

Užitečné statistické funkce v Excelu

Názvy funkcí odpovídají české lokalizaci MS Excel 2007

POČET (hodnota1; [hodnota2]; ...) – spočítá počet dat (neprázdných buněk s číselnou hodnotou) v zadané oblasti.

Např. =**POČET (A1:A100)** vrátí počet dat (neprázdných buněk s číselnou hodnotou) v oblasti A1:A100.

COUNTIF (oblast, "podmínka") – spočítá počet dat v zadané oblasti splňujících danou podmínku.

Např. =**COUNTIF (A1:A100, ">1.5")** vrátí počet dat v oblasti A1:A100, která jsou větší než 1.5.

MAX (hodnota1; [hodnota2]; ...) – spočítá maximální hodnotu v zadané oblasti.

Např. =**MAX (A1:A100)** vrátí maximální hodnotu v oblasti A1:A100.

MIN (hodnota1; [hodnota2]; ...) – spočítá minimální hodnotu v zadané oblasti.

Např. =**MIN (A1:A100)** vrátí minimální hodnotu v oblasti A1:A100.

MODE (hodnota1; [hodnota2]; ...) – spočítá modus, tj. nejčastěji se vyskytující hodnotu v zadané oblasti. Pokud není žádná duplicitní hodnota vrátí MODE chybovou hodnotu #NENÍ_K_DISPOZICI.

Např. =**MODE (A1:A100)** vrátí nejčastěji se vyskytující hodnotu v oblasti A1:A100.

PRŮMĚR (oblast) – spočítá aritmetický průměr dat v zadané oblasti, $\frac{1}{N} \sum_{i=1}^N x_i$

Např. =**PRŮMĚR (A2:A100)** vrátí aritmetický průměr dat v oblasti A2:A100

MEDIAN (oblast) – spočítá medián dat v zadané oblasti

Např. =**MEDIAN (A2:A100)** vrátí medián dat v oblasti A2:A100

GEOMEAN (oblast) – spočítá geometrický průměr dat v zadané oblasti $\sqrt[N]{\prod_{i=1}^N x_i}$

Např. =**GEOMEAN (A2:A100)** vrátí geometrický průměr dat v oblasti A2:A100

HARMEAN (oblast) – spočítá harmonický průměr dat v zadané oblasti $\left(\frac{1}{N} \sum_{i=1}^N \frac{1}{x_i}\right)^{-1}$

Např. =**HARMEAN (A2:A100)** vrátí harmonický průměr dat v oblasti A2:A100

SUMA.ČTVERCŮ (oblast) – spočítá součet kvadrátů dat v zadané oblasti $\sum_{i=1}^N x_i^2$

Např. = **SUMA.ČTVERCŮ (A2:A100)** vrátí součet kvadrátů dat v oblasti A2:A100

STDEVA (oblast) – spočítá standardní odchylku dat (nepředpojatý odhad) v zadané oblasti

$\sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}$, kde \bar{x} je aritmetický průměr.

Např. = **STDEVA (A2:A100)** vrátí standardní odchylku dat v oblasti A2:A100

STDEVPA (oblast) – spočítá standardní odchylku dat (předpojatý odhad) v zadané oblasti

$\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$, kde \bar{x} je aritmetický průměr.

Např. = **STDEVPA (A2:A100)** vrátí standardní odchylku dat v oblasti A2:A100

SMODCH (oblast) je stejné jako **STDEVPA (oblast)**

VAR (oblast) – spočítá rozptyl dat (předpojatý odhad) v zadané oblasti $\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$, kde \bar{x} je aritmetický průměr. Odmocnina z rozptylu je standardní odchylka.

ODMOCNINA (STDEVPA (oblast)) = STDEVPA (oblast) = SMODCH (oblast)

SKEW (oblast) – spočítá nepředpojatý odhad šikmosti dat v zadané oblasti

$$\frac{N}{(N-1)(N-2)} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{s} \right)^3,$$

kde \bar{x} je aritmetický průměr $\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$

a s je $s = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$.

KURT (oblast) – spočítá nepředpojatý odhad špičatosti dat v zadané oblasti

$$\frac{N(N+1)}{(N-1)(N-2)(N-3)} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{s} \right)^4 - 3 \frac{(N-1)^2}{(N-2)(N-3)},$$

kde \bar{x} je aritmetický průměr $\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$

a s je $s = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$.

Generování náhodných čísel v Excelu

NÁHČÍSLO () – vrátí výběr z rovnoměrného rozdělení U(0,1), tj. číslo, které se nachází se stejnou pravděpodobností kdekoli v intervalu (0,1)

RANDBETWEEN (a , b) – vrátí náhodně vybrané celé číslo ležící mezi a a b .

Např. = **RANDBETWEEN (10 , 20)** může vrátit třeba 12

Rozdělení diskrétní náhodné proměnné

POISSON (k , v , kumulativní) – pokud je parametr kumulativní=0 vypočítá pravděpodobnost, že k -krát nastane úspěch podle Poissonova rozdělení s očekávanou hodnotou v , tj. $P(k|v) = \frac{v^k e^{-v}}{k!}$

Pokud je kumulativní=1 vypočítá hodnotu distribuční funkce Poissonova rozdělení s očekávanou hodnotou v , tj. $F(k|v) = \sum_{l=0}^{l=k} \frac{v^l e^{-v}}{l!}$

Např. = **POISSON (2 , 1.5 , 0)** vrátí 0.251

BINOMDIST (k , N , p , kumulativní) – pokud je parametr kumulativní=0 vypočítá pravděpodobnost, že k -krát nastane úspěch při N opakování experimentu, když pravděpodobnost úspěchu při jednom opakování je p , tj. $P(k|N, p) = \frac{N!}{(N-k)! k!} p^k (1-p)^{N-k}$

Pokud je kumulativní=1 vypočítá hodnotu distribuční funkce Binomického rozdělení s očekávanou $F(k|N, p) = \sum_{l=0}^{l=k} \frac{N!}{(N-l)! l!} p^l (1-p)^{N-l}$.

Např. = **BINOMDIST (5 , 10 , 0.5 , 0)** vrátí 0.246

Rozdělení spojité náhodné proměnné

NORMDIST (x , μ , σ , kumulativní) – pokud je parametr kumulativní=0 vrátí hodnotu hustoty pravděpodobnosti normálního rozdělení s očekávanou hodnotou μ a standardní odchylkou σ

$$f(x|\mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[-\frac{(x-\mu)^2}{2\sigma^2} \right]$$

Pokud je parametr kumulativní=1, tak vrací hodnotu distribuční funkce normálního s očekávanou hodnotou μ a standardní odchylkou σ

$$F(x|\mu, \sigma) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(t-\mu)^2}{2\sigma^2}\right] dt.$$

Např. = **NORMDIST (2, 0, 2, 1)** vrátí 0.8413

NORMINV (P, μ , σ) – vypočítá inverzní funkci k distribuční funkci normálního rozdělení s očekávanou hodnotou μ a standardní odchylkou σ , tj. takové x , že $F(x|\mu, \sigma) = P$

Např. = **NORMINV (0.8413, 0, 1)** vrátí 1.9996

Pomocí této funkce je možné vygenerovat v Excelu náhodnou proměnou z normálního rozdělení použitím metody inverzní funkce = **NORMINV (NÁHČÍSLO () , 0, 1)** – vrátí náhodný z normálního rozdělení s očekávanou hodnotou 0 a standardní odchylkou 1.

Korelace a kovariance

COVAR (oblast1, oblast2) – vypočítá kovarianci náhodných proměnných v oblasti 1 a 2

$$\widehat{cov}(x, y) = \langle xy \rangle - \langle x \rangle \langle y \rangle,$$

kde lomená závorka $\langle \ \rangle$ označuje aritmetický průměr, např. $\langle x \rangle = \frac{1}{N} \sum_{i=1}^N x_i$

Např. = **COVAR (A2:A100, B2:B100)**

CORREL (oblast1, oblast2) – vypočítá korelaci náhodných proměnných v oblasti 1 a 2

$$\hat{\rho}_E(x, y) = \frac{\widehat{cov}(x, y)}{\hat{\sigma}_x \hat{\sigma}_y},$$

Např. = **CORREL (A2:A100, B2:B100)**

Poznámka:

Excel používá v odhadu korelačního koeficientu předpojaté odhady standardní odchylky **STDEVPA**

$$\text{tj. } \hat{\sigma}_x = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \langle x \rangle)^2}$$

Korelační koeficient tedy Excel počítá jako

$$= \mathbf{COVAR (oblast1, oblast2) / (STDEVPA (oblast1)*STDEVPA(oblast2))}$$

My na přednášce počítáme odhad Pearsonova korelačního koeficientu s použitím nepředpojatých

odhadů standardní odchylky, tj. jako $\hat{\rho}(x, y) = \frac{\widehat{cov}(x, y)}{\hat{s}_x \hat{s}_y}$, kde

$$\hat{s} \text{ je nepředpojatý odhad standardní odchylky, tj. } \hat{s}_x = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \langle x \rangle)^2}$$

V Excelu by se to tedy počítalo jako

$$= \mathbf{COVAR (oblast1, oblast2) / (STDEVA (oblast1)*STDEVA(oblast2))}$$

Přepočítání mezi tím „naším“ a „Excelovským“ korelačním koeficientem je $\hat{\rho} = \frac{N-1}{N} \hat{\rho}_E(x, y)$.

TDIST (t, ν , chvosty) – vypočítá pravděpodobnost, že výběr se Studentova rozdělení s počtem volnosti ν bude větší než t , tj. $1 -$ hodnota distribuční funkce $T(t|\nu)$ Studentova rozdělení s počtem stupňů volnosti ν v bodě t ,

$$P(x > t) = 1 - T(t|\nu) = 1 - \int_0^t \frac{\Gamma(\frac{\nu+1}{2})}{\sqrt{\nu\pi} \Gamma(\frac{\nu}{2})} \left(1 + \frac{z^2}{\nu}\right)^{-\frac{\nu+1}{2}} dz,$$

Takto se to vypočítá, pokud je parametr chvosty =1.

Pokud je parametr chvosty = 2 vypočítá se $P(|x| > t) = 2 P(x > t)$.

Takže **TDIST (t, ν , 2) = 2*TDIST (t, ν , 1)**

Poznámka:

Musí být $t \geq 0$. Protože Studentovo rozdělení je symetrické okolo nuly, můžeme pravděpodobnost, že $x < t$ pro záporné t spočítat jednoduše jako $P(x > |t|)$, tj. pokud máme t záporné a zajímá nás pravděpodobnost, že $x < t$, tak se to spočítá jednoduše jako **=TDIST (ABS (t) , ν , 1)**

TINV(P, v) – spočítá takovou hodnotu t_p , pro kterou platí, že pravděpodobnost, že náhodná proměnná ze studentova rozdělení s počtem stupňů volnosti v se bude od nuly lišit o víc než t_p je P , tj.

$$1 - P(|t| > t_p | v) = 2[1 - T(t_p | v)] = P.$$

Např. = **TINV(0.05, 20)** vrátí 2.086