sim Bi(100, 0,3)$, $E(Y_{100}) = n\vartheta = 30$, $D(Y_{100}) = n\vartheta(1-\vartheta) = 21$.

Aproximativní výpočet:

$$P(20 \leq Y_{100} \leq 40) = P\left(\frac{19-30}{\sqrt{21}} \leq \frac{Y_{100}-30}{\sqrt{21}} \leq \frac{40-30}{\sqrt{21}}\right) \approx \Phi\left(\frac{10}{\sqrt{21}}\right) - \Phi\left(-\frac{11}{\sqrt{21}}\right) = 0,9773,$$

kde $\Phi(x)$ je distribuční funkce rozložení $N(0,1)$.

Postup ve STATISTICE:

File – New – Number of variables 2, Number of cases 1 – OK.

Nastavíme se kurzorem na 1. sloupec.

Long Name =INormal(10/sqrt(21);0;1)- INormal(-11/sqrt(21);0;1) OK. (Funkce INormal(x;mu;sigma) poskytuje hodnotu distribuční funkce v bodě x normálního rozložení se střední hodnotou mu a směrodatnou odchylkou sigma.)

Přesný výpočet:

$$P(20 \leq Y_{100} \leq 40) = P(19 < Y_{100} \leq 40) = \Phi(40) - \Phi(19) = 0,978614,$$

kde $\Phi(x)$ je distribuční funkce rozložení $Bi(100, 0,3)$.

Postup ve STATISTICE:

Nastavíme se kurzorem na 2. sloupec.

Long Name =IBinom(40;0,3;100)- IBinom(19;0.3;100). (Funkce IBinom(x;p;n) poskytuje hodnotu distribuční funkce v bodě x binomického rozložení s parametry p a n.)

Podle tohoto návodu vyřešte příklady 11.3., 11.5., 11.6.

Př. 11.3.

$n = 400$, $\vartheta = 0,2$, úspěch je nutnost opravy v záruční době

$$n\vartheta = 80, \quad n\vartheta(1-\vartheta) = 64$$

aproximativní výpočet: $P(Y_{400} > 96) \approx 1 - INormal(16/8;0;1) = 0,022750$

přesný výpočet: $P(Y_{400} > 96) = 1 - IBinom(96;0,2;400) = 0,024640$

Př. 11.5.

$n = 10000$, $\vartheta = 0,515$, úspěch je narození chlapce

$$n\vartheta = 5150, \quad n\vartheta(1-\vartheta) = 2497,75$$

Úkol (a)

aproximativní výpočet: $P(Y_{10000} \leq 5000) \approx INormal(-150/sqrt(2497,75);0;1) = 0,001344$

přesný výpočet: $P(Y_{10000} \leq 5000) = IBinom(5000;0,515;10000) = 0,001347$

Úkol (b)

aproximativní výpočet: $P(4999 < Y_{10000} \leq 5300) \approx INormal(150/sqrt(2497,75);0;1) - INormal(-151/sqrt(2497,75);0;1) = 0,997399$

přesný výpočet: $P(4999 < Y_{10000} \leq 5300) = IBinom(5300;0;1) - IBinom(4999;0;1) = 0,997400$

Př. 11.6.

$n = 1000$, $\vartheta = 0,05$, úspěch je zhotovení vadného výrobku

$$n\vartheta = 50, \quad n\vartheta(1-\vartheta) = 47,5$$

aproximativní výpočet: $P(Y_{1000} \leq 70) \approx INormal(20/sqrt(47,5);0;1) = 0,998145$

přesný výpočet: $P(Y_{1000} \leq 70) = IBinom(70;0,05;1000) = 0,997670$