

# ANALÝZA ROZPTYLU

# Analýza rozptylu (ANOVA)

- Často používaná metoda v marketingovém výzkumu i jiných oblastech datové analýzy.
- Metoda umožňuje posoudit vliv různých úrovní/kategorií nějakého kvalitativního nebo kvantitativního znaku na kvantitativní veličinu.
- ANOVA testuje, zda existují rozdíly v populačních průměrech kvantitativního znaku, které náleží různým úrovním znaku kvalitativního.
- Například dovoluje hodnotit účinky různých reklamních kampaní na velikost tržeb z prodeje konkrétního produktu. Různé reklamní kampaně v tomto případě reprezentují různé kategorie sledovaného kvalitativního znaku (znak = reklamní kampaň). Velikost tržeb je pak zmíněný kvantitativní znak.

# Základní idea ANOVY

- Matematicky spočívá základní myšlenka analýzy rozptylu v rozkladu celkového rozptylu kvantitativního znaku na dílčí rozptyly příslušející jednotlivým vlivům, které tuto variabilitu způsobují.
- Kromě dílčích rozptylů je složkou celkového rozptylu také reziduální rozptyl, způsobený nepostiženými vlivy.

# Rozdělení ANOVY

- Podle počtu analyzovaných faktorů rozlišujeme jednofaktorovou, dvoufaktorovou a vícefaktorovou analýzu rozptylu.
- Hovoříme také o jednoduchém a dvojném třídění, případně o tříděních vyšší úrovně (trojném, čtverném a podobně).

# JEDNOFAKTOROVÁ ANOVA

- Často se vyskytuje situace, kdy máme k nezávislých náhodných výběrů, které obecně nepocházejí z jednoho základního souboru.
- Tyto výběry jsou rozsahu  $n_1, n_2 \dots n_k$ , což jsou obecně různá přirozená čísla. Číslo k může být 2, 3, ...
- V každém z těchto náhodných výběrů je znám výběrový průměr  $\bar{x}_i$ , a také výběrový rozptyl  $s_i^2$ . Index i = 1,2,..., k vyjadřuje, o který 1 2 , ..., k výběr jde.

# Rozdělení podle statistického znaku

- Základní soubor rozdělíme podle určitého třídícího statistického znaku  $X$  do  $k$  skupin a z každé z těchto  $k$  populací vybíráme  $n_i$  samostatně prvků.
- Znak  $X$  se pak označuje jako **faktor**, jehož úrovně, respektive kategorie jsou předem stanoveny a hovoří se proto často o **faktoru kontrolovaném**, nebo **faktoru pozorovaném**, např. věková skupina, druh výrobku, typ reklamy, typ služby apod.
- Faktor  $X$  má  $k$  úrovní (kategorií) a potenciálně ovlivňuje statistický znak  $Y$ , jenž má **kvantitativní**, tedy číselnou povahu.

# Princip výpočtu

- Metoda analýzy rozptylu ANOVA spočívá v tom, že se celková variabilita měřená součtem čtverců odchylek zjištěných hodnot od celkového průměru rozdělí na variabilitu uvnitř jednotlivých výběrů a na variabilitu mezi jednotlivými výběry.
- **Analýza rozptylu je statistickým testem**
- ANOVA má stejně jako i jiné statistické testy předpoklady svého použití. V případě ANOVA se předpokládá, že každý z k náhodných výběrů, s nimiž pracujeme, pochází z populace řídící se normálním rozdelením, že tato normální rozdelení mají stejný rozptyl a výběry jsou nezávislé.
- 
-

# Postup testování: nulová hypotéza

Testujeme nulovou hypotézu

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_k$$

- Zkoumáme, zda všech k výběru pochází ze stejné základní populace (základního souboru), což vzhledem k předpokladům učiněným pro ANOVA znamená, že si klademe otázku, zda střední hodnoty jsou stejné, respektive zda efekty jsou nulové.

Alternativní hypotéza je negací nulové hypotézy.



# Postup testování: testové kritérium

- Před vypočtením testového kritéria musíme zjistit hodnoty následujících veličin:

- *Podmíněné průměry*

$$\bar{y}_i = \frac{\sum_{j=1}^{n_i} y_{ij}}{n_i}$$

- pro  $i = 1, 2, \dots, k$ , kde  $y_{ij}$  jsou zjištěné hodnoty.

- *Celkový průměr*

$$\bar{y} = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij} = \frac{1}{n} \sum_{i=1}^k n_i \bar{y}_i$$

- kde  $n$  je celkový rozsah souboru.



# Postup testování: testové kritérium

- Dále musíme zjistit hodnoty
- Mezikupinový součet čtverců

$$S_{y,m} = \sum_{i=1}^k n_i (\bar{y}_i - \bar{y})^2$$

- Kde  $n_i$  je počet měření v jednotlivých skupinách,  $\bar{y}_i$  je výběrový průměr v jednotlivých skupinách.
- Vnitroskupinový součet čtverců
- Celkový součet čtverců .

$$S_{y,v} = \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_i)^2$$

$$S_y = \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2$$

# Postup testování: testové kritérium

- Platí:  $S_y = S_{y,m} + S_{y,v}$
- V anglické literatuře nebo v softwarech je možné se setkat i s následujícím označením:
  - $S_y = S_D$  (D z angl. Difference),
  - $S_{y,m} = S_T$  (T z angl. Treatment),
  - $S_{y,v} = S_R$  (R z angl. Residual).

# Postup testování: testové kritérium

- Pro ověření nulové hypotézy použijeme statistiku:

$$F = \frac{\frac{S_{y,m}}{k-1}}{\frac{S_{y,v}}{n-k}}$$

- která má při platnosti nulové hypotézy *Fisherovo rozdělení*  $F_{k-1, n-k}$ .

# Postup testování: kritická hodnota, výsledek

- Kritická hodnota je  $F_{k-1,n-k}(\alpha)$  , kde  $\alpha$  je zvolená hladina významnosti.

- Kritický obor je dán intervalom

$$C = (F_\alpha(k-1, n-k), \infty)$$

- Kritická hodnota testu pomocí funkce  $K = \text{FINV}()$  nebo v tabulkách

# Výpočet pomocí statistických programů

- ANOVA tabulka

Zdroj proměnlivosti	Součty čtverců odchylek	Počty stupňů volnosti	Průměrné čtverce	Testové kritérium F
Faktor x (meziskupinová variabilita)	$S_{ym}$	$k - 1$	$S_{ym}/(k - 1)$	F
Reziduální (vnitroskupinová variabilita)	$S_{yv}$	$n - k$	$S_{yv} / (n - k)$	
Celkový	$S_y$	$n - 1$		

# Korelační poměr

- Na otázku „Jak silná je vazba mezi nezávislou nominální proměnnou a proměnnou číselnou?“, odpovídá hodnota korelačního poměru.

$$P = \sqrt{\frac{S_{y,m}}{S_y}}$$

# Poměr determinace

- Pokud hodnotu korelačního poměru umocníme, dostáváme poměr determinace  $P^2$ .
- Hodnoty determinačního poměru blízké 1 svědčí o vysoké závislosti mezi proměnnými.
- Poměr determinace nabývá hodnot z intervalu  $[0,1]$ . Čím těsnější je závislost  $Y$  na  $X$ , tím více se hodnota poměru determinace blíží k jedné, tím více se také meziskupinový součet čtverců blíží k celkovému součtu čtverců, přičemž vnitroskupinový součet čtverců se blíží k nule. Naopak, čím více se poměr determinace blíží k 0, tím menší část z celkového součtu čtverců připadá na meziskupinový součet čtverců, a tím menší je závislost znaku  $Y$  na  $X$ .

# Příklad

H1	H2	H3
49	50	50
48	50	50
50	51	52
47	49	52
51	50	51

# Řešení

Anova: jeden faktor							
Faktor							
Výběr	Počet	Součet	Průměr	Rozptyl			
Anova: jeden faktor							
Faktor							
Výběr	Počet	Součet	Průměr	Rozptyl			
H1	5	245	49	2,5			
H2	5	250	50	0,5			
H3	5	255	51	1			
ANOVA							
Zdroj variability	SS	Rozdíl	MS	F	Hodnota P	F krit	
Mezi výběry	10	2	5	3,75	0,054310001	3,885293835	
Všechny výběry	16	12	1,3333333				
celkem	26	14					•

Děkuji za pozornost