

# Sobre a Geração de Mapas de Ambiente de Rádio com Kriging Ordinário

Ricardo Augusto e Cristiano Panazio

**Resumo** — Este artigo apresenta e discute importantes ferramentas da geoestatística utilizadas para a geração de mapas de ambiente de rádio (REM – *Radio Environment Maps*) em sistemas de comunicações sem fio. A partir de um processo de amostragem espacial, o método Kriging Ordinário (KO) foi utilizado para gerar o REM. Resultados de simulação mostram a influência de parâmetros relacionados à modelagem do ambiente de rádio na precisão de geração do REM. Sobre esta perspectiva, são apontados desafios e limitações relacionados à geração e uso do REM em aplicações de sistemas de comunicações sem fio.

**Palavras-Chave** – Kriging, Geoestatística, REM, Semivariograma.

**Abstract** — This article presents and discusses important tools of geostatistics used for the generation of Radio Environment Maps (REM) in wireless communications systems. From a spatial sampling process, Ordinary Kriging method was used to generate REM. Simulation results show the influence of parameters related to the modelling of radio environment on the accuracy of the generation of REM. On this perspective, challenges and limitations related to the generation and use of REM in wireless communications systems are point out.

**Keywords** – Kriging, Geostatistics, REM, Semivariogram.

## I. INTRODUÇÃO

O mapa de ambiente de rádio (REM, em inglês), conceito proposto por [1], consiste em um mapa que indica uma grandeza física do ambiente de rádio, sendo a mais comum, a intensidade dos sinais no ambiente de propagação. O REM é gerado a partir de um conjunto de medidas coletadas do ambiente e pode ser consultado para tomadas de decisão relacionadas aos problemas de cobertura em sistemas de comunicações sem fio [2]. Sobre esta perspectiva, o REM pode ser usado em aplicações como: Tarefas de planejamento e monitoramento de cobertura em sistemas de comunicações sem fio [2]; Minimização de *Drive-Tests* (MDT) [3]; Análise e tomada de decisões em sistemas de acesso dinâmico ao espectro [4]; Sensoriamento espectral de faixas licenciadas e não licenciadas em sistemas de rádios cognitivos [5].

Tem-se como principal desafio do REM a obtenção de mapas da forma mais fidedigna possível sobre toda a região analisada, usando um número relativamente pequeno de medidas [6], pois o desempenho obtido nas aplicações subsequentes depende das informações contidas nos mapas. Diferentes métodos, com abordagens determinísticas e estocásticas, são usados para gerar o REM [5]. Neste contexto, a geoestatística se apresenta como um dos métodos mais promissores [3] [4].

Este trabalho possui o objetivo de apresentar, de forma resumida, as ferramentas da geoestatística necessárias para o tratamento do problema de geração do REM, apontando peculiaridades e limitações que podem ser úteis para futuras pesquisas.

Sobre a estrutura do trabalho, a seção II aborda os conceitos elementares da geoestatística. A seção III traz os aspectos da modelagem e geração do REM bem como os resultados de simulações. Finalmente, as conclusões e propostas para trabalhos futuros são mostradas na seção IV.

## II. CONCEITOS DE GEOESTATÍSTICA

A geoestatística, por meio dos métodos Kriging, visa realizar previsões espaciais para reproduzir um fenômeno espacial em estudo. Isso é feito a partir da caracterização espacial do fenômeno analisado. Tal fenômeno pode ser descrito por um processo aleatório  $Z(\mathbf{s})$  em um domínio  $D$ ,

$$\{Z(\mathbf{s}), \mathbf{s} \in D\} \quad (1)$$

em que  $\mathbf{s}$  é uma coordenada no plano  $(x,y)$ .

A realização da função aleatória espacial, denotada por  $z(\mathbf{s})$ , é conhecida como variável regionalizada (VR), sendo  $\{z(\mathbf{s}_i)\}$ , com  $i=1, 2, \dots, N$  o conjunto de valores regionalizados. Especificamente, tais valores regionalizados são o resultado das realizações de uma coleção de variáveis aleatórias espaciais  $Z(\mathbf{s}_i)$  que formam o processo aleatório  $Z(\mathbf{s})$ . Assim, a VR é obtida por intermédio de um processo de amostragem dos valores da realização do campo espacial. Este processo é chamado de regionalização. Neste sentido, a regionalização é o primeiro passo para se obter a caracterização espacial necessária para a posterior previsão espacial.

### A. Semivariograma Teórico e Experimental

O raciocínio principal da geoestatística é baseado na ideia de que existe uma relação de dependência espacial entre a coleção de variáveis aleatórias que formam o processo aleatório. Esta relação surge na forma de uma correlação espacial estruturada no campo espacial.

As funções covariância  $C(\mathbf{s}_i, \mathbf{s}_j)$  e semivariograma  $\gamma(\mathbf{s}_i, \mathbf{s}_j)$  são usadas para caracterizar a estrutura espacial dos processos aleatórios espaciais. A covariância entre duas variáveis aleatórias nos pares de coordenadas  $(\mathbf{s}_i, \mathbf{s}_j)$  é definida como

$$C(\mathbf{s}_i, \mathbf{s}_j) = E\{(Z(\mathbf{s}_i) - \mu(\mathbf{s}_i))(Z(\mathbf{s}_j) - \mu(\mathbf{s}_j))\}, \forall \mathbf{s}_i, \mathbf{s}_j \in D \quad (2)$$

em que  $\mu(\mathbf{s}_i)$  é a média da variável aleatória  $Z(\mathbf{s}_i)$ . A função semivariograma de um campo aleatório é definida como sendo a variância das diferenças das variáveis aleatórias que compõem  $Z(\mathbf{s})$ , *i.e.*,

$$\begin{aligned} \gamma(\mathbf{s}_i, \mathbf{s}_j) &= \frac{1}{2} \text{Var} \left\{ \left[ Z(\mathbf{s}_i) - Z(\mathbf{s}_j) \right] \right\} \quad \forall \mathbf{s}_i, \mathbf{s}_j \in D \\ &= \frac{1}{2} E \left\{ \left[ \left( Z(\mathbf{s}_i) - Z(\mathbf{s}_j) \right) - E \left\{ \left( Z(\mathbf{s}_i) - Z(\mathbf{s}_j) \right) \right\} \right]^2 \right\} \end{aligned} \quad (3)$$

Neste âmbito, um ponto importante da teoria de processos aleatórios é sua relação com a hipótese de estacionariedade [7] [8]. Especificamente, considerando a estacionariedade no sentido amplo, a caracterização estatística das variáveis aleatórias que formam  $Z(\mathbf{s})$  não depende da posição espacial específica ( $\mathbf{s}$ ), mas sim de um vetor de translação espacial ( $\mathbf{h}$ ) entre os pontos espaciais. Como resultado, a função semivariograma torna-se

$$\gamma(\mathbf{h}) = \frac{1}{2} \text{Var} \left\{ \left[ Z(\mathbf{s} + \mathbf{h}) - Z(\mathbf{s}) \right] \right\} \quad (4)$$

É importante notar que o semivariograma em (4) retrata a relação entre dois pontos espaciais considerando uma determinada direção espacial. Logo, é possível que esta relação mude com a direção retratando um fenômeno anisotrópico [8]. No caso em que não ocorrem alterações no semivariograma em relação à direção, tem-se o semivariograma isotrópico que depende somente de  $|\mathbf{h}|$ . Tratar o caso anisotrópico foge do escopo deste trabalho, que assumirá apenas as hipóteses mais simplificadoras de estacionariedade e isotropia.

Neste contexto, ressalta-se que a realização das predições espaciais depende do conhecimento do semivariograma. Contudo, o que se dispõe na prática, é de um conjunto de medidas coletadas que formam a VR, tornando necessária a estimação de (4). Tal estimação é feita aproximando (4) por uma função analítica cujos parâmetros são ajustados de acordo com o semivariograma experimental que será mostrado a seguir.

Em geral, o cálculo do semivariograma experimental é baseado em distâncias de separação pré-definidas, denotadas como Lags [7-9]. Nota-se que é possível fazer o cálculo do semivariograma experimental diretamente com as distâncias de separação entre as medidas, ou seja, sem aproximações, mas isto requer o uso de métodos não convencionais de regressão não-paramétrica<sup>1</sup>, que não necessariamente geram resultados melhores do que a técnica descrita a seguir [9].

Os passos abaixo descrevem os pontos mais importantes no cálculo do semivariograma experimental baseado nas distâncias Lags:

(1) É gerada uma matriz  $\Delta$ , triangular superior, cujos elementos ( $i,j$ ) são dados pelas distâncias de separação  $|\mathbf{h}_{ij}| = |\mathbf{s}_i - \mathbf{s}_j|$  entre todos os pares de pontos que compõem a VR, i.e., para todo  $i < j$ , sendo  $i, j = 1, \dots, N$ .

(2) Em seguida, uma distância de separação inicial, denominada  $Lag_1$  é escolhida a partir de  $\Delta$ . Em geral, a escolha de  $Lag_1$  é baseada em dois critérios [7], sendo a segunda estratégia utilizada neste trabalho:

- ✓ Adota-se  $Lag_1$  como a menor distância de separação espacial encontrada em  $\Delta$ .
- ✓ Adota-se  $Lag_1$  como a média dos valores mínimos de cada coluna de  $\Delta$  (excluindo os valores nulos).

(3) Define-se  $Lag_m = mLag_1$ , com  $m$  natural e maior que um, de modo a se realizar uma quantização uniforme das

distâncias  $|\mathbf{h}_{ij}|$ . Assim, as distâncias  $|\mathbf{h}_{ij}|$  são quantizadas com  $Q(\mathbf{h}_{ij}) = Lag_k$  para  $k$  que minimiza o valor  $|\mathbf{h}_{ij}| - Lag_k$ .

(4) O método dos momentos de Matheron [7] é usado para calcular o valor do semivariograma experimental

$$\gamma_{\text{exp}}(Lag_m) = \frac{1}{2 \|A_{Lag-m}\|} \sum_{|\mathbf{s}_i - \mathbf{s}_j| \in A_{Lag-m}} \left[ z(\mathbf{s}_i) - z(\mathbf{s}_j) \right]^2 \quad (5)$$

em que  $\|\cdot\|$  denota o operador cardinalidade e  $A_{Lag-m}$  é o conjunto de pares de pontos cujas distâncias quantizadas correspondem à distância de separação  $Lag_m$ . O número total  $m$  de distâncias de separação depende de  $Lag_{\text{máx}}$ , que normalmente é escolhida como metade da distância do mapa analisado [8] [9]. Em geral, têm-se poucos pares de pontos para grandes distâncias de separação. Isso impacta na confiabilidade dos valores do semivariograma experimental para grandes distâncias. Em [8] [9], encontram-se informações detalhadas sobre a forma de cálculo do semivariograma experimental em relação às distâncias de separação e a direção (anisotropia).

Os resultados de estimação do semivariograma experimental, obtidos a partir da (5), são usados em um processo de ajuste a fim de obter um modelo analítico para o semivariograma dos dados. A Figura 1 mostra um exemplo de um modelo analítico ajustado – curva sólida –, a partir de um semivariograma experimental (pontos).

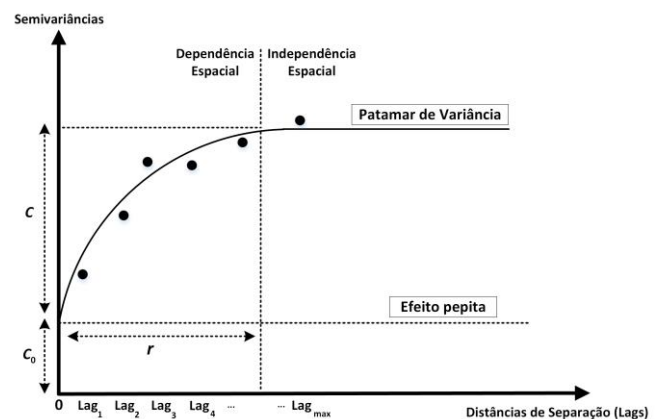


Figura 1: Semivariograma analítico (curva cheia) e experimental (pontos).

Em geral, três parâmetros são ajustados: 1) a variância *sill* retratada pelo patamar ( $C + C_0$ ) do semivariograma; 2) a distância  $r$ , indicando a distância de separação a partir da qual se tem uma independência espacial no processo aleatório; 3) o efeito pepita ( $C_0$ ), que reflete a ocorrência de uma descontinuidade na origem do semivariograma. Em [7], o comportamento dos parâmetros de ajuste do semivariograma analítico é visitado em mais detalhes bem como a apresentação dos modelos analíticos mais utilizados na geoestatística (ex: esférico, seno cardinal e Gaussiano). Neste trabalho, o modelo analítico Gaussiano foi utilizado [7] [8]. O melhor desempenho de ajuste do modelo baseado no semivariograma experimental é o principal objetivo da análise variográfica, uma vez que tal modelo representará a variabilidade espacial do fenômeno em estudo.

### B. Predições Espaciais – Método Kriging Ordinário

Na geoestatística, os diferentes métodos Kriging, usados para realizar as predições espaciais, são baseados no modelo analítico do semivariograma e nas pressuposições relacionadas à hipótese de estacionariedade das funções aleatórias. Dependendo destas hipóteses e do conhecimento a

<sup>1</sup> O cálculo do semivariograma experimental sem aproximações de distância de separação resulta na nuvem do semivariograma, comumente utilizada para identificação de *outliers* nos dados [9].

priori sobre a média do processo aleatório, diferentes preditores Kriging são utilizados.

Sobre a pressuposição de estacionariedade no sentido amplo, ressalta-se duas informações: 1) A média do processo aleatório existe e é constante, ou seja,  $\mu = \mu(\mathbf{s}) = E\{Z(\mathbf{s})\}$ . 2) A covariância do processo aleatório depende somente do vetor de translação  $\mathbf{h}$ . Assim, quando o valor específico da média  $\mu$  é conhecido inicialmente, o método Kriging Simples (KS) é utilizado. Entretanto, somente com várias realizações do processo aleatório é possível obter  $\mu$ . No caso em que  $\mu$  não é necessariamente conhecida, mas constante (estacionariedade no sentido amplo), o método Kriging Ordinário é utilizado [7].

Dentro deste aspecto, um ponto importante consiste na verificação da dependência de  $\mu$  quanto à posição espacial ( $\mathbf{s}$ ), retratando a presença de uma tendência  $\mu(\mathbf{s})$  no processo aleatório espacial. Neste caso, a média do processo aleatório não é constante e conseqüentemente, a abordagem da estacionariedade fica comprometida. Sobre estas circunstâncias, o preditor Kriging Universal (KU) pode ser utilizado, desde que, a tendência possa ser decomposta em um conjunto de funções base representadas por monômios com grau que normalmente não excede a potência de dois [7]. Apesar disso, a tendência presente no ambiente de rádio – descrição que é feita na seção III – é modelada com funções não lineares com potências que normalmente são maiores que dois. Logo, optou-se neste trabalho pela realização da estimação e remoção da tendência do processo aleatório antes do processo de Krigagem. Uma vez removida a tendência dos dados, o método KO pode ser utilizado. Especificamente, o preditor Kriging Ordinário, adotado neste trabalho, é definido por

$$Z^*(\mathbf{s}_0) = \sum_{i=1}^N \lambda_i z(\mathbf{s}_i) \quad (6)$$

em que  $Z^*(\mathbf{s}_0)$  é o resultado da predição espacial em uma determinada coordenada espacial desconhecida  $\mathbf{s}_0$ , obtido a partir das medidas  $z(\mathbf{s}_i)$  e dos pesos Kriging ( $\lambda_i$ ). Estes pesos são calculados sobre a suposição de estacionariedade em segunda ordem (sentido amplo) e, além disso, sob duas condições importantes [7] [8]: 1) que o estimador seja não viesado e 2) que a variância de predição seja mínima.

### 1) Condição de não vies do KO:

A equação (7) mostra o cálculo relacionado à condição de não vies do preditor KO. O valor esperado da diferença entre a predição espacial  $Z^*(\mathbf{s}_0)$  e o valor verdadeiro do processo aleatório no referido ponto  $Z(\mathbf{s}_0)$ , é zero. Para isso a soma dos valores dos pesos Kriging deve ser unitária.

$$\begin{aligned} E\{Z^*(\mathbf{s}_0) - Z(\mathbf{s}_0)\} &= E\left\{\sum_{i=1}^N \lambda_i z(\mathbf{s}_i) - Z(\mathbf{s}_0)\right\} = 0 \\ &= \sum_{i=1}^N \lambda_i E\{z(\mathbf{s}_i)\} - E\{Z(\mathbf{s}_0)\} = 0 \\ &= \sum_{i=1}^N \lambda_i \mu - \mu = 0, \text{ logo, } \sum_{i=1}^N \lambda_i = 1 \end{aligned} \quad (7)$$

em que  $\mu$  é a média (constante) do processo aleatório.

### 2) Variância de Predição do KO

A variância de predição (também chamada de variância Kriging) é dada por definição como

$$\begin{aligned} \text{Var}\{Z^*(\mathbf{s}_0) - Z(\mathbf{s}_0)\} &= E\left\{\left[Z^*(\mathbf{s}_0) - Z(\mathbf{s}_0)\right]^2\right\} \\ &\quad - E\left\{\left[Z^*(\mathbf{s}_0) - Z(\mathbf{s}_0)\right]\right\}^2 \end{aligned} \quad (8)$$

Considerando a condição de não vies para o segundo termo e usando a definição do estimador KO, é possível expandir o primeiro termo da equação (8), resultando em

$$\begin{aligned} \text{Var}\{Z^*(\mathbf{s}_0) - Z(\mathbf{s}_0)\} &= E\left\{\left[Z^*(\mathbf{s}_0) - 2Z^*(\mathbf{s}_0)Z(\mathbf{s}_0) + Z^2(\mathbf{s}_0)\right]\right\} \\ &= \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j E\{Z(\mathbf{s}_i)Z(\mathbf{s}_j)\} \\ &\quad - 2\sum_{i=1}^N \lambda_i E\{Z(\mathbf{s}_i)Z(\mathbf{s}_0)\} + E\{Z^2(\mathbf{s}_0)\} \end{aligned} \quad (9)$$

Ressaltando as seguintes definições da covariância

$$\begin{aligned} E\{Z(\mathbf{s}_i)Z(\mathbf{s}_j)\} &= C(\mathbf{s}_i, \mathbf{s}_j) + \mu^2 \\ E\{Z(\mathbf{s}_i)Z(\mathbf{s}_0)\} &= C(\mathbf{s}_i, \mathbf{s}_0) + \mu^2 \\ E\{Z^2(\mathbf{s}_0)\} &= C(\mathbf{0}) + \mu^2 \end{aligned} \quad (10)$$

e substituindo-as em (9), encontra-se a relação entre a variância de predição e a função de covariância, dada por

$$\begin{aligned} \text{Var}\{Z^*(\mathbf{s}_0) - Z(\mathbf{s}_0)\} &= \sum_{i=0}^N \sum_{j=0}^N \lambda_i \lambda_j C(\mathbf{s}_i, \mathbf{s}_j) \\ &\quad - 2\sum_{i=0}^N \lambda_i C(\mathbf{s}_i, \mathbf{s}_0) + C(\mathbf{0}). \end{aligned} \quad (11)$$

### 3) Sistema de Equações do KO

O problema central do KO consiste em encontrar os pesos que minimizam a variância de predição em (9) sob a condição de não vies em (7). A solução se dá com a aplicação do método de Lagrange utilizando a seguinte função lagrangiana

$$\phi(\lambda_i, \beta) = \text{Var}\{Z^*(\mathbf{s}_0) - Z(\mathbf{s}_0)\} - \beta \left\{ \sum_{i=1}^N \lambda_i - 1 \right\}. \quad (12)$$

em que  $\beta$  é o multiplicador de Lagrange.

O resultado da diferenciação da função em (12) em relação aos pesos Kriging ( $\lambda_i$ ) e ao multiplicador de Lagrange, permite obter o sistema de equações da Krigagem Ordinária

$$\sum_{j=1}^N \lambda_j C(\mathbf{s}_i, \mathbf{s}_j) - \beta = C(\mathbf{s}_i, \mathbf{s}_0) \text{ e } \sum_{i=1}^N \lambda_i = 1, \quad i = 1, \dots, N \quad (13)$$

Este sistema de equações relaciona a função de covariância entre os pontos espaciais ( $\mathbf{s}_i$  e  $\mathbf{s}_j$ ) que formam o campo espacial e o ponto desconhecido ( $\mathbf{s}_0$ ). Substituindo-se a relação do sistema em (13) na expressão (11), obtém-se a variância de predição

$$\sigma_{OK}^2(\mathbf{s}_0) = C(\mathbf{0}) - \sum_{i=1}^N \lambda_i C(\mathbf{s}_i, \mathbf{s}_0) + \beta. \quad (14)$$

Dada a relação entre a função covariância e a função semivariograma  $C(\mathbf{s}_i, \mathbf{s}_j) = C(\mathbf{0}) - \gamma(\mathbf{s}_i, \mathbf{s}_j)$ , é possível reescrever o sistema de equações Kriging em função do semivariograma

$$\sum_{j=1}^N \lambda_j \gamma(\mathbf{s}_i, \mathbf{s}_j) + \beta = \gamma(\mathbf{s}_i, \mathbf{s}_0) \text{ e } \sum_{i=1}^N \lambda_i = 1, \quad i = 1, \dots, N \quad (15)$$

A solução do sistema de equações KO consiste nos pesos Kriging  $\lambda_i$  para aplicação de (6). Além disso, associado a cada predição, é possível calcular a variância de predição em função do semivariograma, dada por:

$$\sigma_{KO}^2(\mathbf{s}_0) = \sum_{i=1}^N \lambda_i \gamma(\mathbf{s}_i, \mathbf{s}_0) + \beta. \quad (16)$$

III. MODELAGEM E GERAÇÃO DO REM

Apresentado o método de predição espacial Kriging, esta seção aborda os aspectos de modelagem do ambiente de rádio que será alvo do processo de predição espacial.

A modelagem do ambiente de rádio é baseada em um sistema de comunicação sem fio composto por dispositivos móveis e uma estação rádio base. Supõe-se que tais dispositivos são capazes de realizar as medidas de intensidade do nível de sinal recebido e enviá-las para a estação rádio-base, que coordena toda a operação da rede do sistema de comunicação sem fio.

Interno à estação rádio-base, o centro de predição espacial é responsável pelo processamento das medidas coletadas e pela geração do REM. Especificamente, o ambiente de rádio é caracterizado por um canal de propagação que apresenta uma série de mecanismos como difrações, reflexões e refrações, além da perda por percurso e absorção de energia. Esses mecanismos influenciam a intensidade dos sinais recebidos e consequentemente afetam a precisão do processo de geração do REM. Assim, o processo aleatório espacial referente ao ambiente de rádio pode ser interpretado como

$$Z(\mathbf{s}) = \mu(\mathbf{s}) + \xi(\mathbf{s}) \tag{17}$$

em que  $\mu(\mathbf{s})$  é a tendência do campo espacial, representada pelo o modelo de perda por percurso (*Path Loss Model*) e  $\xi(\mathbf{s})$  é a parcela aleatória do campo espacial, representada pelos efeitos do sombreamento (*Shadowing*) do canal.

De forma analítica, a modelagem do ambiente de rádio é descrita pela seguinte equação:

$$\bar{P}_L(d) = \underbrace{\bar{P}_L(d_0)}_{\text{Perda por Percurso}} + 10 \log \left( \frac{d}{d_0} \right)^\alpha + \underbrace{X_{\sigma_s}(d)}_{\text{Sombreamento}} \text{ [dB]} \tag{18}$$

em que  $\bar{P}_L(d)$  representa a atenuação (dB) a uma determinada distância  $d$  (metros) e  $\bar{P}_L(d_0)$  retrata a atenuação a uma

distância de referência ( $d_0$ ) desconsiderando os efeitos do sombreamento. A variável aleatória Gaussiana  $X_{\sigma_s}$  (na escala em dB) denota o sombreamento do modelo com média igual a zero e desvio padrão  $\sigma_s$ . Em particular para o sombreamento, tem-se a característica distância de correlação ( $d_c$ ) que é uma medida espacial que reflete o grau de correlação do campo espacial. Finalmente, o parâmetro  $\alpha$  é o coeficiente de propagação do modelo de perda por percurso. Para cenários urbanos e suburbanos (característicos dos sistemas de comunicações sem fio [10]), é possível considerar a variação  $2 < \alpha < 6$ .

O primeiro passo para a geração do REM via KO consiste na verificação e estimação da tendência nos dados da VR. Nas simulações deste trabalho, um processo de regressão não linear, baseado no método dos mínimos quadrados, foi realizado a fim de identificar e estimar a perda por percurso do processo aleatório. Nesta metodologia, assume-se o conhecimento a priori de duas informações importantes: (1) a localização do transmissor; (2) as distâncias envolvidas entre os dispositivos da rede e o transmissor. Isso significa que as incertezas sobre estas informações influenciam o tratamento da tendência dos dados necessário para o KO, afetando, portanto, todo o processo de predição espacial. Em seguida, a tendência é subtraída das medidas coletadas para posterior estimação do semivariograma experimental. O processo de ajuste utilizando o semivariograma experimental permite obter o modelo analítico necessário para o preditor KO.

A Figura 2 mostra os resultados de simulação para a realização de uma função aleatória (c) composta por: (a) perda por percurso e (b) sombreamento com as seguintes configurações:  $\alpha = 3,5$ ,  $d_c=100\text{m}$ ,  $\sigma_s=5\text{dB}$  e grid  $500 \times 500\text{m}$ . Dois casos foram simulados para a mesma realização: (d) com  $N = 30$  medidas; (e) com  $N = 100$  medidas coletadas com estratégia de amostragem com distribuição uniforme.

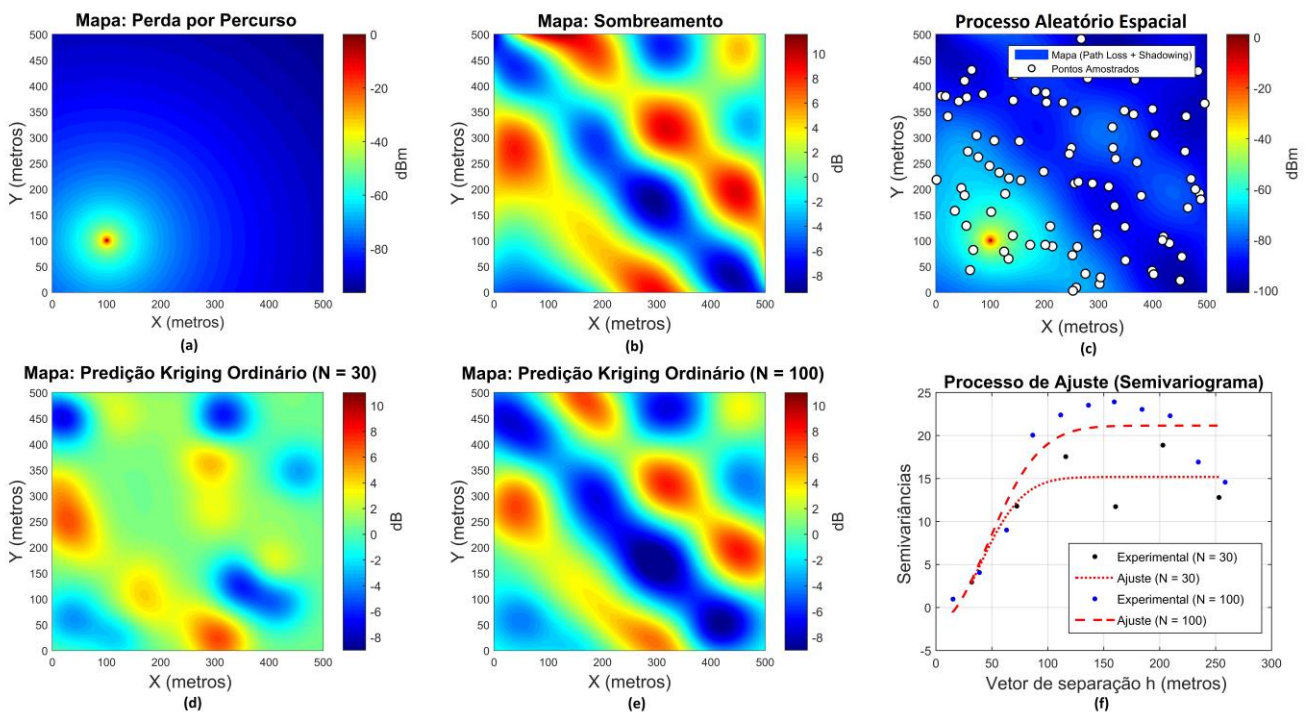


Figura 2: Resultados de simulação: (a) perda por percurso, (b) sombreamento do canal, (c) realizações do processo aleatório e da amostragem espacial (d) predição espacial com  $N = 30$ , (e) predição espacial com  $N = 100$  e (f) semivariograma experimental e analítico.



Os resultados de estimação e ajuste usando o semivariograma experimental são mostrados em (f) para os dois casos de simulação. Nota-se que, embora ambos os casos tenham a mesma separação  $r$  para independência espacial, têm-se patamares diferentes para cada um deles. Ainda, no caso em que  $N = 30$  amostras, fica clara a baixa verossimilhança do mapa gerado em relação à verdadeira realização do sombreamento do ambiente de rádio. Isso significa que inferências espaciais e decisões tomadas com base nestas circunstâncias podem comprometer o desempenho das aplicações subsequentes. De outro modo, com  $N = 100$  amostras, tem-se um resultado de predição que caracteriza melhor precisão na geração do REM.

É intuitivo notar que o número de amostras coletadas ( $N$ ) e, principalmente, o padrão espacial de amostragem afetam o desempenho da predição. Entretanto, ressalta-se que os resultados acima estão relacionados a uma realização particular do processo aleatório. De fato, a aleatoriedade do processo de amostragem e do próprio processo aleatório requer que a análise de desempenho seja feita para mais realizações. Para buscar resultados que levem consistência estatística, a avaliação da precisão é feita utilizando a métrica raiz do erro quadrático médio (RMSE – *Root Mean Square Error*) que capta a magnitude do erro, na forma de diferenças quadráticas, entre os valores reais do processo aleatório e as predições espaciais, de acordo com

$$\text{RMSE} = \sqrt{\frac{1}{N_T} \sum_{i=1}^{N_T} [Z(s_i) - Z^*(s_i)]^2} \quad (19)$$

em que  $N_T$  é o número total de pontos do mapa, ou seja, as comparações são feitas em todo o grid 500m x 500m, com resolução de 1m.

A Figura 3 mostra os resultados de simulação na forma de histograma estatístico para a métrica RMSE referente a 1000 realizações dentro de um cenário com  $\alpha=3,5$ ,  $d_d=100\text{m}$ ,  $\sigma_s=5\text{dB}$  e  $N=100$  amostras.

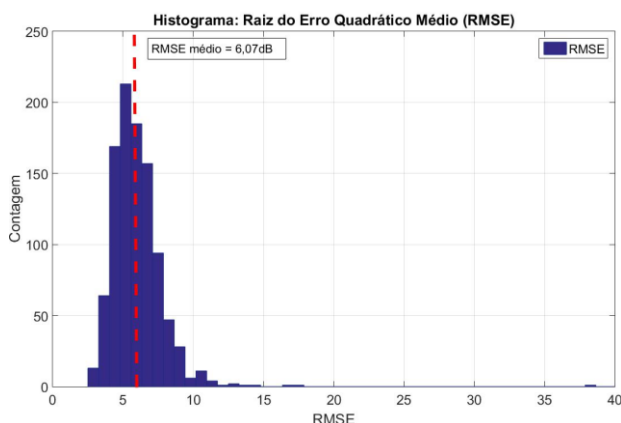


Figura 3: Resultados de simulação para métrica estatística RMSE

Ressalta-se que as realizações dos processos aleatórios bem como os processos de amostragem são independentes. O objetivo seria observar, para estas condições de campo espacial, qual seria o comportamento esperado (médio) do desempenho das predições KO. Assim, sobre estas circunstâncias de propagação, nota-se no histograma que, em média, espera-se um RMSE da ordem de 6dB. Isso significa que, o preditor Kriging é capaz de reproduzir a estrutura do sombreamento do canal com erros que em média, são da ordem de 6dB. Ressalta-se que valores baixos para o RMSE indicam boa precisão na reprodução alcançada pelas

predições espaciais. Ainda assim, são os requisitos de desempenho relacionados às aplicações e a forma como estas venham a utilizar o REM que determinam o grau de precisão exigido nos resultados de geração das predições espaciais.

#### IV. CONCLUSÕES E PROPOSTAS

As principais ferramentas da geoestatística, como o semivariograma experimental e o método KO, foram apresentadas e utilizadas na modelagem e na geração do REM. A influência do número de medidas, do padrão espacial de amostragem e o tratamento da tendência dos dados experimentais foram levantados como pontos importantes na geração REM, sobretudo quando se considera o aspecto funcional dos sistemas de comunicações sem fio. A métrica estatística RMSE foi usada para a verificação e análise do desempenho (médio) do preditor KO na reprodução do sombreamento do ambiente de rádio.

Sobre possíveis desafios a serem tratados e superados, é possível citar: (1) Estudos de influência acerca dos parâmetros e modelos de propagação específicos na precisão de geração do REM; (2) Consideração de incertezas sobre as medidas e localizações dos dispositivos que compõem o sistema de comunicação sem fio; (3) Uso dos resultados da predição espacial Kriging para aplicações em comunicações como sistemas de acesso dinâmico ao espectro; (4) Estudos sobre a utilização de diferentes estratégias de amostragem espacial; (5) Consideração das questões relacionadas à anisotropia na estimação do semivariograma experimental.

#### Referências

- [1] Zhao, Y. ; Gaeddert, J. ; Base K, K. ; Reed, J. H and Wireless@Virginia Tech, "Radio Environment Map Enabled Situation-Aware Cognitive Radio Learning Algorithms". *Proceeding of the SDR 06 - Technical Conference and Product Exposition*, 2006.
- [2] 3GPP TR 36.805 v1.3.0 1, "Study on minimization of drive-tests in next generation networks; (release 9)," tech. rep., 3<sup>rd</sup> Generation Partnership Project, 2009.
- [3] A. Galindo-Serrano, B. Sayrac, S. Ben Jemaa, J. Riihijärvi and P. Mähönen, "Harvesting MDT data: Radio environment maps for coverage analysis in cellular networks," *Cognitive Radio Oriented Wireless Networks (CROWNCOM), 2013 8th International Conference on*, Washington, DC, 2013, pp. 37-42.
- [4] A. Galindo-Serrano, B. Sayrac, S. Ben Jemaa, J. Riihijärvi and P. Mähönen, "Automated coverage hole detection for cellular networks using radio environment maps," *Modeling & Optimization in Mobile, Ad Hoc & Wireless Networks (WiOpt), 2013 11th International Symposium on*, Tsukuba
- [5] H. B. Yilmaz, T. Tugcu, F. Alagöz and S. Bayhan, "Radio environment map as enabler for practical cognitive radio networks," in *IEEE Communications Magazine*, vol. 51, no. 12, pp. 162-169, December 2013.
- [6] S. Grimoud, B. Sayrac, S. Ben Jemaa and E. Moulines, "Best Sensor Selection for an Iterative REM Construction," *Vehicular Technology Conference (VTC Fall), 2011 IEEE*, San Francisco, CA, 2011, pp. 1-5.
- [7] Chiles's, J. P. ; Delfine, P. ; *Geostatistics Modeling Spatial Uncertainty*, Second Edition, Copyright © 2012 by John Wiley & Sons, Inc. All rights reserved.
- [8] Yamamoto J. K. ; Landim, P. M. B. ; "Geoestatística: Conceitos e Aplicações", Oficina de Textos, ano: 2013.
- [9] Diggle, P. J. ; Ribeiro, P. J. ; "Model-based Geostatistics", *Springer Science Business Media*, LLC, 2007
- [10] Cho, Y. S. ; Kim, J. ; Yang, W. Y. ; Kang, C. "MIMO-OFDM Wireless Communications Systems with Matlab", John Wiley & Sons (Asia) Pte Ltd, 2 Clementi Loop, # 02-01, Singapore 129809, 2010.