

## Geostatistické metody prostorové interpolace

### Geostatistické metody interpolace

Stochastické metody lokální interpolace,


Optimalizují výběr bodů okolí, ze kterých je interpolována nová hodnota.

K této optimalizaci se provádí tzv. **strukturní analýza** založená na studiu tzv. strukturních funkcí – např. semivariogramu.

Semivariogram z empiricky zjištěných dat je nahrazen teoretickým modelem a parametry tohoto modelu jsou použity ve vlastním krigování.

**Kriging** je založen na odhadu závislosti průměrné změny v hodnotách studované veličiny a vzdálenosti měřených bodů.

### Základní komponenty spojitého povrchu




$$Z(x) = \mu(x) + \gamma(h) + \varepsilon''$$

Regionalizovaná proměnná se odhaduje v tzv. **strukturní analýze** pomocí hodnot strukturní funkce - tzv. **semivariance**  $\gamma(h)$

### Strukturní analýza

Příklad výpočtu měř prostorové variability pro 1D - řadu hodnot



$$\text{průměr} = (1+3+6+5+3+1+2+3)/8=3,0$$

$$\text{rozptyl} = [(1-3)^2 + (3-3)^2 + (6-3)^2 + (5-3)^2 + (3-3)^2 + (1-3)^2 + (2-3)^2 + (2-3)^2]/8 = 2,75$$

$$\text{kovariance}(1) = [(1-3)*(3-3) + (3-3)*(6-3) + (6-3)*(5-3) + (5-3)*(3-3) + (3-3)*(1-3) + (1-3)*(2-3) + (2-3)*(3-3)]/7 = 1,14$$

$$\text{semivariance}(1) = [(1-3)^2 + (3-6)^2 + (6-5)^2 + (5-3)^2 + (3-1)^2 + (1-2)^2 + (2-3)^2]/7 = 3,43$$

$$\text{semivariance}(2) = [(1-6)^2 + (3-5)^2 + (6-3)^2 + (5-1)^2 + (3-2)^2 + (1-3)^2]/6 = 9,83$$

$$\text{semivariance}(3) = [(1-5)^2 + (3-3)^2 + (6-1)^2 + (5-2)^2 + (3-3)^2]/5 = 12,50$$


### Experimentální semivariogram

Strukturní analýza v 2D – výpočet semivariogramu z naměřených dat:

$$\hat{\gamma}(h) = \frac{1}{2n} \sum_{i=1}^n (z(x_i) - z(x_i + h))^2$$


$n$  - počet dvojic bodů pozorování proměnné s atributem z vzdálených o hodnotu  $h$

$h$  - tzv. lag - vzdálenost dané dvojice bodů.




Experimentální semivariogram (+) s charakteristickými hodnotami pro vzdálenosti  $h$  (\*) a proložený teoretický model semivariogramu (plná čára)

### Strukturní analýza




Experimentální semivariogram

Teoretický semivariogram



## Strukturální analýza


### Prvky (parametry) semivariogramu




$a$  - dosah (range),  $d$  - rozpětí,  $c_0$  - zbytkový rozptyl (nugget),  $c=c_0 + c_1$  - práh (sill),  $h$  - lag (krok vzdálenosti)

## Strukturální analýza


### Efekt anizotropie




### Příklady teoretických semivariogramů:



sférický



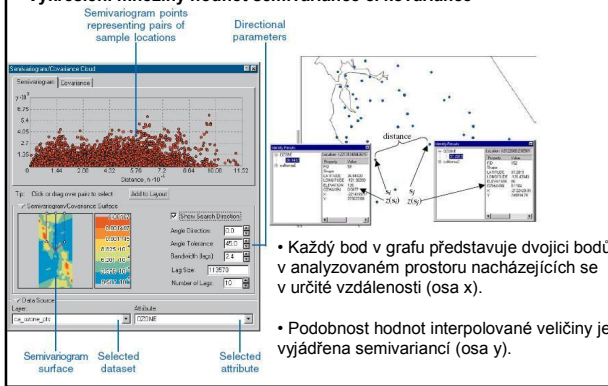
lineární



sinový

## Základní nástroje průzkumové analýzy prostorových dat

### Vykreslení množiny hodnot semivariance či kovariance



• Každý bod v grafu představuje dvojici bodů v analyzovaném prostoru nacházejících se v určité vzdálenosti (osa x).

• Podobnost hodnot interpolované veličiny je vyjádřena semivariancí (osa y).

## KRIGING jako metoda interpolace

Odhad hodnoty v bodě  $x_0$

$$\hat{z}(x_0) = \sum_{i=1}^n \lambda_i \cdot z(x_i)$$

a odhad jeho rozptylu


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

Je konstruován tak, aby byl minimální

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

váhy, které musíme vypočítat

Hodnoty semivariancí poskytují strukturální analýza - z vhodného teoretického modelu semivariogramu



### Postup řešení:

- Na základě předem provedené strukturální analýzy použijeme vhodnou strukturální 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

$$\sum \lambda = 1 \quad (\text{proto je v soustavě použit člen } \phi)$$

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

### Postup řešení:

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

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

- 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

### Základní krigování (ordinary kriging)

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


kde  $\mu$  je neznámá hodnota trendu.



### Univerzální krigování (Universal kriging)

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

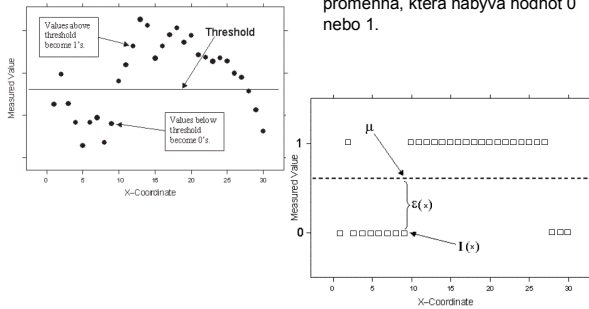
kde  $\mu(x)$  je deterministická funkce



### 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.



### Hodnocení a verifikace modelů

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

Mapy druhé odmocniny  $\sigma_e^2$

tzv. **směrodatné chyby** (odchytky) 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

### 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 blíží jsou vypočtené hodnoty hodnotám měřeným).

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

### Základní kriging

