

8. Analýza rozptylu a korelace



Parametrická analýza rozptylu
Post hoc testy
Kruskal-Wallisův test
Korelace
Lineární regrese

Anotace



- **t-test** slouží pro porovnání průměrů spojité proměnné ve dvou (diskrétních) skupinách.
- **Analýza rozptylu (ANOVA)** umožňuje totéž porovnání provést pro větší počet (diskrétních) skupin.
- **Korelační analýza** je využívána pro vyhodnocení míry vztahu dvou spojitých proměnných.
- **Regresní analýza** vytváří model vztahu dvou nebo více proměnných, tedy jakým způsobem jedna proměnná (vysvětlovaná) závisí na jiných proměnných (prediktorech).

Regresní analýza je obdobně jako ANOVA nástrojem pro vysvětlení variability hodnocené proměnné.

Existují rovněž neparametrické varianty t-testu a ANOVy.

Analýza rozptylu - ANOVA



- Zobecnění dvouvýběrového t-testu
- ANOVA je základním nástrojem pro analýzu rozdílů mezi průměry v několika skupinách
- H_0 : všechny střední hodnoty jsou stejné
 H_A : alespoň jedna dvojice středních hodnot se liší
- Předpoklady: normální rozložení ve skupinách, nezávislost skupin, shoda rozptylů (Levenův či Bartlettův test)
- Pokud H_0 zamítáme na hl. význ. $\alpha \rightarrow$ nás zajímá, která dvojice středních hodnot se od sebe liší
 - metody mnohonásobného testování (tzv. post hoc testy), např. Scheffého, Tukeyova metoda

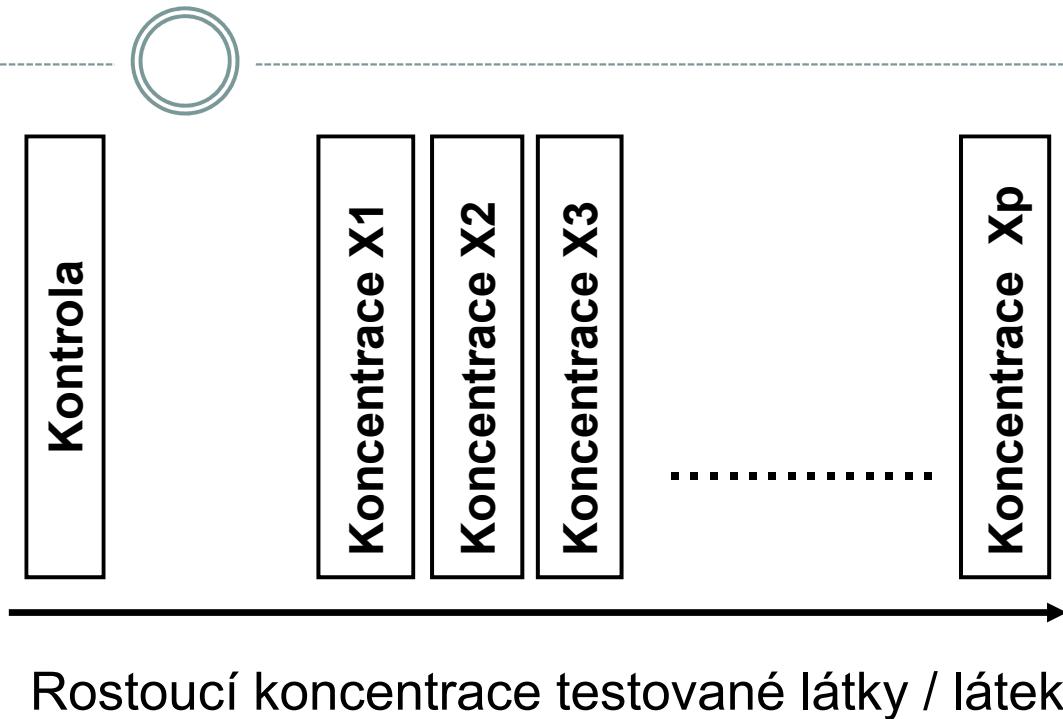
Anotace



- Základní myšlenka, na níž je ANOVA založena, je rozdělení celkové variability v datech (neznámé, dané pouze náhodným rozložením) na část systematickou (spjatou s kategoriemi pacientů, vysvětlená variabilita) a část náhodnou. Pokud systematická, tedy nenáhodná a vysvětlitelná část variability převažuje, považujeme daný kategoriální faktor za významný pro vysvětlení variability dat.
- Analýza rozptylu vyhodnocuje pouze celkový vliv faktoru na variabilitu, v případě analýzy jednotlivých kategorií je třeba využít tzv. post-hoc testy

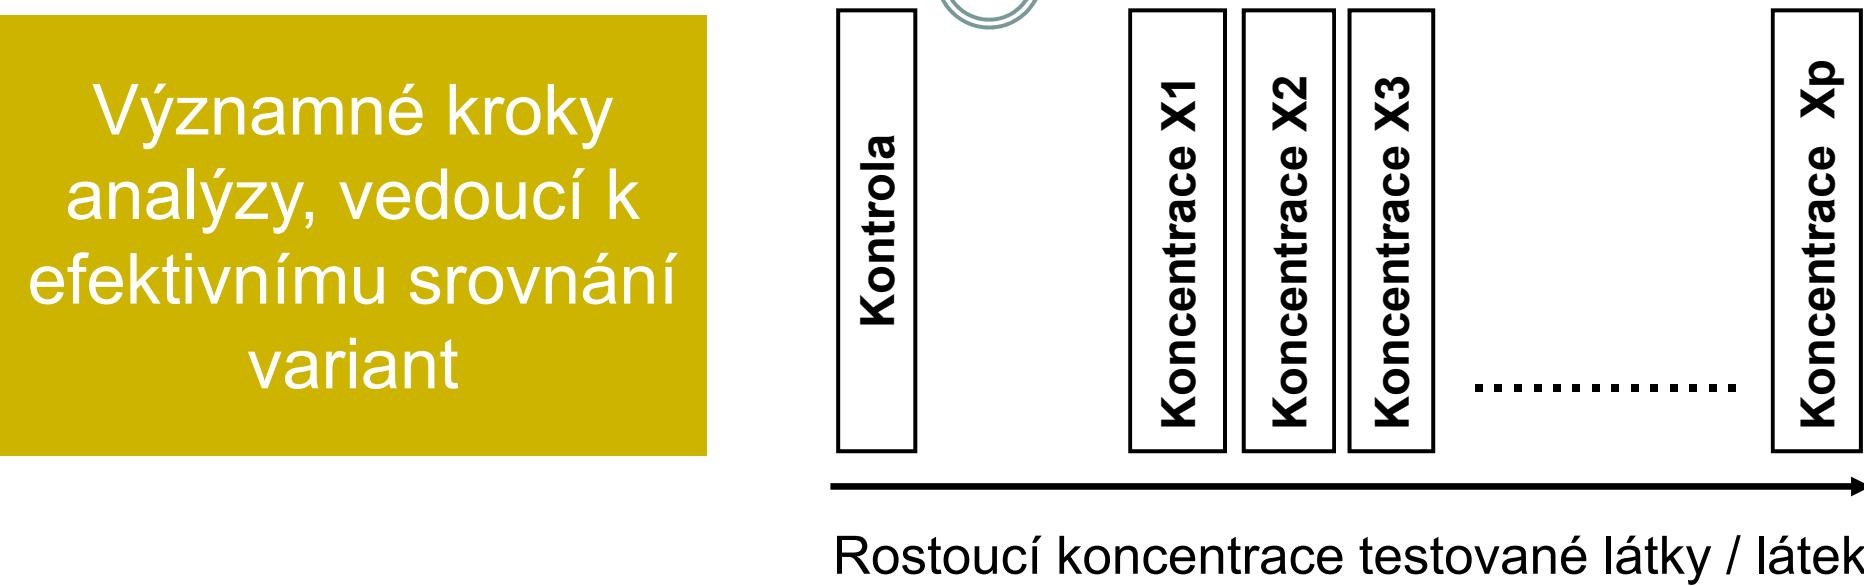
Analýza rozptylu - ANOVA

Základní technika
sloužící
k posouzení rozdílů
mezi více úrovněmi
pokusného zásahu



- ➡ Celkově významné změny v reakci biologického systému
- ➡ Vzájemné rozdíly účinku jednotlivých dávek
- ➡ Rozdíly účinku dávek od kontroly

Analýza rozptylu - ANOVA



- ➡ Splnění předpokladů analýzy
Transformace dat
- ➡ Relevantnost kontroly
(vliv vlastní aplikace látek)
- ➡ Vhodnost modelu ANOVA pro účely testu
- ➡ Vlastní srovnání variant
Minimalizace chyb při ověřování hypotéz

Analýza rozptylu - ANOVA

**SPLNĚNÍ PŘEDPOKLADŮ ANOVA JE NEZBYTNOU PODMÍNKOU
POUŽITÍ TÉTO TECHNIKY**

**ANOVA
= parametrická
analýza dat**

1. Předpoklad nezávislosti
opakování experimentu

2. Homogenita
rozptylu v rámci
pokusných variant

Normalita rozložení
3. v rámci pokusných
variant

ALTERNATIVOU JSOU NEPARAMETRICKÉ METODY

Analýza rozptylu - ANOVA

Předpoklady analýzy rozptylu jsou nezbytné pro dosažení sily testu

- **Symetrické rozložení hodnot a normalita odchylek** od hodnoceného modelu ANOVA.

Velkou část dat lze adekvátně normalizovat použitím logaritmické transformace. Předpoklad lognormální transformace může pochopitelně být teoreticky vyloučen u mnoha datových souborů obsahujících diskrétní parametry, kde je indikována vhodnost jiného typu transformace. U asymetricky rozložených a u diskrétních dat je nutné využít neparametrické alternativy analýzy rozptylu.

- **Statistická nezávislost reziduů**

vyhodnocovaného modelu ANOVA. Pokud odhad a posouzení korelačních vztahů mezi pokusnými variantami není přímo předmětem výzkumu, lze jejich vliv na vyhodnocení odstranit znáhodněním dat v rámci pokusných variant - tedy změnou pořadí v náhodné. Rozsah vlivu těchto autokorelačních vztahů musí být ovšem primárně omezen správností experimentálního uspořádání.

- **Homogenita rozptylu** je nutným předpokladem pro smysluplnost vzájemných srovnání pokusných variant. U testů toxicity by splnění tohoto předpokladu mělo být ověřováno (Bartlettův test), neboť vážné rozdíly (až řádové) v jednotkách testovaného parametru mohou nastat v důsledku inhibice dávkami látky. Nehomogenita rozptylu je často ve vztahu k nenormalitě (asimetrii) dat a lze ji odstranit vhodnou normalizující transformací.

- **Aditivita** jako předpoklad týkající se složitějších experimentálních uspořádání. Exaktní otestování aditivity více pokusných faktorů je procedura poměrně náročná na experimentální design vyvážený co do počtu opakování. Je rovněž obtížné testovat interakci na nestandardních datech, neboť případná transformace může změnit charakter odchylek původních dat od hodnoceného modelu ANOVA.

Analýza rozptylu - ANOVA

Omezení aplikace ANOVA lze řešit

- **Chybějící data.** Vážným problémem jsou chybějící údaje o celé skupině kombinací testovaných látek, například u faktoriálních pokusů, kdy je znemožněno hodnocení experimentu jako celku.
- **Různé počty opakování** Jde o typický jev pro experimentální datové soubory. Při různých počtech opakování v experimentálních variantách jsou testy ANOVA citlivější na nenormalitu dat. Pokud jsou počty opakování zcela odlišné (až řádové rozdíly), je nutno použít neparametrické techniky nebo analýzu rozptylu nevyvážených pokusů.
- **Odlehlé hodnoty.** Ojedinělé odlehlé hodnoty musí být před parametrickou analýzou rozptylu vyloučeny.
- **Nedostatek nezávislosti mezi rezidui modelu.** Jde o závažný nedostatek, zkreslující výsledek F-testu. Velmi často je tato skutečnost důsledkem špatného provedení nebo naplánování experimentu.

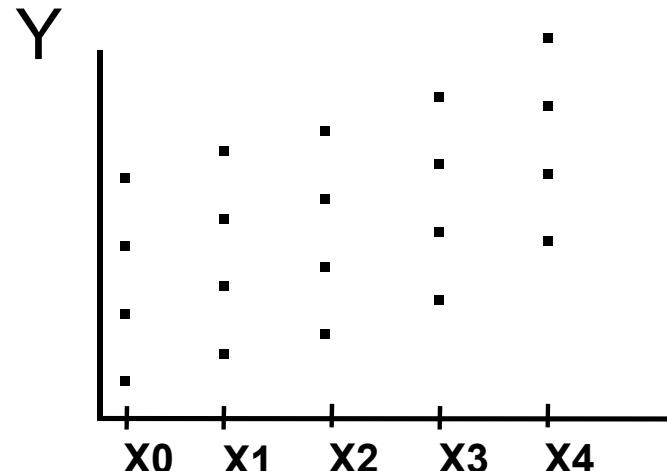
- **Nehomogenita rozptylu.** Velmi častý nedostatek experimentálních dat, často související s nenormalitou rozložení nebo s odlehlými hodnotami.
- **Nenormalita dat.** I v tomto případě lze situaci upravit vyloučením odlehlých hodnot nebo normalizující transformací.
- **Neadditivita kombinovaného vlivu více pokusných zásahů.** Tuto situaci lze testovat jednak speciálními testy aditivity nebo přímo F testem kontrolujícím významnost vlivu interakce pokusných zásahů. Při významné interakci je nutné prozkoumat především její charakter ve vhodném experimentálním uspořádání.

Modeły analýzy rozptylu

Model I. Pevný model

$x_0 \ x_1 \ x_2 \ x_3 \ x_4$

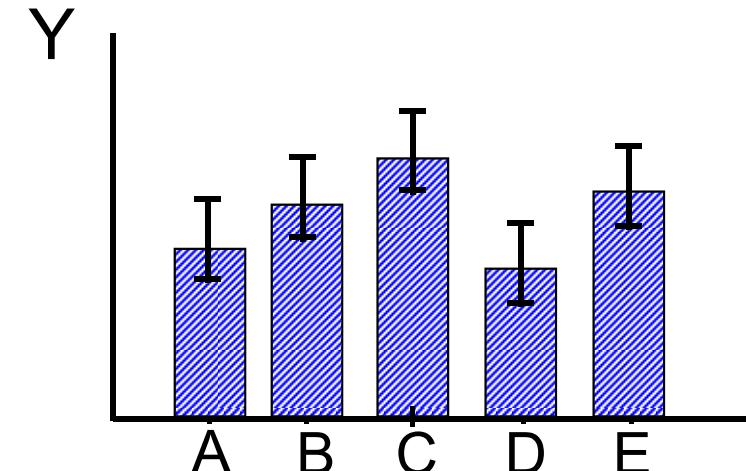
$$y_{ij} = \mu + \alpha_i + \epsilon_{ij}$$



Model II. Náhodný model

A B C D E

$$y_{ij} = \mu + A_i + \varepsilon_{ij}$$



ANOVA – základní výpočet



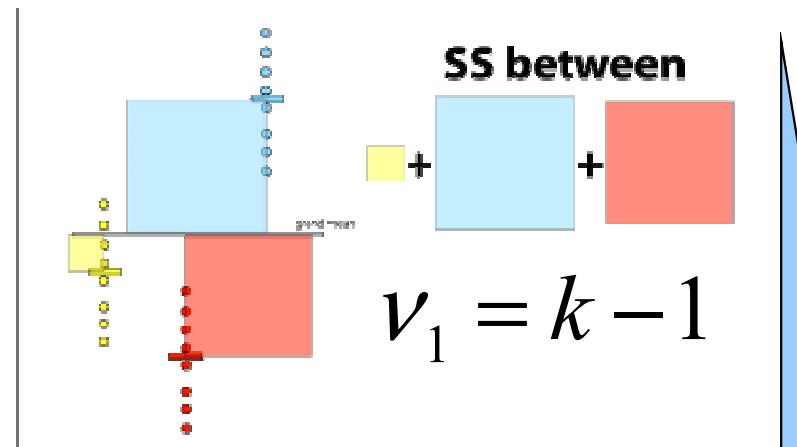
- Základním principem ANOVY je porovnání rozptylu připadajícího na:

- Rozdělení dat do skupin (tzv. effect, variance between groups)
 - Variabilitu objektů uvnitř skupin (tzv. error, variance within groups), předpokládá se, že jde o náhodnou variabilitu (=error)

1. Variabilita mezi skupinami

Rozptyl je počítán pro celkový průměr (tzv. grand mean) a průměry v jednotlivých skupinách dat

Stupně volnosti jsou odvozeny od počtu skupin (= počet skupin - 1)

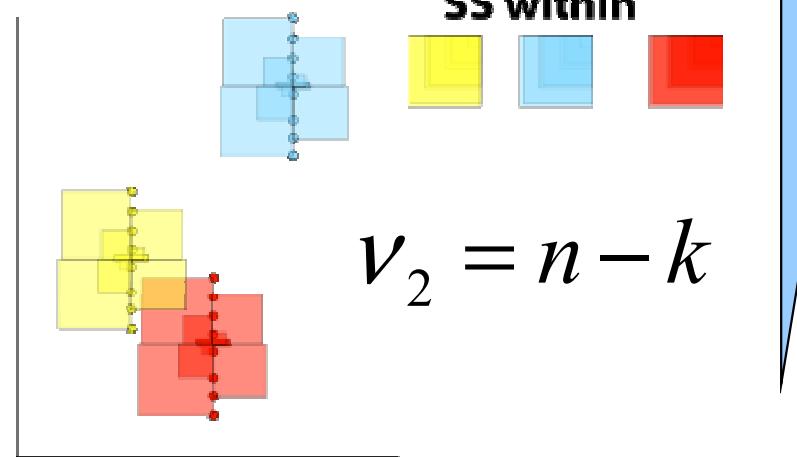


$$F = \frac{\text{between_groups}}{\text{within_groups}}$$

2. Variabilita uvnitř skupin

Rozptyl je počítán pro průměry jednotlivých skupin a objekty uvnitř příslušných, celková variabilita je pak sečtena pro všechny skupiny

Stupně volnosti jsou odvozeny od počtu hodnot (= počet hodnot - počet skupin)



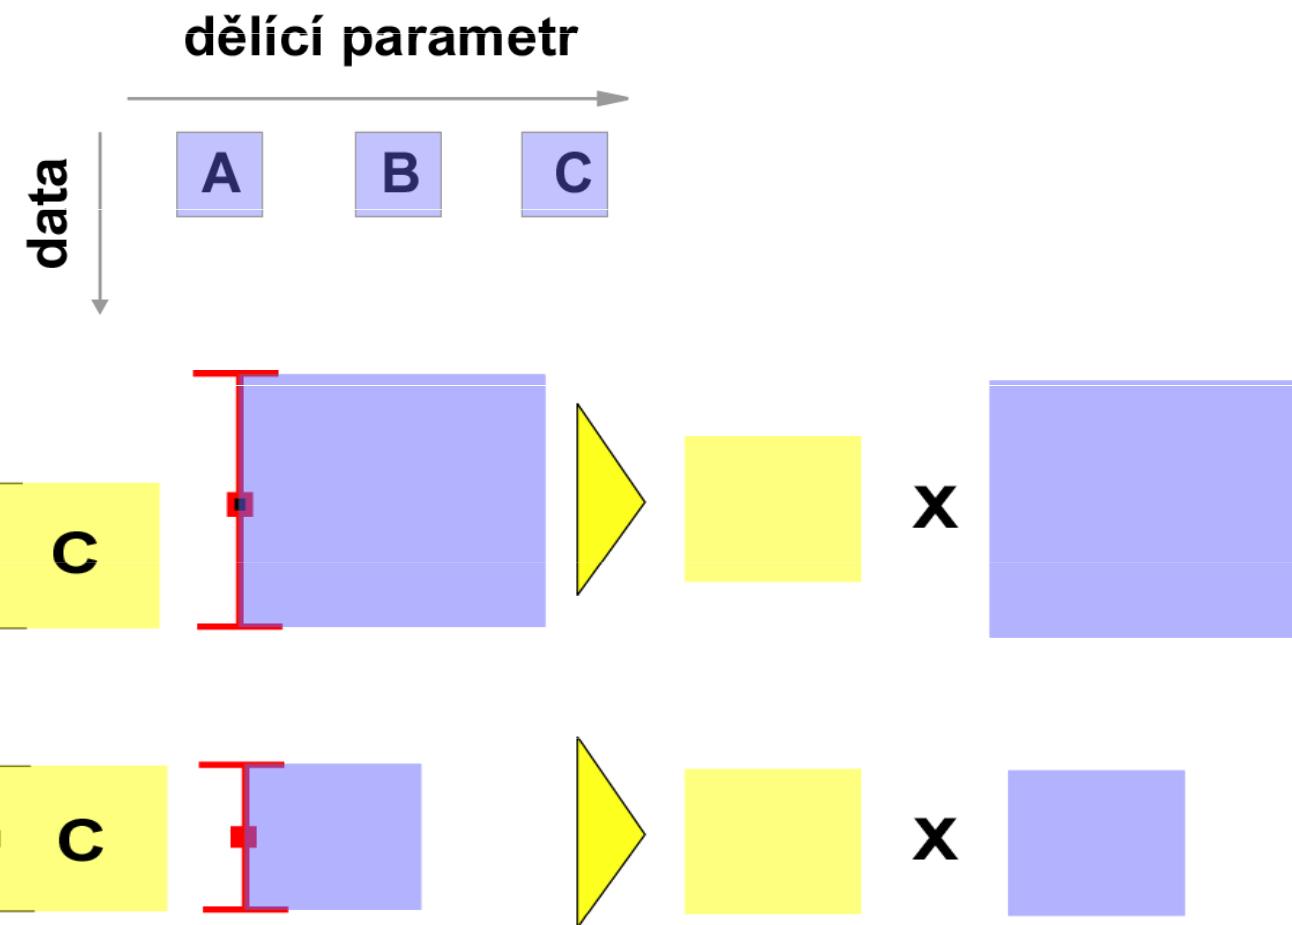
Výsledný poměr (F) porovnáme s tabulkami F rozložení pro V_1 a V_2 stupňů volnosti

SS = sum of squares

Jednoduchý ANOVA design



Nejjednodušším případem ANOVA designu je rozdělení na skupiny podle jednoho parametru.



Nested ANOVA

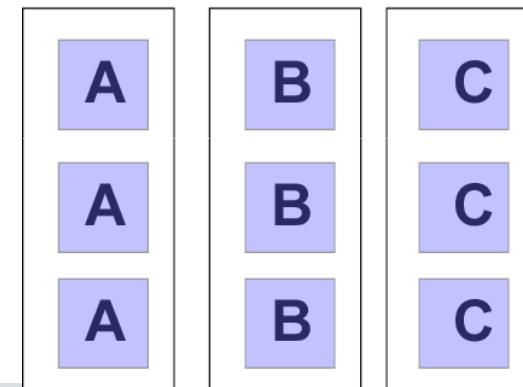


- Rozdělení skupin na náhodné podskupiny (např. opakování experimentu), podskupiny jsou vždy v jedné skupině (ne kartézský součin).
- Cílem je zjistit, zda data v jedné skupině nejsou pouhou náhodou
- Nejprve je testována shoda podskupin v hlavních skupinách,
 - pokud jsou shodné, je vše v pořádku
 - pokud nejsou, stále lze zjišťovat, zda se variabilita uvnitř hlavních skupin liší od celkové variability

jednoduchá ANOVA



nested ANOVA



Two way ANOVA



Pro rozdělení do kategorií je zde více parametrů (možné jsou všechny varianty kartézského součinu).

Na rozdíl od nested ANOVY nejde o náhodná opakování experimentu, ale o řízené zásahy (např.vliv pH a koncentrace O₂)

Kromě vlivu hlavních faktorů se uplatňuje i jejich interakce

faktor 1

		A	B	C
faktor 2	1			
	2			

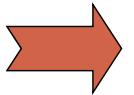
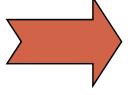


interakce

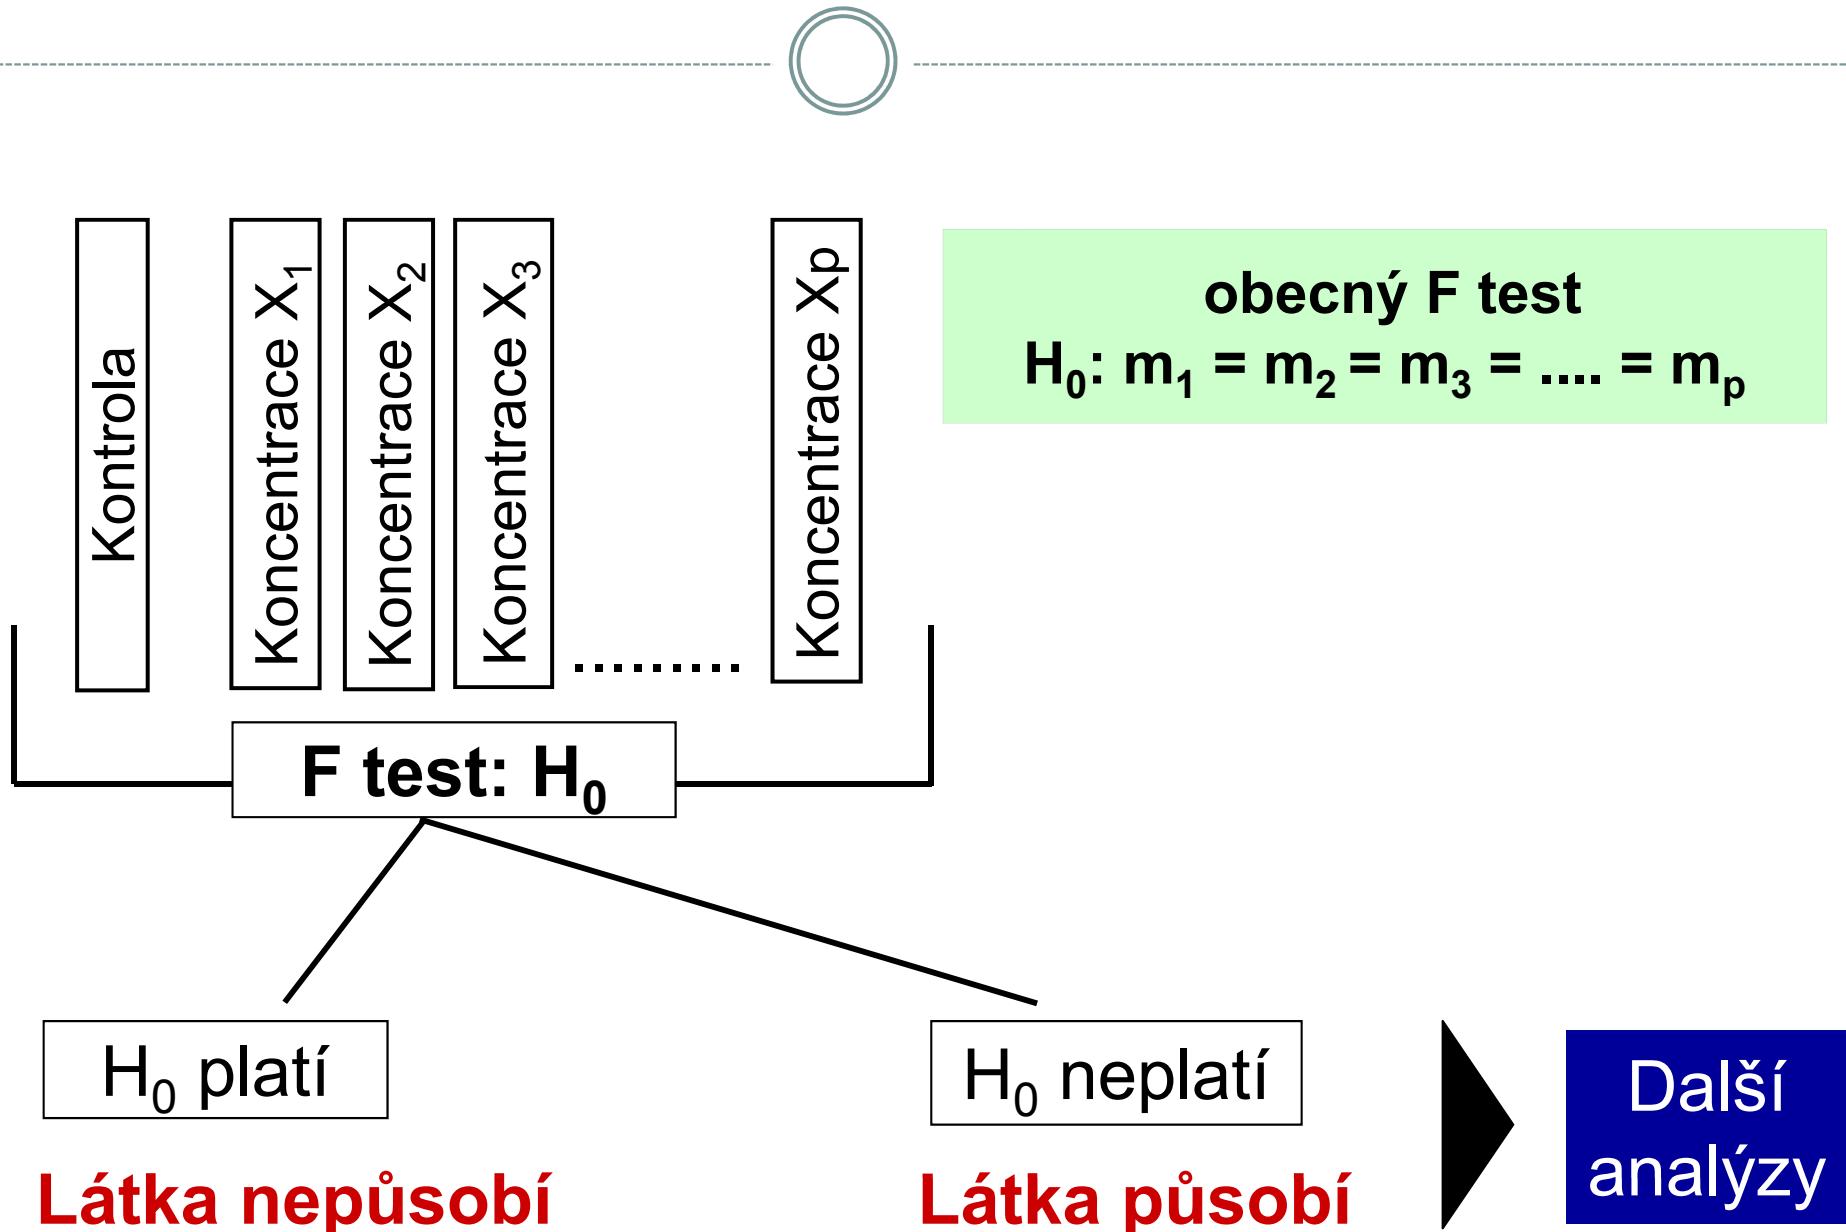
Modeły analýzy rozptylu - základní výstup

*Základním výstupem analýzy rozptylu je
Tabulka ANOVA - frakcionace komponent rozptylu*

Zdroj rozptylu	St. v.	SS	MS	F
Pok. zásah (mezi skupinami)	a - 1	SS_B	$SS_B/(a - 1)$	MS_B/MS_E
Uvnitř skupin	N - a	SS_E	$SS_E/(N - a)$	
Celkem	$N - 1$			SS_T

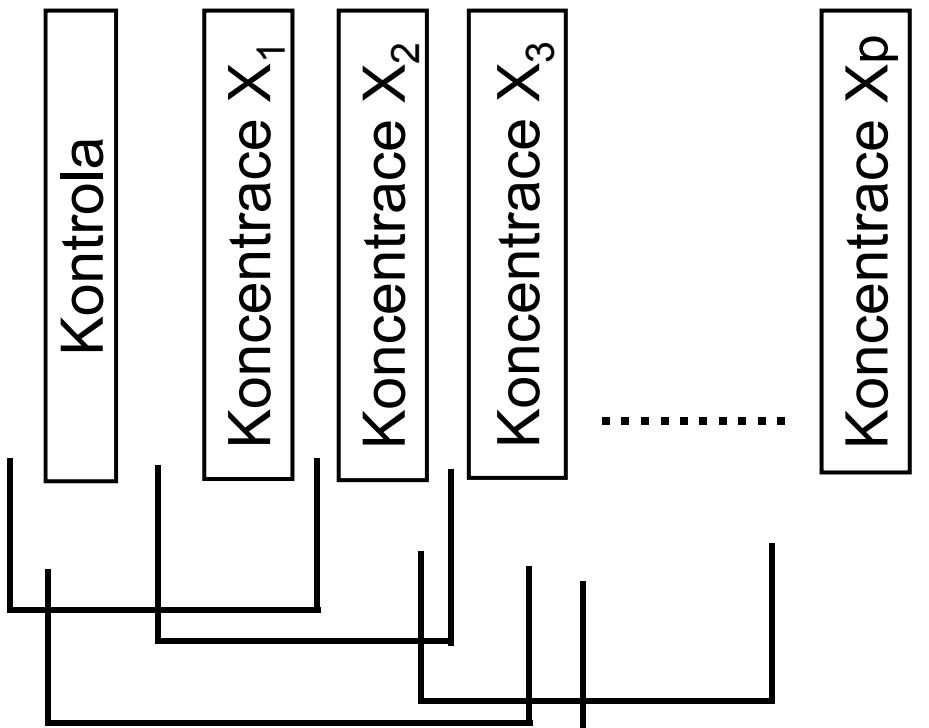
- SS_B/SS_T  Kvantifikovaný podíl rozdílu mezi pokusnými zásahy na celkovém rozptylu
- MS_B/MS_T  Statistická významnost rozdílu

Analýza rozptylu - obecný F test



Analýza rozptylu - Testy kontrastů

ANOVA: H_0 zamítnuta
Testy kontrastů



Plánované

Neplánované

Pro srovnání variant
s kontrolou

Testování kontrastů
"Multiple range testy"

Parametrické

Neparametrické

Rozdíly v smysluplných
kombinacích ?

Příklad: Anova - One way



Dávka rostlinného stimulátoru (0, 4, 8, 12 mg/l)

A = 4 ; n = 8

I. ANOVA

Bartlett's test: P = 0,9847

K-S test: P = 0,482 - 0,6525 pro jednotlivé kategorie

Source	D. f.	SS	MS	F
Between Groups	3	305,8	101,9	8,56
Within Groups	28	322,2	11,9	
Total (corr.)	31	638,0		

II. Multiple Range Test

NKS -test

Level	Average	Homogenous Groups
0	34,8	x
4	41,4	x
12	41,8	x
8	52,6	x

Srovnání variant v testech

Srovnávání variant po celkovém testu ANOVA

Mnoho existujících algoritmů není vhodných pro konkrétní případ

Day and Quin
Ecological Monographs, 1989

Test	Využití	Poznámka	Testy pro jednoduché kontrasty			Testy nevhodné		
Dunnett Williams	Srovnání s kontrolou	Ex. i modifikace pro různá n.	Scheffe	Tukey	LSD	Bonferroni	Dunn- Sidák	Kramer
ANOVA testy (F)	Orthogonální kontrasty	Plánovaná srovnání	Duncan	Student - Newmann-Keuls	Waller-Duncan k ratio			
Ryan Q test	Jednoduché kontrasty	Vyhodnocen jako nejlepší test						

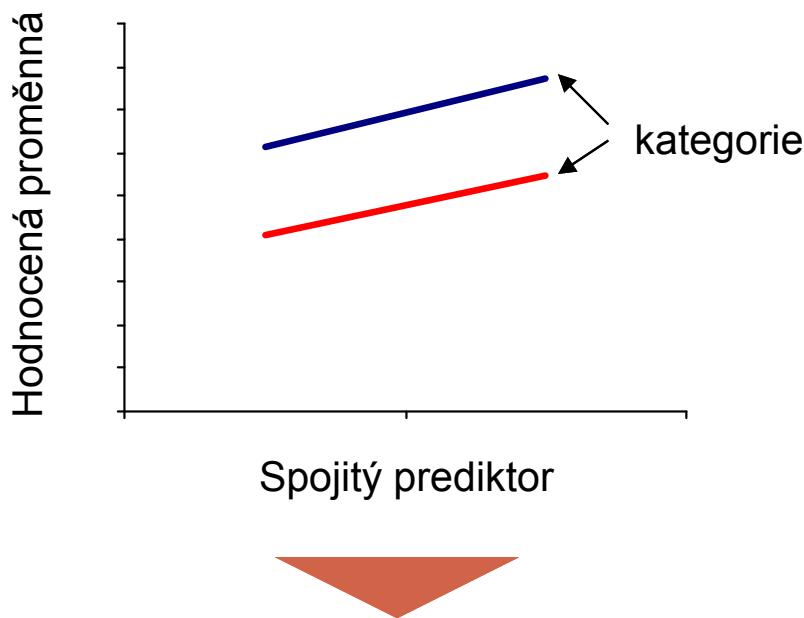
Řada post-hoc testů v různých SW

The image displays three windows from different statistical software packages, each showing a list of post-hoc test methods:

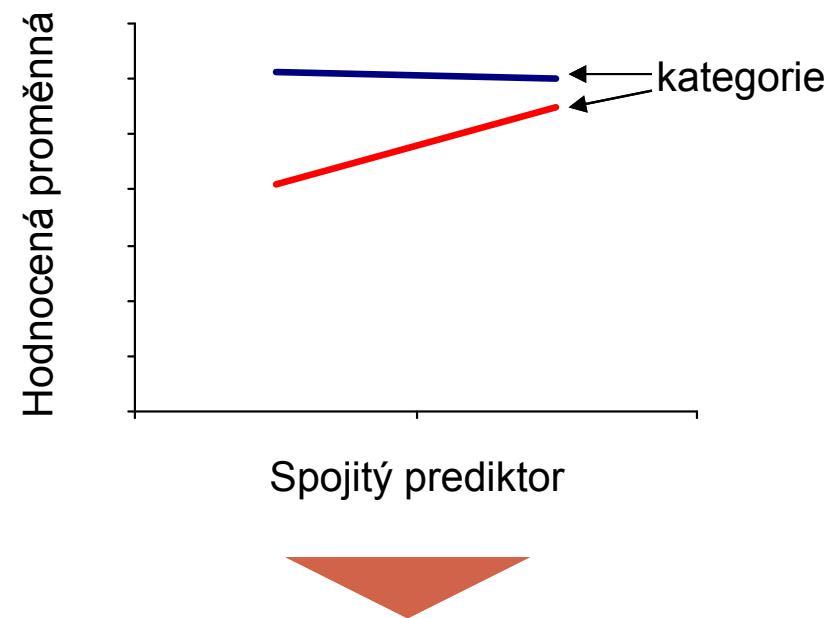
- SAS:** A window titled "One-Way ANOVA for PRODUCTS" under "Means > Comparison". It lists various post-hoc test methods such as Bonferroni t test, Tukey's studentized range test (HSD), Duncan's multiple-range test, Dunnett's t test, Fisher's least significant-difference test, Gabriel's multiple-comparison procedure, Student-Newman-Keuls multiple range test, Waller-Duncan k-ratio t test, Scheffé's multiple comparison procedure, and Ryan-Einot-Gabriel-Welsch multiple-range test.
- StatSoft:** A window titled "ANOVA Results 1: srovnání hmotnosti ovcí" under "Post-hoc". It shows a list of dependent variables (Hmotnost) and various display options like "Significant differences", "Homogeneous groups", and "Confidence intervals". It also includes error term options (Between error, Within error, Between; within; pooled, MS) and range tests (Fisher LSD, Bonferroni, Tukey HSD, Unequal N HSD).
- SPSS:** A window titled "One-Way ANOVA: Post Hoc Multiple Comparisons". It is divided into two sections: "Equal Variances Assumed" and "Equal Variances Not Assumed". Under "Equal Variances Assumed", it lists LSD, Bonferroni, Sidak, Scheffe, R-E-G-W F, R-E-G-W Q, S-N-K, Tukey, Tukey's-b, Duncan, Hochberg's GT2, and Waller-Duncan. It also includes options for Type I/Type II Error Ratio (100), Dunnett, Control Category (Last), Test (2-sided, < Control, > Control), and CG cell # (1). Under "Equal Variances Not Assumed", it lists Tamhane's T2, Dunnett's T3, Games-Howell, and Dunnett's C. At the bottom, it shows a significance level of .05 and buttons for Continue, Cancel, and Help.

ANCOVA

- Rozšíření ANOVA
- Současná analýza kategoriálních a spojитých prediktorů
- Testování hypotézy paralelismu regresních vztahů



Kategorie pacientů (pokusný zásah)
neovlivňuje vztah proměnných



Kategorie pacientů (pokusný zásah)
ovlivňuje vztah proměnných

Korelace a regrese



- Korelační analýza je využívána pro vyhodnocení míry vztahu dvou spojitých proměnných. Obdobně jako jiné statistické metody, i korelace mohou být parametrické nebo neparametrické
- Regresní analýza vytváří model vztahu dvou nebo více proměnných, tedy jakým způsobem jedna proměnná (vysvětlovaná) závisí na jiných proměnných (prediktorech). Regresní analýza je obdobně jako ANOVA nástrojem pro vysvětlení variability hodnocené proměnné

Korelace



- K měření těsnosti lineárního vztahu 2 spojitych proměnných
 - $r = 0 \rightarrow$ nekorelované
 - $r > 0 \rightarrow$ kladně korelované
 - $r < 0 \rightarrow$ záporně korelované
- H_0 : proměnné X, Y jsou stochasticky nezávislé náhodné veličiny
 $(r = 0)$
 H_A : proměnné X, Y nejsou stochasticky nezávislé náhodné veličiny
 $(r \neq 0)$
- Parametrický korelační koeficient:
Pearsonův kor. koef. (dvourozměrné normální rozložení)
- Neparametrické korelační koeficienty:
Spearmanův (pořadový) kor. koef., **Kendallovo tau**.

Jednoduchá lineární regrese

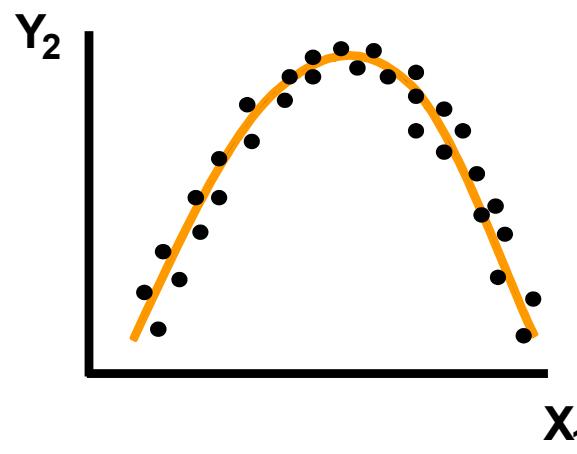
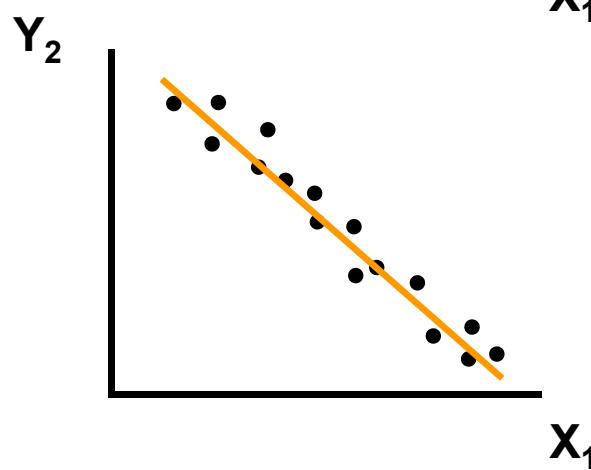
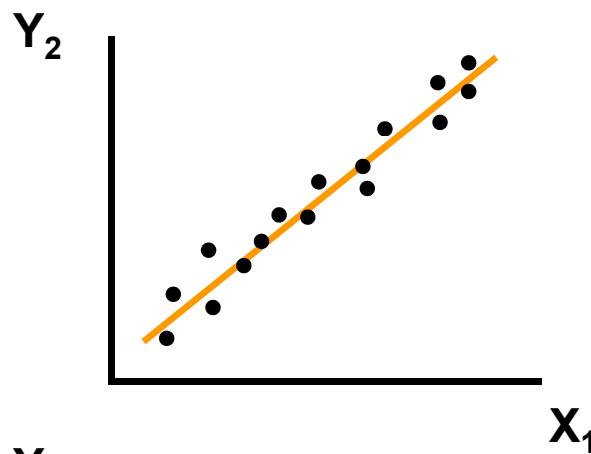


- V případě existence vzájemného vztahu (korelace) lze tento vztah podrobněji popsát.
- Cíl regresní analýzy: popsát závislost hodnot proměnné Y na hodnotách proměnné X.
- V případě lineární regrese je tento popis dán lineárním modelem tvaru $y = ax + b$.
- Existují i techniky nelineární regrese.
- Nemáme-li dostatek informací k teoretickému souboru, snažíme se odhadnout typ funkce pomocí dvouozměrného diagramu.

Základy korelační analýzy - I.



Korelace – vztah (závislost) dvou znaků (parametrů)



X_2	X_1	ANO	NE
ANO	a	b	
NE	c	d	

Základy korelační analýzy - II.

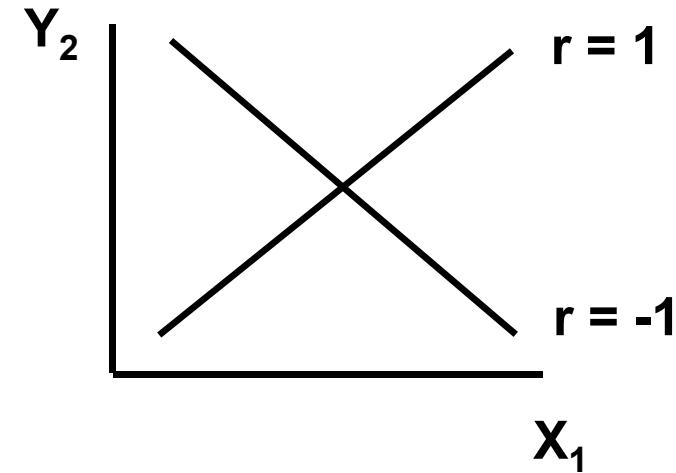
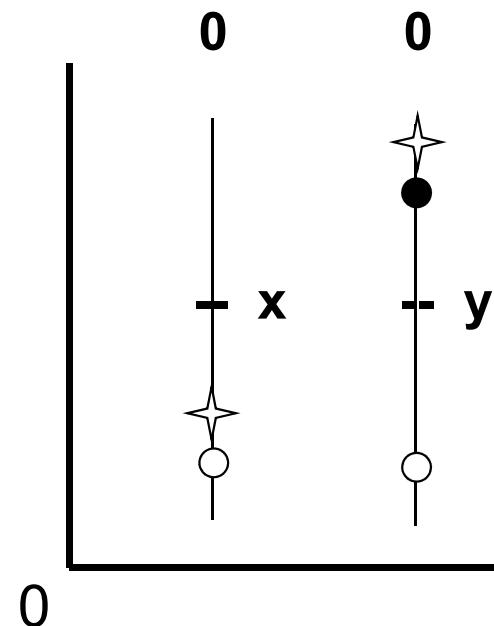


Parametrické míry korelace

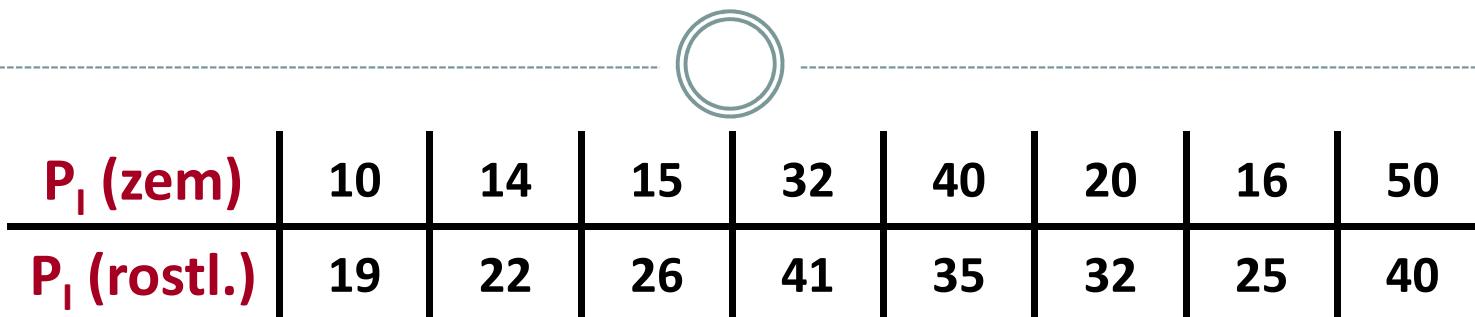
Kovariance

$$Cov(x, y) = E(x_i - \bar{x}).(y_i - \bar{y})$$

Pearsonův
koeficient korelace



Základy korelační analýzy - III.



$$I = 1, \dots, n; n = 8; v = 6$$

$$r = \frac{Cov(x, y)}{S_x \cdot S_y} = \frac{\sum x_i y_i - \frac{1}{n} \sum x_i \sum y_i}{\sqrt{\left[\sum x_i^2 - \frac{1}{n} (\sum x_i)^2 \right] \left[\sum y_i^2 - \frac{1}{n} (\sum y_i)^2 \right]}} = 0,7176$$

I. $H_0 : \rho = \phi : \alpha = 0,05$

tab : $r(v=6) = 0,7076$

II. $H_0 : \rho = \phi$

$$t = \left[\frac{r}{\sqrt{1 - r^2}} \right] \cdot \sqrt{n - 2} \quad v = n - 2$$

$$t = \frac{0,7176}{0,6965} \cdot \sqrt{6} = 2,524 \quad \left. \begin{array}{c} P \\ \leq \\ 0,05 \end{array} \right\}$$

tab : $t_{0,975}^{(n-2)} = 2,447$

Základy korelační analýzy - IV.

Srovnání dvou korelačních koeficientů (r)

1. $n_1 = 1258$

$r_1 = 0,682$

2. $n_2 = 462$

$r_2 = 0,402$

Krevní tlak x koncentrace kysl. radikálů

$$Z_i = 1.1513 \cdot \log \frac{(1 + r_i)}{(1 - r_i)}$$

$Z_1 = 0,833$



$Z_2 = 0,426$

Test: $H_0: \rho_1 = \rho_2 ; \alpha = 0,05$

$$Z = \frac{Z_1 - Z_2}{\sqrt{\frac{1}{n_1 - 3} + \frac{1}{n_2 - 3}}} = \frac{0,407}{0,0545} = 7,461$$

tabulky : $Z_{0,975} = 1,96$

7,461 >> 1,96 => P << 0,01

Základy korelační analýzy - V.

Neparametrická korelace (rs)



P_i v půdě	1	2	3	6	7	5	4	8
P_i v rostl.	1	2	4	8	6	5	3	7
d_i	0	0	1	2	-1	0	-1	-1

$$i = 1, \dots, n; \quad n = 8 \Rightarrow v = 6$$

$$r_s = 1 - \frac{6 \cdot \sum di^2}{n(n^2 - 1)} = 0,9048$$

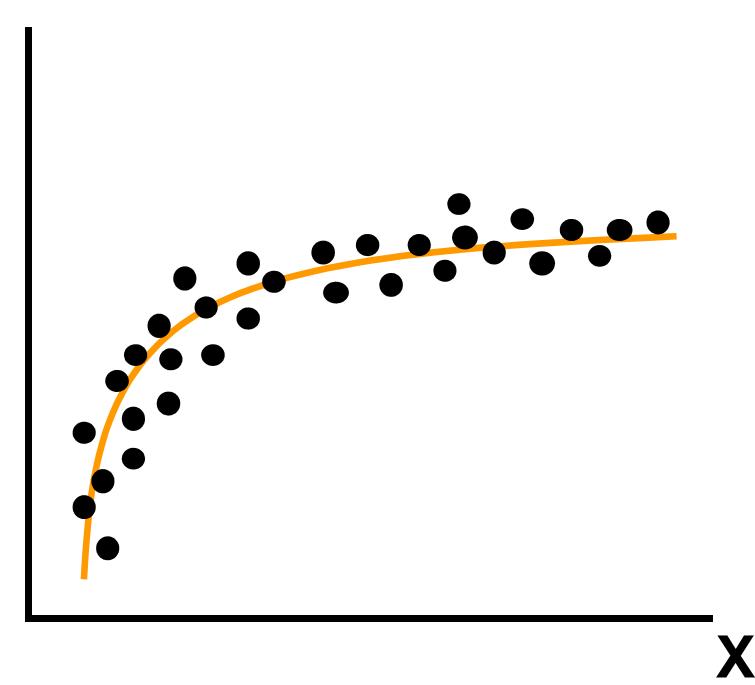
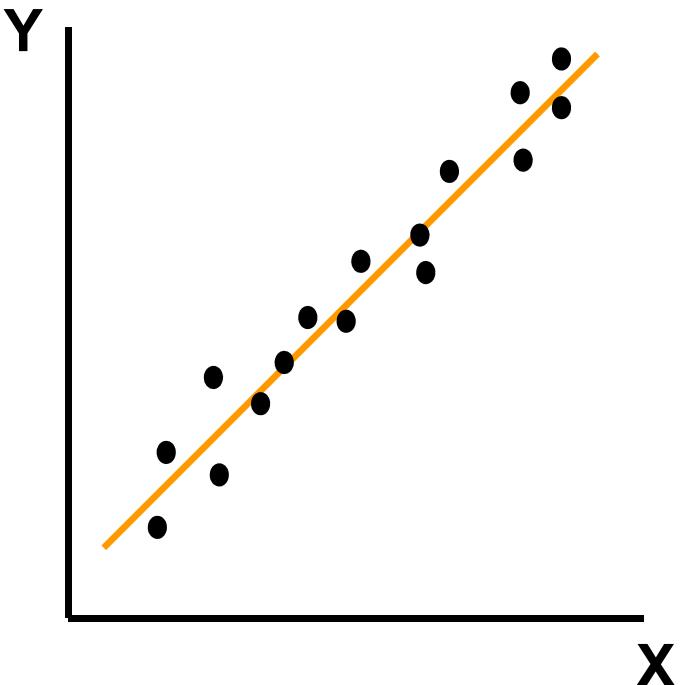
$$\text{tab : } r_s(v=6) = 0,89$$

Pacient č.	1	2	3	4	5	6	7
Lékař 1	4	1	6	5	3	2	7
Lékař 2	4	2	5	6	1	3	7
d_i	0	-1	1	-1	2	-1	0

$$r_s = 1 - \frac{6 \cdot 8}{7(49 - 1)} = 0,857$$

P = 0,358

Korelace v grafech I.



Vztahy velmi často implikují funkční vztah mezi Y a X.

$$Y = a + b \cdot X$$

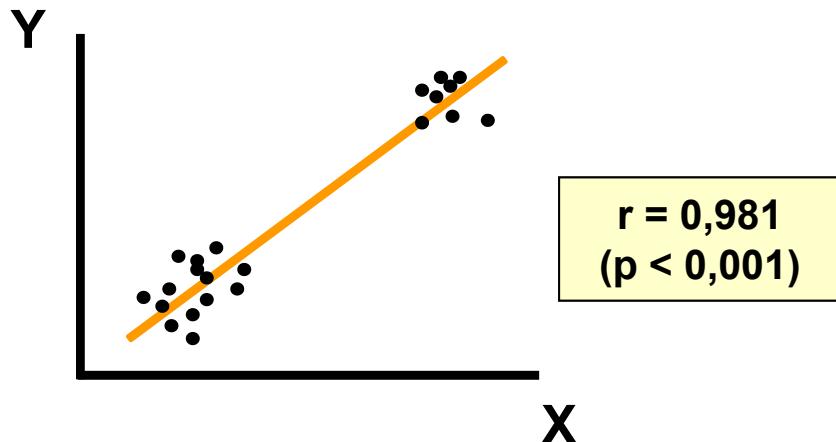
$$Y = a + b_1 \cdot X_1 + b_2 \cdot X_2 + b_3 \cdot X_3$$

$$Y = a + b_1 \cdot X_1 + b_2 \cdot X_2$$

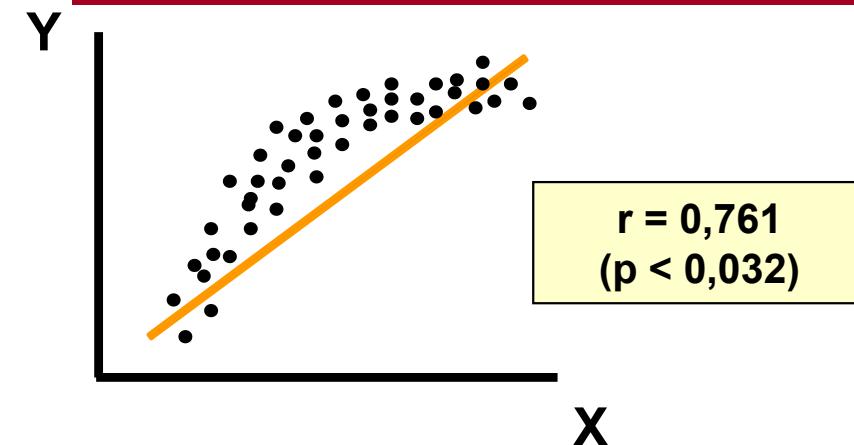
$$Y = a + b_1 \cdot X_1 + b_2 \cdot X_2 + b_3 \cdot X_1 \cdot X_2$$

Korelace v grafech II.

Problém rozložení hodnot



Problém typu modelu



Problém velikosti vzorku

