

Analýza dat pro Neurovědy



RNDr. Eva Janoušová
doc. RNDr. Ladislav Dušek, Dr.

Jaro 2012

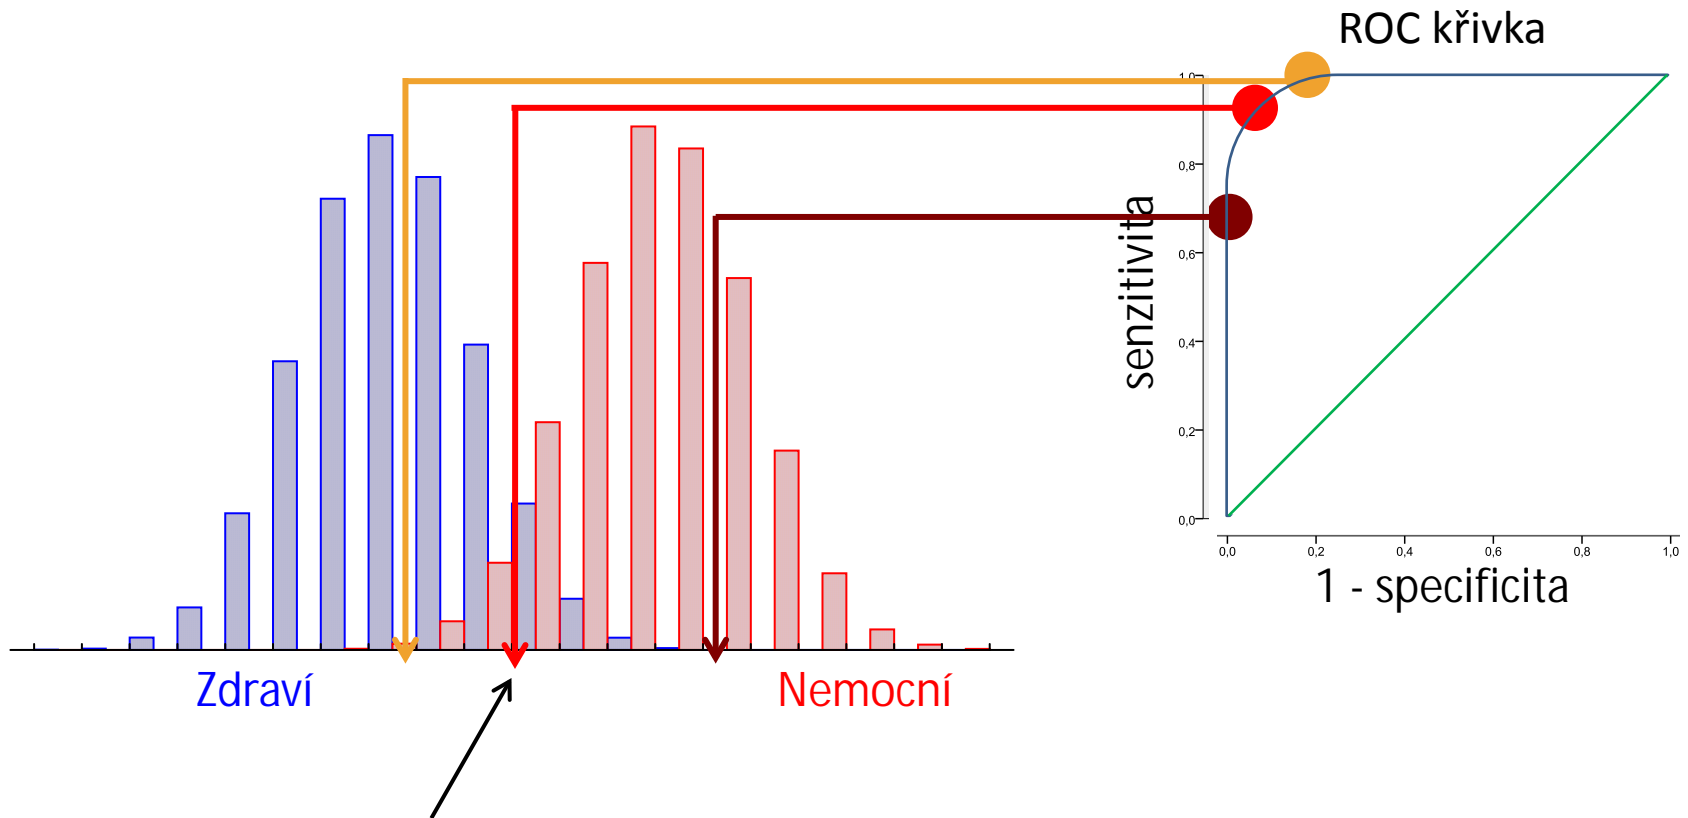
4. Hledání diagnostického cut-off pomocí ROC křivek.

ROC analýza – motivace

- Dříve probrané ukazatele diagnostické síly testů (senzitivita, specificita apod.) **nelze použít u diagnostických testů, jejichž výstupem je spojitá (kvantitativní) proměnná** (např. koncentrace analytu v krevním séru, systolický krevní tlak).
- Na základě předchozích výzkumů známe dělicí body, které odlišují normální a patologické hodnoty spojité proměnné, pomocí nichž můžeme spojitou proměnnou binarizovat – tzn. vytvoření dvou kategorií „pozitivní“ / „negativní“ (např. „pod normou“ / „v normě“).
- Pokud dělicí body nejsou známy předem, můžeme se je snažit nalézt pomocí ROC („Receiver Operating Characteristic“) **křivky**.
- **Cíle ROC analýzy:**
 1. Určit, zda je spojitá proměnná vhodná pro diagnostické odlišování zdravých a nemocných jedinců.
 2. Nalezení dělicího bodu („cut-off point“) na škále hodnot spojité proměnné, který nejlépe odlišuje zdravé a nemocné jedince.

ROC analýza


- Princip: Jakákoli hodnota spojité proměnné nějak rozlišuje zdravé a nemocné jedince, tzn. je spojena s nějakou senzitivitou a specificitou.




Nejlepší dělicí bod („cut-off“) – nejvyšší senzitivita a specificita pro odlišení skupin – tzn. maximální součet hodnot senzitivity a specificity.

ROC analýza – plocha pod ROC křivkou

- Plocha pod ROC křivkou = „Area Under the Curve“ (AUC).
- Nabývá hodnot od 0 do 1.
- Slouží k vyjádření diagnostické síly (efektivity) testu.
- Čím větší hodnota AUC, tím lepší diagnostický test je (hodnota AUC nad 0,75 většinou poukazuje na uspokojivou diskriminační schopnost testu).




ROC analýza – srovnání diagnostické síly různých testů



ROC analýza – srovnání diagnostické síly různých testů

- Lze srovnat i velmi rozdílné testy (např. testy založené na různých proměnných).




Diagnostický test	AUC
DT1	0,949
DT2	0,872
DT3	0,770

→ nejlepší

→ nejhorší

ROC analýza

Příklad: Zjistěte, zda je MMSE skóre vhodné na diagnostiku mírné kognitivní poruchy (MCI). Najděte dělicí bod (cut-off), který nejlépe odlišuje pacienty s MCI od kontrolních subjektů.



MMSE skóre	Sensitivity	1-Specificity	Specificity	Sensitivity + Specificity
-23	0,002	0,000	1,000	1,002
-24	0,101	0,000	1,000	1,101
-25	0,239	0,004	0,996	1,235
-26	0,399	0,022	0,978	1,377
-27	0,581	0,061	0,939	1,520
-28	0,749	0,217	0,783	1,531
-29	0,924	0,574	0,426	1,350
-30	1,000	1,000	0,000	1,000

Blok 5

Jak hodnotit vztah spojitých
proměnných a základy regresního
modelování.

Osnova

1. Základy korelační analýzy
2. Základy regresní analýzy
3. Analýza přežití a Coxův model proporcionálních rizik


1. Základy korelační analýzy

Motivace

- Zatím jsme se zabývali spojitou proměnnou v jedné skupině, spojitou proměnnou ve více skupinách, diskrétní proměnnou v jedné skupině, diskrétní proměnnou ve více skupinách, vztahem dvou diskrétních proměnných.
- Teď se chceme zabývat dvěma spojitými proměnnými:
 1. **Chceme zjistit, jestli mezi nimi existuje vztah** – např. jestli vyšší hodnoty jedné proměnné znamenají nižší hodnoty jiné proměnné.
 2. **Chceme kvantifikovat vztah mezi dvěma spojitými proměnnými** – např. pro použití jedné proměnné na místo druhé proměnné.
 3. **Chceme predikovat hodnoty jedné proměnné na základě znalosti hodnot jiných proměnných.**

Jak hodnotit vztah dvou spojitých proměnných?


- Nejjednodušší formou je **bodový graf (x-y graf)**.
- Např. vztah objemu hipokampu a amygdaly:




Korelace

- **Korelační koeficient** – kvantifikuje míru vztahu mezi dvěma spojitými proměnnými (X a Y).
- Standardní metodou je výpočet **Pearsonova korelačního koeficientu (r)**:
 - Charakterizuje **linearitu** vztahu mezi X a Y – jinak řečeno variabilitu kolem lineárního trendu.
 - Nabývá hodnot od -1 do 1.
 - Hodnota r je kladná (kladná korelace), když vyšší hodnoty X souvisí s vyššími hodnotami Y, a naopak je záporná (záporná korelace), když nižší hodnoty X souvisí s vyššími hodnotami Y.
 - Proměnné jsou nekorelované, pokud $r = 0$.
 - Hodnoty 1 nebo -1 získáme, když body x-y grafu leží na přímce.
- Lze statistickým testem **otestovat, zda jsou dvě spojitě proměnné nezávislé** – hypotézy mají tvar: $H_0: r = 0$ (tzn. korelační koeficient je roven nule) a $H_1: r \neq 0$.


Pearsonův korelační koeficient (r)




$r = 1,0$



$r = -0,9$



$r = 0,4$




$r = 0,05$

Pearsonův korelační koef. – problematické situace I.


- Pearsonův korelační koeficient není vhodné počítat v situaci, kdy:
 - se v datech vyskytuje více skupin
 - proměnné mají nelineární vztah
 - se v datech vyskytují odlehlé hodnoty

Více skupin




$r = 0,84$
($p < 0,001$)

Nelineární vztah



$r = 0,58$
($p < 0,001$)



Odlehlá hodnota



$r = 0,36$
($p = 0,009$)

Pearsonův korelační koef. – problematické situace II.



- Problém velikosti vzorku:



- Test na ověření, zda je Pearsonův korelační koeficient různý od nuly, je parametrický test – předpoklad normality srovnávaných spojitých proměnných!

Pearsonův korelační koef. – problematické situace III.

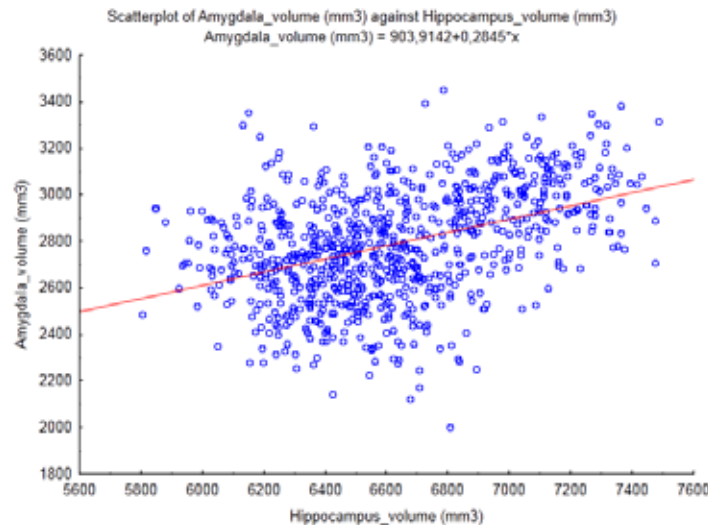
- Při srovnání dvou spojitých proměnných je nutné vykreslovat bodový graf, protože histogramy pro jednotlivé proměnné zvlášť nám nemusejí odhalit odlehlé hodnoty!



Pearsonův korelační koeficient

- **Příklad:** Ověřte, zda existuje vztah objemu hipokampu a amygdaly v souboru 833 subjektů.


- **Řešení:**



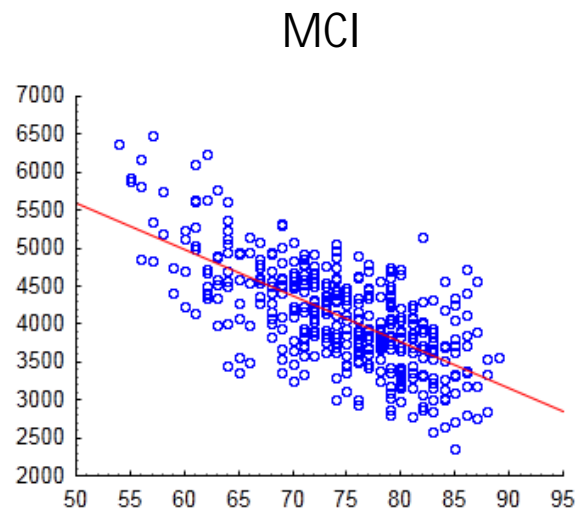
		Correlations (Data_neuro_vycistena4) Marked correlations are significant at $p < ,05000$ N=833 (Casewise deletion of missing data)	
Variable		Hippocampus_volume (mm3)	Amygdala_volume (mm3)
Hippocampus_volume (mm3)		1,0000	,4173
		p= ---	p=0,00
Amygdala_volume (mm3)		,4173	1,0000
		p=0,00	p= ---

Úkol 1.


- **Zadání:** Ověřte, zda existuje vztah objemu nucleus caudatus a věku u pacientů s AD, pacientů s MCI a u kontrol. Nezapomeňte ověřit normalitu srovnávaných proměnných.
- **Řešení:**



$$r = 0,68$$
$$(p < 0,001)$$



$$r = 0,67$$
$$(p < 0,001)$$



$$r = 0,43$$
$$(p < 0,001)$$

Srovnání dvou korelačních koeficientů

- **Příklad:** Srovnejte korelační koeficienty objemu nucleus caudatus a věku u pacientů s AD a kontrolních subjektů.

- **Postup:**

Z předchozího úkolu víme, že:

$$r_1 = 0,68$$

$$N_1 = 197$$

$$r_2 = 0,43$$

$$N_2 = 230$$

The screenshot shows a dialog box titled "Difference tests: r, %, means: Data_neuro_vycistena4". It contains three sections for different types of statistical tests:

- Difference between two correlation coefficients:** This section is active. It shows $r_1 = .68$ with $N_1 = 197$ and $r_2 = .43$ with $N_2 = 230$. The resulting p-value is $p: .0002$. The "Two-sided" test option is selected. A "Compute" button is visible.
- Difference between two means (normal distribution):** This section is inactive. It shows $M_1 = 0$, $StDv_1 = 1$, $N_1 = 10$ and $M_2 = 0$, $StDv_2 = 1$, $N_2 = 10$. The resulting p-value is $p: 1,0000$. The "Two-sided" test option is selected. A "Compute" button is visible.
- Difference between two proportions:** This section is inactive. It shows $Pr.1: .500000$, $N1: 10$ and $Pr.2: .500000$, $N2: 10$. The resulting p-value is $p: 1,0000$. The "Two-sided" test option is selected. A "Compute" button is visible.


Poznámka

- Korelace dvou náhodných veličin se často interpretuje pomocí druhé mocniny Pearsonova korelačního koeficientu: r^2 .
- Hodnota r^2 vyjadřuje, kolik % své variability sdílí jedna veličina s druhou, jinak řečeno, kolik % variability jedné veličiny může být predikováno pomocí té druhé.
- S hodnotou r^2 se setkáte v lineárních modelech.

Spearmanův korelační koeficient (r_s)

- Pearsonův korelační koeficient je náchylný k odlehlým hodnotám a obecně odchylným od normality. **Spearmanův korelační koeficient** stejně jako řada dalších neparametrických metod **pracuje pouze s pořadími** pozorovaných hodnot.
- Hodnoty Spearmanova korelačního koeficientu r_s se pohybují stejně jako u Pearsonova korelačního koeficientu r od -1 do 1.

Srovnání Pearsonova a Spearmanova korelačního koeficientu




Pearsonův korelační koeficient:
 $r = 0,65$
($p = 0,029$)

Spearmanův korelační koeficient:
 $r_s = 0,95$
($p < 0,001$)

Spearmanův korelační koeficient není náchylný k odlehlým hodnotám.

Spearmanův korelační koeficient

- **Příklad:** Zjistěte, zda existuje vztah objemu hipokampu a MMSE skóre.
- **Řešení:**



		Spearman Rank Order Correlations (Data_neuro_vycistena4) MD pairwise deleted Marked correlations are significant at p <,05000			
Variable		MMSE	Hippocampus_v olume (mm3)		
MMSE		1,000000	0,626892		
Hippocampus_volume (mm3)		0,626892	1,000000		

		Spearman Rank Order Correlations (Data_neuro_vycistena4) MD pairwise deleted Marked correlations are significant at p <,05000			
Pair of Variables		Valid N	Spearman R	t(N-2)	p-value
MMSE	& Hippocampus_volume (mm3)	833	0,626892	23,19513	0,00

Úkol 2.

- **Zadání:** Zjistěte, zda existuje vztah objemu všech dalších pěti mozkových sktruktur s MMSE skóre (nezapomeňte vykreslit bodové grafy).
- **Řešení:**

		Spearman Rank Order Correlations (Data_neuro_vycistena4) MD pairwise deleted Marked correlations are significant at p <,05000			
Pair of Variables		Valid N	Spearman R	t(N-2)	p-value
MMSE	& Amygdala_volume (mm3)	833	0,338742	10,37852	0,000000
MMSE	& Thalamus_volume (mm3)	833	-0,000759	-0,02187	0,982557
MMSE	& Pallidum_volume (mm3)	833	0,039167	1,12992	0,258834
MMSE	& Putamen_volume (mm3)	833	0,324925	9,90402	0,000000
MMSE	& Nucl_caud_volume (mm3)	833	0,011837	0,34124	0,733012


2. Základy regresní analýzy

Motivace



- Cílem regresní analýzy je popsat závislost hodnot jedné proměnné na hodnotách druhé proměnné.
- Např. závislost objemu hipokampu na věku.
- Dva problémy:
 - Vybrat správnou funkci k popisu dané závislosti.
 - Stanovit konkrétní parametry daného typu funkce.

Příklady závislostí

Lineární



Nelineární




Lineární regrese

Obecný zápis:

$$\mathbf{y} = \mathbf{X} * \boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

Zápis, pokud máme pouze jednu nezávisle proměnnou:

$$y = \beta_0 + \beta_1 * x + \varepsilon$$



y – závisle proměnná (vysvětlovaná proměnná)

x – nezávisle proměnná (vysvětlující proměnná, regresor)

ε – náhodná složka modelu přímky (rezidua přímky)

β_0 – intercept

β_1 – regresní koeficient – „sklon regresní přímky“


Lineární regrese

Obecný zápis:

$$\mathbf{y} = \mathbf{X} * \boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

Zápis, pokud máme pouze jednu nezávisle proměnnou:

$$y = \beta_0 + \beta_1 * x + \varepsilon$$



y – závisle proměnná (vysvětlovaná proměnná)

x – nezávisle proměnná (vysvětlující proměnná, regresor)

ε – náhodná složka modelu přímky (rezidua přímky)

β_0 – intercept

β_1 – regresní koeficient – „sklon regresní přímky“


Lineární regrese

Obecný zápis:

$$\mathbf{y} = \mathbf{X} * \boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

Zápis, pokud máme pouze jednu nezávisle proměnnou:

$$y = \beta_0 + \beta_1 * x + \varepsilon$$



y – závisle proměnná (vysvětlovaná proměnná)

x – nezávisle proměnná (vysvětlující proměnná, regresor)

ε – náhodná složka modelu přímky (rezidua přímky)

β_0 – intercept

β_1 – regresní koeficient – „sklon regresní přímky“


Lineární regrese

Obecný zápis:

$$\mathbf{y} = \mathbf{X} * \boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

Zápis, pokud máme pouze jednu nezávisle proměnnou:

$$y = \beta_0 + \beta_1 * x + \varepsilon$$



y – závisle proměnná (vysvětlovaná proměnná)

x – nezávisle proměnná (vysvětlující proměnná, regresor)

ε – náhodná složka modelu přímky (rezidua přímky)




Odhad koeficientů $\boldsymbol{\beta}$ metodou nejmenších čtverců:

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$$

β_0 – intercept


β_1 – regresní koeficient – „sklon regresní přímky“

Lineární regrese - příklady




Regresní analýza v grafech

Grafy residuí modelů (příklady)



Obecné tvary residuí modelů (schéma)




Lineární regrese – příklad I


- Příklad:** Proveďte regresní analýzu, v níž budete modelovat závislost objemu nucleus caudatus na věku.

Regression Summary for Dependent Variable: Nucl_caud_volume (mm3) (Data_neuro_vycistena4)						
R= ,62657661 R2= ,39259825 Adjusted R2= ,39186732						
F(1,831)=537,12 p<0,0000 Std.Error of estimate: 494,97						
	b*	Std.Err. of b*	b	Std.Err. of b	t(831)	p-value
N=833						
Intercept			8348,848	186,0558	44,8728	0,00
Age	-0,626577	0,027036	-57,369	2,4754	-23,1759	0,00


Q-Q graf reziduí



Histogram reziduí

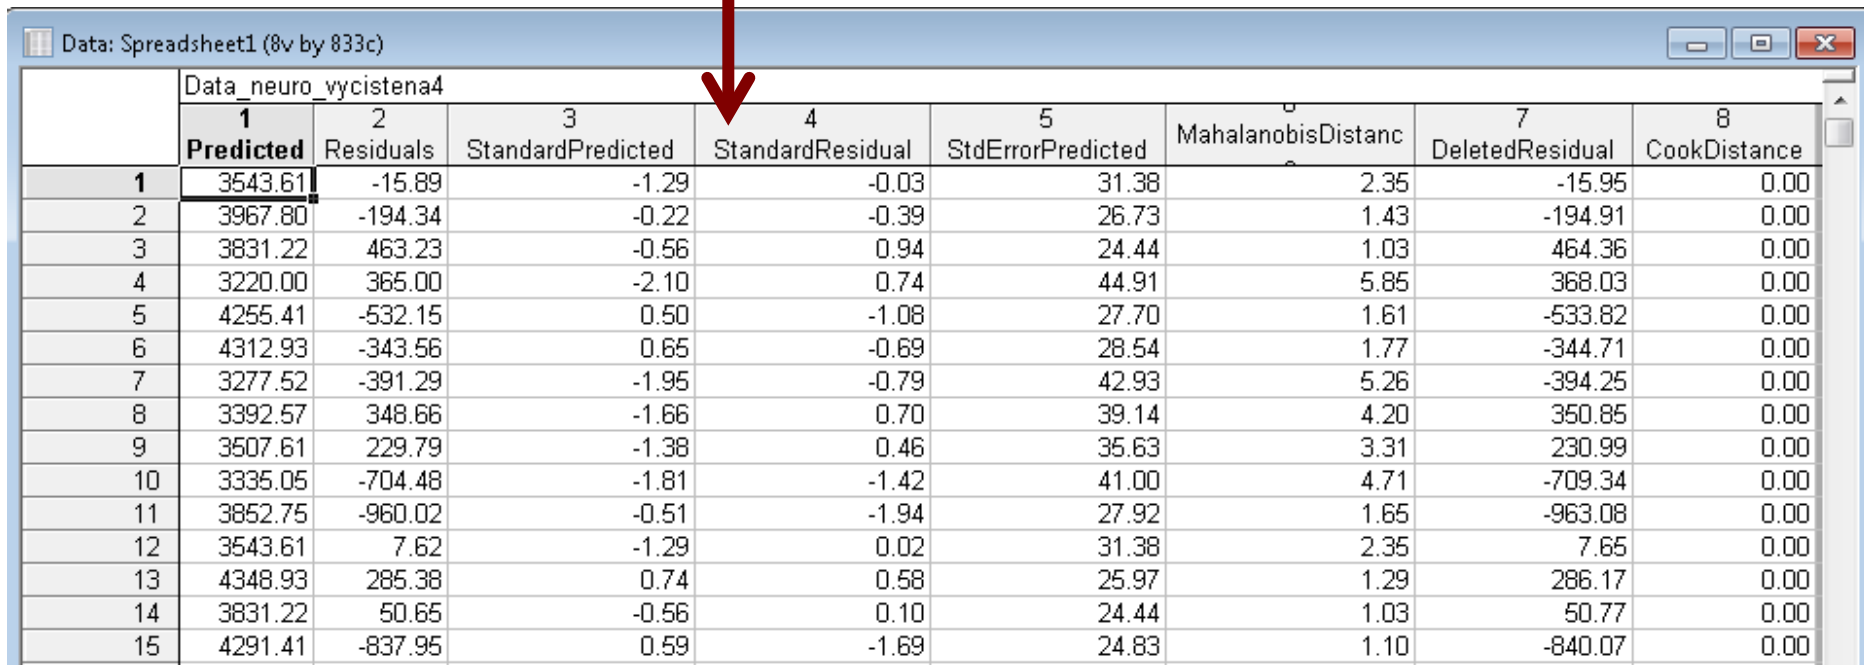


Bodový graf reziduí vs. predikované hodnoty



Lineární regrese – příklad II

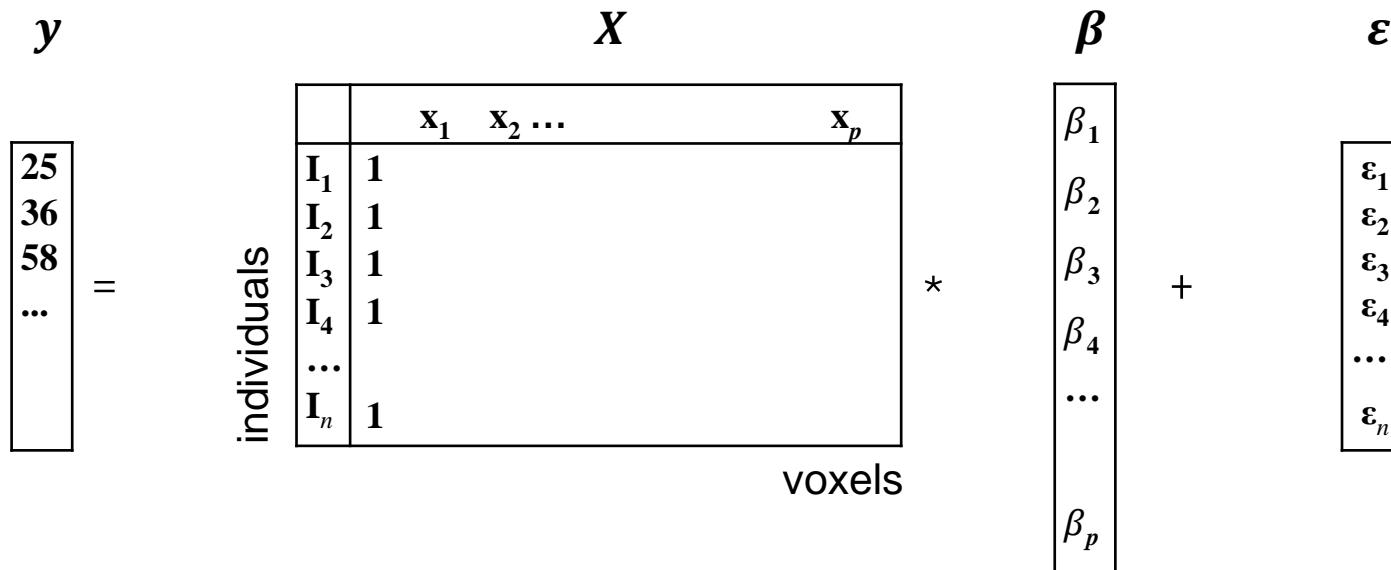
- Příklad:** Chceme zjistit, zda se liší objem nucleus caudatus podle typu onemocnění (pacienti s AD, pacienti s MCI, kontroly). Srovnávané skupiny subjektů však obsahují jiný poměr mužů a žen a liší se i věkovým složením. Odstraňte vliv věku a pohlaví, aby výsledek srovnání objemu nucleus caudatus podle typu onemocnění nebyl ovlivněn tím, že skupiny nejsou srovnatelné.



	1	2	3	4	5	6	7	8
	Predicted	Residuals	StandardPredicted	StandardResidual	StdErrorPredicted	MahalanobisDistanc	DeletedResidual	CookDistance
1	3543.61	-15.89	-1.29	-0.03	31.38	2.35	-15.95	0.00
2	3967.80	-194.34	-0.22	-0.39	26.73	1.43	-194.91	0.00
3	3831.22	463.23	-0.56	0.94	24.44	1.03	464.36	0.00
4	3220.00	365.00	-2.10	0.74	44.91	5.85	368.03	0.00
5	4255.41	-532.15	0.50	-1.08	27.70	1.61	-533.82	0.00
6	4312.93	-343.56	0.65	-0.69	28.54	1.77	-344.71	0.00
7	3277.52	-391.29	-1.95	-0.79	42.93	5.26	-394.25	0.00
8	3392.57	348.66	-1.66	0.70	39.14	4.20	350.85	0.00
9	3507.61	229.79	-1.38	0.46	35.63	3.31	230.99	0.00
10	3335.05	-704.48	-1.81	-1.42	41.00	4.71	-709.34	0.00
11	3852.75	-960.02	-0.51	-1.94	27.92	1.65	-963.08	0.00
12	3543.61	7.62	-1.29	0.02	31.38	2.35	7.65	0.00
13	4348.93	285.38	0.74	0.58	25.97	1.29	286.17	0.00
14	3831.22	50.65	-0.56	0.10	24.44	1.03	50.77	0.00
15	4291.41	-837.95	0.59	-1.69	24.83	1.10	-840.07	0.00

Vícenásobná lineární regrese

$$y = X\beta + \varepsilon$$



X – matice plánu (design matice)

3. Analýza přežití a Coxova regrese

Analýza přežití


- Analýza doby od vstupní události do výskytu sledované (koncové) události.
- **Vstupní událost** – např.:
 - narození
 - začátek léčby
 - počátek nemoci
 - vstup do studie
 - dosažení remise (uzdravení pacienta)
 - operace
 - začátek používání přístroje
- **Koncová (sledovaná) událost** – např.:
 - úmrtí
 - výskyt progresse onemocnění
 - výskyt relapsu onemocnění (tzn. návrat onemocnění)
 - dosažení remise (uzdravení pacienta)
 - porucha přístroje
- Dobu mezi vstupní a koncovou událostí nazýváme jako **doba přežití**.

Analýza přežití

- Uplatnění analýzy přežití:
 - v lékařském výzkumu:
 - hodnocení celkového přežití („Overall Survival“ – OS)
 - hodnocení času do progresu („Progression-free Survival“ – PFS)
 - a další
 - v průmyslu
 - v zemědělství

Cenzorování

- Doba přežití dané osoby je cenzorována, pokud během pozorování nenastane sledovaná událost – důvody:
 - ztráta kontaktu s danou osobou (osoba se přestěhuje nebo přestane chodit na prohlídky)
 - v době uzavření studie se sledovaná událost ještě nevyskytla
 - pozorovaná osoba zemřela na jinou nemoc




Analýza přežití – vstupní data

- Pro každého člověka dvojice hodnot:
 - T – čas přežití:
 - u osob, u nichž sledovaná událost nastala, je to čas od vstupní události do sledované události
 - u osob, u nichž sledovaná událost nenastala, je to čas od vstupní události do ukončení studie
 - C – identifikátor cenzorování – pouze 2 hodnoty:
 - 1 ... sledovaná událost nastala
 - 0 ... sledovaná událost nenastala (osoba je cenzorována)
- Cenzorovaná pozorování (tzn. osoby, u nichž sledovaná událost nenastala) nesmíme z analýzy vyhodit – obsahují informaci!!!

Neparametrické odhady křivky přežití

- V klinickém výzkumu i populačním modelování jsou pro popis přežití standardem neparametrické metody – Kaplan-Meierova metoda a metoda Life-tables.
1. **Kaplan-Meierova metoda** – založena na jednotlivých pozorovaných časech přežití, vhodná zejména pro hodnocení dat klinických studií – vyžaduje přesný záznam doby sledování.
 2. **Life-tables** – založena na agregaci pozorování do časových intervalů, vhodná zejména pro popis přežití na populační úrovni, kde není k dispozici tak kvalitní záznam doby sledování.

Kaplan-Meierova křivka přežití



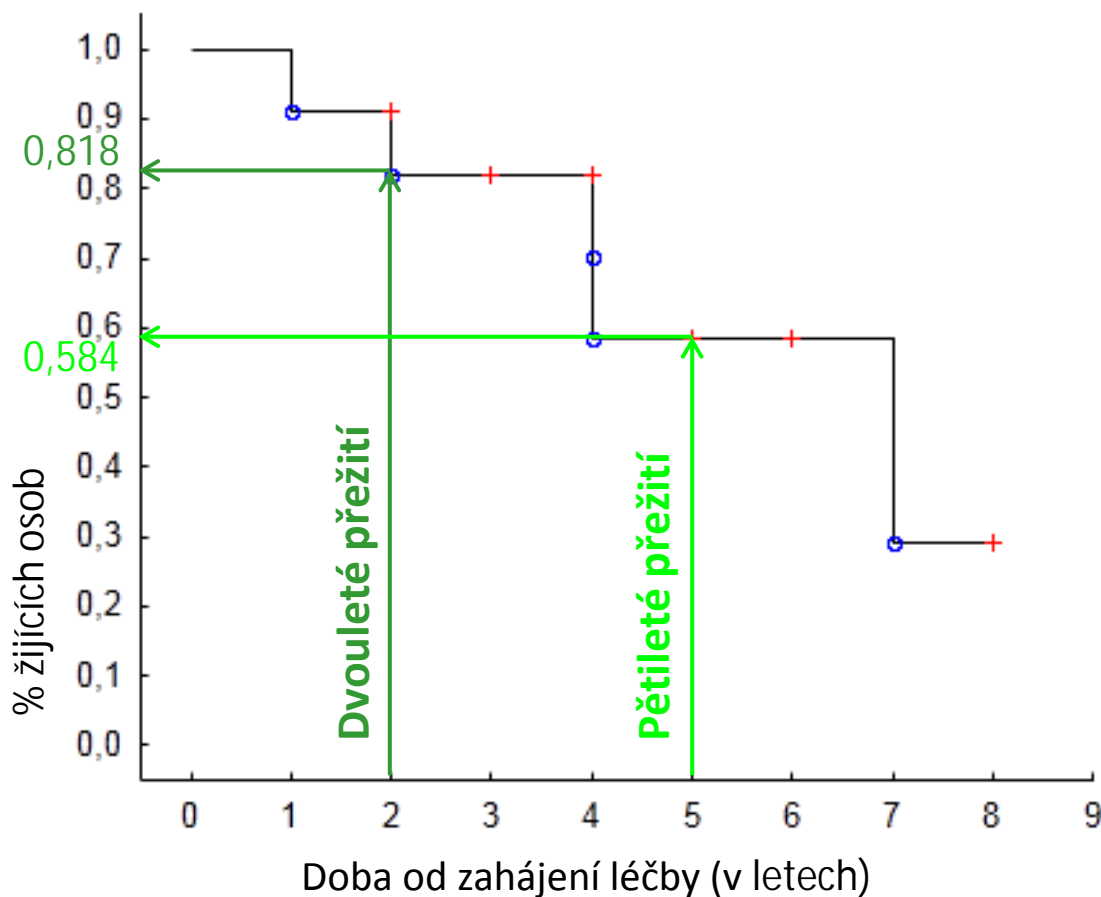
Vstupní data

Pacient	Čas	Úmrtí
1	1	1
2	2	1
3	2	0
4	3	0
5	4	1
6	4	1
7	4	0
8	5	0
9	6	0
10	7	1
11	8	0

- Křivka přežití odráží **procento žijících osob v daném čase**.
- Křivka přežití je **klesající**:
 - pokles křivky přežití nastane v čase koncové události u necenzorované osoby
 - velikost „schodu“ je dána počtem osob, kteří v daném čase zůstávají „v riziku“

Křivka přežití – hodnocení x-letého přežití

Celkové přežití pacientů s epilepsií



Kaplan-Meier (Product-limit) analysis (Data_preziti) Note: Censored cases are marked with +

	Time	Cumulative Survival	Standard Error
1	1	0,909	0,087
2	2	0,818	0,116
3+	2		
4+	3		
5	4	0,701	0,147
6	4	0,584	0,163
7+	4		
8+	5		
9+	6		
10	7	0,292	0,222
11+	8		

2-leté přežití: 81,8% (tzn. po dvou letech od zahájení léčby žije 81,8% pacientů)

5-leté přežití: 58,4% (tzn. po pěti letech od zahájení léčby žije 58,4% pacientů)

Křivka přežití – hodnocení x-letého přežití – výpočet intervalu spolehlivosti

Výpočet intervalu spolehlivosti pro x-leté přežití:

$$\text{Odhad pravděpodobnosti přežití v čase } t \pm 1,96 \times \text{SE (odhadu)}$$

Kaplan-Meier (Product-limit) analysis (Data_preziti) Note: Censored cases are marked with +

	Time	Cumulative Survival	Standard Error
1	1	0,909	0,087
2	2	0,818	0,116
3+	2		
4+	3		
5	4	0,701	0,147
6	4	0,584	0,163
7+	4		
8+	5		
9+	6		
10	7	0,292	0,222
11+	8		

Dolní mez IS:

Horní mez IS:

$$0,818 - 1,96 * 0,116 = 0,591 \quad 0,818 + 1,96 * 0,116 = 1,045$$

$$0,584 - 1,96 * 0,163 = 0,265 \quad 0,818 + 1,96 * 0,116 = 0,903$$


Závěr: 2-leté přežití: 81,8% (59,1%; 100,0%)
5-leté přežití: 58,4% (26,5%; 90,3%)

Upozornění

- Pokud horní mez intervalu spolehlivosti vyjde větší než 1 (tzn. 100%), je třeba toto číslo nahradit hodnotou 1 (resp. 100%).
- Pokud dolní mez intervalu spolehlivosti vyjde menší než 0 (tzn. 0%), je třeba toto číslo nahradit hodnotou 0 (resp. 0%).
- **Procento žijících lidí totiž nemůže být větší než 100% a menší než 0% !**

Křivka přežití – medián přežití

Medián přežití je čas od vstupní události, v němž je pravděpodobnost přežití 50%, tedy čas, kterého se podle očekávání dožije polovina sledovaných pacientů.




Závěr:

Medián přežití je 7 let.

(Tzn. čas, kterého se dožila polovina sledovaných pacientů, je 7 let.)

Křivka přežití – medián přežití v softwaru STATISTICA

Software STATISTICA provádí interpolaci – počítá aproximativní medián. Nevadí to, pokud je velký počet sledovaných událostí.



Survival Time	
25'th percentile (lower quartile)	3,2
50'th percentile (median)	4,9
75'th percentile (upper quartile)	6,2

Závěr:
Medián přežití je 4,9 let.




Poznámky

- **Sestrojovat křivky přežití za každou cenu je mnohdy zavádějící** – zvláště v případě použití stratifikačních kritérií vedoucích k nízkým N ve skupinách. è riziko zkreslení a dezinterpretace výsledků!!
- Podíl cenzorovaných pozorování je důležitou charakteristikou – je vhodné uvádět:
 - Podíl pacientů ztracených ze sledování (lost to follow-up).
 - Podíl pacientů „bez události“ na konci studie.
- S křivkami přežití by měla být vždy reportována **maximální a minimální doba sledování** dosažitelná ve studii (dáno začátkem náboru a datem ukončení studie) – samozřejmě ve vztahu k události, která nás zajímá.
- Je nutné mít na paměti **nízkou věrohodnost „konce“ křivky přežití** – zůstává-li ve studii 10 pacientů nebo méně, „skoky“ v přežití s každou další událostí jsou dramatické.


Srovnání křivek přežití

- Častým cílem klinického výzkumu je srovnání přežití dvou a více skupin pacientů
- Standardem v analýze klinických dat jsou opět neparametrické testy:
 - Log-rank test
 - Gehanův-Wilcoxonův test
- **Log-rank test** je zaměřen na srovnání očekávaných a pozorovaných počtů událostí v jednotlivých skupinách
- **Gehanův-Wilcoxonův test** umožňuje klást větší důraz na rozdíly v raných fázích sledování pacientů.

$S(t)$ v čase




Srovnání křivek přežití – ukázka



Srovnání dvou křivek přežití – příklad

- Příklad:** Srovnajte přežití pacientů, kteří byli léčeni dvěma různými preparáty.




Life Table for Group 1 and Group 2
(Data_preziti_2kat) Group 1: Code 1,
Group 2: Code 2

	Group 1: Cum.%	Group 2: Cum.%
1,00	100,0	100,0
1,78	90,9	100,0
2,56	81,3	100,0
3,33	81,3	100,0
4,11	56,3	87,5
4,89	56,3	87,5
5,67	56,3	72,9
6,45	56,3	72,9
7,22	28,2	72,9
8,00	28,2	

Srovnání třech křivek přežití – příklad

- **Příklad:** Srovnejte přežití pacientů se třemi diagnózami (CML, CLL a AML).



	Group 1	Group 2	Group 3
,50	100,0	100,0	100,0
1,33	90,9	100,0	62,5
2,17	81,3	100,0	62,5
3,00	81,3	100,0	46,9
3,83	81,3	100,0	28,1
4,67	56,3	86,7	0,0
5,50	56,3	72,2	0,0
6,33	56,3	72,2	0,0
7,17	28,2	72,2	0,0
8,00	28,2		0,0

Coxův model proporcionálních rizik

- Analýza vlivu prognostických faktorů onemocnění na přežití pacientů, na dosažení remise apod.
- **Příklad:** Testování vlivu binární proměnné (např. užívání léčby B) na celkové přežití.

Výsledek analýzy:

Variable	Hazard ratio (HR) (poměr rizik)	95% conf. Int.	P-value
DRUG B	2.18	1.4 – 3.5	0.001

Interpretace:

U pacientů užívajících v období před vstupem do studie přípravek B, je více jak dvojnásobně vyšší riziko úmrtí ve sledovaném období než u pacientů neužívajících přípravek B.

Coxův model proporcionálních rizik

- **Příklad:** Testování vlivu kategoriální proměnné (např. věk při diagnóze) na celkové přežití.

Výsledek analýzy:

Age group	HR	95% conf. Int.	P-value
1: [20-29]	1.0		
2: [30-34]	3.31	1.37-8.01	<0.001
3: [35-39]	3.72	1.51-9.14	<0.001
4: [40-54]	6.43	2.56-16.12	<0.001

Interpretace:

S rostoucím věkem při diagnóze roste riziko úmrtí ve sledovaném období. Nárůst rizika je vztažen k věkové skupině 20 - 29 let.

Coxův model proporcionálních rizik

- **Příklad:** Testování vlivu spojité **proměnné** (např. věk při diagnóze) na celkové **přežití**.

Výsledek analýzy:

Variable	HR	95% conf. Int.	P-value
AGE _[5 years interval]	1.50	1.3 – 1.8	<0.001



Interpretace:

Nárůst věku při diagnóze o 5 let zvyšuje riziko úmrtí 1,5-krát.

Coxův model proporcionálních rizik – důležité!

- Coxův model má smysl počítat, pokud se křivky přežití od sebe postupně oddalují. Pokud se křivky oddálí a pak se zase přiblíží nebo pokud se dokonce křivky překříží, tak nelze Coxův model pro výpočet poměru rizik (hazard ratio) použít!

OK



Coxův model proporcionálních rizik – příklad

- **Příklad:** Vypočtete poměr rizika úmrtí podle ECOG skóre.

Parameter Estimates (Data_Cox)								
	Standard Error	Chi-square	P value	95% Lower CL	95% Upper CL	Hazard Ratio	95% Hazard Ratio Lower CL	95% Hazard Ratio Upper CL
ECOG1	0,192764	20,60900	0,000006	0,497283	1,252903	2,399098	1,644247	3,500491