

## KRIGING geostatistické metody interpolace

### Vlastnosti krigování

Metoda krigování se často označuje akronymem **BLUE** (Best Linear Unbiased Estimator – tedy nejlepší lineární nezkreslený odhad).

Výchozí podmínky krigování:

Odhadovaná hodnota je vypočtena jako **lineární** kombinace vstupních hodnot

$$\hat{z}(x_0) = \sum_{i=1}^n \lambda_i \cdot z(x_i) \quad \text{kde pro váhy platí} \quad \sum_{i=1}^n \lambda_i = 1$$

Nezkreslený (**nestranný**) odhad značí, že průměrná chyba tohoto odhadu je rovna nule

$$\sum (\hat{z}_i - z_i) = 0$$

Odhad je **nejlepší**, protože je minimalizován rozptyl odhadu

$$\sum (\hat{z}_i - z_i)^2 = \min.$$

### Vlastnosti krigování

Pokud prostorově závislá náhodná kolísání nejsou překryta nekorelovaným šumem, potom může být semivariogram využit k určení vah  $\lambda_i$  potřebných pro interpolaci.

Procedura je podobná jako v případě metody vážených klouzavých průměrů s tím rozdílem, že právě váhy jsou odhadnuty geostatistickými metodami.

Váhy  $\lambda_i$  jsou zvoleny tak, aby odhad byl nestranný a odhad rozptylu byl menší, než jakákoliv jiná lineární kombinace pozorovaných hodnot (minimální).


Přitom pro minimální rozptyl hodnot  $\hat{z}(x_0)$  platí výraz :

$$\hat{\sigma}_e^2 = \sum_{i=1}^n \lambda_i \gamma(x_i, x_0) + \phi \quad \sum_{i=1}^n \lambda_i \gamma(x_i, x_j) + \phi = \gamma(x_j, x_0)$$

$\gamma(x_i, x_j)$  semivariance proměnné z mezi body  $x_i$  a  $x_j$ .

$\phi$  Lagrangeův multiplikátor, který zajišťuje požadavek minimalizace odchylek a zároveň podmínku, že suma vah je rovna jedné.

PŘÍKLAD: Výpočet neznámé hodnoty v bodě metodou základního krigingu.



### Postup řešení:

- Na základě předem provedené strukturní analýzy použijeme vhodnou strukturní funkci (např. sférický semivariogram) s příslušnými hodnotami parametrů
- Řešíme soustavu rovnic, kde jednotlivé členy mají následující význam:

$$A \cdot \lambda = b$$

$A$  – matice semivariancí mezi všemi dvojicemi bodů  
 $b$  – vektor semivariancí mezi všemi body a bodem predikovaným  
 $\lambda$  – vektor vah jednotlivých bodů  
 $\phi$  – tzv. Lagrangeův člen

- Soustavu rovnic řešíme pro váhy  $\lambda$ , tak, aby byla splněna podmínka  $\sum \lambda = 1$  (proto je v soustavě použit člen  $\phi$ )

$$A^{-1} \cdot b = \begin{bmatrix} \lambda \\ \phi \end{bmatrix}$$

### Postup řešení:

$$\begin{bmatrix} \gamma_{11} & \gamma_{12} & \dots & \dots & \gamma_{1n} & 1 \\ \gamma_{21} & \gamma_{22} & \dots & \dots & \gamma_{2n} & 1 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \gamma_{n1} & \gamma_{n2} & \dots & \dots & \gamma_{nn} & 1 \\ 1 & 1 & \dots & \dots & 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \dots \\ \dots \\ \lambda_n \\ \phi \end{bmatrix} = \begin{bmatrix} \gamma_{10} \\ \gamma_{20} \\ \dots \\ \dots \\ \gamma_{n0} \\ 1 \end{bmatrix}$$

**Postup řešení:**

4. K určení hodnot semivarianci je zapotřebí vytvořit matici vzdáleností mezi datovými body a vektor vzdáleností mezi měřenými body a bodem predikovaným
5. Řešením soustavy rovnic získáme hodnoty vah  $\lambda$  a hodnotu  $\phi$
6. Vypočteme predikovanou hodnotu v bodě ( $i=0$ ):

$$\hat{z}(x_0) = \sum_{i=1}^n \lambda_i \cdot z(x_i) \quad Z(x_{i=0}) = 4,560$$

7. Vypočteme rozptyl odhadu:

$$\hat{\sigma}_e^2 = \sum_{i=1}^n \lambda_i \gamma(x_i, x_0) + \phi \quad \sigma_e^2 = 4,008$$


**Typy krigování**

- krigování s bodovým odhadem
- krigování s blokovým odhadem
- základní (ordinary) krigování
- jednoduché (simple) krigování
- univerzální krigování
- indikátorové krigování
- pravděpodobnostní krigování
- co-kriging
- lognormální krigování.

**Základní krigování (ordinary kriging)**

$$Z(x_i) = \mu(x_i) + \varepsilon(x_i)$$


kde  $\mu$  je neznámá hodnota trendu.



**Jednoduché krigování (Simple kriging)**

$$Z(x_i) = \mu(x_i) + \varepsilon(x_i)$$


kde  $\mu$  je známá konstanta.



**Univerzální krigování (Universal kriging)**

$$Z(x_i) = \mu(x_i) + \varepsilon(x_i)$$


kde  $\mu(x)$  je deterministická funkce




**Indikátorové krigování**

$$I(x_i) = \mu + \varepsilon(x_i)$$

kde  $\mu$  neznámá konstanta,  $\varepsilon(x)$  autokorelovaná náhodná proměnná a  $I(x)$  je binární proměnná, která nabývá hodnot 0 nebo 1 - indikátor




Výsledkem odhadu je pravděpodobnost překročení určité prahové hodnoty



### Pravděpodobnostní krigování (probability kriging)

$$I(x) = I(Z(x) > c_1) = \mu_1 + \varepsilon_1(x) \quad Z(x) = \mu_2 + \varepsilon_2(x)$$

kde  $\mu_1$  a  $\mu_2$  jsou neznámé konstanty.  $I(x)$  je binární proměnná vytvořená indikátorovým prahováním ( $I(Z(x) > c_1)$ ) a  $\varepsilon_1(x)$  a  $\varepsilon_2(x)$  jsou dvě náhodné chyby.



### Co-kriging

Proměnné  $z_1$  a  $z_2$  vykazují prostorovou korelaci.

Proměnná  $z_2$  je snáze získatelná


Hodnot proměnné  $z_2$  je využito k interpolaci hodnot proměnné  $z_1$ .

Základní co-kriging využívá následujících modelů:


$$Z_1(x) = \mu_1 + \varepsilon_1(x)$$

$$Z_2(x) = \mu_2 + \varepsilon_2(x)$$

kde  $\mu_1$  a  $\mu_2$  jsou neznámé konstanty a  $\varepsilon_1(x)$  a  $\varepsilon_2(x)$  dvě náhodné chyby.



### Blokový odhad při základním krigování (Block kriging)



### Hodnocení a verifikace modelů

Krigování jako interpolační metoda umožňuje pro každý interpolovaný bod odhadnout potenciální velikost chyby odhadu.

Mapy druhé mocniny  $\sigma_e^2$

tzv. **směrodatné chyby** (odchylky) **krigingu (Standard error map)**,


Mají-li chyby predikce normální rozdělení, potom **95% interval spolehlivosti predikovaných hodnot** lze určit z následujícího vztahu:

$$Z(x_0) \pm 1,96 \cdot \sqrt{\sigma_e^2}$$

kde  $Z(x_0)$  je odhad hodnoty proměnné  $z$  v bodě  $x_0$  a  $\sigma_e^2$  je rozptyl odhadu.

Při opakovaném použití stejného modelu padne 95 % odhadovaných hodnot do uvedeného intervalu

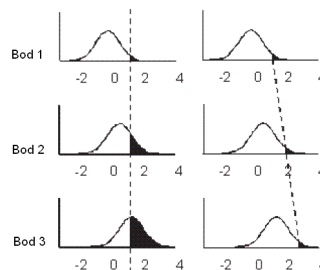
### Probability map



Pravděpodobnost, že predikovaná hodnota bude větší než prahová hodnota - např. 1.

Při konstantní prahové hodnotě se její pravděpodobnost výskytu pro jednotlivé body mění – tedy lze z ní vytvořit mapu pravděpodobností (**probability map**).


### Quantile map



Určení kvantilu s např. 5 procentní pravděpodobností výskytu.

Při konstantní pravděpodobnosti se budou měnit hodnoty kvantilů a lze je opět prezentovat ve formě kvantilové mapy (**quantile map**).

### Křížová validace modelu




Jednotlivé body měření (červené) jsou po jednom postupně vynechány ze vstupní množiny dat  
 Ze zbývajících (modrých) je vypočtena hodnota v místě vynechaného bodu.  
 Následně jsou porovnány pozorované a vypočtené hodnoty

### Validace modelu

Vstupní soubor měřených hodnot rozdělí na dvě části – data trénovací a testovací.

Trénovací množina dat se použije pro odhad trendu a autokorelačního modelu.

Pokud sestavený model vyhovuje trénovacím datům, je ověřen na datech testovacích.



Korelační pole měřených a predikovaných hodnot

Obecnou vlastností krigingu jako interpolační metody je podhodnocení vysokých hodnot a naopak nadhodnocení hodnot nízkých.

### Sumární statistika rozdílů pozorovaných a vypočtených hodnot

Rozdíly pozorovaných a vypočtených hodnot lze hodnotit dále uvedenými měrami:

**MPE – mean prediction error** - průměr rozdílů měřených a předikovaných hodnot - hodnoty chyb odhadů by měly být nestranné – tedy jejich průměr by se měl rovnat nule.

$$MPE = \frac{\sum_{i=1}^n (\hat{z}(x_i) - z(x_i))}{n}$$

**RMSPE (root mean square prediction error)** – druhá odmocnina průměrného čtverce vzdálenosti vypočtených hodnot od teoretických. Slouží k porovnání několika různých modelů. Čím menší je RMSPE, tím vhodnější je model (tím bližší jsou vypočtené hodnoty hodnotám měřeným).

$$RMSPE = \sqrt{\frac{\sum_{i=1}^n (\hat{z}(x_i) - z(x_i))^2}{n}}$$