

## Matemática II

### Introdução à Geostatística

2013/2014

(F. Valente e M. Mesquita)

### Análise espacial de dados

- Estudar e modelar fenómenos que se distribuem no espaço.
- Obter modelo inferencial que considere o relacionamento espacial presente no fenómeno em estudo.
- Objectivo:** caracterização da distribuição espacial de variáveis que apresentam uma certa estrutura no espaço e quantificação da incerteza ligada ao fenómeno espacial em estudo.

2

### Análise espacial de dados

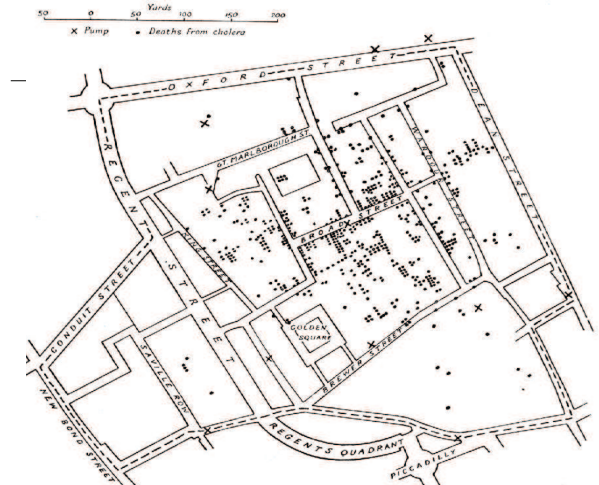
#### Exemplos:

- modelação de recursos geológicos (concentração de metais em jazidos minerais, qualidade de águas subterrâneas),
- estudos pedológicos (distribuição superficial de características do solo),
- ecologia (distribuição de espécies vegetais ou animais, padrão espacial de aves de migratórias),
- ambiente (ordenamento do território, estudos de poluição do solo, da água ou do ar).

#### Exemplo pioneiro:

- Estudo efectuado por John Snow em meados do século XIX, durante uma epidemia de cólera em Londres, para avaliar a relação entre a distribuição dos óbitos por cólera e a localização das bombas de água que abasteciam a cidade.

3



4

### Tipos de dados em análise espacial

#### Padrões pontuais – dados provenientes de fenómenos que se localizam em pontos no espaço.

- Exemplos: localização de espécies vegetais, ocorrência de doenças;

#### Superfícies contínuas (dados geoestatísticos) – dados provenientes de fenómenos que se distribuem de forma contínua no espaço.

- Exemplos: dados geológicos, topográficos, ecológicos, climatológicos, pedológicos, hidrológicos.

#### Dados de áreas – dados associados a unidades de análise, habitualmente delimitadas por polígonos fechados onde se supõe haver homogeneidade.

- Exemplos: dados de censos, estatísticas de saúde.

5

### Objectivos específicos

- Análise de padrões de pontos – o objectivo é estudar a distribuição espacial (localização) dos acontecimentos estudados (padrão aleatório, aglomerado ou regularmente distribuído).
- Análise de dados geoestatísticos – o objectivo é reconstruir a superfície contínua com base num conjunto finito de dados observados na região de estudo.
- Análise de dados de áreas – o objectivo é modelar o padrão espacial dos dados (áreas diferenciadas vs. continuidade espacial) e estabelecer associações com outras variáveis.

6

## Dados geoestatísticos

Tipicamente, os dados geoestatísticos podem ser representados por

$$(x_i, z_i), \quad i=1, \dots, n$$


em que  $x_i$  identifica uma localização espacial (a 1, 2 ou 3 dimensões) e  $z_i$  é o valor da variável em estudo (variável resposta) associado à localização  $x_i$ .

Exemplos:

- cotas de 52 locais numa dada região; objectivo: construir um mapa de altitudes para toda a região;
- conteúdo em cálcio de 178 locais numa dada região; objectivo: construir um mapa da variação espacial do conteúdo de cálcio no solo nesta região.

7


Mapa topográfico com base nas cotas de 52 locais



## Representação computacional de dados geográficos

Como construir este tipo de mapas?

Num computador, a representação de uma superfície contínua pode ser feita por discretização numa malha regular.



A cada célula vai estar associado um valor numérico da variável em estudo.

Como obter esse valor?

9

## Modelação espacial de superfícies

A superfície que representa o fenómeno em estudo pode ser obtida por modelação/interpolação espacial através de:

### 1) modelos determinísticos

#### – de efeitos locais

admitindo que predominam os efeitos locais, cada ponto da superfície é estimado por interpolação das observações mais próximas;

#### – de efeitos globais

supondo que a variação em larga escala é dominante, a superfície é aproximada por um ajustamento polinomial aos dados;

### 2) modelos estatísticos (krigagem),

cada ponto da superfície é estimado através de um estimador estatístico;

10

## Modelos determinísticos locais

O valor a estimar no ponto  $x_0$  é calculado por combinação linear dos valores observados numa sua vizinhança.

Fórmula geral de interpolação:

$z(x_0)$  é o valor a estimar no ponto  $x_0$ ,

$z(x_j)$  é o valor observado em  $x_j$

$w_j$  é um factor de ponderação

$$z(x_0) = \frac{\sum_{j=1}^m w_j z(x_j)}{\sum_{j=1}^m w_j}$$

O valor a atribuir a  $w_j$  depende do método utilizado:


#### interpolação por vizinho mais próximo

(ou método dos polígonos de influência)

factor de ponderação 1 ( $w_j = 1$ )

para a observação  $z(x_j)$  mais próxima de  $x_0$

e zero para as restantes observações.




11

## Modelos determinísticos locais (cont.)


#### interpolação por média simples

o valor de  $z(x_0)$  é dado pela média aritmética dos valores  $z(x_j)$  de  $m$  observações vizinhas (factor de ponderação 1 para as  $m$  observações vizinhas e zero para as restantes).



#### interpolação pelo inverso da potência das distâncias


o factor de ponderação é dado por  $w_j = (1/d_j)^s$ , em que  $d_j$  a distância euclidiana do ponto  $x_j$  ao ponto  $x_0$ , para  $m$  observações vizinhas, e zero para as restantes.



12

## Exemplo:

| Ponto | x  | y  | z  | distância |
|-------|----|----|----|-----------|
| 1     | 45 | 25 | 40 | 11.18     |
| 2     | 60 | 30 | 38 | 25.00     |
| 3     | 40 | 45 | 45 | 15.81     |
| 4     | 35 | 15 | 28 | 15.00     |
| 5     | 10 | 30 | 32 | 25.00     |
| A     | 35 | 30 | ?  | 0.00      |



13

## Principais vantagens e desvantagens dos modelos determinísticos

### Vantagens:

- fáceis de implementar (estão disponíveis em muitas aplicações computacionais);
- razoavelmente fiéis aos valores observados;
- úteis para uma rápida visualização dos dados.

### Desvantagens:

- métodos que têm por base critérios estritamente geométricos que podem ser contraditórios com a estrutura espacial do fenómeno (por exemplo, existência de direcções privilegiadas);
- não estimam valores da variável em estudo fora da gama de valores observados;
- não avaliam a incerteza associada à caracterização do fenómeno espacial.

14

## Modelos geoestatísticos

Procuram ultrapassar as limitações dos métodos determinísticos

Têm em consideração:

- 1) a estrutura espacial da grandeza em estudo, em geral, os fenómenos distribuem-se no espaço de uma forma não aleatória;
- 2) a avaliação da incerteza associada à caracterização do fenómeno espacial, a informação disponível (o conjunto de observações) é em geral escassa pelo que a modelação probabilística vai permitir a inferência espacial em pontos não amostrados e a quantificação da incerteza associada a essa estimação.

15

## Conceitos básicos

**Dependência espacial** – a maior parte das ocorrências apresentam entre si uma relação que depende da distância entre elas.

Exemplos: se existe poluição num dado local é provável que locais próximos também estejam poluídos; se a presença de uma árvore adulta inibe o desenvolvimento de outras, essa inibição irá diminuir com a distância.

**Autocorrelação espacial** – medida que avalia a dependência espacial; o prefixo *auto* indica que a correlação é avaliada para a mesma variável, mas medida em locais distintos.

Exemplo de indicadores de autocorrelação espacial: covariância, coeficiente de correlação e variograma.

16

## Conceitos básicos (cont.)

### Variável aleatória $Z(x)$ :

O conjunto de dados observados nos locais  $x_i, i = 1, 2, \dots, n, \{z(x_1), z(x_2), \dots, z(x_n)\}$ , é interpretado como uma realização de um conjunto de variáveis aleatórias  $\{Z(x_1), Z(x_2), \dots, Z(x_n)\}$  correlacionadas entre si.

- Cada uma destas variáveis tem

$$\text{média } E[Z(x_i)] = \mu(x_i)$$

$$\text{variância } Var[Z(x_i)] = E[Z^2(x_i)] - \mu^2(x_i)$$

- Entre quaisquer duas variáveis aleatórias pode definir-se

$$\text{covariância } C[Z(x_i), Z(x_j)] = E[Z(x_i)Z(x_j)] - \mu(x_i)\mu(x_j)$$

$$\text{coeficiente de correlação } \rho = \frac{C[Z(x_i), Z(x_j)]}{\sqrt{Var[Z(x_i)]Var[Z(x_j)]}}$$

$$\text{variograma } \gamma[Z(x_i), Z(x_j)] = \frac{1}{2}Var[(Z(x_i) - Z(x_j))]$$

17

## Conceitos básicos (cont.)

Como do conjunto de v.a.s  $\{Z(x_i)\}_{i=1}^n$  só se conhece uma realização  $\{z(x_i)\}_{i=1}^n$ , o conjunto de dados experimentais, é impossível determinar qualquer parâmetro estatístico.

**Solução geoestatística:** assumir várias hipóteses que permitam fazer inferência, com a (pouca) informação disponível:

**1) Hipótese de estacionariedade da média** – admite-se que todas as v.a. têm a mesma média  $E[Z(x_i)] = \mu, \forall i$ .

**2) Hipótese de estacionariedade da covariância e do variograma** – a covariância e o variograma entre duas variáveis aleatórias só depende do vector distância  $\mathbf{h}$  que as separa e é independente da sua localização,

$$C[Z(x_i), Z(x_j)] = C[Z(x_i), Z(x_i + \mathbf{h})] = C(\mathbf{h})$$

$$\gamma[Z(x_i), Z(x_j)] = \gamma[Z(x_i), Z(x_i + \mathbf{h})] = \gamma(\mathbf{h})$$

18

## Consequências da estacionaridade

- ▣ A variância das v.a.s  $Z(x_i)$  é constante,

$$\text{Var}[Z(x_i)] = C(0) = \sigma^2, \forall i$$

- ▣ O coeficiente de correlação também só depende do vector distância  $\mathbf{h}$ ,

$$\rho(\mathbf{h}) = \frac{C(\mathbf{h})}{\sigma^2} = \frac{C(\mathbf{h})}{C(0)}$$


- ▣ O variograma pode escrever-se como

$$\gamma(\mathbf{h}) = \frac{1}{2} E[(Z(x_i) - Z(x_i + \mathbf{h}))^2]$$

$$\gamma(\mathbf{h}) = \sigma^2(1 - \rho(\mathbf{h})) = C(0) - C(\mathbf{h})$$

19

## Variograma e covariância espacial



20

## Estacionaridade

- ▣ Com as hipóteses de estacionaridade, a média, o variograma e a covariância passam a ser independente da localização  $x_i$  (e  $x_j$ ) e podem ser estimadas pelos estimadores

$$\mu^* = \frac{\sum_{i=1}^n Z(x_i)}{n}$$

$$\gamma^*(\mathbf{h}) = \frac{\sum_{k=1}^{n(\mathbf{h})} [Z(x_k) - Z(x_k + \mathbf{h})]^2}{2n(\mathbf{h})}$$

$$C^*(\mathbf{h}) = \frac{\sum_{k=1}^{n(\mathbf{h})} [Z(x_k)Z(x_k + \mathbf{h}) - \mu^*(x_k)\mu^*(x_k + \mathbf{h})]}{n(\mathbf{h})}$$

em que  $\mu^*(x_k) = \frac{1}{n(\mathbf{h})} \sum_{k=1}^{n(\mathbf{h})} Z(x_k)$ ,  $\mu^*(x_k + \mathbf{h}) = \frac{1}{n(\mathbf{h})} \sum_{k=1}^{n(\mathbf{h})} Z(x_k + \mathbf{h})$


e  $n(\mathbf{h})$  é o número de pares de pontos  $(x_k, x_k + \mathbf{h})$  para cada valor  $\mathbf{h}$ .

21

## Isotropia

- ▣ Quando para além da estacionaridade, a covariância e o variograma têm o mesmo comportamento em todas as direcções diz-se que há **isotropia**. Isto é,  $C(\mathbf{h})$  e  $\gamma(\mathbf{h})$  só dependem de  $h = \|\mathbf{h}\|$ , a distância euclidiana entre as localizações.

- ▣ Caso contrário, quando a estrutura de correlação varia, quer com a distância  $h$ , quer com a direcção, o fenómeno é **anisotrópico**.



22

## Modelos geoestatísticos: aspectos fundamentais

- ▣ Os valores da amostra são realizações de variáveis aleatórias localizadas espacialmente numa região  $A$ .

- ▣ A correlação entre estas v.a.s, medida pela covariância ou variograma, não depende da sua localização mas unicamente do vector  $\mathbf{h}$  e avalia a continuidade espacial/dispersão da variável em estudo na região  $A$ .

- ▣ Um valor não amostrado em  $x_0$  é também considerado uma v.a.  $Z(x_0)$  que poderá ser estimado através de um novo estimador  $Z^*(x_0)$ .

23

## Fases de um estudo geoestatístico

### ▣ Análise exploratória dos dados

- representação visual dos dados em gráficos e mapas;
- estatística descritiva: medidas de localização e dispersão, histograma, caixa-de-bigodes, "outliers";
- identificação de padrões de dependência espacial no fenómeno em estudo, procura de regiões não homogêneas.

### ▣ Análise estrutural dos dados

- estudo da continuidade espacial: determinação do variograma experimental e sua modelação.

### ▣ Estimação

- determinação da variável em estudo em pontos não amostrados: krigagem

24

## Análise exploratória dos dados

- ▣ Descrição univariada – com o objectivo de avaliar a dispersão da variável (atributo) em estudo;
- ▣ Descrição bivariada – com o objectivo de estudar o comportamento conjunto de dois atributos, ou o mesmo atributo medido em localizações distintas;
- ▣ Descrição espacial – com o objectivo de visualizar o modo como o atributo se dispersa no espaço:
  - localização espacial dos valores extremos (valores extremos distribuem-se na região em estudo vrs. valores muito altos/baixos concentrados);
  - anisotropia, anomalias, descontinuidades,...

25

## Análise estrutural dos dados


- ▣ **Objectivo:** caracterização e quantificação do modo como se dispersa espacialmente a variável em estudo.
  - Esta etapa é a base dos processos de inferência/estimação espacial.
- ▣ **Ferramenta básica:** variograma
  - Representa a taxa média de variação do fenómeno em estudo com a distância;
  - Descreve o padrão de variação espacial;
  - Resume a informação num ponto, a partir dos valores observados em pontos próximos.

26

## Variograma

- ▣ **Variograma experimental** – construído com os dados da amostra

- ▣ **Variograma teórico** – modelo teórico que relaciona a variância entre dois pontos distanciados de  $h$  unidades





$$\gamma^*(h) = \frac{\sum_{k=1}^{n(h)} [z(x_k) - z(x_k + h)]^2}{2n(h)}$$

- modelo

27

## Características do variograma

- ▣ Para fenómenos estacionários, o variograma apresenta as seguintes características:
  - 1)  $\gamma(0) = 0$ , mas pode ser descontínuo na origem;
  - 2) é uma função crescente;
  - 3) quando  $h \rightarrow \infty$ ,  $\gamma(h) \rightarrow C(0)$



28

## Patamar, amplitude e efeito pepita

- ▣ **Patamar** – representa a variabilidade da variável  $Z$ .
- ▣ **Amplitude** – mede a distância a partir da qual os valores da variável  $Z$  deixam de estar correlacionados.
- ▣ **Efeito pepita** – mede fundamentalmente duas parcelas da variabilidade total do fenómeno em estudo:
  - variação espacial numa escala inferior à distância mínima entre pontos amostrados;
  - variabilidade devida a erros de medição.

29

## Modelos de variogramas


- ▣ Antes do variograma poder ser utilizado, tem de ser ajustado aos dados um modelo teórico (uma função matemática).
  - A função a ajustar tem de satisfazer certas condições.
- ▣ Na prática, a modelação do variograma limita-se ao uso de um conjunto restrito de funções que cobrem a generalidade das situações de dispersão dos fenómenos espaciais que nos interessam estudar:
  - **modelo esférico**,
  - **modelo exponencial**,
  - **modelo Gaussiano**.

30

## Modelo esférico

Um dos modelos mais usuais em geoestatística.

$$\gamma(h) = \begin{cases} C \left[ 1.5 \frac{h}{\phi} - 0.5 \left( \frac{h}{\phi} \right)^3 \right], & 0 \leq h \leq \phi \\ C, & h > \phi. \end{cases}$$



Função de dois parâmetros:  
C - patamar  
 $\phi = a$  - amplitude


31

## Modelo exponencial

Função de 2 parâmetros: C - patamar e  $\phi = a/3$ .

Neste caso, o valor da amplitude a é a distância em que o modelo atinge 95% do patamar, isto é,  $\gamma(a) = 0.95C(0)$ .

$$\gamma(h) = C(1 - e^{-h/\phi}), \quad h \geq 0$$




32

## Modelo Gaussiano

Função de 2 parâmetros: C - patamar e  $\phi = a/\sqrt{3}$ .

Também aqui, o valor da amplitude a é a distância em que o modelo atinge 95% do patamar, isto é,  $\gamma(a) = 0.95C(0)$ .

$$\gamma(h) = C(1 - e^{-(h/\phi)^2}), \quad h \geq 0$$



Contrariamente aos modelos anteriores, este modelo tem um crescimento lento junto à origem.

33

## Ajustar um modelo ao variograma experimental

- Processo que envolve várias tentativas e no qual a experiência e o conhecimento do fenômeno é muito importante.
- Pode fazer-se o ajustamento de forma manual, analisando o resultado visualmente, ou utilizar técnicas de ajustamento automático.
- A forma analítica de um modelo não é muito importante desde que as principais características do fenômeno sejam respeitadas, nomeadamente:
  - o efeito pepita,
  - o declive na origem,
  - a amplitude,
  - o patamar,
  - as anisotropias.

34

## Variograma ajustado

Com o comando `eyefit` do *package* **geoR** é possível visualizar no variograma experimental alguns modelos teóricos, nomeadamente, os modelos referidos anteriormente.

```
> eyefit(exemplo.variogr)
cov.model sigmasq phi tausq kappa kappa2 practicalRange
exponential 9.52 1.06 1.19 <NA> <NA> 3.18
```

Neste exemplo, o modelo escolhido foi o exponencial com parâmetros  $C = 9.52$  (`sigmasq`) e  $\phi = 1.06$  (`phi`), efeito pepita  $C_0 = 1.61$  (`tausq`) e amplitude  $a = 3.18$  (`practicalRange`). O variograma resultante pode ser descrito por

$$\gamma_{ajust}(h) = C_0 + \gamma(h), \quad h > 0$$

35

## Estimação

**Krigagem:**

- método de estimação que deve o seu nome ao trabalho pioneiro de D.G. Krige (1951).
- método que utiliza o “melhor” estimador linear não-enviezado (centrado).

A krigagem pode assumir diversas formas. A mais usual é designada por **krigagem normal** ou ordinária (*ordinary kriging*): assume-se que o fenômeno em estudo é estacionário mas de média  $\mu$  desconhecida.

36

## Estimação

▣ **Objectivo:** estimação do valor da variável  $Z$  num ponto  $x_0$  não amostrado,  $Z(x_0)$ .

▣ **Estimador a utilizar:**  $Z^*(x_0)$ , que deverá

- 1) ser combinação linear dos valores conhecidos  $Z(x_i)$ ,  $i = 1, \dots, n$

$$Z^*(x_0) = \sum_{i=1}^n \lambda_i Z(x_i)$$

- 2) com média do erro de estimação ( $\epsilon$ ) nula

$$E[\epsilon(x_0)] = E[Z^*(x_0) - Z(x_0)] = 0$$

- 3) com variância do erro de estimação mínima

$$\min Var[\epsilon(x_0)] = E[(Z^*(x_0) - Z(x_0))^2]$$

37

## Estimação

▣ Considerando as hipóteses de estacionaridade e a primeira condição,

$$E[Z^*(x_0)] = E[Z(x_0)] = \mu$$

$$E[Z^*(x_0)] = E\left[\sum_{i=1}^n \lambda_i Z(x_i)\right] = \mu \sum_{i=1}^n \lambda_i$$

a segunda condição é satisfeita se  $\sum_{i=1}^n \lambda_i = 1$

e a terceira pode ser reescrita em termos da covariância ou do variograma

$$\min Var[\epsilon(x_0)] = C(0) + \sum_i \sum_j \lambda_i \lambda_j C(x_i, x_j) - 2 \sum_i \lambda_i C(x_i, x_0)$$

$$\min Var[\epsilon(x_0)] = 2 \sum_i \lambda_i \gamma(x_i, x_0) - \sum_i \sum_j \lambda_i \lambda_j \gamma(x_i, x_j)$$

38

## Krigagem

▣ O problema de determinar  $\lambda_1, \lambda_2, \dots, \lambda_n$  que

$$\min Var[\epsilon(x_0)] \quad \text{s.a.} \quad \sum_{i=1}^n \lambda_i = 1$$

pode ser resolvido através do sistema linear de  $(n+1)$  equações a  $(n+1)$  incógnitas – **sistema de krigagem**

$$\begin{cases} \lambda_1 C(x_1, x_1) + \lambda_2 C(x_1, x_2) + \dots + \lambda_n C(x_1, x_n) + \alpha = C(x_1, x_0) \\ \lambda_1 C(x_2, x_1) + \lambda_2 C(x_2, x_2) + \dots + \lambda_n C(x_2, x_n) + \alpha = C(x_2, x_0) \\ \vdots \\ \lambda_1 C(x_n, x_1) + \lambda_2 C(x_n, x_2) + \dots + \lambda_n C(x_n, x_n) + \alpha = C(x_n, x_0) \\ \lambda_1 + \lambda_2 + \dots + \lambda_n = 1 \end{cases}$$

em que  $\alpha$  é mais uma incógnita (o parâmetro de Lagrange), introduzida pelo método utilizado na resolução deste problema (método dos multiplicadores de Lagrange). 39

## Krigagem

▣ O sistema de krigagem pode também ser descrito em função do variograma

$$\begin{cases} \lambda_1 \gamma(x_1, x_1) + \lambda_2 \gamma(x_1, x_2) + \dots + \lambda_n \gamma(x_1, x_n) - \alpha = \gamma(x_1, x_0) \\ \lambda_1 \gamma(x_2, x_1) + \lambda_2 \gamma(x_2, x_2) + \dots + \lambda_n \gamma(x_2, x_n) - \alpha = \gamma(x_2, x_0) \\ \vdots \\ \lambda_1 \gamma(x_n, x_1) + \lambda_2 \gamma(x_n, x_2) + \dots + \lambda_n \gamma(x_n, x_n) - \alpha = \gamma(x_n, x_0) \\ \lambda_1 + \lambda_2 + \dots + \lambda_n = 1 \end{cases}$$

▣ O valor mínimo da variância do erro de estimação ( $\epsilon$ ) é

$$\begin{aligned} \text{Variância de krigagem} \quad Var[\epsilon(x_0)] &= C(0) - \sum_{i=1}^n \lambda_i C(x_i, x_0) - \alpha \\ Var[\epsilon(x_0)] &= \sum_{i=1}^n \lambda_i \gamma(x_i, x_0) + \alpha \end{aligned}$$

40

## Sistema de krigagem: notação matricial

▣ O sistema anterior pode ser escrito sob a forma matricial  $Kx = M$ , em que

- $K$  é uma matriz quadrada de ordem  $(n+1)$  cujos elementos são  $\gamma(x_i, x_j) = \gamma_{ij}$ , o variograma entre os pontos observados  $x_i$  e  $x_j$ ,
- $x$  é o vector das incógnitas  $(\lambda_1, \lambda_2, \dots, \lambda_n, \alpha)$ ,
- $M$  é um vector cujos elementos são  $\gamma(x_i, x_0) = \gamma_{i0}$ , o variograma entre o ponto observado  $x_i$  e o ponto a estimar  $x_0$ .

$$Kx = M$$

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

41

## Estimação e erro

▣ Obtida a solução do sistema de krigagem, – a estimativa do valor da variável  $Z$  num ponto  $x_0$  não amostrado,  $z^*(x_0)$ , é calculada com base no conjunto de dados experimentais  $\{z(x_1), z(x_2), \dots, z(x_n)\}$  como

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

– a estimativa da variância do erro de estimação é calculada como

$$Var[\epsilon(x_0)] = \sum_{i=1}^n \lambda_i \gamma(x_i, x_0) + \alpha$$

42



## **Bibliografia:**

---

- ☞ Armstrong, M. (1998) Basic Linear Geostatistics, Springer-Verlag.
- ☞ Diggle, P. e Ribeiro Jr., P (2007) Model-based Geostatistics, Springer.
- ☞ Soares, A. (2000) Geoestatística para as Ciências da Terra e do Ambiente, IST Press.