

## Nové možnosti rozvoje vzdělávání na Technické univerzitě v Liberci

Specifický cíl A3: Tvorba nových profesně zaměřených studijních programů

**NPO\_TUL\_MSMT-16598/2022**



## Analýza závislostí – část 3

Ing. Vladimíra Hovorková Valentová, Ph.D.

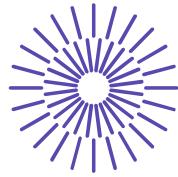


Financováno  
Evropskou unií  
NextGenerationEU



Národní  
plán  
obnovy

MŠMT  
MINISTERSTVO ŠKOLSTVÍ,  
MLÁDEŽE A TĚLOVÝCHOVY



## Analýza závislostí číselných proměnných (regresní a korelační analýza)

- zkoumání závislosti dvou event. více proměnných, měření síly této závislosti, atd.
- cílem je hlubší vniknutí do podstaty sledovaných jevů a procesů, přiblížení k tzv. příčinným souvislostem.

### Korelační tabulka

- dvourozměrná tabulka, ve které jsou uspořádány numerické proměnné.

#### **Korelační tabulka**

$x_i \backslash y_j$	$y_1$	$y_2$	$\dots$	$y_l$	Součty četností $n_{i\bullet}$
$x_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1l}$	$n_{1\bullet}$
$x_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2l}$	$n_{2\bullet}$
.	.	.	.	.	.
.	.	.	.	.	.
.	.	.	.	.	.
$x_k$	$n_{k1}$	$n_{k2}$	$\dots$	$n_{kl}$	$n_{k\bullet}$
Součty četností $n_{\bullet j}$	$n_{\bullet 1}$	$n_{\bullet 2}$	$\dots$	$n_{\bullet l}$	$n$

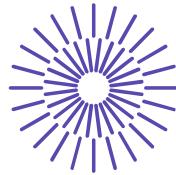
#### Symbolika:

$n_{ij}$  ..... sdružené (simultánní) absolutní četnosti

$n_{i\bullet}$ ,  $n_{\bullet j}$  ..... okrajové (marginální) absolutní četnosti

$$n_{i\bullet} = \sum_{j=1}^l n_{ij}; \quad n_{\bullet j} = \sum_{i=1}^k n_{ij}$$

$$\sum_{i=1}^k n_{i\bullet} = \sum_{j=1}^l n_{\bullet j} = \sum_{i=1}^k \sum_{j=1}^l n_{ij} = n$$



### Podmíněné rozdělení četnosti:

Rozdělení četností jedné proměnné, které odpovídá určité obměně druhé proměnné (tj. za podmínky, že druhá proměnná nabyla určité obměny).

$$\text{Podmíněný průměr: } \bar{y}_i = \frac{\sum_{j=1}^l y_j n_{ij}}{n_{i\bullet}}$$

$$\text{Podmíněný rozptyl: } s_i^2 = \frac{\sum_{j=1}^l (y_j - \bar{y}_i)^2 n_{ij}}{n_{i\bullet}}$$

### Grafické znázornění dvourozměrného rozdělení četností

- je další formou popisu závislosti;

- různé typy grafů:

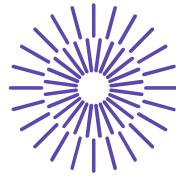
- ❖ **čára podmíněných průměrů,**
- ❖ **čára podmíněných rozptylů,**
- ❖ **bodový graf (diagram).**

## Regresní analýza

- zkoumání jednostranné závislosti proměnné  $y$  (závislá, vysvětlovaná) na proměnné  $x$  (nezávislá, vysvětlující), resp. na proměnných  $x_1, x_2, \dots, x_k$ ;
- nezávislá proměnná = příčina, závislá proměnná = důsledek;
- důležitý je přitom směr závislosti, tzn. která proměnná je závislá, a která nezávislá;
- závislost většinou modelujeme nějakou matematickou funkcí (tzv. regresní funkce).

### Postup regresní analýzy:

1. Volba typu regresní funkce.
2. Odhad parametrů zvolené regresní funkce.
3. Testování hypotéz o parametrech regresní funkce.
4. Ověření vhodnosti zvoleného regresního modelu.



## Jednoduchá regresní analýza

### 1. Volba typu regresní funkce

- při volbě typu regresní funkce lze uplatnit různá kritéria;
- volba by se měla v prvé řadě opírat o určitou teorii, tzn. vyplývat z věcného rozboru vztahů proměnných;
- vždy se snažíme o jednoduchost modelu (ne příliš mnoho parametrů);
- je třeba změřit vhodnou charakteristikou přilnavost regresní funkce k datům.

### 2. Odhad parametrů regresní funkce

#### Regresní modely

- matematické modely, které vyjadřují představu o průběhu závislosti proměnných;
- umožňují odhady neznámých hodnot závisle proměnné  $y$  ze známých hodnot nezávisle proměnné  $x$ , resp. nezávisle proměnných  $x_1, x_2, \dots, x_k$ .

#### Obecný tvar modelu:

$$y_i = \eta_i + \varepsilon_i = \eta(x_i) + \varepsilon_i, \quad i = 1, 2, \dots, n.$$

**Symbolika:**  $\eta_i$  ... deterministická složka

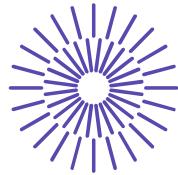
$\varepsilon_i$  ... náhodná (rušivá) složka

**Typy modelů:** 1. aditivní (součtový) – jeho složky se skládají sčítáním, je nejčastější.

2. multiplikativní (součinový) – jeho složky se skládají násobením.

#### Teoretická regresní funkce: $\eta = \eta(x)$

- existují různé typy regresních funkcí;
- nejčastější jsou lineární regresní funkce;
- linearita se může hodnotit jak z hlediska proměnných, tak z hlediska parametrů;



- každá regresní funkce má určitý počet parametrů (jejich počet je  $p$ ).

**Parametry regresní funkce:**

- neznámé konstanty; symbolicky je značíme řeckými písmeny  $(\beta_0, \beta_1, \dots, \beta_k)$ ;
- jejich hodnoty lze odhadnout z výběrových dat;
- k jejich odhadu je třeba zvolit takovou metodu, aby odhady měly co nejlepší vlastnosti.

**1) Funkce lineární z hlediska parametrů**

**přímka**  $\eta = \beta_0 + \beta_1 x$

**rovina**  $\eta = \beta_0 + \beta_1 x_1 + \beta_2 x_2$

**nadrovina**  $\eta = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$

**parabola**  $\eta = \beta_0 + \beta_1 x + \beta_2 x^2$

**hyperbola**  $\eta = \beta_0 + \beta_1 x^{-1}$

**logaritmická funkce**  $\eta = \beta_0 + \beta_1 \ln x$

**polynom**  $\eta = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_k x^k$

**2) Funkce nelineární z hlediska parametrů**

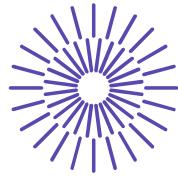
**exponenciální funkce**  $\eta = \beta_0 \beta_1^x$

**mocninná funkce**  $\eta = \beta_0 x^{\beta_1}$

**Törnquistova křivka**  $\eta = \frac{\beta_0 x}{x + \beta_1}$

**I. Jednoduchá lineární regrese**

- regresní funkce je lineární z hlediska parametrů;
- má jednu vysvětlující proměnnou (regresor)  $x$ .



**Teoretická (hypotetická) regresní funkce:**  $\eta = \beta_0 + \beta_1 x$

-  $\beta_0, \beta_1 \dots$  parametry;  $x \dots$  regresor

- nutno provést odhad teoretické regresní funkce, tzn. odhad neznámých parametrů  $\beta_0, \beta_1$ ;

- nejlepší metodou odhadu parametrů lineární regresní funkce je **metoda nejmenších čtverců**;

- takový postup zaručí, že výběrová regresní funkce bude co nejlépe přiléhat k výběrovým hodnotám.

**Empirická (výběrová) regresní funkce:**  $\hat{\eta} = Y = b_0 + b_1 x$

$b_0, b_1 \dots$  odhad parametrů;  $b_0 = \hat{\beta}_0; b_1 = \hat{\beta}_1$

- odhad parametrů se provádí metodou nejmenších čtverců;

- když odhadneme parametry, získáme tzv. výběrovou regresní funkci.

### Metoda nejmenších čtverců

- lze ji použít pouze k odhadu parametrů funkcí lineárních v parametrech (v lineární regresi);

- princip: parametry odhadujeme tak, aby pro ně byl minimální součet čtverců reziduí.

$$y_i = \eta_i + \varepsilon_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, 2, \dots, n$$

$$y_i = Y_i + \hat{\varepsilon}_i = b_0 + b_1 x_i + \hat{\varepsilon}_i$$

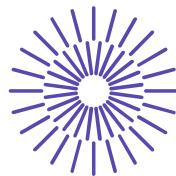
$$\text{Reziduum: } \hat{\varepsilon}_i = y_i - Y_i = y_i - b_0 - b_1 x_i = e_i$$

$$S = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - b_0 - b_1 x_i)^2 \quad \Rightarrow \quad \text{minimalizovat}$$

1. Stanovíme parciální derivace a položíme je rovny 0.

2. Vznikne soustava dvou rovnic (tzv. normální rovnice).

3. Vyřešíme je a získáme vzorce pro výpočet  $b_0$  a  $b_1$ .



### Vzorce pro výpočet parametrů výběrové regresní přímky:

$$b_1 = \frac{\sum_{i=1}^n x_i y_i - \frac{\sum_{i=1}^n x_i}{n} \cdot \frac{\sum_{i=1}^n y_i}{n}}{\frac{\sum_{i=1}^n x_i^2}{n} - \left( \frac{\sum_{i=1}^n x_i}{n} \right)^2} = \frac{\bar{xy} - \bar{x} \cdot \bar{y}}{s_x^2} = \frac{s_{xy}}{s_x^2}$$

$$b_0 = \frac{\sum y_i \cdot \sum x_i^2 - \sum x_i \cdot \sum x_i \cdot y_i}{n \sum x_i^2 - (\sum x_i)^2} = \bar{y} - b_1 \cdot \bar{x}$$

$b_1$  ... **výběrový regresní koeficient (směrnice výběrové regresní přímky)**

- udává, jak velká průměrná změna proměnné  $y$  odpovídá zvýšení proměnné  $x$  o jednotku.

$s_{xy}$  ... **kovariance**

- symetrická míra, tzn.  $s_{xy} = s_{yx}$ .

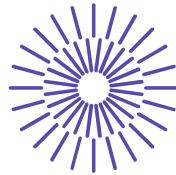
## II. Nelineární regrese

- není-li regresní funkce lineární v parametrech, nelze její parametry odhadnout metodou nejmenších čtverců;
- pro odhad parametrů se používá řada různých metod;
- častá je metoda linearizující transformace (např. zlogaritmování);
- většinou následují další metody pro zlepšení vlastností odhadů;
- výpočetně značně náročné (využití statistických programů).

## **3. Testování hypotéz o parametrech regresní funkce**

### ***t – testy***

- dílčí testy o nulových hodnotách jednotlivých regresních parametrů.



**1)  $H_0 : \beta_j = 0, j = 1, 2, \dots, k$**

$H_1 : \text{non } H_0$

**2) Testové kritérium:**

$$t = \frac{b_j}{s(b_j)} , \quad j = 1, 2, \dots, k. \quad \text{Statistika } t \text{ má při platnosti } H_0 \text{ rozdělení } t \text{ s } (n-p) \text{ stupni volnosti.}$$

**3) Kritický obor:**

$$W \equiv \left\{ t; \quad t \leq t_{\frac{\alpha}{2}}(n-p) \cup t \geq t_{1-\frac{\alpha}{2}}(n-p) \right\}$$

**4) Závěr testu:**

Pokud leží hodnota testového kritéria v kritickém oboru, zamítáme  $H_0$  a přijímáme  $H_1$ , jinak řečeno, test je statisticky významný. Testovaný parametr je statisticky významný, je v regresní funkci přínosný.

#### 4. Ověření vhodnosti zvoleného regresního modelu

##### Celkový F – test

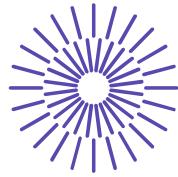
- testujeme vhodnost modelu jako celku;
- analýza rozptylu.

**1)  $H_0 : \beta_0 = c, \beta_1, \beta_2, \dots, \beta_k = 0$  (regresní funkce nemá žádný význam, tj. není vhodná)**

$H_1 : \text{non } H_0$

**2) Testové kritérium:**

$$F = \frac{S_T/p - 1}{S_R/(n-p)} ; \quad \text{Statistika } F \text{ má při platnosti } H_0 \text{ rozdělení } F \text{ s } (p-1) \text{ a } (n-p) \text{ stupni volnosti.}$$



**Rozklad celkového součtu čtverců:**  $S_y = S_T + S_R$

$S_y$  ... **celkový součet čtverců**; charakterizuje celkovou variabilitu proměnné  $y$ .

$S_T$  ... **teoretický součet čtverců**; část variability, kterou lze vysvětlit zvolenou regresní funkcí.

$S_R$  ... **reziduální součet čtverců**; část variability, kterou nelze zvolenou regresní funkcí vysvětlit.

$$S_y = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$S_T = \sum_{i=1}^n (Y_i - \bar{y})^2 ; \quad S_R = \sum_{i=1}^n (y_i - Y_i)^2 .$$

### 3) Kritický obor:

$$W \equiv \{F; F > F_{1-\alpha}(p-1; n-p)\}$$

### 4) Závěr testu:

Pokud leží hodnota testového kritéria v kritickém oboru, zamítáme  $H_0$  a přijímáme  $H_1$ , jinak řečeno, test je statisticky významný. Model lze považovat za vhodný.

## Kritéria pro posouzení kvality regresní funkce

### 1. Index determinace

- za vhodnější se považuje ta regresní funkce, u které je hodnota  $I^2$  vyšší.

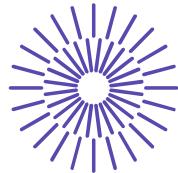
$$\text{Index determinace: } I^2 = \frac{S_T}{S_y} ; \quad I^2 \in \langle 0; 1 \rangle$$

- udává, jaký podíl variability proměnné  $y$  lze vysvětlit zvolenou regresní funkcí (lze udávat i v %).

- je zároveň mírou těsnosti závislosti proměnné  $y$  na proměnné  $x$ .

- obecná míra, nezávislá na typu regresní funkce (lze použít i pro měření nelineární závislosti).

- tato míra není symetrická.



*Pozn.:* Při srovnávání funkcí s rozdílným počtem parametrů musíme hodnotu  $I^2$  upravit (penalizovat), neboť u funkce s vyšším počtem parametrů vychází hodnota  $I^2$  automaticky vyšší. Existují různé formy penalizace, např.:

$$I_{adj}^2 = 1 - \left(1 - I^2\right) \cdot \frac{n-1}{n-p} = 1 - \frac{(n-1)S_R}{(n-p)S_y} .$$

*Pozn.:* *adjusted* = upravený.

**Index korelace:**  $I = \pm \sqrt{I^2}$ ;  $I \in \langle -1; 1 \rangle$

## 2. Testové kritérium F

- za vhodnější je považována ta funkce, u níž je hodnota F vyšší.

## 3. Reziduální součet čtverců a reziduální rozptyl

**Reziduální součet čtverců:**  $S_R = \sum_{i=1}^n (y_i - Y_i)^2$

- za vhodnější považujeme funkci, která má reziduální součet čtverců nižší. Reziduální součet čtverců lze použít pouze tehdy, když srovnáváme funkce se stejným počtem parametrů.

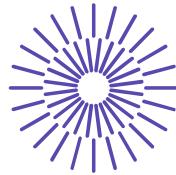
**Reziduální rozptyl:**  $s_R^2 = \frac{S_R}{n-p}$

- za vhodnější považujeme funkci, která má reziduální rozptyl nižší. Reziduální rozptyl můžeme použít vždy, bez ohledu na to, kolik parametrů mají srovnávané regresní funkce.

## Korelační analýza

- zabývá se především intenzitou vzájemného vztahu proměnných;
- je základní metodou měření síly lineární závislosti číselných proměnných;
- „correlatio“ = vzájemná souvislost (z lat.).

*! Z výpočetních a interpretačních hledisek se regresní a korelační analýza prolínají, nelze mezi nimi stanovit ostrou hranici.*



### Sdružené regresní přímky

$$Y = a_{yx} + b_{yx}x \quad \text{popisuje závislost } y \text{ na } x$$

$$X = a_{xy} + b_{xy}y \quad \text{popisuje závislost } x \text{ na } y$$

$$a_{yx} = \bar{y} - b_{yx}\bar{x} \quad b_{yx} = \frac{s_{xy}}{s_x^2}$$

$$a_{xy} = \bar{x} - b_{xy}\bar{y} \quad b_{xy} = \frac{s_{xy}}{s_y^2}$$

1.  $b_{yx} = b_{xy} = 0 \Rightarrow x \text{ a } y \text{ jsou korelačně nezávislé; sdružené regresní přímky svírají pravý úhel.}$

2.  $b_{yx} = \frac{1}{b_{xy}} \Rightarrow x \text{ a } y \text{ jsou úplně závislé; sdružené regresní přímky svírají nulový úhel}$

(splývají).

### Míry těsnosti lineární závislosti

**Koefficient determinace:**  $r_{yx}^2 = r_{xy}^2 = b_{yx} \cdot b_{xy} = \frac{s_{xy}}{s_x^2} \cdot \frac{s_{xy}}{s_y^2} = \frac{s_{xy}^2}{s_x^2 \cdot s_y^2}; \quad r_{xy}^2 \in \langle 0;1 \rangle$

**Koefficient korelace:**  $r_{yx} = r_{xy} = \sqrt{r_{yx}^2} = \frac{s_{xy}}{\sqrt{s_x \cdot s_y}} = \frac{\overline{xy} - \bar{x} \cdot \bar{y}}{\sqrt{(\bar{x}^2 - \bar{x}^2) \cdot (\bar{y}^2 - \bar{y}^2)}}; \quad r_{xy} \in \langle -1;1 \rangle$

- měří sílu lineární závislosti, nikoli závislosti obecně (lineární závislost = korelovanost).

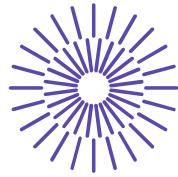
- koeficient je symetrický.

### Interpretace:

1. znaménko  $+/-$  udává směr závislosti:

$$r_{xy} > 0 \Rightarrow \text{přímá závislost}$$

$$r_{xy} < 0 \Rightarrow \text{nepřímá závislost}$$



2.  $|r_{xy}|$  udává sílu závislosti:

$$r_{xy} = 0 \quad \Rightarrow \text{lineární nezávislost}$$

$$|r_{xy}| = 1 \quad \Rightarrow \text{funkční (úplná) závislost}$$

$$|r_{xy}| \rightarrow 0 \quad \Rightarrow \text{slabá lineární závislost}$$

$$|r_{xy}| \rightarrow 1 \quad \Rightarrow \text{silná lineární závislost}$$

### Test hypotézy o nulové hodnotě korelačního koeficientu

1)  $H_0 : \rho_{yx} = 0$  (lineární nezávislost  $x$  a  $y$ )

$H_1 : \text{non } H_0$

2) **Testové kritérium:**

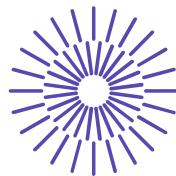
$$t = \frac{r_{yx} \cdot \sqrt{n-2}}{\sqrt{1-r_{yx}^2}} ; \quad \text{Statistika } t \text{ má při platnosti } H_0 \text{ rozdělení t s } (n-2) \text{ stupni volnosti.}$$

3) **Kritický obor:**

$$W \equiv \left\{ t; t \leq t_{\frac{\alpha}{2}}(n-2) \cup t \geq t_{1-\frac{\alpha}{2}}(n-2) \right\}$$

4) **Závěr testu:**

Pokud leží hodnota testového kritéria v kritickém oboru, zamítáme  $H_0$  a přijímáme  $H_1$ , tzn. prokázali jsme hypotézu o lineární závislosti proměnných  $x$  a  $y$ .



## Pořadová korelace

- Pokud chceme získat rychlou představu o síle závislosti mezi 2 kvantitativními znaky nebo určit závislost mezi pořadími znaků, nahradíme původní hodnoty  $x_i$  a  $y_i$  jejich pořadovými čísly  $i_x$  a  $i_y$  podle toho, která místa hodnoty zaujímají v uspořádané řadě.

$$\text{Spearmanův koeficient pořadové korelace: } r_s = 1 - \frac{6 \sum_{i=1}^n (i_x - i_y)^2}{n(n^2 - 1)} ; \quad r_s \in \langle -1; 1 \rangle$$

- varianta korelačního koeficientu;
- měří sílu lineární závislosti dvou pořadí.

**Interpretace:** stejná jako u korelačního koeficientu.

## Test hypotézy o nezávislosti pořadovou korelací

**1) Hypotéza:  $H_0 : \rho_S = 0$  (nezávislost pořadí)**

$H_1 : \text{non } H_0$

**2) Testové kritérium:**

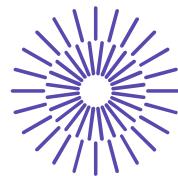
$$t = \frac{r_s \cdot \sqrt{n-2}}{\sqrt{1-r_s^2}} ; \quad \text{Statistika } t \text{ má při platnosti } H_0 \text{ rozdělení } t \text{ s } (n-2) \text{ stupni volnosti} .$$

**3) Kritický obor:**

$$W \equiv \left\{ t; t \leq t_{\frac{\alpha}{2}}(n-2) \cup t \geq t_{1-\frac{\alpha}{2}}(n-2) \right\}$$

**4) Závěr testu:**

Pokud leží hodnota testového kritéria v kritickém oboru, zamítáme  $H_0$  a přijímáme  $H_1$ , tzn. prokázali jsme hypotézu o lineární závislosti obou pořadí.



## Vícenásobná lineární regrese

- zkoumáme závislost proměnné  $y$  na dvou či více vysvětlujících proměnných (regresorech)

$x_1, x_2, \dots, x_k$ ;

- volba typu regresní funkce je obtížná; vhodné použití statistických programů;

- nejčastěji proto volíme lineární regresní funkci.

***Theoretická vícenásobná lineární regresní funkce:***

$$\eta = \beta_0 + \beta_1 x_1 + \beta_2 x_2 \dots + \beta_k x_k .$$