

**METODOLOGIA GEOESTATÍSTICA PARA
CARACTERIZAR A VARIABILIDADE
TEMPORAL DE ELEMENTOS CLIMÁTICOS
DE JUIZ DE FORA – MG**

VANIA CORRÊA MOTA

2008

VANIA CORRÊA MOTA

**METODOLOGIA GEOESTATÍSTICA PARA
CARACTERIZAR A VARIABILIDADE TEMPORAL DE
ELEMENTOS CLIMÁTICOS DE JUIZ DE FORA – MG**

Dissertação apresentada à Universidade Federal de Lavras como parte das exigências do Programa de pós-graduação em Estatística e Experimentação Agropecuária, para a obtenção do título de Mestre.

Orientador:
Prof. Dr. Renato Ribeiro de Lima

**LAVRAS
MINAS GERAIS – BRASIL
2008**

**Ficha Catalográfica Preparada pela Divisão de Processos Técnicos da
Biblioteca Central da UFLA**

Mota, Vania Corrêa.

Metodologia geoestatística para caracterizar a variabilidade temporal de elementos climáticos de Juiz de Fora – MG / Vania Corrêa Mota. –

Lavras: UFLA, 2008.

111 p. : il.

Dissertação (Mestrado) – Universidade Federal de Lavras, 2008.

Orientador: Renato Ribeiro de Lima.

Bibliografia.

1. Geoestatística. 2. Precipitação pluvial. 3. Temperatura do ar. 4. Mudanças climáticas. I. Universidade Federal de Lavras. II. Título.

CDD – 551.633

VANIA CORRÊA MOTA

**METODOLOGIA GEOESTATÍSTICA PARA
CARACTERIZAR A VARIABILIDADE TEMPORAL DE
ELEMENTOS CLIMÁTICOS DE JUIZ DE FORA – MG**

Dissertação apresenta à Universidade Federal de Lavras como parte das exigências do Programa de pós-graduação em Estatística e Experimentação Agropecuária, para a obtenção do título de Mestre.

APROVADA em 27 de fevereiro de 2008

Prof. Dr. Luiz Gonsaga de Carvalho	UFLA
Prof. Dr. Marcelo Silva de Oliveira	UFLA
Prof. Dr. Marcelo de Carvalho Alves	UFLA

Prof. Dr. Renato Ribeiro de Lima
UFLA
(Orientador)

LAVRAS
MINAS GERAIS – BRASIL
2008

DEDICO

A

DEUS,

Senhor todo poderoso, o Alfa e o Ômega.

Autor da minha vida e meu senhor, pela oportunidade de estar aqui, e por ter posto diante de mim essa porta aberta, a qual ninguém pode fechar.

A meus queridos pais, Ailson Machado Mota e Oraide Corrêa Pinheiro, pelo amor, apoio, carinho, incentivo e por terem sido pacientes, principalmente nesses últimos anos em que estive envolvida com o mestrado.

Ao meu irmão, Wagner Pinheiro Mota, pelo carinho, amor, confiança e paciência.

Ao meu querido avô, Antonio Ramos da Motta (*in memoriam*), pelos ensinamentos, amor e pela enorme saudade.

A meus tios, tias, padrinhos, madrinhas, primos, primas, amigos e avós, pelo apoio, dedicação, confiança, que me ajudaram a progredir.

A todos que, de forma direta ou indireta, contribuíram para a realização deste novo desafio em minha vida, deixo aqui o meu muito obrigada!

AGRADECIMENTOS

A DEUS, e a JESUS CRISTO, por me darem sabedoria, saúde, força, coragem e muita persistência para que eu pudesse, em meio às lutas, ultrapassar todos os obstáculos desta caminhada e conseguir conquistar meu objetivo.

À Universidade Federal de Lavras (UFLA), por meio do Departamento de Ciências Exatas (DEX), pela oportunidade e apoio ao longo do curso.

Ao CNPq, pela concessão da bolsa de estudos.

Ao professor Renato Ribeiro de Lima, pela orientação, compreensão, paciência, confiança e amizade.

Ao Dr. Marcelo de Carvalho Alves, pela paciência, orientação, incentivo, apoio, dedicação, confiança, amizade e, principalmente, pelo plantão tira-dúvidas, o meu muito obrigada.

Aos amigos Teodora, Geraldino, Sirene e Suely e família, pelo apoio, pelas valiosas sugestões, pelos atendimentos sempre solícitos e pela grande amizade.

A Lourdinha e família, pelo apoio, ensinamentos, amizade e ajuda, os meus sinceros agradecimentos.

A todos os professores, colegas de curso e funcionários do Departamento de Ciências Exatas, pela grata e prazerosa convivência, ensinamentos e cooperação. Em especial a Maria e a Josi, pela amizade.

SUMÁRIO

RESUMO.....	i
ABSTRAT	ii
CAPÍTULO 1.....	1
1. Introdução Geral	2
2 Referencial teórico.....	5
2.1 Noções básicas de geoestatística.....	6
2.1.1 Variáveis regionalizadas (VR).....	6
2.1.2 Hipóteses de estacionaridade	8
2.2 Semivariograma.....	10
2.2.1 Métodos de ajuste do semivariograma e modelos de semivariograma teórico	15
2.2.2 Seleção de modelos de semivariograma	17
2.3 Krigagem	19
2.3.1 Validação cruzada.....	22
2.4 Aplicações da geoestatística a dados climáticos	23
2.4.1 Generalidades climáticas	26
3 Referências bibliográficas.....	28
CAPÍTULO 2: Estudo da dependência temporal da precipitação pluvial e da temperatura do ar de Juiz de Fora, MG por meio de análises geoestatísticas..	33
1 Resumo	34
2 Abstract.....	35
3 Introdução	36
4 Material e métodos.....	38
4.1 Material.....	38
4.1.1 Origem dos dados	38
4.1.2 Dados observados	39
4.1.3 Dados de previsão de cenários futuros.....	39
4.2. Métodos	41

4.2.1 Análise exploratória.....	41
4.2.2 Análise estrutural	41
4.2.3 Interpolador geoestatístico – krigagem ordinária.....	43
5 Resultados e discussão.....	44
5.1 Análise da estrutura de continuidade temporal.....	48
6 Conclusões.....	65
7 Referências bibliográficas.....	66
CAPÍTULO 3: Caracterização da dependência temporal de elementos climáticas para cenários futuros de Juiz de Fora, MG por meio de semivariograma e krigagem.....	
1 Resumo	71
2 Abstract.....	72
3 Introdução.....	73
4 Material e métodos.....	75
4.1. Material.....	75
4.1.1 Origem dos dados	75
4.1.2 Dados observados	76
4.1.3 Dados de previsão de cenários futuros.....	76
4.1.4 Arranjo ou malha utilizada nas análises.....	78
4.2 Métodos	79
4.2.1 Análise estrutural	79
4.2.2 Interpolador geoestatístico – krigagem ordinária.....	81
5 Resultados e discussão.....	83
5.1 Análise isotrópica	83
5.2 Análise Anisotrópica.....	93
5.3 Análise da interpolação geoestatística	100
6 Conclusões.....	106
7 Considerações finais	107
8 Referências bibliográficas.....	108

RESUMO

MOTA, Vania Corrêa. **Metodologia geoestatística para caracterizar a variabilidade temporal de elementos climáticos de Juiz de Fora, MG.** 2008. 111 p. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) – Universidade Federal de Lavras, Lavras, MG.*

O objetivo geral deste trabalho foi avaliar a aplicação de uma metodologia de análise geoestatística e dois arranjos, um unidimensional, no qual considera-se apenas os meses no estudo da variabilidade temporal e outro, bidimensional, onde se considera meses e anos nas análises, para caracterizar a variabilidade temporal da precipitação pluvial e da temperatura de Juiz de Fora – MG. Foram utilizadas séries históricas de uma estação pluviométrica da Agência Nacional das Águas - ANA, bem como dados de previsão de mudanças climáticas sob cenários futuros, do Painel Intergovernamental de Mudanças Climáticas - IPCC. Verificou-se a utilização de modelos de semivariograma e a krigagem ordinária para representar e caracterizar a dependência temporal da precipitação pluvial, para os dados observados de precipitação no período de 1967 a 1999 e os cenários futuros A2, A1B e B1 de mudanças climáticas para precipitação pluvial e temperatura do ar as no período de 2000 a 2099. Pela análise semivariográfica, foi possível detectar que as duas variáveis avaliadas apresentaram-se estruturadas temporalmente. Verificou-se, melhor ajuste do modelo 'wave', para os dados observados e cenários futuros de precipitação pluvial, e para a variável temperatura do ar verificou melhor ajuste do modelo gaussiano, quando considerado o arranjo unidimensional. A representação gráfica da krigagem, em uma forma bidimensional, mostrou-se bastante adequada, pois facilitou a visualização do comportamento sazonal das variáveis ao longo do tempo. Ao realizar as análises considerando um arranjo bidimensional, observou-se melhor ajuste do modelo 'wave' quando comparado com o modelo gaussiano e esférico, considerando o arranjo de dados mensais e anuais, utilizando-se o critério de Akaike e o grau de dependência do semivariograma teórico. Com o uso da Geoestatística, representou-se o padrão da variabilidade temporal da precipitação e da temperatura ao longo dos anos e dos meses, por meio da interpolação de krigagem e verificou-se possíveis alterações dessas variáveis nos cenários futuros de mudanças climáticas.

* Comitê de Orientação: Prof. Dr. Renato Ribeiro de Lima – UFLA (Orientador); Marcelo de Carvalho Alves – UFLA (Co-orientador).

ABSTRACT

MOTA, Vania Corrêa. **Geostatistic methodology to characterize the temporal variability of climatic elements of Juiz de Fora – MG.** 2008. 111 p. Dissertation (Master in Statistics and Agricultural Experimentation) – Universidade Federal de Lavras, Lavras. †

In this work it was evaluated the application of a methodology of geostatistic and two grids, one unidimensional and another two-dimensional. In unidimensional grid, months were used as coordinates and in two-dimensional grid years and months were considered as coordinates to characterize the temporal variability of the pluvial precipitation and of the air temperature of Juiz de Fora – MG. It was considered a historical series of a pluviometrical station of the ANA (National Agency of the Waters). Futhermore, it was evaluated climatic changes forecast data of future scenarios of the Intergovernmental Panel of Climatic Changes - IPCC. The observed data of precipitation are from 1967 to 1999 period and the future scenarios A2, A1B and B1 of climatic changes are from 2000 to 2099 period. In this last case, it was used the ordinary kriging to represent the pluvial precipitation and the temperature for the three scenarios along the time. The semivariografic analysis detected that the two variables present temporal dependence, both isotropy and anisotropy, in the directions of the proposed arrangement. It was verified that the best adjustment for the pluvial precipitation adjustment was with the wave model when the unidimensional grid was used. The best adjustment for the variable temperature of the air was presented by the gaussian model. The analysis by using two-dimensional grid was an interesting alternative to visualize the results of the ordinary kriging. It was a didactic form to present the variability of the pluvial precipitation and temperature of the air along the time. When it was used the two-dimensional grid, the semivariogram model which presented the best adjustment was wave model, by considering the Akaike Criterion and the degree of the theoretical semivariogram dependence. The pattern of the precipitation and the temperature temporal variability was satisfactorily represented by using kriging, along the years and of the months. In that graphic representation was easy to verify possible alterations in those variables for the future scenarios of climatic changes.

† Guidance Committee: Prof. Dr. Renato Ribeiro de Lima – UFLA (Adviser); Marcelo de Carvalho Alves – UFLA (Co - Adviser).

CAPÍTULO 1

1 INTRODUÇÃO GERAL

Muitos pesquisadores das áreas de climatologia, meteorologia, hidrologia e áreas afins têm verificado a ocorrência de mudanças climáticas em diversas regiões do planeta. Nesse cenário, os elementos precipitação pluvial e temperatura do ar aparecem como sendo aqueles em que mais se observam essas mudanças.

As mudanças climáticas, segundo o Painel Intergovernamental de Mudanças Climáticas, IPCC, são definidas como sendo mudanças temporais do clima, devido à variabilidade natural e ou ao resultado de atividades antrópicas (IPCC, 2001). Dessa forma, torna-se necessário verificar a presença ou a ocorrência de alterações na variabilidade do clima em escala local, para que se possa afirmar que estejam ocorrendo ou não mudanças climáticas na região em estudo.

Porém, os dados climatológicos apresentam alguns problemas quanto à sua utilização, devendo ser manipulados com precauções. É necessário, em primeiro lugar, verificar a qualidade das observações que, muitas das vezes, apresentam problemas de erros de leitura, defeitos de aparelhos, entre outros (Dubreuil, 2005). Pode-se, por métodos de estatística clássica, detectar erros e, às vezes, corrigi-los. Entretanto, em determinados contextos, esses métodos podem não produzir a eficiência esperada. Um exemplo disso ocorre quando algumas variáveis apresentam-se com dependência espacial, ou seja, existe autocorrelação espacial entre as observações. Dentre as abordagens utilizadas para modelar a variabilidade espacial, pode-se citar a geoestatística.

Na geoestatística consideram-se as associações entre amostras vizinhas com base em sua grandeza geométrica. Por meio da localização das amostras, detecta-se a influência de uma sobre a outra, de acordo com a distância entre elas

(Melem, 2002). Segundo Ribeiro Júnior (1995), deixar de considerar a correlação espacial significa deixar de observar importantes aspectos que determinam a ocorrência do fenômeno estudado, enquanto que na análise estatística clássica de dados pressupõe-se que as observações não influenciam em sua vizinhança, ou seja, as variáveis aleatórias são independentes entre si.

Existem vários tipos de dados que podem ser analisados utilizando-se geoestatística (Carvalho et al., 2004). Exemplos de tais dados são os diversos elementos climáticos, tais como a precipitação pluvial e a temperatura do ar (Vianello & Alves, 1991).

Fenômenos naturais apresentam-se freqüentemente estruturados com relação à vizinhança. Dessa forma, pode-se dizer que essas variações não são aleatórias e, portanto, apresentam algum grau de dependência espacial ou temporal. Dados no espaço e no tempo são necessários para modelar distribuições hidrológicas das inundações, erosões e outros processos não controláveis do meio ambiente, a exemplo de enchentes, secas e geadas, entre outros (Ferreira, 2005; Haberlandt, 2007).

Segundo Nobre (2001), sob efeito de ações antrópicas, observou-se aumento das emissões de gases de efeito estufa (GEE) para a atmosfera, de modo a aumentar a probabilidade de mudanças climáticas globais de grande magnitude. Entre essas mudanças, as mais significativas foram: o aumento de temperatura, as modificações nos padrões de chuvas e as alterações na distribuição de extremos climáticos. Outros fatores relevantes que comprovam a ocorrência de mudanças climáticas referem-se aos relatos científicos sobre a intensificação da freqüência da variabilidade climática associada aos eventos conhecidos como “El Nino” e “La Niña” (Berlato & Fontana, 2003; Marengo et al., 2007). Estes fenômenos atuam sobre o regime pluvial da América do Sul, modificando a distribuição temporal e espacial de chuvas, acarretando incertezas climáticas (Vieira & Carvalho, 2001).

Assim, o estudo da variabilidade temporal de elementos climáticos é de extrema importância e a utilização de metodologias adequadas, como a análise geoestatística, torna-se muito útil para representar a precipitação pluvial e a temperatura no tempo e no espaço.

Dessa forma, partindo da hipótese de que, com o uso da metodologia geoestatística, é possível representar a dependência temporal de variáveis climáticas, de forma a elucidar fatores relacionados com mudanças climáticas globais, o objetivo deste trabalho foi avaliar a aplicação dessa metodologia de análise, considerando-se dois arranjos, um unidimensional, no qual se consideram apenas os meses no estudo da variabilidade temporal e outro, bidimensional, em que se consideram meses e anos nas análises, para caracterizar a variabilidade temporal da precipitação pluvial e da temperatura de Juiz de Fora, MG. Foram utilizados dados de séries históricas de uma estação pluviométrica da Agência Nacional das Águas (ANA), bem como dados de previsão de mudanças climáticas de cenários futuros do Painel Intergovernamental de Mudanças Climáticas (IPCC).

Abordou-se, no Capítulo 1, um referencial teórico, com princípios e conceitos referentes à metodologia adotada e aos elementos climáticos. No Capítulo 2, o objetivo foi verificar o uso da metodologia de análise geoestatística para caracterizar a dependência temporal da precipitação pluvial e da temperatura do ar de Juiz de Fora, MG, para os dados observados (ano 1967 a 1999) e para os cenários futuros de mudanças climáticas, considerando um arranjo unidimensional. No Capítulo 3, o objetivo foi verificar o uso de modelos de semivariograma e a krigagem ordinária para caracterizar e representar a dependência temporal da precipitação pluvial e da temperatura do ar de Juiz de Fora, MG, para os dados observados (ano 1967 a 1999) e para os cenários futuros de mudanças climáticas, utilizando anos e meses como coordenadas.

2 REFERENCIAL TEÓRICO

A geoestatística surgiu na África do Sul, quando o engenheiro de minas Daniel Krige, trabalhando com dados de concentração de ouro, concluiu que as covariâncias de duas amostras dependiam da distância entre elas. Foi então que o professor George Matheron, ligado à escola francesa, fundou, na década de 1960, o ‘Centre de Geoestatistique de Fontainebleau’ e desenvolveu, baseado nestas observações de Daniel Krige, a Teoria das Variáveis Regionalizadas (VR) (Matheron, 1963).

A partir dos grupos de estudos de ‘Fontainebleau’ surgiram os primeiros modelos geoestatísticos e os sistemas de krigagem, os quais abordavam os problemas ligados aos recursos geológicos como fenômenos espaciais (Soares, 2006). Esta foi chamada de primeira grande fase, a era da geoestatística mineira.

No final dos anos 1970 e início dos anos 1980, uma outra área de aplicação marca a segunda etapa da evolução da geoestatística: o ambiente. Nessa fase, os modelos assimilavam as especificidades dos dados relativos às ciências ambientais, como, por exemplo, poluição dos solos, poluição da atmosfera e qualidade de água de aquíferos subterrâneos. Nessa fase, também foi introduzido o tempo como a quarta coordenada (Soares, 2006).

Em meados dos anos 1980, surgiu o terceiro avanço da metodologia geoestatística, na área petrolífera (Soares, 2006). Com isto, verificou-se o potencial de uso da Teoria das Variáveis Regionalizadas, para estudar a variabilidade espacial e temporal de variáveis em diferentes áreas do conhecimento.

2.1 Noções básicas de geoestatística

2.1.1 Variáveis regionalizadas (VR)

Matheron (1963) definiu as VR como uma função espacial numérica que varia de um local para outro, com continuidade aparente, ou seja, distribuída de forma contínua no espaço. Do ponto de vista estatístico, uma VR é simplesmente uma variável aleatória ou função $Z(x_j)$ que assume um valor para cada x_j no espaço p -dimensional \mathfrak{R}^p , em que x_j representa uma posição nesse espaço.

Segundo Oliveira (2003), a localização ou o suporte geométrico é uma das características da VR e está diretamente ligada à estrutura do fenômeno espacial. Essa variável apresenta-se com valores no campo geométrico em que a mesma foi definida, isto é, no local onde será avaliada sua variabilidade. Outra característica importante, segundo Guerra (1988), é a continuidade espacial da VR, expressa por meio de uma flutuação entre os valores de amostras vizinhas, referentes ao grau de dependência espacial ou temporal de um valor e outro. A aplicação da teoria de VR a problemas voltados para a geologia e mineração recebeu o nome de geoestatística (Journel & Huijbregts, 1991).

A geoestatística pode ser vista como um ramo da estatística espacial que estuda a relação de uma variável regionalizada com ela mesma em uma outra posição, ou seja, são técnicas que consideram a localização e o arranjo espacial de uma variável na análise ou na interpretação dos resultados de um estudo (Cressie, 1993).

Segundo Pontes (2002), a geoestatística é baseada, fundamentalmente, em dois conceitos: o do semivariograma, utilizado para descrever a estrutura da variabilidade espacial e o da krigagem, utilizado para estimar os valores não observados, com variância mínima.

A geoestatística modela os valores de um atributo, dentro de uma região, como uma função aleatória (Cressie, 1993). Uma função aleatória ou processo

estocástico é definido como um conjunto de variáveis aleatórias dependentes $Z(x_j)$, uma para cada localização x_j na área de estudo P e é simbolizado por $Z(x)$. Segundo Cressie (1993), esse processo estocástico é representado por:

$$\left[Z(x_j) : x_j \in P \subset \mathfrak{R}^p \right],$$

em que Z é a variável aleatória que está continuamente variando em P ; x_j é a localização da variável, considerada fixa; P é a região em estudo e \mathfrak{R}^p é o espaço p -dimensional, sendo $p = 1, 2, 3$ e 4 , mais especificamente.

Para os casos em que $p = 1$, têm-se variações unidimensionais, como as utilizadas em estudos de séries temporais. Para $p = 2$, os dados estão localizados em um plano, para $p = 3$ no espaço tridimensional e para $p = 4$, consideram-se as variações no espaço-tempo (Oliveira, 1991).

A função aleatória expressa aspectos aleatórios e estruturados de uma variável regionalizada de tal forma que: i) localmente, para um ponto x_j , $Z(x_j)$ é uma variável aleatória, ii) $Z(x)$ é também uma função aleatória no sentido de que, para cada par de pontos (x_j) e $(x_j + h)$, cuja distância entre eles é igual a h , as correspondentes variáveis regionalizadas $Z(x_j)$ e $Z(x_j + h)$ são, em geral, correlacionadas, expressando a estrutura espacial da variável regionalizada $Z(x_j)$ (Oliveira, 2003).

Portanto, para cada posição de $x_j \in P$, o valor do atributo de um dado espacial é modelado como uma variável aleatória $Z(x_j)$, a qual pode assumir distintos valores para o atributo e a cada uma dessas variáveis aleatórias, está associada uma distribuição de probabilidade (Samper & Ramirez, 1990; Oliveira, 2003). Como a geoestatística modela os valores de um atributo como uma função aleatória, para qualquer conjunto de n localizações $x_j, j = 1, 2, \dots, n$, corresponde um vetor de n variáveis aleatórias $Z(x_1), Z(x_2), \dots, Z(x_n)$, que é caracterizado por uma função de distribuição acumulada n -variada (Samper & Ramirez, 1990;

Melem, 2002; Oliveira, 2003). Porém, segundo Melem (2002), na prática, a análise é limitada a funções de distribuições acumuladas envolvendo não mais que duas localizações de cada vez e seus primeiros momentos correspondentes.

Assim, para que se possa realizar inferência em relação à função aleatória e seus momentos, são necessárias repetidas medidas da variável regionalizada em cada localização ou que se repita indefinidamente um experimento, o que é impossível, na maioria das vezes (Goovaerts, 1997; Melem, 2002; Oliveira, 2003). Como exemplos, podem ser citadas a precipitação pluvial mensal e a temperatura média mensal do ar.

Diante dessa impossibilidade, certas restrições são necessárias em estudos de geoestatística, tais como algumas hipóteses de estacionaridade. Supor que uma função aleatória é estacionária é o mesmo que considerar que a função aleatória repete-se no espaço ou no tempo de tal forma que esta proporcione informações equivalentes a muitas realizações da mesma função aleatória, possibilitando, assim, a inferência estatística (Samper & Ramirez, 1990; Oliveira, 2003).

2.1.2 Hipóteses de estacionaridade

Uma função aleatória $Z(x)$ é estacionária de primeira ordem se

$$E[Z(x)] = m(x) = \mu = \text{constante}, \quad (1)$$

isto é, a esperança matemática da variável aleatória é a mesma para todo processo, independente da localização, no tempo e ou no espaço, em que é observada.

A função aleatória $Z(x)$ é estacionária de segunda ordem quando o valor esperado $E[Z(x)]$ existe e não depende da posição x_j e, para cada par de variáveis aleatórias $Z(x_j)$ e $Z(x_j + h)$, a função covariância, dada por

$$\text{Cov}[Z(x_j), Z(x_j + h)] = \text{Cov}(h) = E[Z(x_j)Z(x_j + h)] - m^2, \quad (2)$$

existe e é uma função da distância h , para qualquer x_j de uma área P .

Note que a estacionaridade da covariância (ou estacionaridade de segunda ordem) implica na estacionaridade da variância (variância finita) e, aplicando-se as condições de estacionaridade, definidas em (1) e (2), a variância de $Z(x_j)$ é dada por:

$$\begin{aligned} \text{Var}[Z(x_j)] &= E[Z^2(x_j)] - m^2(x_j) \\ &= E[Z(x_j)Z(x_j + 0)] - m(x_j)m(x_j + 0) \\ &= \text{Cov}(Z(x_j), Z(x_j)) \end{aligned}$$

Assim, tem-se que $\text{Cov}(0) = \text{Var}[Z(x_j)]$.

Segundo Oliveira (2003), a hipótese de estacionaridade de segunda ordem é muito forte e é usualmente substituída por uma hipótese mais fraca e menos restritiva, chamada hipótese intrínseca. Essa hipótese é mais freqüentemente utilizada em geoestatística, pois, aumenta-se o campo de modelos possíveis (Vieira, 2000; Andriotti, 2004).

A hipótese intrínseca é verificada quando existir a estacionaridade de primeira ordem e, para todo vetor h , o incremento $[Z(x_j) - Z(x_j + h)]$ tem variância finita, independente da posição x_j , dependendo apenas do vetor h , isto é:

$$\text{Var}[Z(x_j) - Z(x_j + h)] = E[Z(x_j) - Z(x_j + h)]^2 = 2\gamma(h), \quad (3)$$

em que $\gamma(h)$ é denominado semivariograma.

Assim, partindo-se de (3), tem-se que

$$\begin{aligned}
2\gamma(h) &= E[Z(x_j) - Z(x_j + h)]^2 \\
&= E[Z^2(x_j) - m^2] + E[Z^2(x_j + h) - m^2] - 2Cov[Z(x_j), Z(x_j + h)] \\
&= Var[Z(x_j)] + Var[Z(x_j + h)] - 2Cov(h) \\
&= Cov(0) + Cov(0) - 2Cov(h) \\
&= 2Cov(0) - 2Cov(h) .
\end{aligned} \tag{4}$$

A relação apresentada em (4) é importante, pois, segundo Cressie (1993), implica que $Z(x)$ é intrinsecamente estacionária com $2\gamma(h) = 2[Cov(0) - Cov(h)]$.

Quando a hipótese de estacionaridade de segunda ordem é satisfeita, isto implica que a hipótese intrínseca também o é, mas o inverso não é verdadeiro (Melem, 2002).

Se a hipótese de segunda ordem for satisfeita, o variograma $2\gamma(h)$ e a covariância $Cov(h)$ são ferramentas equivalentes para caracterizar a dependência espacial e ou temporal dos dados.

Para avaliar em qual tipo de estacionaridade os dados se enquadram, o semivariograma é a principal ferramenta utilizada (Melem, 2002).

2.2 Semivariograma

O semivariograma é uma ferramenta utilizada na geoestatística para caracterizar a estrutura e a magnitude da continuidade espacial ou temporal da variável estudada, porque exige uma estacionaridade menos restritiva, a hipótese intrínseca (Ribeiro Júnior, 1995; Mello, 2004).

Considerando, então, todos os pares de pontos medidos, a variável aleatória de interesse, separados por um vetor h dentro da área P estudada, $\{[Z(x_j), Z(x_j + h)], j = 1, 2, \dots, n\}$, como um conjunto de repetições, temos uma função que depende da distância h . As diferenças quadráticas entre valores levam em conta a distância h que os separa permite a construção do

semivariograma, que é a ferramenta base da geoestatística (Isaaks & Srivastava, 1989).

O semivariograma, um parâmetro populacional, é estimado por meio do semivariograma experimental. O semivariograma experimental pode ser obtido por meio do estimador clássico de Matheron e do estimador robusto de Cressie (Cressie, 1993). De acordo com Burrough & McDonnell (1998), o estimador clássico é dado por:

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{j=1}^{N(h)} [z(x_j) - z(x_j+h)]^2, \quad (5)$$

em que $N(h)$ é o número de pares possíveis para uma dada distância h ; $\hat{\gamma}(h)$ é o estimador da semivariância para uma distância h ; $z(x_j)$ e $z(x_j+h)$ são as observações da variável aleatória regionalizada na posição x_j e x_j+h , respectivamente e h é a distância entre as duas observações.

O estimador robusto, proposto por Cressie & Hawkins (1980), é obtido a partir do estimador clássico de Matheron, dado em (3), e é usado quando existem valores discrepantes ou “outliers”. De acordo com Cressie (1993), este estimador é dado por:

$$\bar{\gamma}(h) = \frac{1}{2} \left\{ \frac{\left[\frac{1}{N(h)} \sum_{N(h)} |z(x_j) - z(x_j+h)|^2 \right]^4}{0,457 + \frac{0,494}{N(h)}} \right\}, \quad (6)$$

em que $B = 0,457 + \frac{0,494}{N(h)}$ é uma correção para o viés (assintoticamente).

Da definição do semivariograma são decorrentes as seguintes propriedades (Oliveira, 1991; Cressie, 1993; Melem, 2002):

i) $\gamma(0) = 0$ e como $[z(x_j+h) - z(x_j)]^2 = [[z(x_j) - z(x_j+h)]^2]; \quad (7)$

ii) $\gamma(h) = \gamma(-h) \geq 0 \quad (8)$

A característica ideal do semivariograma, segundo Vieira (2000), seria se, intuitivamente, seu comportamento fosse mais realístico, ou seja, representasse o que se espera dos dados amostrados, conforme Figura 1.1.




FIGURA 1.1 Representação gráfica de um semivariograma.

Os parâmetros do semivariograma, representados na Figura 1.1, são:

- a) efeito pepita (C_0): revela a descontinuidade do semivariograma para distâncias menores do que a menor distância entre as amostras. Parte dessa descontinuidade pode ser também devida a erros de medição (Isaaks & Srivastava, 1989), mas é impossível quantificar se a maior contribuição provém dos erros de medição ou da variabilidade de pequena escala não captada pela amostragem. O termo efeito pepita deve ser aplicado sempre

que essa descontinuidade da origem do semivariograma ocorrer, independentemente do tipo de variável estudada;

- b) alcance (a): é a distância dentro da qual as amostras apresentam-se correlacionadas espacialmente, ou seja, é a linha divisória entre a estatística clássica e a geoestatística (Vieira, 2000). De acordo com Andriotti (2004), o alcance representa a zona de influência de uma observação e separa o campo aleatório do campo estruturado;
- c) patamar ($C = C_0 + C_I$): é o valor do semivariograma correspondente a seu alcance (a) e coincide com a variância a priori do conjunto de dados estudados (Andriotti, 2004). Deste ponto em diante, considera-se que não existe mais dependência espacial ou temporal entre as amostras;
- d) contribuição (C_I): é a diferença entre o patamar (C) e o efeito pepita (C_0).

Na prática, para a construção do semivariograma, as distâncias h entre as observações, denominadas também de “lags”, são consideradas em até a metade (50%) da distância máxima entre as observações (Clark, 1979; Soares, 2006).

Como o semivariograma depende da distância h da direção θ (ângulo), ele deve ser construído em direções distintas no espaço. Por exemplo: na direção $\theta = 0^\circ$ (Norte), nas direções das duas diagonais $\theta = 45^\circ$ e $\theta = -45^\circ$ ou 135° e na direção $\theta = 90^\circ$ (Leste), no intuito de se estudar as mudanças da direção do vetor h . Uma das formas de se apresentar essas direções, em estudo envolvendo geoestatística, está apresentada na Figura 1.2.

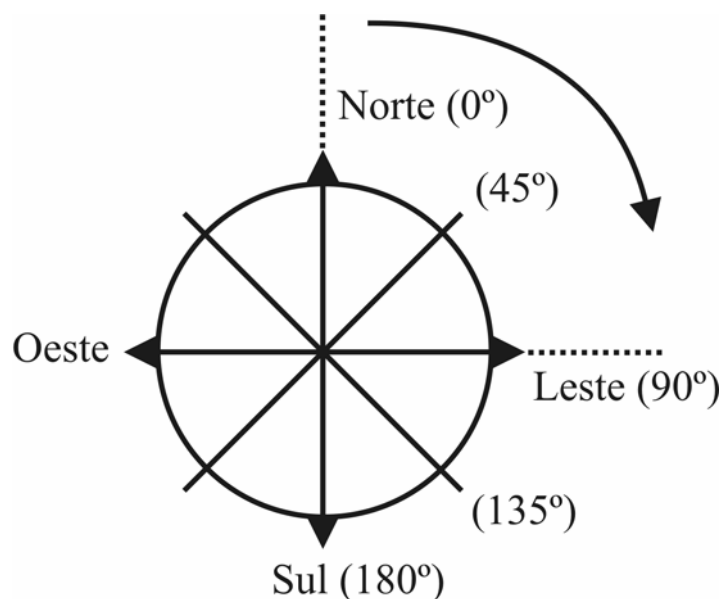


FIGURA 1.2 Convenções direcionais utilizadas em geostatística.

Segundo Vieira (2000) e Soares (2006), quando o gráfico do semivariograma experimental apresenta e exhibe o mesmo comportamento em todas as direções consideradas, ele é chamado isotrópico (omnidirecional), isto é com uma tolerância angular de 90° e, caso contrário, é chamado anisotrópico. A anisotropia pode ser dos tipos geométrica e zonal. A anisotropia é do tipo geométrica quando o mesmo modelo apresenta mesmo patamar e diferentes alcances, enquanto que a zonal o mesmo modelo apresenta mesmo alcance e diferentes patamares (Isaaks & Srivastava, 1989). Como a isotropia, a anisotropia zonal é um caso menos freqüente nos fenômenos naturais. O mais comum é encontrar combinações das anisotropias, geométrica e zonal, denominada anisotropia combinada (Isaaks & Srivastava, 1989; Cressie, 1993 e Goovaerts, 1997).

De acordo com Andriotti (2004), é recomendável executar semivariogramas em, pelo menos, quatro direções, pois, fazendo-se em apenas duas, corre-se o risco de não se verificar a presença de anisotropia.

Com base no gráfico de $\hat{\gamma}(h)$ versus h para cada direção θ , ajusta um modelo teórico (ou semivariograma teórico) ao semivariograma experimental, de tal maneira que, a partir desse modelo, possam ser feitas inferências em relação aos parâmetros do semivariograma. Esse é o objetivo fundamental de um estudo semivariográfico.

2.2.1 Métodos de ajuste do semivariograma e modelos de semivariograma teórico

Segundo Journel & Huijbregts (1991), por meio do semivariograma experimental, o pesquisador pode definir o modelo teórico que melhor descreve o comportamento dos dados no espaço (ou no tempo). Posteriormente, a preocupação do pesquisador se volta para o ajuste de uma função matemática, fato que, na década de 1980, ainda não acontecia, pois, na época, o ajuste do modelo teórico (espacial) ao semivariograma experimental, era usualmente feito de forma subjetiva (“a sentimento”), sem nenhum procedimento matemático.

De acordo com Mello (2004), com o passar dos anos e os avanços dos recursos computacionais, métodos de ajuste automatizados foram sendo estudados e incorporados em programas computacionais de geoestatística, tal como o método dos mínimos quadrados ordinários, método dos mínimos quadrados ponderados, máxima verossimilhança, entre outros.

Para o método de estimação de mínimos quadrados ordinários (OLS), os valores desconhecidos do vetor de parâmetros, $\beta = [C_0, C, a]$, do semivariograma, são estimados calculando-se os valores numéricos para os parâmetros que minimizam a soma de quadrados dos desvios entre as respostas

estimadas e observadas pelo modelo (Draper & Smith, 1980). Matematicamente, a função pode ser escrita como:

$$Q = \sum_h [\gamma(h) - \gamma(h, \beta)], \quad (9)$$

em que $\gamma(h)$ representa o semivariograma experimental, dado em (3) e (4), $\gamma(h, \beta)$ é o modelo de semivariograma teórico (Eq. 10, 11 e 12) e β é o vetor de parâmetros. As estimativas dos parâmetros são obtidas de tal forma que a soma dos quadrados das distâncias entre os valores observados e os estimados a partir da equação 9, sejam as menores possíveis. Essas estimativas são obtidas determinando-se as derivadas parciais de Q em relação a C_0 , C e a , igualando-se a zero as equações de derivadas parciais e resolvendo-se este sistema de três equações com três incógnitas.

O modelo a ser ajustado é um dos aspectos mais importantes da geoestatística, pois todos os cálculos posteriores dependem dos resultados dos parâmetros do modelo. Caso não tenha obtido um bom ajuste, os cálculos seguintes conterão erros que poderão afetar as inferências necessárias para a realização da krigagem. Portanto, essa fase deve ser considerada crucial e receber uma atenção especial.

Os modelos teóricos devem fornecer soluções estáveis para o estimador de krigagem linear (Mello, 2004). Em outras palavras, isso quer dizer que, estatisticamente, é obrigatório que os modelos ajustados satisfaçam às seguintes propriedades, i) e ii) definidas em 7 e 8 (Oliveira, 1991). Os modelos que apresentam essa característica são os chamados modelos autorizados. Alguns dos modelos teóricos (ou semivariograma teórico) ajustados aos semivariogramas experimentais são: esférico, gaussiano e “wave” (Isaaks & Srivastava, 1989; Burrough & McDonnell, 1998).

O modelo esférico é definido por:

$$\gamma(h, \beta) = \begin{cases} C_0 + C_1 \left[\frac{3}{2} \left(\frac{h}{a} \right) - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right] & 0 \leq h \leq a \\ C_0 + C_1 & h > a \end{cases} \quad (10)$$

Esse modelo apresenta-se com comportamento linear na origem e a é seu alcance prático (Chilès & Delfiner, 1999; Andriotti, 2004).

O modelo Gaussiano é dado por:

$$\gamma(h, \beta) = C_0 + C_1 \left(1 - \exp \left(-3 \left(\frac{h^2}{a^2} \right) \right) \right), \text{ se } a > 0. \quad (11)$$

Esse modelo alcança o patamar assintoticamente e tem um comportamento parabólico na origem (Cressie, 1993). O alcance prático do modelo gaussiano é atingido quando o h for aproximadamente igual a $1,73 a$ (Chilès & Delfiner, 1999).

O modelo “wave”, dado por

$$\gamma(h, \beta) = C_0^2 + \frac{a}{h} \operatorname{sen} \left(\frac{h}{a} \right), \quad (12)$$

apresenta variações periódicas, o que é um indicativo de crescimento não monotônico da semivariância com a distância e apresenta modelos com e sem patamar (Chilès & Delfiner, 1999; Andriotti, 2004). Estas estruturas não monotônicas podem ter amplitudes de ondas reduzidas, ser isotrópicas e anisotrópicas (Carvalho et al., 2004). O alcance prático do modelo “wave” é atingido quando o h for aproximadamente igual a $4,5 a$ (Chilès & Delfiner, 1999).

2.2.2 Seleção de modelos de semivariograma

Após o ajuste do semivariograma teórico, a etapa seguinte é verificar qual é o melhor modelo. Nessa seleção de modelos, normalmente, são utilizados o Critério de Informação de Akaike (AIC) e o grau de dependência espacial (DE) dos dados. O AIC é baseado na teoria da decisão e será considerado como o

melhor modelo aquele que apresentar menor valor de AIC. Para avaliar a DE dos dados, pode-se utilizar uma relação proposta por Cambardella et al. (1994), e o modelo que detectar a maior DE será considerado o melhor.

Alguns autores, como Oliveira (2003) e Mello (2004), utilizaram o Critério de Informação de Akaike (Carlin & Louis, 1996), para a seleção de modelos.

De acordo com Carlin & Louis (1996), o AIC é definido por:

$$AIC = -2l + 2p,$$

em que l é o \ln da função de verossimilhança e p é o número de parâmetros. No entanto, Webster & Oliver (2001) propuseram uma aproximação para o valor de AIC, dada por:

$$AIC = 2p + n \cdot \ln(RSS/n), \quad (13)$$

em que n é o número de observações e RSS é a soma de quadrados de resíduos, obtidos a partir da seguinte expressão:

$$RSS = \sum_{j=1}^n [z(x_j) - \hat{z}(x_j)]^2. \quad (14)$$

A verificação do grau de dependência espacial é um outro fator também muito utilizado após o ajuste do semivariograma teórico (Cambardella et al. 1994). Avaliar o grau de dependência espacial da variável estudada é de fundamental importância em um estudo geoestatístico, pois a dependência espacial é um conceito chave para a compreensão e a análise desse fenômeno estudado no espaço e no tempo. Essa noção parte do que Tobler (1970) chama de primeira lei da geografia: “todas as coisas são parecidas, mas coisas mais próximas se parecem mais que coisas mais distantes”. Ou, como afirma Cressie (1993), “a dependência espacial está presente em todas as direções e fica mais fraca à medida que se aumenta a dispersão dos dados no espaço”. A DE relaciona o comportamento dos parâmetros do semivariograma, principalmente o

efeito pepita, e é definido, de acordo com Cambardella et al. (1994), pela seguinte expressão:

$$DE = \frac{C_0}{C_0 + C_1} \times 100. \quad (15)$$

A DE é classificada como forte dependência espacial, se os semivariogramas têm efeito pepita igual ou inferior a 25% do patamar; moderada, quando está entre 25% e 75% e fraca dependência, quando superior a 75%.

2.3 Krigagem

A krigagem é um método de interpolação de valores em qualquer posição no campo de estudo, associado a uma medida de qualidade da estimativa, do tipo BLUE (sigla para “best linear unbiased estimator”) (Isaaks & Srivastava, 1989; Webster & Oliver, 2001; Andriotti, 2004). O nome krigagem foi dado por George Matheron, em homenagem ao matemático sul-africano Daniel Krige (Matheron, 1963).

Para os geoestatísticos, krigagem é um nome genérico, adaptado para a família de algoritmos de regressão de mínimos quadrados generalizados (Goovaerts, 1997). Todos os estimadores de krigagem são variantes do estimador básico de regressão linear $Z^*(x)$ que, segundo Goovaerts (1997), é definido por

$$Z^*(x) = \sum_{j=1}^{n(x)} \lambda_j(x) [Z(x_j) - m(x_j)] + m(x),$$

em que: $\lambda_j(x)$ são os pesos definidos para os dados $z(x_j)$, interpretado como a realização da variável aleatória $Z(x_j)$. As quantidades $m(x)$ e $m(x_j)$ são os valores esperados das variáveis aleatórias $Z^*(x)$ e $Z(x_j)$. O número de amostras necessárias para a estimação, bem como seus pesos, varia de um local para outro.

Na prática, somente os $n(x)$ pares de observações próximos ao local x , a ser estimado são mantidos. A interpretação de $z(x)$ e $z(x_j)$, como realizações das variáveis aleatórias $Z^*(x)$ e $Z(x_j)$, possibilita definir o erro de estimação como uma variável aleatória $Z^*(x) - Z(x)$. A estimação por krigagem se baseia na minimização da estimativa da variância do erro $\sigma^2_E(x)$, sob a suposição de não-tendenciosidade do estimador que, de acordo com Goovaerts (1997), é definida por:

$$\sigma^2_E(x) = \text{Var}\{Z^*(x) - Z(x)\} \text{ é mínima,} \quad (16)$$

a qual é minimizada considerando-se:

$$E\{Z^*(x) - Z(x)\} = 0. \quad (17)$$

As equações (15) e (16) representam condições de variância mínima e de não-tendenciosidade, respectivamente. A condição de variância mínima significa que, embora possam existir diferenças, ponto por ponto, entre o valor estimado e o observado, essas diferenças devem ser mínimas, em que o mínimo é obtido entre todos os valores estimados. A condições de não-tendenciosidade significam que, em média, a diferença entre valores estimados para o mesmo ponto deve ser nula (Vieira, 2000).

Os estimadores de krigagem se diferenciam conforme o modelo considerado para o componente de tendência (Vieira & Carvalho, 2001). Existem vários tipos de krigagem: krigagem ordinária (KO), krigagem simples (KS) e krigagem em blocos (KB), entre outros. A krigagem ordinária é o método geoestatístico univariado que tem sido utilizado por muitos autores no estudo da distribuição espacial de precipitação pluvial e temperatura (Tabios & Salas, 1985; Phillips et al. 1992; Melem, 2002). A KO estima em qualquer lugar, exceto nos locais onde se dispõem de observações de campo, nos quais ela reproduz o valor medido (Andriotti, 2004).

Segundo Goovaerts (1997), na krigagem ordinária, as flutuações locais da média são consideradas, limitando-se o domínio de sua estacionaridade para a vizinhança local. A média é constante, mas desconhecida. O estimador linear é definido por:

$$Z_{KO}^*(x) = \sum_{j=1}^{n(x)} \lambda_j(x) z(x_j),$$

para

$$\sum_{j=1}^{n(x)} \lambda_j(x) = 1,$$

sendo os $n(x)$ pesos $\lambda_j(x)$ determinados de tal maneira que a variância do erro seja mínima (Goovaerts, 1997). Esses pesos são obtidos por meio do sistema de equações lineares, o qual é conhecido por ‘sistema de krigagem ordinária’:

$$\begin{cases} \sum_{j=1}^{n(x)} \lambda_j(x) \gamma(x_j - x_i) - \alpha(x_0) = \gamma(x_j - x_0) & j = 1, 2, \dots, n(x) \\ \sum_{j=1}^{n(x)} \lambda_j(x) = 1, \end{cases} \quad (18)$$

em que, $\gamma(x_j - x_i)$ e $\gamma(x_j - x_0)$ são, respectivamente, a semivariância entre os pontos x_j e x_i e entre os pontos x_i e x_0 e α é o multiplicador de Lagrange, necessário para a minimização da variância do erro.

As únicas informações exigidas pelo sistema de krigagem, definida em (14), são os valores do semivariograma para diferentes distâncias (“lags”), que são obtidos de um modelo de semivariograma teórico, ajustado ao semivariograma experimental. A validação cruzada (*cross validation*) é uma ferramenta utilizada para testar os tipos de krigagem. Com ela, podem-se avaliar algumas suposições sobre o modelo de semivariograma (e seus parâmetros), ajustados ao semivariograma experimental (Melem, 2002).

2.3.1 Validação cruzada

A validação cruzada (*cross validation*) é a adaptação de uma técnica de estatística não paramétrica de validação de um conjunto de dados $z(x_j), (j = 1, 2, \dots, n)$ (Soares, 2006). Segundo Webster & Oliver (2001) e Cressie (1993), o processo consiste nas seguintes etapas:

i) eliminar ou cortar do conjunto de dados, o valor observado em um ponto qualquer, $z(x_j)$;

ii) calcular, pelo método de krigagem, o valor estimado no ponto x_j , empregando-se somente os dados restantes, isto é, calcular $\hat{z}(x_j)$;

iii) calcular o erro de estimação por meio da expressão $[z(x_j) - \hat{z}(x_j)]$ e comparar esse valor com $\frac{[z(x_j) - \hat{z}(x_j)]}{\sigma_E(x_j)}$, em que $\sigma_E(x_j)$ é o desvio padrão

de krigagem, calculada pela raiz quadrada de $\sigma^2_E(x_j)$, definida em (12), o qual representa o erro do valor predito pelo modelo, quando a krigagem é feita para a localização x_j (omitindo-se o valor amostral da localização x_j);

iv) repetir as fases anteriores para todos os pontos e comprovar que:

a) os erros de krigagem são sistemáticos, calculando-se o erro médio (EM).

Então, pode-se afirmar que:

$$EM = \frac{1}{n} \sum_{j=1}^n [z(x_j) - \hat{z}(x_j)] \approx 0. \quad (19)$$

b) os erros são compatíveis com a variância de predição, calculando-se a razão do quadrado médio do erro (RQME). Assim, tem-se:

$$\text{RQME} = \left\{ \frac{1}{n} \sum_{j=1}^n \left[\frac{z(x_j) - \hat{z}(x_j)}{\sigma_E(x_j)} \right]^2 \right\}^{\frac{1}{2}} \approx 1. \quad (20)$$

A validação cruzada é realizada com o objetivo de aferir a qualidade do modelo escolhido para o semivariograma que será utilizado na krigagem (Soares, 2006) e também avaliar toda a modelagem do processo estocástico (Oliveira, 2003). Como, para cada local, tem-se um valor medido e pode-se estimar outro pela krigagem, então, pode-se calcular a regressão linear $\hat{Z}(x_j) = \alpha + \delta Z(x_j)$ entre esses pares de dados e obter os valores da interseção (α), o coeficiente angular (δ) e a correlação entre os pares (r). O melhor ajuste se obtém quando os coeficientes de correlação e de determinação sejam próximos de 1, o intercepto próximo de zero e o coeficiente angular próximo de 1 (Vieira, 2000). Assim, os erros de estimativas de valores em locais não observados podem ser medidos pelo julgamento desses parâmetros.

2.4 Aplicações da geoestatística a dados climáticos

Segundo Cressie (1993) e Oliveira (2003), têm-se observado variáveis com dependência espacial em diversas áreas do conhecimento, tais como em climatologia, hidrologia e solos, entre outras. De acordo com Páscoa (2006), as inferências sobre o clima apresentadas por órgãos de pesquisas apresentaram substanciais diferenças, em detrimento da variabilidade apresentada pelos atributos climáticos. Baú et al. (2006) ressaltaram que, para quantificar uma variável climática, deve-se considerar a variação dos processos físicos dessa variável no espaço e no tempo. Por exemplo, a chuva varia ao longo do espaço e, por isso, sua distribuição deveria assumir valores distintos em função das coordenadas do ponto geográfico de interesse. A chuva também possui variação temporal, ou seja, sua distribuição deve assumir valores distintos ao longo do

tempo, de acordo com as estações do ano, latitude, longitude e altitude (Lanna, 1997).

A existência de dependência espacial na temperatura média do ar foi estudada por Melem (2002) que utilizou a krigagem universal para a construção de mapas e verificou melhor ajuste para o modelo esférico. Melem (2002) acrescenta ainda que, com o uso da geoestatística, pode-se efetuar o mapeamento climático do estado do Paraná e compará-lo com os existentes no Instituto Agrônomo do Paraná (Iapar). Este autor verificou que, para o mês de julho, melhores estimativas foram obtidas pela metodologia geoestatística em relação às obtidas pelo Iapar, que utilizou a metodologia de estatística clássica.

Páscoa (2006) estudou a temperatura para o estado de Minas Gerais e também verificou que as estimativas deste atributo apresentam ótimos resultados considerando-se os modelos de semivariogramas e a interpolação por krigagem. O autor ajustou para os meses de novembro a março o modelo exponencial e, para os meses de maio a setembro, foi ajustado o modelo gaussiano. Assim, foram definidos dois grupos distintos, concluindo-se, pelos mapas, que as maiores temperaturas se encontram na região norte/nordeste do estado e as menores temperaturas na região sul/sudeste.

A precipitação pluvial foi estudada na Suíça por Atkinson & Lloyd (1998), que utilizaram a krigagem ordinária e a krigagem indicatriz. Segundo este estudo, os dados de chuva não apresentaram distribuição normal e os autores usaram, então, uma distribuição log-normal. Os dados pluviais apresentaram anisotropia geométrica, ou seja, o comportamento da dependência espacial apresentou padrão diferenciado, de acordo com a direção. O melhor método de interpolação foi o de krigagem ordinária.

Tabios & Salas (1985) realizaram uma investigação das diferentes técnicas de interpolação espacial para estimar a precipitação anual em cinco locais selecionados. A comparação foi baseada nos seguintes critérios: (i) a

média e a variância das precipitações anuais observadas e interpoladas; (ii) a soma do erro quadrático entre os valores das precipitações anuais observadas e interpoladas; (iii) a proporção da variância calculada pela interpolação e (iv) o coeficiente de determinação entre os valores observados e interpolados e o desvio padrão do erro da interpolação. O resultado desse estudo mostrou que, para a estimação de precipitação anual, a técnica de krigagem foi a melhor entre todas as técnicas. Por outro lado, a interpolação polinomial foi a que apresentou o pior resultado.

Entretanto, Carvalho et al. (2004), ao estudarem a precipitação pluvial média anual do estado de São Paulo, verificaram que o modelo “Hole effect” (“wave”) foi o mais apropriado para descrever essa variável, devido à periodicidade dos dados. Já Carvalho & Assad (2005), ao trabalharem com dados anuais de precipitação oriundos de médias de uma série de 40 anos do estado de São Paulo, ajustaram o modelo esférico e utilizaram a krigagem ordinária para estimar os valores em pontos não amostrados. Os resultados obtidos foram bastante satisfatórios, possibilitando constatar que o interpolador geoestatístico é uma ferramenta apropriada para análise de dados climáticos, quando comparada com outros dois métodos de interpolação espacial: o da curvatura mínima e o do inverso do quadrado da distância.

Silva et al. (2003), ao estudarem o comportamento temporal de chuvas mensais em Uberaba, MG, detectaram a presença de efeito pepita puro, que corresponde a uma total ausência de dependência espacial. Alves et al. (2005) estudaram a precipitação mensal em Uberlândia, MG e verificaram aplicação do modelo gaussiano para descrever a variabilidade temporal dos dados e a krigagem ordinária para construção dos mapas.

2.4.1 Generalidades climáticas

Marengo et al. (2007) definiram o clima como a “média do tempo, ou mais rigorosamente, como a descrição estatística em termos de média e de variabilidade de quantidades relevantes, numa distância de meses a milhares de anos”. Clima, num senso mais amplo, é um estado, incluindo uma descrição estatística, do sistema climático.

As diversas formas de vida na superfície terrestre têm sido prejudicadas, de uma forma ou de outra, por mudanças climáticas (Marengo et al., 2007). O conhecimento das mudanças climáticas de uma região é de fundamental importância, pois o clima pode ser considerado um dos fatores preponderantes para a ecologia e para a socioeconomia de determinada região (Vianello & Alves, 1991). Vários eventos, congressos e palestras foram organizados para discutir a problemática das mudanças climáticas globais. Assim, foi implantado, em 1988, pela Organização Meteorológica Mundial (OMM) e pelo Programa das Nações Unidas para o Meio Ambiente (PNUMA), o Painel Intergovernamental sobre Mudanças Climáticas (IPCC), a fim de: (1) fornecer aos formuladores de políticas públicas uma fonte de informação objetiva sobre as causas das mudanças climáticas; (2) avaliar os impactos ambientais e socioeconômicos e (3) formular possíveis estratégias para minimizar estes impactos (Marengo, 2007).

O IPCC é conhecido por produzir, em intervalos regulares de tempo, uma avaliação do estado de conhecimento sobre as mudanças climáticas, tendo publicado seus relatórios em 1990, 1995, 2001 e 2007. Estes relatórios são reconhecidos como fontes seguras e confiáveis de informações sobre mudanças climáticas e servem de base para a elaboração de documentos e estudos, pelos diversos países (IPCC, 2007).

Segundo o IPCC, as atividades antrópicas foram a principal causa do aquecimento global e mudanças climáticas globais relacionadas com padrões de precipitação e temperatura do ar (Nobre, 2007). Assim, segundo Dias & Dias

(2007), as alterações previstas na sazonalidade da temperatura e da precipitação podem ter impactos na biodiversidade e nas atividades agrícolas.

No Brasil, foi observado um aumento das temperaturas do ar durante o Século XX, de forma compatível com o aquecimento global experimentado pelo planeta. No que se refere à precipitação pluvial, não há indicação clara de mudança e o que se observa é variabilidade climática nas escalas interanual (poucos anos) e interdecadal (dezenas de anos) (Nobre, 2001).

Apesar dos trabalhos já publicados sobre clima e mudanças climáticas, estudos ainda são necessários para identificar metodologias que auxiliem na caracterização mais adequada da estrutura e da magnitude da dependência temporal de variáveis climáticas, tais como a precipitação pluvial e a temperatura do ar. Assim, a geoestatística pode ser utilizada no estudo dessas variáveis, por meio de modelos de semivariograma e mapas de krigagem.

3 REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, G. F.; GONZAGA, F. A. S.; GUIMARÃES, E. C.; TAVARES, M. Comportamento da precipitação mensal de Uberlândia: Análise da dependência temporal. In: ENCONTRO INTERNO DE INICIAÇÃO CIENTÍFICA, 5., 2005, Uberlândia. **Anais...** Uberlândia: PROPP/UFU, 2005. v. 1, p. 1-10. 1 CD-ROM.

ANDRIOTTI, J. L. S. **Fundamentos da estatística e geoestatística**. São Leopoldo: Unisinos, 2004. 165 p.

ATKINSON, P. M.; LLOYD, C. D. Mapping precipitation in Switzerland with ordinary and indicator kriging. **Journal of Geographic Information and Decision Analysis**, Southampton, v. 2, n. 2, p. 72-86, 1998.

BAÚ, A. L.; GOMES, B. M.; QUEIROZ, M. M. F. de; OPAZO, M. A. U.; SAMPAIO, S. C. Comportamento espacial da precipitação pluvial mensal provável da mesoregião oeste do Estado do Paraná. **Irrigação**, Botucatu, v. 11, n. 2, p. 150-168. ab./jun. 2006.

BERLATO, M. A.; FONTANA, D. C. **El Niño e La Niña: impactos no clima, na vegetação e na agricultura do Rio Grande do Sul; aplicações de previsões climáticas na agricultura**. Porto Alegre: UFRGS, 2003. 110 p.

BURROUGH, P. A.; McDONNELL, R. A. **Principles of geographical information systems: spatial Information Systems and Geostatistics**. Oxford: Oxford Universit, 1998. 333 p.

CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURCO, R. F.; KONOPKA, A. E. Fieldscale variability of soil properties in Central Iowa soils. **Soil Science Society of America Journal**, Madison, v. 58, n. 5, p. 1501-1511. Sept./Oct. 1994.

CARLIN, B. P.; LOUIS, T. A. **Bayes and empirical bayes methods for data analysis**. New York: Chapman & Hall, 1996. 417 p.

CARVALHO, J. R. P.; ASSAD, E. D. Análise Espacial da precipitação pluviométrica no Estado de São Paulo: comparação de métodos de interpolação. **Engenharia Agrícola**, Jaboticabal, v. 25, n. 2, p. 377-384, maio/ago. 2005.

CARVALHO, J. R. P. de; VIEIRA, S. R.; VENDRUSCULO, L. G. **Uso da técnica de mínimos quadrados ponderados para ajuste de modelos ao semivariograma**, Campinas: Embrapa Informática Agropecuária, 2004. 15 p. (Boletim de Pesquisa e Desenvolvimento / Embrapa Informática Agropecuária, 11).

CHILÈS, J. P.; DELFINER, P. **Geostatistics: modeling spatial uncertainty wiley series in probability and statistics applied probability and statistics**. New York: J. Wiley, 1999. 695 p.

CLARK, I. **Practical Geoestistics**. Essex: Applied Science, 1979. 129 p.

CRESSIE, N.; HAWKINS, D. M. Robust estimation of the variogram, I. **Journal of the International Association for Mathematical Geology**, New York, v. 12, n. 2, p. 115-125, 1980.

CRESSIE, N. **Statistics for spatial data**. New York: J. Wiley, 1993. 900 p.

DIAS, M. A. F. da S.; DIAS, P. L. da S., As incertezas regionais nos cenários de mudanças climáticas globais. **Boletim da Sociedade Brasileira de Meteorologia**, São José dos Campos, v. 31, n. 1, p. 12-16, abr. 2007.

DUBREUIL, V. Clima e Teledetecção: uma abordagem geográfica. **Revista Brasileira de Climatologia**, Presidente Prudente, v. 1, n. 1. p. 76-99, dez. 2005.

DRAPER, N. R.; SMITH, H. **Applied Regression Analysis wiley series in probability and mathematical statistics**. New York: J. Wiley, 1980. 409 p.

FERREIRA, D. B. **Relações entre a variabilidade da precipitação e a produtividade agrícola de soja e milho nas regiões sul e sudeste do Brasil**. 2005. 123 p. Dissertação (Mestrado em Meteorologia)- Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

GOOVAERTS, P. **Geostatistics for natural resources evaluation**. New York: Oxford University, 1997. 512 p.

GUERRA, P. A. G. **Geoestatística operacional**. Brasília: MME, 1988. 145 p.

HABERLANDT, U. Geostatistical interpolation of hourly precipitation from rain gauges and radar for a large-scale extreme rainfall event. **Journal of Hydrology**, Hannover, v. 332, n. 1 /2, p. 144–157, Jan. 2007.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE - IPCC. In: CLIMATE Change 2007: the PHYSICAL Science Basis, Summary for policy Makers. Geneva, 2007.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. In: HOUGHTON, J. T.; DING, Y.; GRIGGS, D. J.; NOGUER, N.; VAN DER LINDEN, P. J.; XIAOSU, D.; MASKELL, K.; JOHNSON, C. A. (Ed.). **Climate Change 2001: the scientific basis**. Cambridge: Cambridge University, 2001.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied geostatistics**. New York: Oxford University, 1989. 561 p.

JOURNEL, A. G.; HUIJBREGTS, CH. J. **Mining geostatistics**. London: Academic, 1991. 600 p.

LANNA, A. E. Elementos de Estatística e Probabilidades, In: TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. Porto Alegre: URGs, 1997. p. 79-176.

MARENGO, J. A. O quarto relatório do IPCC (IPCC AR4) e projeções de mudanças de clima para o Brasil e América do Sul. **Boletim da Sociedade Brasileira de Meteorologia**, São José dos Campos. v. 31, n. 1, p.23-28, abr. 2007.

MARENGO, J. A.; ALVES, L. M.; CASTRO, C. A. C.; MENDES, D. **Início da estação chuvosa nas Regiões Sudeste, Centro-Oeste e sul do Nordeste do Brasil, afetadas pela crise de energia**. Disponível em: <<http://www.cptec.inpe.br/energia/saiba/iniciochuvas.shtml>>. Acesso em: jun. 2007.

MATHERON, G. Principles of geostatistics. **Economic Geology**, Lancaster, v. 58, n. 5, p. 1246-1266, dez. 1963.

MELEM, V. M. **Utilização da geoestatística na construção de mapas de temperatura média mensal para o estado do Paraná**. 2002. 125 p. Tese (Doutorado em Agronomia/Energia na Agricultura) – Faculdade de Ciências Agrônomicas, Universidade Estadual Paulista ‘Julio de Mesquita Filho’, Botucatu.

MELLO, J. M. **Geoestatística aplicada ao inventário florestal**. 2004. 122 p. Tese (Doutorado em Recursos Florestais/Silvicultura e Manejo Florestal) - Escola Superior de Agricultura ‘Luiz de Queiroz’, Universidade de São Paulo, Piracicaba.

NOBRE, C. A. Mudanças climáticas globais e o Brasil: porque devemos nos preocupar. **Boletim da Sociedade Brasileira de Meteorologia**, São José dos Campos, v. 31, n. 1, p. 7-11, abr. 2007.

NOBRE, C. A. Mudanças climáticas globais: possíveis impactos nos ecossistemas do país: modelos e cenários para a Amazônia: o papel da ciência. **Revista Parcerias estratégicas**, Brasília, DF, n. 12, 20 p, set. 2001.

OLIVEIRA, M. S. de. **Planos amostrais para variáveis espaciais utilizando geoestatística**. 1991. 100 p. Dissertação (Mestrado em Estatística) – Instituto de Matemática, Estatística e Ciências da Computação, Universidade Estadual de Campinas, Campinas.

OLIVEIRA, M. C. N. de. **Métodos de estimação de parâmetros em modelos geoestatísticos com diferentes estruturas de covariância: uma aplicação ao teor de cálcio no solo**. 2003. 140 p. Dissertação (Mestrado em Agronomia – área de concentração: Estatística e Experimentação Agronômica) Escola Superior de Agricultura ‘Luiz de Queiroz’, Universidade de São Paulo, Piracicaba.

PÁSCOA, M. A. R. de. **Comportamento da temperatura média mensal no estado de Minas Gerais**. 2006. 32 f. Monografia (Graduação em Matemática) – Universidade Federal de Uberlândia, Uberlândia., 2006.

PHILLIPS, D. L.; DOLPH, J.; MARKS, D. A comparison of geostatistical procedures for spatial analysis of precipitations in mountainous terrain. **Agricultural And Forest Meteorology**, Amsterdam, v. 58, n. 1/2, p. 119-141, Mar. 1992.

PONTES, J. M. **A geoestatística: aplicações em experimentação de campo**. 2002. 82 p. Dissertação (Mestrado em Agronomia/Estatística e Experimentação Agropecuária) – Universidade Federal de Lavras, Lavras.

RIBEIRO JÚNIOR, P. J. **Métodos geoestatísticos no estudo da variabilidade espacial de parâmetros do solo**. 1995. 99 p. Dissertação (Mestrado em Agronomia/Estatística e Experimentação Agropecuária) - Escola Superior de Agricultura ‘Luiz de Queiroz’, Universidade de São Paulo, Piracicaba.

SAMPER, F. J. S. ; RAMIREZ, J. C. **Geoestadística: aplicaciones a la hidrogeología subterránea**. Barcelona: Torres, 1990. 141 p.

SILVA, J. W.; GUIMARÃES, E. C.; TAVARES, M. Variabilidade temporal da precipitação mensal e anual na estação climatológica de Uberaba-MG. **Ciência e**

Agrotecnologia, Lavras, v. 27. n. 3, p. 665-674, maio/jun. 2003.

SOARES, A. G. **Geoestatística para as ciências da terra e do ambiente**. Lisboa: IST, 2006. 186 p.

TABIOS, G. Q.; SALAS, J. D. A comparative analysis of techniques for spatial interpolation of precipitation. **Water Resources Bulletin**, Hernden, v. 21, n. 3, p. 365-380, 1985.

TOBLER, W. R. A computer model simulating urban growth in the Detroit region. **Economic Geograph**, Worcester, v. 46, n. 2, p. 234-240, 1970.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. Viçosa, MG: UFV, 1991. 449 p.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R. F. de; ALVAREZ V., V. H.; SCHAEFER, C. E. G. R. (Ed.). **Tópicos em ciência do solo**, Viçosa, MG: SBCS, 2000. v. 1, p. 1-54.

VIEIRA, S. R. Handbook for geostatistical analysis of variability in soil and climate data. **Tópicos em ciência do solo**. Viçosa, MG: SBCS, 2002. v. 2, p. 1 - 45.

VIEIRA, S. R.; CARVALHO, R. P. **Estudo da periodicidade temporal de chuvas em bacia hidrográfica dos Rios Turvo / Grande: uma proposta**. Campinas: Embrapa Informática Agropecuária, 2001. 17 p. (Documentos / Embrapa Informática Agropecuária, 4).

WEBSTER, R.; OLIVER, M. A. **Geostatistics for environmental scientists**. New York: J. Wiley, 2001. 271 p.

CAPÍTULO 2

ESTUDO DA DEPENDÊNCIA TEMPORAL DA PRECIPITAÇÃO PLUVIAL E DA TEMPERATURA DO AR DE JUIZ DE FORA, MG, POR MEIO DE ANÁLISES GEOESTATÍSTICAS

1 RESUMO

MOTA, Vania Corrêa. Estudo da dependência temporal da precipitação pluvial e da temperatura do ar de Juiz de Fora, MG, por meio de análises geoestatísticas. In: _____. **Metodologia geoestatística para caracterizar a variabilidade temporal de elementos climáticos de Juiz de Fora**. 2008. Cap. 2, p.33-69. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) – Universidade Federal de Lavras, Lavras.‡

O objetivo da realização do presente trabalho foi verificar o uso da metodologia de análise geoestatística para caracterizar a dependência temporal da precipitação pluvial e da temperatura do ar de Juiz de Fora, MG, para dados observados do ano 1967 a 1999 e para os cenários futuros de mudanças climáticas, no período de 2000 a 2099, utilizando um arranjo unidimensional. Com base nos semivariogramas experimentais e teóricos, considerando isotropia, constatou-se dependência temporal das variáveis, com melhor ajuste do modelo “wave”, para os dados observados e cenários futuros de precipitação pluvial. Para a variável temperatura do ar, verificou-se melhor ajuste do modelo gaussiano, quando comparado com os demais modelos. Na escolha dos melhores modelos, foram utilizados o critério de Akaike e o grau de dependência temporal, obtido a partir do semivariograma teórico. Verificou-se, para análise dos dados ao longo do tempo, que o artifício utilizado de forma bidimensional é uma alternativa para a visualização dos dados obtidos pela krigagem ordinária, sendo uma forma mais didática para apresentar esses dados de precipitação pluvial e temperatura do ar.

‡ Comitê Orientador: Prof. Dr. Renato Ribeiro de Lima – UFLA (Orientador); Marcelo de Carvalho Alves – UFLA (Co-orientador).

2 ABSTRACT

MOTA, Vania Corrêa. **Geostatistic methodology to characterize the temporal variability of climatic elements of Juiz de Fora – MG.** In: _____. **Study of the temporal dependence of the pluvial precipitation and air temperature of Juiz de Fora, MG, by using geoestatistics analisys.** 2008. Cap.2, p. 33-69 (Dissertation -Master in Statistics and Agricultural Experimentation) – Federal University of Lavras, Lavras, MG, Brazil.*

The objective of this work was verify the use of the geostatistics analysis to characterize the temporal dependence of the pluvial precipitation and air temperature of the municipal district of Juiz de Fora - MG, by using one-dimensional grid. The pluvial precipitation, in the period of 1967 to 1999, and forecast data of future scenarios of climatic changes from 2000 to 2099 for the variables precipitation and air temperature were analyzed. Temporal dependence of the pluvial precipitation was verified by using experimental and theoretical semivariograms. In this case, it was considered isotropy conditions. It was verified temporal dependence of the variables, and the best adjusted model for the observed data and future sceneries of pluvial precipitation was the wave. In the case of the air temperature better the best adjustment was obtained by using the Gaussian model. The kriging results were represented in a two-dimensional graphic which was a very interesting alternative for the visualization of the data behaviour along the time.

* Guidance Committee: Prof. Dr. Renato Ribeiro de Lima – UFLA (Adviser); Marcelo de Carvalho Alves – UFLA (Co-Adviser).

3 INTRODUÇÃO

As condições climáticas podem interferir no planejamento de diversas atividades ecológicas e sócio-econômicas e têm recebido atenção especial dos pesquisadores, devido às previsões de alterações no clima do planeta (Marengo et al. 2007). Dentre os estudos de variabilidade dos elementos climáticos, os mais abordados são precipitação pluvial e a temperatura do ar, que são normalmente utilizados em estudos de projetos urbanos, agrícolas, ambientais, dentre outros setores, como o serviço público de saúde (Vianello & Alves, 1991).

Dados no espaço e no tempo são necessários para modelar distribuições hidrológicas das inundações, erosões e outros processos não controláveis que ocorrem no meio ambiente, tais como enchentes, secas e geadas, entre outros (Ferreira, 2005; Haberlandt, 2007). As etapas de preparo do solo, definição de datas de plantio, estudo dos recursos hídricos, evapotranspiração, controle de vacinação e reforço no estoque de medicamentos para combater problemas respiratórios e possíveis epidemias, bem como uma infinidade de outras atividades, são projetadas mediante o uso de um bom estimador para a precipitação e para a temperatura (Mello et al., 2003; Queiroz et al., 2001).

Estudar a precipitação pluvial e a temperatura no período atual e em cenários futuros de mudanças climáticas é de vital importância para o setor agrícola, pois o conhecimento dessas variáveis ao longo dos anos garante a obtenção de altas produtividades e estabilidade do rendimento, na maioria das espécies cultivadas (Queiroz et al., 2001).

Segundo o Painel Intergovernamental sobre Mudanças Climáticas, o IPCC, estima-se um aquecimento global em torno de 1° e 3,5°C até o ano 2100, podendo haver diferenças regionais marcantes na agricultura (Assad & Luchiari, 1989; Nobre, 2001; IPCC, 2007). De acordo com Siqueira et al. (2000), os

cenários climáticos futuros implicam numa redução média de 31% na produção nacional de grãos de trigo, com maiores reflexos nas regiões Centro-Sul do país. No caso do milho, os decréscimos médios correspondem a 16%, sendo mais expressivos para as regiões Nordeste e Norte. Para a soja, são projetados acréscimos médios na produção de grãos em torno de 27%, como resultante de efeitos do aumento das concentrações de CO₂. Na região Sudeste, o efeito das elevações das temperaturas e das chuvas no zoneamento do café mostrou clara tendência de diminuição das áreas aptas para o cultivo do café arábica.

Queiroz et al. (2001) comentam que as anomalias da precipitação pluvial e da temperatura constituem a maior causa das perdas de produção e de produtividade anual das culturas. Dessa forma, o conhecimento prévio do transcurso anual da precipitação pluvial e da temperatura, em escala local e sua variabilidade espacial e temporal, contribui para o planejamento de medidas de redução dos impactos das anomalias climáticas sob o setor agrícola.

Portanto, é importante que se estude o comportamento dos elementos climáticos ao longo do tempo e ou do espaço. Assim, objetivou-se, com o presente capítulo, verificar o uso da metodologia de análise geoestatística para caracterizar a dependência temporal da precipitação pluvial e da temperatura do ar de Juiz de Fora, MG, para os dados observados nos anos de 1967 a 1999 e para os cenários futuros de mudanças climáticas, utilizando um arranjo unidimensional.

4 MATERIAL E MÉTODOS

4.1 Material

4.1.1 Origem dos dados

Este estudo foi realizado com dados do município de Juiz de Fora, estado de Minas Gerais, cuja localização pode ser vista na Figura 2.1.

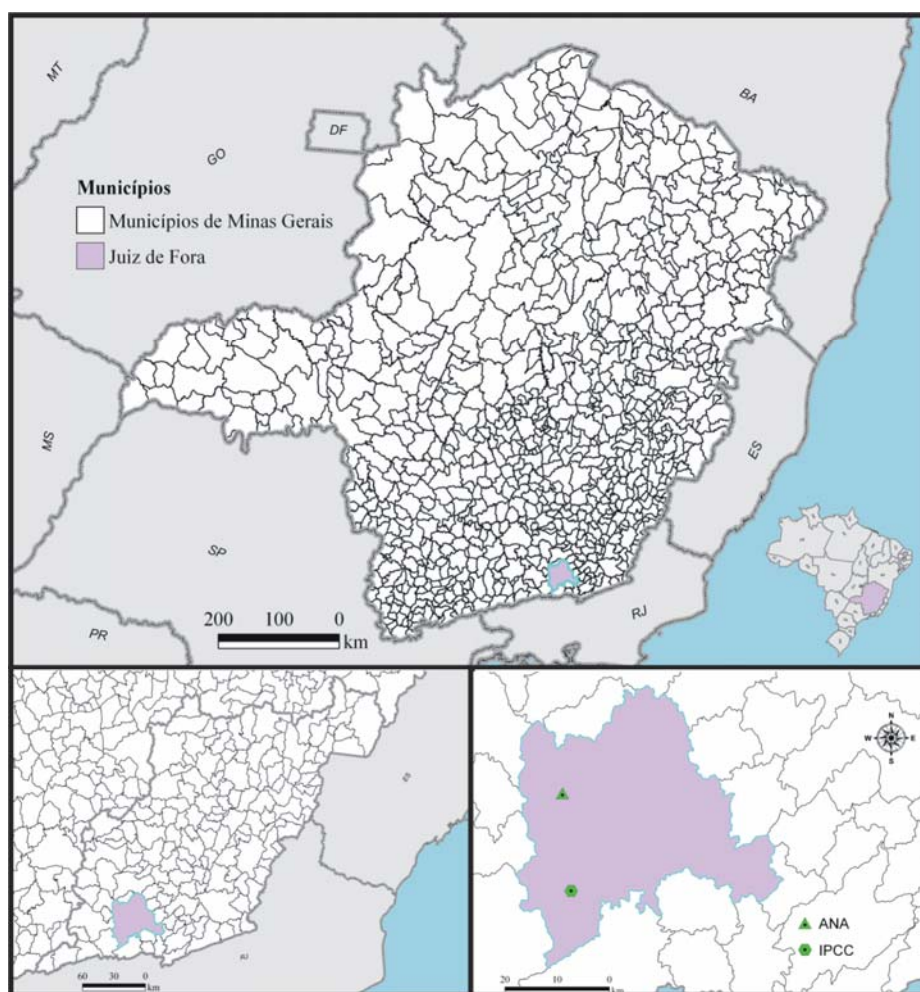


FIGURA 2.1 Localização de Juiz de Fora no estado de Minas Gerais.

Este município encontra-se na latitude de 21°45'50''S, longitude de 43°21'0''W. Segundo a classificação internacional de Köppen, o clima da região é do tipo tropical de altitude CWA, caracterizado por duas estações bem definidas: uma seca e de menores temperaturas, que se estende de maio a setembro, e outra úmida e de temperaturas mais elevadas, de outubro a abril. A temperatura média anual é de 19,3°C e a precipitação anual é de 1.644 mm (Brasil, 1992).

Neste estudo foram analisados dados coletados em uma estação pluviométrica e dados de previsão do IPCC.

4.1.2 Dados observados

Os dados observados referem-se à precipitação pluvial mensal, em mm, oriundos em uma estação pluviométrica da Agência Nacional das Águas, localizada no município de Juiz de Fora, MG. Essa estação, denominada de Estação Torreões, localiza-se na latitude -21°52'9'', longitude -43°33'20'' e altitude de 442 m (ANA, 2007). Nas análises, foram utilizados os dados do período de 1967 a 1999, perfazendo um total de 396 meses. Esses dados fazem parte da base de dados de séries históricas da ANA (ANA, 2007).

4.1.3 Dados de previsão de cenários futuros

Para os dados de previsão de cenários futuros, foram consideradas duas variáveis: precipitação pluvial mensal, em mm e temperatura média mensal do ar, em °C. Esses dados referem-se ao período de 2000 a 2099 e foram obtidos da base de dados do IPCC (IPCC, 2001). Os dados fazem parte de previsões realizadas pelo *National Center for Atmospheric Research* (NCAR, 2007), referentes ao Terceiro Relatório de Avaliação (TAR), modelo CCSM 3.0, com a resolução espacial de 1,4° x 1,4°, latitude de -21,7119° e longitude de -43,5938°. Para efeito de análise, o período considerado no estudo foi dividido em três: P1 (2000 a 2032), P2 (2033 a 2065) e P3 (2066 a 2099). Para a variável

temperatura, o período P3 compreendeu os anos de 2066 a 2098.

Os dados do TAR consideram diferentes cenários de mudanças climáticas, em que é considerado um conjunto de diferentes forças externas, como, por exemplo ozônio, atividades de vulcões, etc., com a mesma condição inicial. Foram considerados três cenários que diferem entre si em relação a mudanças climáticas: um mais pessimista (A2), um intermediário (A1B) e outro mais otimista (B1). Esses cenários e períodos foram adotados, a fim de possibilitar a comparação de diferentes simulações de mudanças climáticas com o período das Normais Climatológicas de 1961 a 1990.

Nas projeções de mudanças climáticas, utilizou-se uma hierarquia de modelos com base em fatores como clima, meio-ambiente, uso da terra, aspectos tecnológicos e socioeconômicos, integrados, para indicar respostas globais e padrões regionais de mudanças climáticas (Nakicenovic et al., 2001). Esses cenários variaram de acordo com o grau de interferências antrópicas no ambiente (Carter et al., 2001; Cubash et al., 2001; Marengo et al., 2007), sendo:

-A2: cenário caracterizado por um mundo futuro muito heterogêneo, em que a regionalização é dominante. Existiria um fortalecimento de identidades culturais regionais, com ênfase em valores da família e tradições locais. Outras características são: crescimento populacional alto e menor preocupação em relação ao rápido desenvolvimento econômico e tecnológico;

- A1B: cenário caracterizando um mundo futuro no qual a globalização é dominante. Há rápido crescimento econômico e desenvolvimento de tecnologias mais eficientes, com aumento da população global na metade do século XXI, seguida por declínio. Os temas subjacentes principais são a convergência econômica e cultural, com redução significativa em diferenças regionais e renda per capita. Nesta

simulação, os indivíduos procuram riqueza pessoal em lugar de qualidade ambiental;

- B1: cenário caracterizado por rápida mudança na estrutura econômica mundial, com introdução de tecnologias limpas, tendência a serviços e economia de informação, redução na intensidade de materiais e a introdução de recursos tecnológicos básicos e eficientes. Há ênfase em soluções globais para a economia, a sustentabilidade ambiental e social, mas sem iniciativas relacionadas a fatores climáticos.

4.2. Métodos

4.2.1 Análise exploratória

Antes da aplicação das ferramentas da geoestatística, os dados foram analisados utilizando-se procedimentos de análise estatística descritiva, buscando visualizar o comportamento geral dos dados e identificar possíveis valores discrepantes, o que é fundamental para a tomada de decisões durante a análise dos dados.

4.2.2 Análise estrutural

A análise estrutural compreende uma fase muito importante, pois tem como objetivo construir um modelo estatístico que descreve a continuidade da variável resposta e sua variabilidade espacial e ou temporal, por meio do semivariograma experimental e teórico.

Os semivariogramas foram estimados por meio dos estimadores clássico e robusto, considerando isotropia (omnidirecional), para as variáveis precipitação pluvial (dados observados e cenários futuros) e temperatura do ar, em cenários futuros. Nas análises foi utilizado um arranjo unidimensional ao longo do tempo, uma vez que os dados referem-se a mensurações mensais.

Na obtenção dos semivariogramas foi definido, como distância máxima (máximo valor de h), o valor de 10 meses, pois o interesse foi caracterizar a dependência temporal em pequenas distâncias.

Para o ajuste do semivariograma teórico, foi utilizado o método dos mínimos quadrados ordinários (OLS). Os modelos estatísticos comparados foram esférico, gaussiano e “wave” que, conforme Isaaks & Srivastava (1989), são definidos por:

$$\begin{aligned}
 \text{- modelo esférico: } \gamma(h, \beta) &= \begin{cases} C_0 + C \left[\frac{3}{2} \left(\frac{h}{a} \right) - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right], & 0 \leq h \leq a, \\ C_0 + C & , h > a \end{cases} \\
 \text{- modelo gaussiano: } \gamma(h, \beta) &= C_0 + C_1 \left(1 - \exp \left(-3 \left(\frac{h^2}{a^2} \right) \right) \right), \text{ se } a > 0, \\
 \text{- modelo “wave”}: \gamma(h, \beta) &= C_0^2 + \frac{a}{h} \operatorname{sen} \left(\frac{h}{a} \right),
 \end{aligned}$$

em que $\gamma(h, \beta)$ é a semivariância para a distância h ; C_0 é o efeito pepita; $C_0 + C_1$ é o patamar e a é o alcance da dependência espacial.

Do conjunto de resultados obtidos, pelos estimadores clássico e robusto para os três modelos, foram estimados seus parâmetros e selecionado o melhor modelo, de acordo com a aproximação para o valor do Critério de Akaike (AIC) proposta por Webster & Oliver (2001), ou seja:

$$AIC = 2p + n \cdot \ln(RSS/n),$$

em que n é o número de observações, p é o número de parâmetros e RSS é a soma de quadrados de resíduos, definida em (14). A relação $C_0/C_0 + C_1$, normalmente, é utilizada para avaliar o grau de dependência espacial das variáveis e, como neste estudo, os dados foram analisados ao longo do tempo, essa relação foi chamada de grau de dependência temporal, o que é uma adaptação da definição apresentada por Cambardella et al. (1994).

4.2.3 Interpolador geoestatístico – krigagem ordinária

A krigagem interpola valores em uma superfície contínua e faz uso explicitamente da variância entre os valores observados, representada no semivariograma.

Para realizar a interpolação por krigagem ordinária e mapear as variáveis em estudo, utilizaram-se as estimativas dos parâmetros referentes ao melhor modelo de semivariograma selecionado anteriormente. De acordo com Goovaerts (1997), o estimador linear é dado pela seguinte equação:

$$Z_{KO}^*(x) = \sum_{j=1}^{n(x)} \lambda_j(x) z(x_j),$$

em que $n(x)$ é o número de observações de $z(x_j)$ utilizadas para estimar $Z_{KO}^*(x)$ e λ_j são os pesos associados às observações $z(x_j)$. Nesse caso, para que $Z_{KO}^*(x)$ seja não tendencioso, a soma dos pesos das observações deve ser igual a 1, a esperança entre o valor estimado e o observado deve ser zero e a variância da estimativa deve ser mínima, conforme definições apresentadas nas Equações 16 e 17.

Os resultados da krigagem, além da forma unidimensional, também foram representados por meio de uma imagem bidimensional, na qual os meses foram alocados na vertical e os anos na horizontal.

Para verificar se a krigagem ordinária descreve adequadamente a variabilidade temporal das variáveis estudadas e se as hipóteses assumidas de estacionaridade foram satisfeitas, foi utilizada a validação cruzada (“cross-validation”).

Todas as análises foram realizadas utilizando-se o pacote geoR (Ribeiro Júnior & Diggle, 2001), do aplicativo R (R Development Core Team, 2007).

5 RESULTADOS E DISCUSSÃO

Na Tabela 2.1 são apresentados os resultados da análise descritiva dos dados de precipitação pluvial, coletados na estação Torreões. A média mensal de precipitação, nos 33 anos estudados, foi de 124,68 mm/mês, com precipitação mínima de zero e total máxima em torno de 755,60 mm. Analisando-se a média, a mediana, os coeficientes de assimetria e de curtose, verificou-se que a variável precipitação se afastou da distribuição normal, apresentando um comportamento assimétrico à esquerda e com distribuição leptocúrtica. Estas características também foram observadas por Alves et al. (2005), ao estudarem o comportamento temporal das chuvas de Uberlândia, MG.

TABELA 2.1 - Estatísticas descritivas da precipitação pluvial do período de 1967 a 1999 de Juiz de Fora, MG, para a estação Torreões.

Estatísticas	Estação Torreões
N	396
Média	124,68
Mediana	77,85
Mínima	0,00
Máxima	755,60
Variância	16149,29
DP	127,08
Assimetria	1,42
Curtose	2,27
CV	101,92

Obs: N = número de observações, DP = desvio padrão, CV = coeficiente de variação

A análise descritiva dos dados simulados para os cenários futuros A2, A1B e B1 de mudanças climáticas nos períodos P1, P2 e P3, para as variáveis precipitação pluvial e temperatura, estão apresentadas nas Tabelas 2.2 e 2.3, respectivamente.

TABELA 2.2 Estatísticas descritivas da precipitação pluvial de Juiz de Fora, MG, para os cenários A2, A1B e B1 do IPCC nos períodos P1 (2000 a 2032), P2 (2033 a 2065) e P3 (2066 a 2099).

	Cenário A2		
	P1	P2	P3
N	396	396	408
Média	75,61	77,35	79,96
Mediana	56,06	59,55	61,97
Mínima	9,41	9,05	8,10
Máxima	244,31	242,89	254,75
Variância	3579,32	3881,87	4184,08
DP	59,83	62,30	4,68
Assimetria	0,79	0,72	0,75
Curtose	-0,56	-0,71	-0,60
CV	79,12	80,55	80,89
	Cenário A1B		
	P1	P2	P3
N	396	396	408
Média	77,91	80,27	80,57
Mediana	53,72	59,14	61,83
Mínima	8,70	9,44	10,07
Máxima	222,79	261,01	237,50
Variância	3883,96	4148,95	3958,92
DP	62,32	0,71	62,92
Assimetria	0,72	-0,16	0,64
Curtose	-0,79	64,41	-0,85
CV	79,98	80,24	78,09
	Cenário B1		
	P1	P2	P3
N	396	396	408
Média	77,34	79,14	81,07
Mediana	56,96	58,24	56,26
Mínima	10,41	9,50	10,02
Máxima	270,00	268,11	241,45
Variância	3883,53	4034,45	4069,66
DP	62,32	63,52	63,79
Assimetria	0,82	0,78	0,67
Curtose	-0,39	-0,53	-0,87
CV	80,57	80,26	78,68

Obs: N = número de observações, DP = desvio padrão, CV = coeficiente de variação

TABELA 2.3 Estatísticas descritivas da temperatura do ar de Juiz de Fora, MG, para os cenários A2, A1B e B1 do IPCC, nos períodos P1 (2000 a 2032), P2 (2033 a 2065) e P3 (2066 a 2098).

	Cenário A2		
	P1	P2	P3
N	396	396	396
Média	21,69	22,30	23,78
Mediana	22,02	22,99	24,38
Mínima	16,65	16,99	18,88
Máxima	25,65	26,05	28,16
Variância	5,15	4,78	4,38
DP	2,27	2,18	-0,52
Assimetria	-0,49	-0,59	-0,72
Curtose	-1,02	-0,87	2,09
CV	10,67	9,80	8,79
	Cenário A1B		
	P1	P2	P3
N	396	396	396
Média	21,33	22,28	23,06
Mediana	22,08	22,99	23,72
Mínima	16,58	17,59	18,86
Máxima	25,21	26,16	27,04
Variância	4,50	4,56	3,98
DP	2,18	2,13	1,99
Assimetria	-0,56	-0,56	-0,55
Curtose	-0,92	-0,93	-0,86
CV	10,22	9,56	8,65
	Cenário B1		
	P1	P2	P3
N	396	396	396
Média	21,21	21,71	21,98
Mediana	21,97	22,47	22,62
Mínima	16,53	17,21	17,16
Máxima	25,27	25,68	25,35
Variância	4,92	4,58	4,37
DP	2,22	2,14	2,09
Assimetria	-0,55	-0,59	-0,60
Curtose	-0,99	-0,90	-0,87
CV	10,46	9,86	9,51

Obs: N = número de observações, DP = desvio padrão, CV = coeficiente de variação

Para o cenário A2, mais pessimista, onde se espera um rápido e alto crescimento populacional e pouca preocupação com o desenvolvimento tecnológico e econômico, verificou-se aumento médio da precipitação nos

próximos 99 anos. Para o período P1, a média foi de 75,61 mm; para o P2 de 77,35 mm e P3, de 79,96 mm. Para os valores mínimos, observou-se diminuição do P1 para o P3 em torno de 1 mm e, para as máximas, houve aumento de aproximadamente 10 mm .

A temperatura para esse cenário também apresentou mudanças. Do P1 ao P3, observa-se, de acordo com os dados da Tabela 2.3, um aumento na média de 2,09°C, com os valores de temperaturas mínimos apresentando diferença, do P1 para o P3, de, aproximadamente, 1°C e valores de temperatura máxima apresentando pequena diferença entre os períodos. Os aumentos da chuva e da temperatura, provavelmente, se devem ao aquecimento global do planeta. Estes resultados corroboram com os resultados observados pelo Quarto Relatório do IPCC, o qual afirma que as atividades antrópicas constituem a principal causa do aquecimento global e aponta o acúmulo de gases de efeito estufa, dióxido de carbono e o metano, como os principais responsáveis (IPCC, 2007 ; Nobre, 2007).

Para o cenário intermediário A1B, no qual as populações, de modo geral, procuraram riqueza pessoal em lugar de qualidade ambiental, observaram-se também aumentos na temperatura de, aproximadamente, 1,80°C para os próximos 98 anos, quando comparado o P1 com o P3. Para precipitação pluvial, os valores máximos aumentaram no P2 e diminuíram no P3. Isso, provavelmente, é reflexo do aumento populacional até a metade do século XXI, seguida por declínio posterior e introdução de tecnologias novas e mais eficientes, acarretando na diminuição dos índices pluviais.

Entretanto, para o cenário B1, mais otimista, onde serão introduzidas tecnologias limpas com redução de matérias e sustentabilidade ambiental, também se verificou pequena diminuição para precipitação pluvial nos valores máximos do P3. Para temperatura, observou-se aumento médio de aproximadamente 0,77°C, o que é inferior aos demais cenários. Porém, observa-

se uma previsão de aumento da temperatura média nos três cenários, o que obriga a sociedade a olhar para o aquecimento global como um problema permanente, pois, mesmo simulando diferentes cenários, verificaram-se aumento na temperatura e mudanças dos padrões de precipitação.

O aquecimento tende a ser sempre maior para o cenário pessimista A2, comparando-se com os cenários intermediário A1B e otimista B1. As projeções para a temperatura média do ar são mais reveladoras e a consistência entre os modelos é maior (IPCC, 2007). Marengo (2007), ao estudar os cenários de mudanças climáticas para o Brasil, observou que, no cenário pessimista A2, o aquecimento varia entre 3°C e 5°C, em todo o Brasil, sendo mais intenso na região tropical. Já para as projeções de precipitação pluvial, o mesmo autor verificou aumento na frequência de extremos de chuvas em todo o Brasil, principalmente na Amazônia, no Sul e no Sudeste.

Para os três cenários, com seus respectivos períodos, observou-se, para precipitação pluvial, que as médias dos dados de previsão estão muito abaixo das médias dos dados observados, apresentando diferença de, aproximadamente, 40 mm. Isso pode ser explicado pela grande área utilizada pelo modelo de previsão dos cenários futuros, com resolução espacial de 1,4° x 1,4° e pela localização da estação Torreões, que não está no mesmo local do ponto do IPCC, apesar de ambas estarem no município de Juiz de Fora. De maneira geral, maiores incertezas são observadas nos cenários de precipitação, quando comparados aos de temperatura (IPCC, 2007).

5.1 Análise da estrutura de continuidade temporal

Pela análise semivariográfica, foi possível detectar que os dados observados de precipitação pluvial da estação Torreões se apresentaram estruturados temporalmente. O modelo “wave” foi o que se ajustou melhor aos semivariogramas experimentais, quando comparado aos modelos esférico e

gaussiano, apresentando menor valor de aproximação do critério de Akaike. Esse resultado foi observado pelo estimador clássico e robusto, tendo o estimador clássico fornecido melhores ajustes, conforme pode ser observado na Tabela 2.4.

TABELA 2.4 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais clássico e robusto, relativos à precipitação pluvial de Juiz de Fora, para os dados observados, considerando o arranjo unidimensional.

Estação Torreões						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	5,92	5,18	5,93	6,60	5,51	6,00
C_0	1532,23	5267,18	6094,66	0,00	1411,77	1822,22
$C_0 + C_1$	21182,42	17585,10	14532,93	23555,67	22494,12	18890,34
AIC	4102,88	4170,07	3735, 9	4591,27	4545,84	4114,270
DT	0,07%	0,29%	0,41%	0,00%	0,06%	0,09%

Pelo grau de dependência temporal (DT), nota-se que a variável precipitação pluvial apresentou-se moderadamente estruturada, de acordo com o resultado do estimador clássico para o modelo “wave”. No caso do resultado obtido pelo estimador robusto, houve forte estrutura de continuidade temporal, conforme classificação adaptada de Cambardella et al. (1994).

O semivariograma experimental para os dados observados de precipitação pluvial, utilizando o estimador clássico para o modelo “wave”, está apresentado na Figura 2.2. O exame do semivariograma para a precipitação pluvial média mensal revela que existe dependência temporal, com alcance (a) de 5,93 meses. O alcance indica que os índices de precipitação pluvial apresentaram dependência temporal de até 5,93 meses e valores separados por

distâncias superiores a 5,93 são considerados temporalmente independentes entre si.

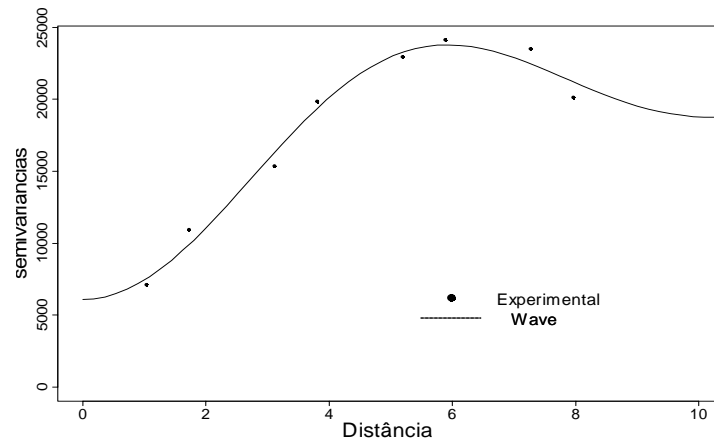


FIGURA 2.2 Semivariograma experimental e teórico, com ajuste do modelo “wave”, para os dados observados de precipitação pluvial de Juiz de Fora, MG.

As análises da precipitação pluvial e da temperatura do ar para os cenários futuros de mudanças climáticas, cenário mais pessimista (A2), cenário intermediário (A1B) e cenário otimista (B1) foram baseadas em modelos e os valores da aproximação do critério de Akaike (AIC) e grau de dependência temporal (DT), utilizando o estimador de mínimos quadrados ordinários estão apresentados nas Tabelas 2.5 e 2.7, respectivamente. Observou-se que o modelo ‘wave’ foi o que melhor se ajustou aos semivariogramas experimentais para a série de precipitação pluvial nos cenários A2, A1B e B1, nos três períodos avaliados, sendo esse resultado verificado pelos estimadores clássico e robusto (Figura 2.3). Esse modelo apresentou forte dependência temporal, ou seja, os

semivariogramas têm efeito pepita igual ou inferior a 25% do patamar, conforme classificação adaptada de Cambardella et al. (1994).

TABELA 2.5 – Resultados da aproximação do critério de Akaike (AIC) e do grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais clássico e robusto, relativos à precipitação pluvial de Juiz de Fora, para o cenário A2, A1B e B1 nos períodos, P1, P2 e P3 considerando o arranjo unidimensional.

Cenário A2 P1						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
AIC	3271,11	3179,10	2719,74	3903,29	3821,21	3474,60
DT	0,00%	0,04%	0,13%	0,00%	0,00%	0,01%
Cenário A2 P2						
AIC	3379,41	3247,91	2767,13	4024,52	3899,356	3506,94
DT	0,00%	0,02%	0,11%	0,00%	0,00%	0,00%
Cenário A2 P3						
AIC	3430,01	3326,95	2841,71	4105,08	3999,34	3642,99
DT	0,00%	0,03%	0,11%	0,00%	0,00%	0,00%
Cenário A1B P1						
AIC	3373,07	3240,80	2758,86	4009,13	3874,34	3484,40
DT	0,00%	0,02%	0,11%	0,00%	0,00%	0,00%
Cenário A1B P2						
AIC	3452,86	3324,10	2838,68	4093,19	3957,53	3568,58
DT	0,00%	0,02%	0,10%	0,00%	0,00%	0,00%
Cenário A1B P3						
AIC	3447,91	3329,93	2813,67	4127,36	3998,32	3647,61
DT	0,00%	0,02%	0,09%	0,00%	0,00%	0,00%
Cenário B1 P1						
AIC	3340,07	3237,52	2790,23	3982,896	3874,07	3508,18
DT	0,00%	0,03%	0,12%	0,00%	0,00%	0,00%
Cenário B1 P2						
AIC	3396,30	3277,55	2786,64	4064,93	3959,19	3592,71
DT	0,00%	0,03%	0,11%	0,00%	0,00%	0,00%
Cenário B1 P3						
AIC	3450,77	3312,00	2826,03	4071,81	3934,04	3540,02
DT	0,00%	0,01%	0,09%	0,00%	0,00%	0,00%

Obs: Cenário mais pessimista (A2), cenário intermediário (A1B) e cenário otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2099 (P3).

As estimativas dos parâmetros do modelo “wave” para a variável precipitação pluvial, relativas aos três cenários, estão apresentadas na Tabela 2.6. Verificou-se que os valores das estimativas dos alcances oscilaram de 5,79 a 5,82 meses, ao longo dos períodos dos cenários futuros analisados. Esses resultados foram próximos aos obtidos pelos dados observados de precipitação pluvial no período de 1967 a 1999.

TABELA 2.6 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), do modelo “wave” ajustado ao semivariograma experimental (omnidirecional) clássico, relativo à precipitação pluvial de Juiz de Fora, para os cenários A2, A1B e B1, considerando o arranjo unidimensional.

		a	C_0	$C_0 + C_1$
A2	P1	5,80	622,85	4672,22
	P2	5,81	579,81	5228,27
	P3	5,79	657,74	5536,41
A1B	P1	5,80	583,07	5214,61
	P2	5,81	588,81	5612,78
	P3	5,82	533,14	5375,65
B1	P1	5,80	661,53	5103,21
	P2	5,81	622,83	5367,84
	P3	5,80	543,61	5517,90

Cenário mais pessimista (A2), cenário intermediário (A1B) e cenário otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2099 (P3).

Para a variável temperatura, cujos resultados estão apresentados na Tabela 2.7, verificou-se melhor ajuste do modelo “wave”, com menor valor de AIC e forte dependência temporal, para o cenário A2 no período P1. Já para o cenário A2, nos períodos P2 e P3 e para os demais cenários, verificou-se melhor ajuste para o modelo gaussiano, com forte grau de dependência temporal, quando utilizando o estimador clássico. Já ao se utilizar o estimador robusto, verificou-se melhor ajuste do modelo “wave” para todos os cenários.

Um aspecto importante é que os valores das estimativas do AIC foram sempre menores quando se utilizou o estimador clássico, não havendo a necessidade de utilizar o estimador robusto, no caso deste estudo, para as duas variáveis.

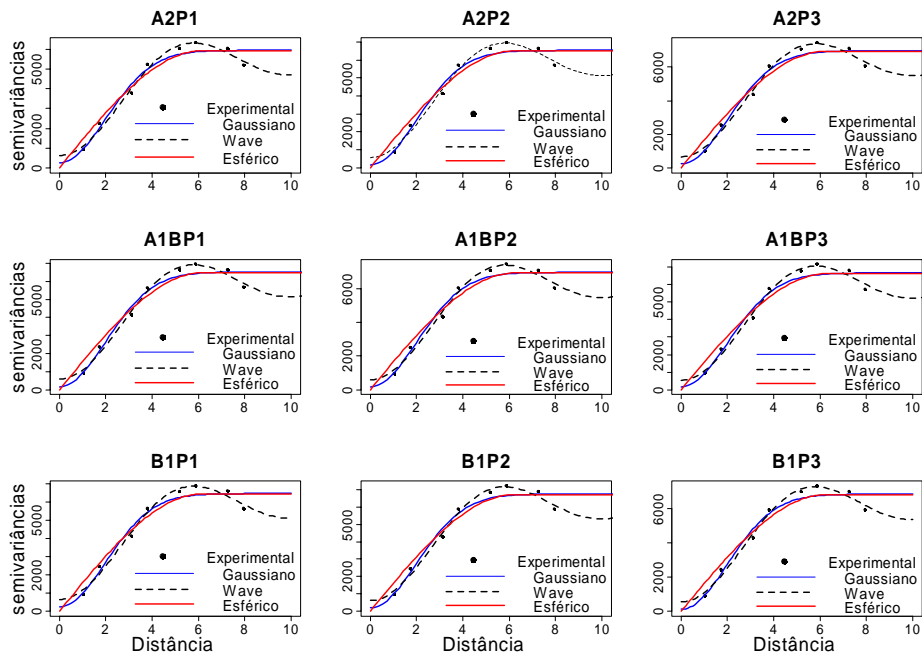


FIGURA 2.3 Semivariogramas experimentais e teóricos pelo estimador clássico para precipitação pluvial, com ajuste dos modelos `wave`, gaussiano e esférico, para o cenário A2, A1B e B1.

O modelo “wave” ajustado ao cenário A2 no período P1 apresentou alcance de 5,63 meses. As estimativas dos parâmetros do modelo gaussiano estão apresentadas na Tabela 2.8. Observou-se que os valores das estimativas do efeito

pepita foram próximos de zero, indicando uma pequena variabilidade de curta escala, não explicada pelo modelo.

TABELA 2.7 – Resultados da aproximação do critério de Akaike (AIC) e do grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais clássico e robusto, relativos à temperatura do ar de Juiz de Fora, para o cenário A2, A1B e B1, nos períodos, P1, P2 e P3, considerando o arranjo unidimensional.

Cenário A2 P1						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
AIC	-2039,19	-2258,71	-2371,69	-1397,79	-1469,70	-1906,18
DT	0,00%	0,01%	0,15%	0,00%	0,00 %	0,04%
Cenário A2 P2						
AIC	-2217,99	-2498,54	-2297,97	-1553,55	-1605,70	-1944,31
DT	0,00%	0,01%	0,19%	0,00%	0,03%	0,08%
Cenário A2 P3						
AIC	-2456,58	-2935,61	-2159,91	-1778,95	-1737,83	-2021,03
DT	0,00%	0,00%	0,28%	0,00%	0,12%	0,19%
Cenário A1B P1						
AIC	-2203,31	-2495,87	-2306,95	-1521,64	-1568,34	-1980,99
DT	0,00%	0,01%	0,18%	0,00%	0,02%	0,07%
Cenário A1B P2						
AIC	-2260,48	-2559,61	-2293,18	-1636,99	-1687,64	-2072,03
DT	0,00%	0,01%	0,20%	0,00%	0,03%	0,09%
Cenário A1B P3						
AIC	-2429,28	-2737,96	-2341,10	-1821,73	-1838,03	-2199,07
DT	0,00%	0,01%	0,23%	0,00%	0,05%	0,12%
Cenário B1 P1						
AIC	-2131,97	-2408,34	-2308,60	-1498,82	-1607,48	-2064,65
DT	0,00%	0,01%	0,17%	0,00%	0,00%	0,05%
Cenário B1 P2						
AIC	-2199,02	-2462,96%	-2358,73%	-1585,75	-1637,55	-2058,33
DT	0,00%	0,01%	0,18%	0,00%	0,03%	0,07%
Cenário B1 P3						
AIC	-2302,53	-2678,84	-2251,17	-1779,52	-1856,42	-2169,01
DT	0,00%	0,00%	0,21%	0,00%	0,02%	0,11%

Obs: Cenário mais pessimista (A2), cenário intermediário (A1B) e cenário otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2098 (P3).

A aplicação da metodologia geoestatística a uma série distribuída ao longo do tempo também foi estudada por Clark (1979), na qual avaliou a

temperatura da água. A autora comenta que a série é unidimensional, isto é, a dimensão é o tempo em lugar do espaço e verificou pelo, semivariograma experimental, flutuações periódicas da variável estudada, assim como os dados de Juiz de Fora.

Os semivariogramas experimentais e teóricos para os modelos esférico, gaussiano e “wave”, para a variável temperatura nos cenários A2, A1B e B1, encontram-se na Figura 2.4. A dependência temporal está bem identificada ao longo dos meses, ou seja, na forma gráfica, para valores pequenos da distância h a semivariância é pequena e com o aumento da distancia h a semivariância cresce até um ponto em que se se estabiliza, atingindo o patamar.

TABELA 2.8 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) do modelo Gaussiano ajustado ao semivariograma experimental clássico, relativo à temperatura do ar de Juiz de Fora, para os cenários A2 A1B e B1, considerando o arranjo unidimensional.

		a	C_0	$C_0 + C_1$
A2	P2	4,45	0,11	8,04
	P3	4,21	0,09	7,21
A1B	P1	3,64	0,00	5,96
	P2	4,09	0,04	6,87
	P3	4,02	0,08	5,97
B1	P1	4,31	0,06	7,64
	P2	4,28	0,08	7,10
	P3	4,00	0,00	6,67

Cenário mais pessimista (A2), cenário intermediário (A1B) e cenário otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2098 (P3).

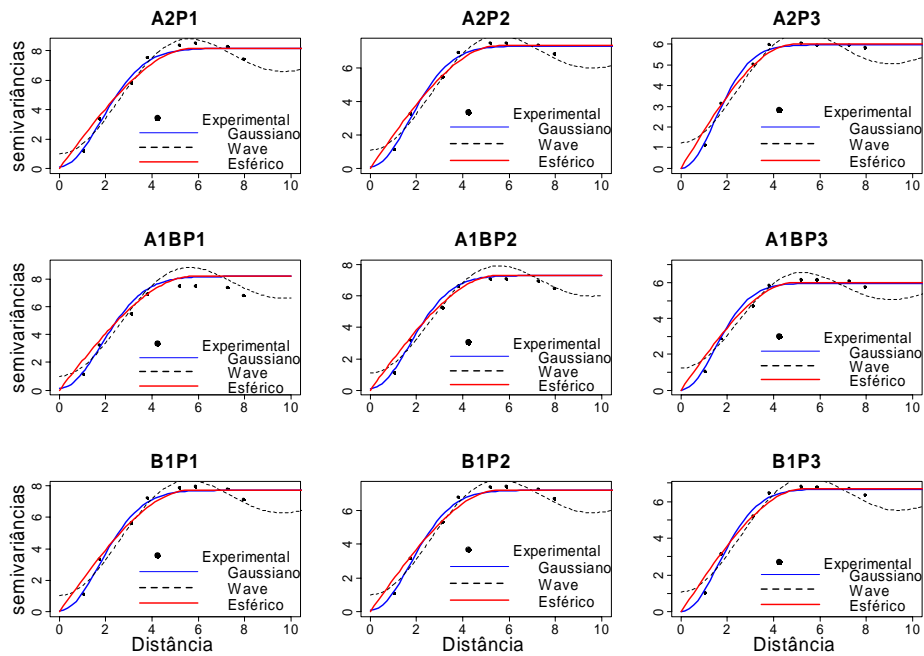


FIGURA 2.4 Semivariogramas experimentais e teóricos pelo estimador clássico para temperatura do ar, com ajuste dos modelos, 'wave', gaussiano e esférico para o cenário A2, A1B e B1.

Uma vez estimados os parâmetros dos modelos e escolhido o melhor modelo para dados observados e previsões de cenários futuros para a precipitação pluvial e previsões para a temperatura, foi realizada a interpolação geoestatística (krigagem) e os resultados das previsões estão apresentados nas Figuras 2.5, 2.6 e 2.7, respectivamente.

Visualmente, a série de precipitação pluvial para os dados observados apresentou uma sazonalidade, o que, segundo Ferraz (1999), é muito comum em séries climatológicas. Essa variável apresentou alguns picos, com altos índices de precipitação, conforme pode ser observado na Figura 2.5. Esses altos índices referem-se a valores próximos há 200 meses, que correspondem,

aproximadamente, ao ano de 1983, mais especificamente janeiro de 1983, com um índice de 396,2 mm/mês. Vale ressaltar que, naquele ano ocorreu um fenômeno atípico, denominado de “El Niño”, o qual apresentou uma intensidade muito forte (Berlato & Fontana, 2003). O “El Niño” provoca mudanças na circulação atmosférica em escala regional e global, gerando anomalias climáticas, com aumentos de precipitações pluviais. Esse pico de alto índice de precipitação, provavelmente, se deve à ocorrência desse fenômeno.




FIGURA 2.5 Série da precipitação pluvial da estação Torreões distribuída ao longo do tempo.

Para a precipitação pluvial e a temperatura do ar, referentes aos dados de previsão de cenários futuros, verificou-se uma aparente estabilidade nos dados, não sendo destacado, em nenhum dos três cenários, algum tipo de valor discrepante, caracterizando a ocorrência de anomalias climáticas, como “El Niño” e “La Nina”. Esperava-se uma variabilidade maior das variáveis ao longo dos meses em relação aos valores discrepantes. Segundo Berlato & Fontana

(2003), a precipitação pluvial e a temperatura do ar são os elementos climáticos mais afetados por essas anomalias.

Um aspecto importante a ser discutido é a veracidade dos dados de previsão de cenários futuros, apesar de esses dados serem fornecidos pelo IPCC e esse ser considerado e reconhecido amplamente como sendo a fonte mais confiável de informações de clima. Há muita discussão e dúvidas entre um grande número de cientista sobre essas afirmações e resultados de dados de previsão destes relatórios de avaliação do IPCC.

E importante lembrar que as previsões de mudanças climáticas apresentadas pelo IPCC baseiam-se nos resultados de modelos que descrevem a atmosfera de forma global e apresentam incertezas quanto às análises dos efeitos regionais, tendo como um dos principais problemas a resolução espacial das simulações numéricas para definir os cenários futuros, que tem uma resolução típica de 100 k m. Todavia, estes resultados devem ser vistos com cautela, devido às limitações do modelo, nesse caso, o modelo CCSM 3.0 e, para uma análise mais detalhada dessas variáveis, seria interessante uma resolução espacial em escopo regional ou local.

De forma geral, os resultados obtidos da análise do comportamento da precipitação pluvial e da temperatura do ar dos dados de previsão de cenários futuros de Juiz de Fora estão de acordo com os resultados das avaliações que Marengo (2007) apresentou em sua pesquisa sobre as projeções de mudanças climáticas para o Brasil e a América do Sul. Este autor conclui que a maior resolução obtida em modelos de escopo regional ou local concorreria para a previsão realista de alterações extremas e seria útil para o estudo sobre os impactos da mudança do clima em áreas como gerenciamento de recursos hídricos, ecossistemas e atividades agrícolas.

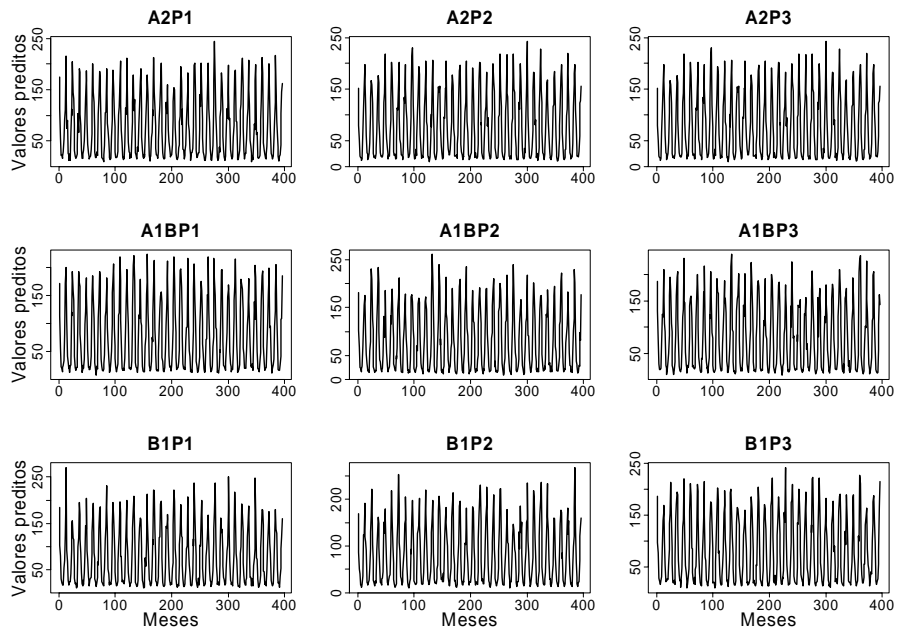


FIGURA 2.6 Série da precipitação pluvial distribuída ao longo do tempo, para os cenários A2, A1B e B1.

As representações gráficas das Figuras 2.5 a 2.7 são formas unidimensionais, comuns em estudos de séries temporais. Nas Figuras 2.8 a 2.10 estão apresentados os resultados de uma forma bidimensional, o que, normalmente, é utilizado em estudos de geoestatística. Nesses mapas, cada retângulo na horizontal representa um determinado mês, em cada um dos anos.

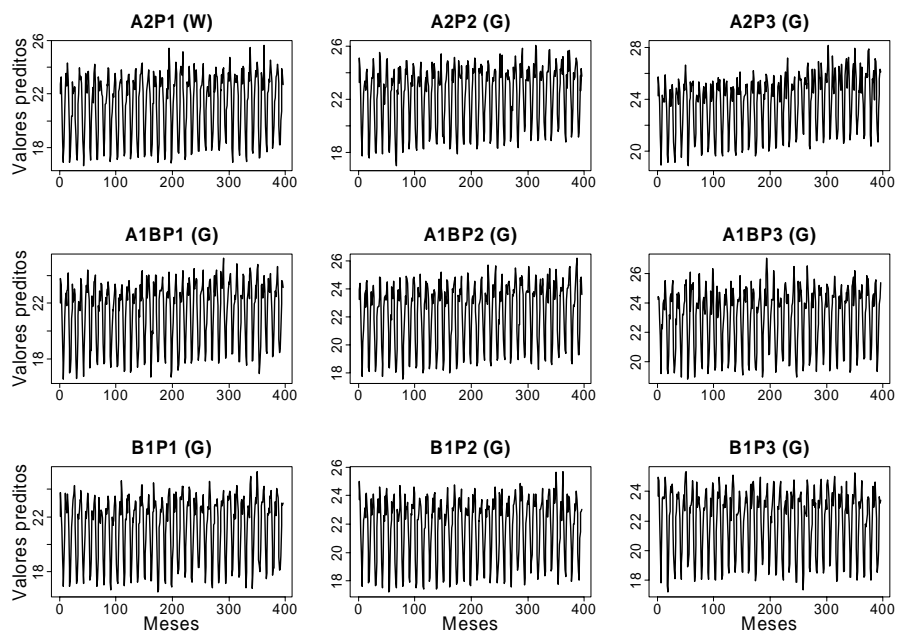


FIGURA 2.7 Série da temperatura do ar distribuída ao longo do tempo, com ajuste dos modelos “wave” (W) e gaussiano (G), para os cenários A2, A1B e B1.

Observou-se que, utilizando-se o artifício de se considerar o tempo em uma escala bidimensional, em vez de unidimensional, os dados podem ser apresentados de forma mais didática, em que é visível o padrão de sazonalidade da variável precipitação pluvial, caracterizado por áreas de maior e menor concentração das chuvas, ao longo dos vários anos estudados. Os mapas apresentados nas Figuras 2.8 e 2.9 revelam uma faixa central, que corresponde aos meses de maio a setembro, em vermelho, com baixas precipitações ao longo de todos os anos avaliados, que representa o período da seca, o qual é bem definido para o município de Juiz de Fora. Nota-se, ainda, que os maiores

índices de precipitação são observados nos meses de novembro a março (retângulos amarelos e alaranjados), o que era de se esperar, pois, trata-se do período chuvoso. Além disso, observa-se, neste período, maior variabilidade dos índices pluviiais.




FIGURA 2.8 Representação bidimensional da krigagem para precipitação pluvial da estação Torreões, de Juiz de Fora, MG.

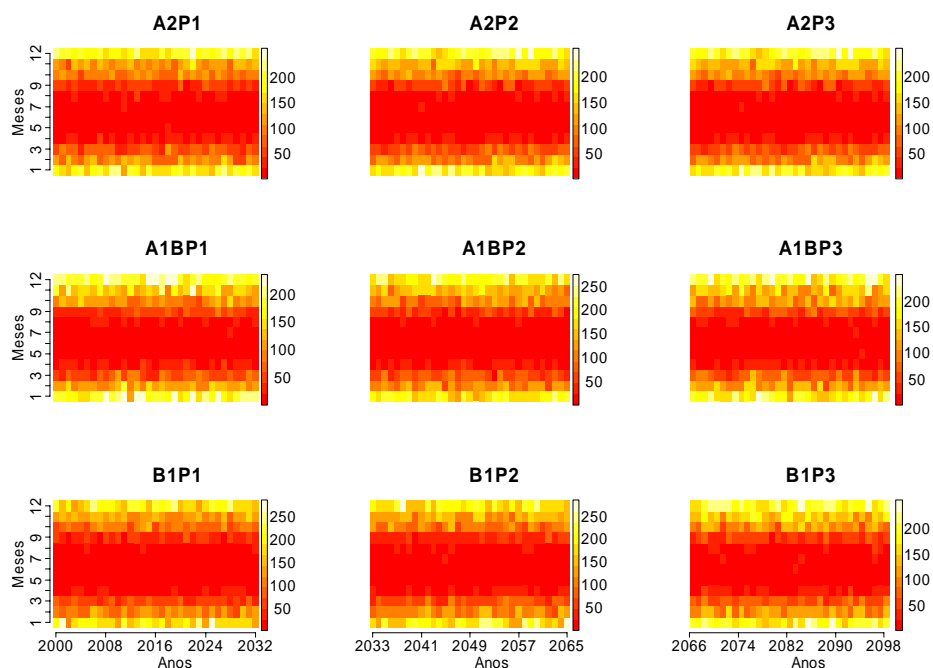


FIGURA 2.9 Representação bidimensional da krigagem para precipitação pluvial de Juiz de Fora, MG, para os cenários A2, A1B e B1.

De forma semelhante, um padrão sazonal da variável temperatura do ar também foi observado. Na Figura 2.10 verifica-se a presença de uma faixa central, mais bem definida, que corresponde aos meses de maio a agosto, onde ocorrem as temperaturas mais baixas. Esse comportamento foi observado para todos os anos avaliados. Nos demais meses, pode-se observar a ocorrência de temperaturas mais altas, pois se tratam dos meses mais quentes do ano.

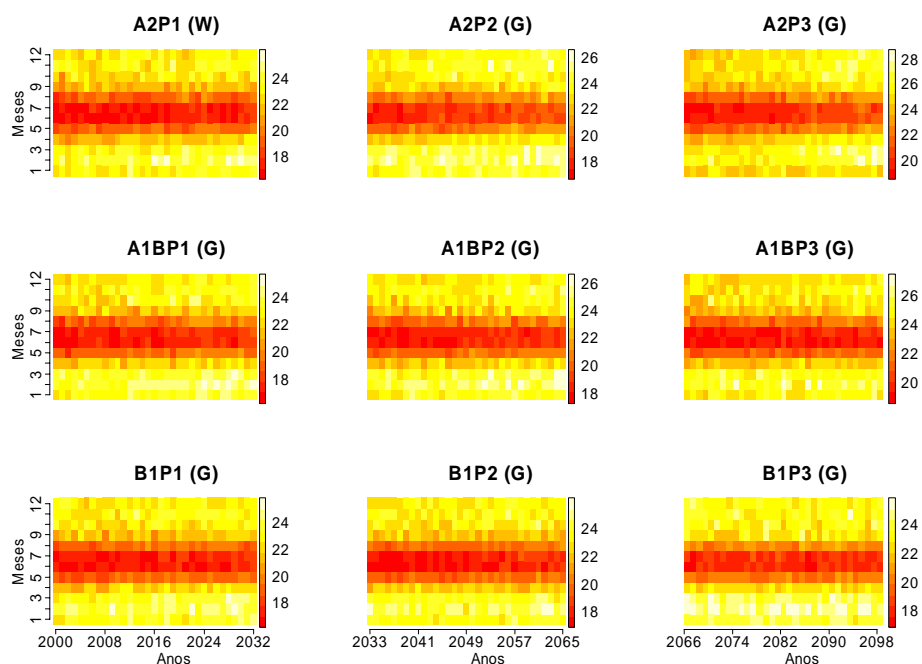


FIGURA 2.10 Representação bidimensional da krigagem para temperatura do ar de Juiz de Fora, MG, com ajuste dos modelos “wave” (W) e gaussiano (G), para os cenários A2, A1B e B1.

A validação cruzada para os modelos esférico, gaussiano e “wave” indicaram que os dados observados e de previsão de cenários futuros foram adequados para representar a variabilidade temporal dos dados e seguiram a distribuição normal. Na Figura 2.11, estão apresentados os resultados dessa validação para os dados observados de precipitação pluvial. Verificou-se que os valores preditos estão próximos da reta; a distribuição dos erros positivos e negativos está dispersa ao longo dos meses observados no estudo e os dados da probabilidade teórica e observada encontram-se sobre a reta, indicando que o método utilizado para a predição, ou seja, a krigagem ordinária, foi eficiente. De

forma semelhante, foi observada a eficiência da krigagem para os dados de previsão dos cenários futuros, obtendo-se resultados similares.

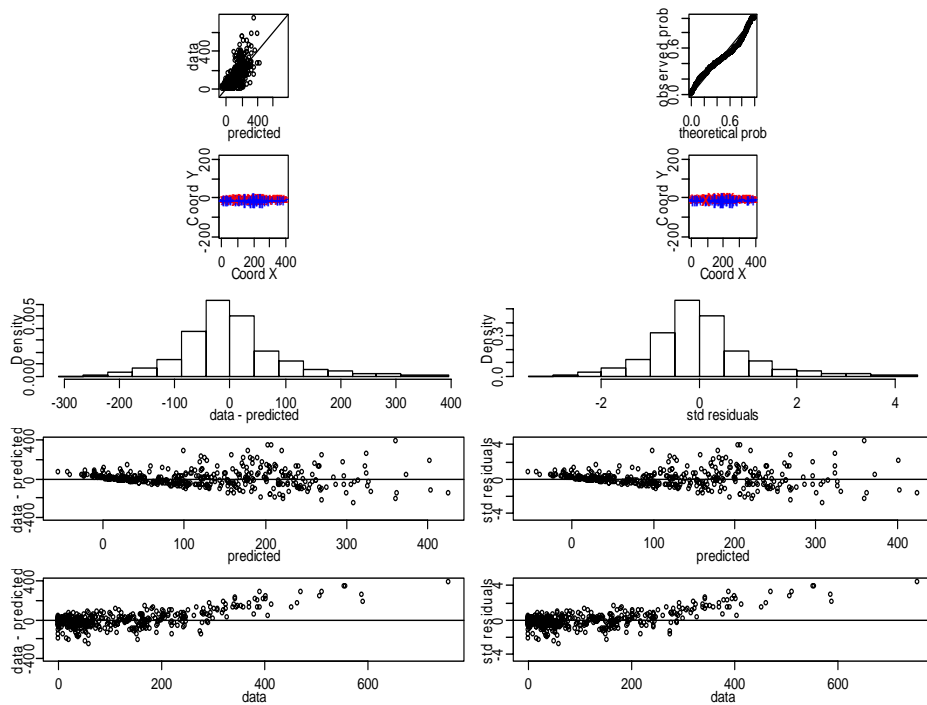


FIGURA 2.11 Validação cruzada para os dados observados de precipitação pluvial da estação Torreões, utilizando o modelo “wave”.

6 CONCLUSÕES

Com base nos semivariogramas experimentais e teóricos, constatou-se dependência temporal das variáveis, pelo estimador clássico e robusto. Com o estimador clássico, obtiveram-se melhores ajustes.

Observou-se, pelo estimador clássico, melhor ajuste do modelo “wave” para os dados observados e os cenários futuros de precipitação pluvial. Para a variável temperatura do ar, verificou-se melhor ajuste do modelo gaussiano, quando comparado aos demais modelos.

Verificou-se, para análise dos dados ao longo do tempo, que a forma bidimensional para se representar o resultado da krigagem é uma alternativa muito interessante para a visualização dos resultados. Com essa representação, observou-se, de forma muito clara, os dois períodos, chuvoso e seco que, devido ao clima de Juiz de Fora, MG, são muito bem definidos, com precipitações e temperaturas muito diferentes.

Outros arranjos temporais devem ser avaliados em estudos posteriores, considerando a forma bidimensional desde o ajuste de semivariogramas até a krigagem, a fim de se obter melhor ajuste e mapas de contornos mais suavizados no estudo de séries temporais de variáveis climáticas.

7 REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, G. F.; GONZAGA, F. A. S.; GUIMARÃES, E. C.; TAVARES, M. Comportamento da precipitação mensal de Uberlândia: Análise da dependência temporal. In: ENCONTRO INTERNO DE INICIAÇÃO CIENTÍFICA, 5., 2005, Uberlândia. **Anais...** Uberlândia: PROPP/UFU, 2005. v. 1, p. 1-10. 1 CD-ROM.

AGÊNCIA NACIONAL DAS ÁGUAS. **Sistemas Hidrológicas:** Sistemas de informações hidrológicas – hidroweb. Disponível em: <<http://www.ana.gov.br>>. Acesso em: jul. 2007.

ASSAD, E. D.; LUCHIARI JUNIOR.. A future scenario and agricultural strategies against climatic changes: the case of tropical savannas. In: PINTO, H. S.; ASSAD, E. D.; ZULLO JUNIOR, J.; BRUNINI, O. **Mudanças climáticas e estratégias futuras.** São Paulo: USP, 1989.

BRASIL. Ministério da Agricultura e Reforma Agrária. Secretaria Nacional de Irrigação. Departamento Nacional de Meteorologia. **Normais climatológicas:** (1961-1990). Brasília, 1992. 84 p.

BERLATO, M. A.; FONTANA, D. C. **El Niño e La Niña:** impactos no clima, na vegetação e na agricultura do Rio Grande do Sul; aplicações de previsões climáticas na agricultura. Porto Alegre: UFRGS, 2003. 110 p.

CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURCO, R. F.; KONOPKA, A. E. Fieldscale variability of soil properties in Central Iowa soils. **Soil Science Society of America Journal**, Madison, v. 58, n. 5, p. 1501-1511. Sept./Oct. 1994.

CARTER, T. R.; ROVERE, E. L. L.; JONES, R. N.; LEEMANS, R.; MEARNES, L. O.; NAKICENOVIC, N.; PITTOCK, A. B.; SEMENOV, S. M.; SKEA, J. Developing and Applying Scenarios. In: MCCARTHY, J. J.; CANZIANI, O. F.; LEARY, N. A.; DOKKEN, D. J.; WHITE, K. S. (Ed.). **Climate change 2001:** impacts, adaptation, and vulnerability. Contribution of Working Group II to the Third Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, 2001. p. 147-190.

CLARK, I. **Practical Geostatistics**. Essex: Applied Science, 1979. 129 p.

CUBASCH, U.; MEEHL, G. A.; BOER, G. J.; STOUFFER, R. J.; DIX, M.; NODA, A.; SENIOR, C. A.; RAPER, S.; YAP, K. S. The Climate System: an Overview. In: HOUGHTON, J. T.; DING, Y.; GRIGGS, D. J.; NOGUER, M.; VAN DER LINDEN, P. J.; DAI, X.; MASKELL, K.; JOHNSON, C. A. (Ed.). **Climate change 2001: projections of future climate change**. Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, 2001. p. 87-98.

FERRAZ, M. I. F. **Uso de modelos de séries temporais nas precipitações pluviiais no município de Lavras, MG**. 1999. 97 p. Dissertação (Mestrado em Agronomia/Estatística e Experimentação Agropecuária) - Universidade Federal de Lavras, Lavras.

FERREIRA, D. B. **Relações entre a variabilidade da precipitação e a produtividade agrícola de soja e milho nas regiões sul e sudeste do Brasil**. 2005. 123 p. Dissertação (Mestrado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

GOOVAERTS, P. **Geostatistics for natural resources evaluation**. New York: Oxford University, 1997. 512 p.

HABERLANDT, U. Geostatistical interpolation of hourly precipitation from rain gauges and radar for a large-scale extreme rainfall event. **Journal of Hydrology**, Hannover, v. 332, p. 144–157, Jun. 2007.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. **Climate Change 2007: the PHYSICAL Science Basis, Summary for policy Makers**. Genebra, 2007.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. In: HOUGHTON, J. T.; DING, Y.; GRIGGS, D. J.; NOGUER, N.; VAN DER LINDEN, P. J.; XIAOSU, D.; MASKELL, K.; JOHNSON, C. A. (Ed.). **Climate Change 2001: the scientific basis**. Cambridge: Cambridge University, 2001.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied geostatistics**. New York: Oxford University, 1989. 561 p.

MARENGO, J. A. O quarto relatório do IPCC (IPCC AR4) e projeções de mudanças de clima para o Brasil e América do Sul. **Boletim da Sociedade**

Brasileira de Meteorologia, São José dos Campos. v. 31, n. 1, p.23-28, abr. 2007.

MARENGO, J. A.; ALVES, L. M.; CASTRO, C. A. C.; MENDES, D. **Início da estação chuvosa nas Regiões Sudeste, Centro-Oeste e sul do Nordeste do Brasil, afetadas pela crise de energia**. Disponível em: <<http://www.cptec.inpe.br/energia/saiba/iniciochuvas.shtml>>. Acesso em: jun. 2007.

MELLO, C. R.; SILVA, A. M. da; LIMA, J. M.; FERREIRA, D. F.; OLIVEIRA, M. S. de. Modelos matemáticos para predição da chuva de projeto para regiões do Estado de Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campinas Grande, v. 7, n. 1, p. 121-128, jan./mar. 2003.

NAKICENOVIC, N.; ALCAMO, J.; DAVIS, G. VRIES, B. de; FENHANN, J.; GAFFIN, S.; GREGORY, K.; GRÜBLER, A.; JUNG, T. Y.; KRAM, T.; LA ROVERE, E. L.; MICHAELIS, L.; MORI, V.; MORITA, T.; PEPPER, W. ; PITCHER, H.; PRICE, L.; RAIHI, K.; ROEHL, A.; ROGNER, H. -H.; SANKOVSKI, A.; SCHLESINGER, M.; SHUKLA, P.; SMITH, S.; SWART, R.; VAN ROOIJEN, S.; VICTOR, N.; DADI, Z. **Special Report on Emissions scenarios**: International Panel on Climate Change. Cambridge: Cambridge University, 2000. 599 p.

NATIONAL CENTER FOR ATMOSPHERIC RESEARCH. **Geographic Information System (Gis) Initiative**. Boulder, Co: NCAR/UCAR/NSF, 2007. Disponível em: <<http://www.gis.ncar.edu>>. Acesso em: out. 2007.

NOBRE C. A. Mudanças climáticas globais e o Brasil: porque devemos nos preocupar. **Boletim da Sociedade Brasileira de Meteorologia**, São José dos Campos. v. 31, n. 1, p. 7-11, abr. 2007.

NOBRE , C. A. Mudanças climáticas globais: possíveis impactos nos ecossistemas do país: modelos e cenários para a Amazônia: o papel da ciência. **Revista Parcerias estratégicas**, Brasília, DF, n. 12, 20 p, set. 2001.

QUEIROZ, E. F. de; SILVA, R. J. B. de; OLIVEIRA, M. C. N de. Modelo de análise de regressão periódica da precipitação mensal da bacia atlântico sudeste, no Estado do Paraná. **Pesquisa Agropecuária Brasileira**, Brasília, v. 36, n. 5, p. 27-742, maio 2001.

R DEVELOPMENT CORE TEAM. **R: a language and environment for statistical computing**. Viena: R Foundation for Statistical Computing, 2007. Disponível em: <<http://www.R-project.org>>.

RIBEIRO JÚNIOR, P. J.; DIGGLE, P. J. GeoR: a package for geostatistical analysis. **R-NEWS**, London, v. 1, n. 2, p. 15-18, june 2001.

SIQUEIRA, O. J. W.; STEINMETZ, S.; FERREIRA, M. F., COSTA, A. C.; WOZNIAK, M. A. Mudanças climáticas projetadas através dos modelos GISS e reflexos na produção agrícola brasileira. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 8, n. 2, p. 311-320, out. 2000.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. Viçosa, MG: UFV, 1991. 449 p.

WEBSTER, R.; OLIVER, M. A. **Geostatistics for Environmental Scientists**. New York: John Wiley & Sons, 2001. 271 p.

CAPÍTULO 3

CARACTERIZAÇÃO DA DEPENDÊNCIA TEMPORAL DE ELEMENTOS CLIMÁTICOS PARA CENÁRIOS FUTUROS DE JUIZ DE FORA, MG, POR MEIO DE SEMIVARIOGRAMA E KRIGAGEM

1 RESUMO

MOTA, Vania Corrêa. Estudo da dependência temporal da precipitação pluvial e da temperatura do ar de Juiz de Fora, MG, por meio de análises geoestatísticas. In: _____. **Caracterização da dependência temporal de elementos climáticos para cenários futuros de Juiz de Fora, MG, por meio de semivariogramas e krigagem.** 2008. Cap.3, p.70-111 Dissertação (Mestrado em Estatística e Experimentação Agropecuária) – Universidade Federal de Lavras, Lavras.**

O objetivo deste trabalho foi verificar o uso de modelos de semivariograma e krigagem ordinária para caracterizar e representar a dependência temporal da precipitação pluvial e da temperatura do ar do município de Juiz de Fora, MG, utilizando anos e meses como coordenadas referenciadas. Foi utilizada uma série de precipitação pluvial, nos anos de 1967 a 1999 e dados de previsão de precipitação pluvial e temperatura do ar em cenários futuros de mudanças climáticas, de 2000 a 2099. Com base nos semivariogramas experimentais e teóricos, considerando isotropia e anisotropia, foi constatada dependência temporal da precipitação pluvial, com melhor ajuste do modelo “wave”, quando comparado com os modelos gaussiano e esférico. A estrutura e a magnitude de dependência temporal das duas variáveis, em cenários futuros e nas direções 0° (meses) e 90° (anos), foram caracterizadas utilizando-se o arranjo proposto. Com o uso da geoestatística, o padrão da variabilidade temporal da precipitação pluvial e da temperatura do ar foi representado ao longo dos anos e dos meses por meio da interpolação de krigagem, verificando-se possíveis mudanças nos padrões de precipitação pluvial e temperatura, para os dados de previsão de mudanças climáticas, com maior alteração para o cenário mais pessimista.

** Comitê Orientador: Prof. Dr. Renato Ribeiro de Lima – UFLA (Orientador); Marcelo de Carvalho Alves – UFLA (Co-orientador).

2 ABSTRACT

MOTA, Vania Corrêa. **Geostatistic methodology to characterize the temporal variability of climatic elements of Juiz de Fora – MG.** In:_____. **Characterization of the climatic elements temporal dependence of future scenarios in Juiz de Fora, MG, by using semivariograms and kriging.** 2008. Cap. 3, p. 70-111. Dissertation (Master in Statistics and Agricultural Experimentation) – Federal University of Lavras, Lavras, MG, Brazil.*

The objective of this work was verify the use of semivariogram models and ordinary kriging to characterize and to represent the temporal dependence of the pluvial precipitation and air temperature of the municipal district of Juiz de Fora - MG, by using years and months with coordinates. The observed pluvial precipitation, between 1967 to 1999, and the forecast data of future scenarios of climatic changes, from 2000 to 2099, for the pluvial precipitation and air temperature were analyzed. The semivariograms were adjusted by considering isotropy and anisotropy conditions. The wave model presented better adjustment than the Gaussian and spherical models when the two-dimensional grid was used. The structure and the magnitude of temporal dependence of the two variables were characterized by considering the 0° (months) and 90° (years) directions. The parttern of the temporal variability of the precipitation and the air temperature was represented by using kriging. Possible changes in the patterns of the pluvial precipitation and the air temperature for the future scenarios were verified by using two-dimensional grid and kriging. The greatest changes in the pattern of the two variables were verified in the most pessimist future scenario.

* Guidance Committee: Prof. Dr. Renato Ribeiro de Lima – UFLA (Adviser); Marcelo de Carvalho Alves – UFLA (Co-Adviser).

3 INTRODUÇÃO

As alterações climáticas ocorridas atualmente são observadas sobretudo nas áreas urbanas e rurais. Nas áreas urbanas, essas alterações são observadas devido ao aumento populacional. Já nas áreas rurais, o setor agrícola é o mais atingido por oscilações e alterações climáticas, pois o cultivo agrícola é extremamente dependente das variáveis climáticas.

Algumas dessas alterações são verificadas quando se pretende modelar elementos climáticos, como dados de precipitação pluvial e temperatura do ar. Para estudar a precipitação pluvial e a temperatura do ar, é necessário caracterizar a distribuição dessas variáveis ao longo do tempo. No entanto, de posse de extensas séries históricas, torna-se mais complexa a identificação do comportamento espaço-temporal dos dados. Muitos fatores afetam essa distribuição e isso determina sua variação espacial, temporal e sazonal (Mendonça & Oliveira, 2007). Para estudar essa variação, estão disponíveis, nos dias atuais, muitas técnicas de interpolação espacial com variados graus de complexidade, de forma a representar processos climatológicos (Goovaerts, 1997; Mendonça & Oliveira, 2007).

A primeira técnica para estimar precipitação média regional surgiu em estudos de Thiessen (1911), com a técnica do polígono de Thiessen. Outro trabalho clássico em análise de dados com dependência espacial foi realizado por Matheron (1963), que introduziu a teoria da variável regionalizada, hoje conhecida como metodologia geoestatística, para estimar as médias regionais, considerando os processos estocásticos.

A geoestatística é baseada, fundamentalmente, em apenas dois conceitos: o do semivariograma, utilizado para descrever a estrutura da dependência espacial e ou temporal dos dados e o da krigagem, utilizado para estimar os valores não observados, com variância mínima (Pontes, 2002).

Entretanto, na maioria das vezes, o interesse da análise geoestatística não se limita à obtenção de um modelo de dependência espacial ou temporal, desejando-se também prever valores em pontos não amostrados. O interesse pode ser em um ou mais pontos específicos da área ou em obter uma malha de pontos interpolados que permitam visualizar o comportamento da variável na região por meio de um mapa de isolinhas ou de contornos a fim de descrever melhor a variabilidade espacial e ou temporal dos dados.

Fisicamente, existe uma diferença entre as dimensões espaciais e temporais, pois as unidades das coordenadas dos dois processos apresentam grandezas diferentes e os modelos precisam considerá-las (Chilés & Delfiner, 1999; Silva, 2006). Para contornar esse problema, utiliza-se um arranjo temporal proposto por Sant'Anna Neto (2005), no qual consideram-se anos e meses como se fossem coordenadas de longitude e latitude, respectivamente, para caracterizar a dependência temporal de variáveis climáticas, tais como a precipitação pluvial e a temperatura.

Assim, objetivou-se, com o presente trabalho, verificar o uso de modelos de semivariograma e utilizar a krigagem ordinária para caracterizar e representar a dependência temporal da precipitação pluvial e da temperatura do ar de Juiz de Fora, MG, para os dados observados (ano 1967 a 1999) e para os cenários futuros de mudanças climáticas, utilizando anos e meses como coordenadas.

4 MATERIAL E MÉTODOS

4.1. Material

4.1.1 Origem dos dados

Este estudo foi realizado com dados do município de Juiz de Fora, estado de Minas Gerais, cuja localização pode ser vista no mapa da Figura 3.1.

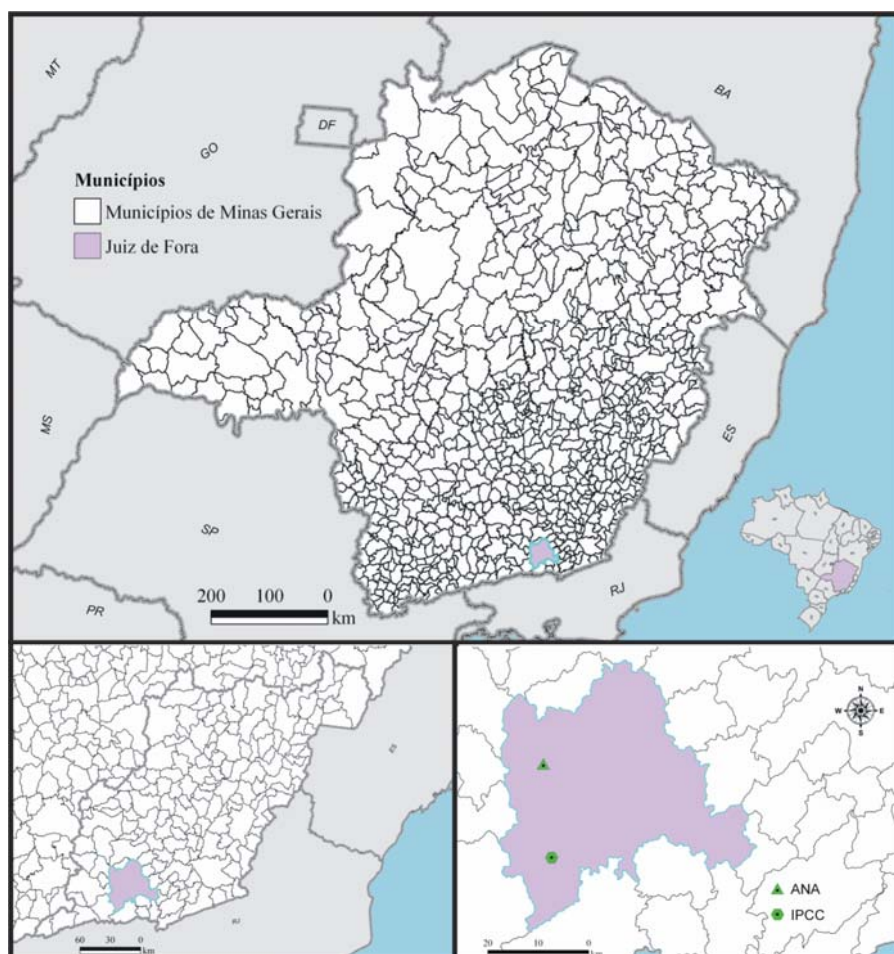


FIGURA 3.1 Localização de Juiz de Fora no estado de Minas Gerais.

O município localiza-se nas coordenadas latitude de 21°45'50''S e longitude de 43°21'0''W. Segundo a classificação internacional de Köppen, o clima da região é do tipo tropical de altitude CWA, caracterizado por duas estações bem definidas: uma seca e de menores temperaturas, que se estende de maio a setembro, e outra úmida e de temperaturas mais elevadas, de outubro a abril. A temperatura média anual é de 19,3°C e a precipitação anual é de 1.644 mm (Brasil, 1992).

Neste estudo foram analisados dados coletados em uma estação pluviométrica e dados de previsão do IPCC.

4.1.2 Dados observados

Os dados observados referem-se à precipitação pluvial mensal, em mm, oriundos em uma estação pluviométrica da Agência Nacional das Águas, localizada no município de Juiz de Fora, MG. Essa estação, denominada de Estação Torreões, localiza-se na latitude -21°52'9'', longitude -43°33'20'' e altitude de 442 m (ANA, 2007). Nas análises, foram utilizados os dados do período de 1967 a 1999, perfazendo um total de 396 meses. Esses dados fazem parte da base de dados de séries históricas da ANA (ANA, 2007).

4.1.3 Dados de previsão de cenários futuros

Para os dados de previsão de cenários futuros, foram consideradas duas variáveis: precipitação pluvial mensal, em mm e temperatura média mensal do ar, em °C. Esses dados de previsão de cenários futuros foram obtidos da base de dados do IPCC (IPCC, 2001) e referem-se ao período de 2000 a 2099. Esses dados fazem parte de previsões realizadas pelo 'National Center for Atmospheric Research' (NCAR, 2007), referentes ao Terceiro Relatório de Avaliação (TAR), modelo CCSM 3.0, com a resolução espacial de 1,4° x 1,4°, com latitude de -21,7119° e longitude de -43,5938°. Para efeito de análise, esse período foi dividido em três: P1, de 2000 a 2032; P2, de 2033 a 2065 e P3, de

2066 a 2099 (para a precipitação) ou de 2066 a 2098 (para a temperatura).

Os dados do TAR consideram diferentes cenários de mudanças climáticas, em que é considerado um conjunto de diferentes forças externas, como, por exemplo, ozônio, atividades de vulcões, etc., com a mesma condição inicial. Foram considerados três cenários que diferem entre si em relação a mudanças climáticas: um mais pessimista (A2), um intermediário (A1B) e outro mais otimista (B1). Esses cenários e períodos foram adotados, a fim de possibilitar a comparação de diferentes simulações de mudanças climáticas com o período das Normais Climatológicas de 1961 a 1990.

Nas projeções de mudanças climáticas, utilizou-se uma hierarquia de modelos com base no clima, no meio-ambiente, no uso da terra, nos aspectos tecnológicos e socioeconômicos, integrados, para indicar respostas globais e padrões regionais de mudanças climáticas (Nakicenovic et al. 2001). Esses cenários variaram de acordo com o grau de interferências antrópicas no ambiente (Carter et al., 2001; Cubash et al., 2001; Marengo et al., 2007), sendo:

- A2: cenário caracterizado por um mundo futuro muito heterogêneo, em que a regionalização é dominante. Existiria um fortalecimento de identidades culturais regionais, com ênfase em valores da família e tradições locais. Outras características são crescimento populacional alto e menor preocupação em relação ao rápido desenvolvimento econômico e tecnológico;

- A1B: cenário caracterizando um mundo futuro, no qual a globalização é dominante. Há rápido crescimento econômico e desenvolvimento de tecnologias mais eficientes, com aumento da população global na metade do século XXI, seguida por declínio. Os temas subjacentes principais são: a convergência econômica e cultural, com redução significativa em diferenças regionais e renda per capita. Nesta

simulação, os indivíduos procuram riqueza pessoal em lugar de qualidade ambiental;

- B1: cenário caracterizado por rápida mudança na estrutura econômica mundial, com introdução de tecnologias limpas, tendência a serviços e economia de informação, redução na intensidade de materiais e a introdução de recursos tecnológicos básicos e eficientes. Há ênfase em soluções globais para a economia, a sustentabilidade ambiental e social, mas sem iniciativas relacionadas a fatores climáticos.

4.1.4 Arranjo ou malha utilizada nas análises

Para utilizar os métodos geoestatísticos, a fim de realizar um estudo e análise da dependência e da variabilidade espacial e ou temporal, é necessário que as observações sejam referenciadas, não havendo a necessidade de se utilizar coordenadas geográficas, mas algum outro tipo de referência. Neste estudo, como as observações foram coletadas ao longo do tempo, consideraram-se, no arranjo proposto, anos e meses como coordenadas referenciadas, conforme proposta por Sant' Anna Neto (2005), da mesma forma como longitude e latitude são utilizadas no caso de dados georreferenciados. Uma representação gráfica deste arranjo é apresentada na Figura 3.2. De forma semelhante, foi utilizado um arranjo para os cenários futuros de 2000 a 2099.

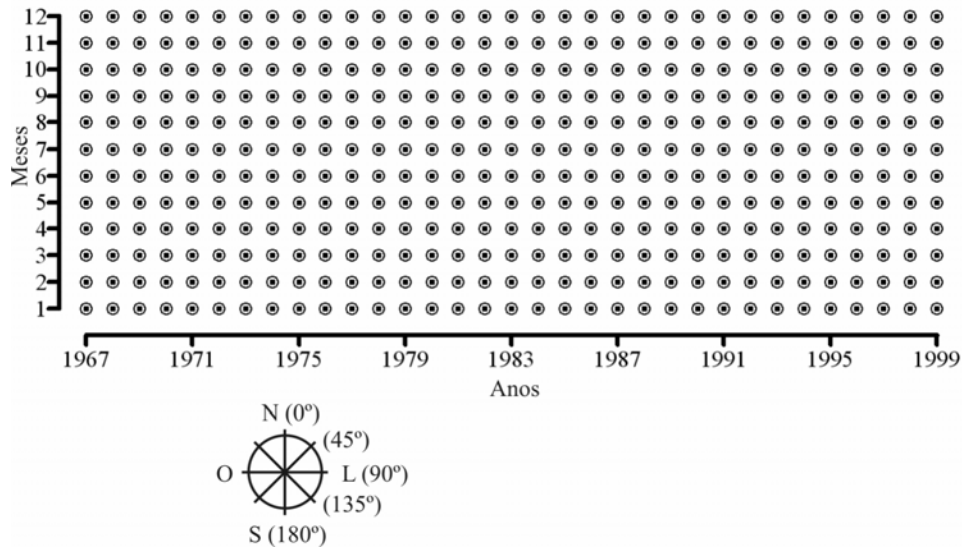


FIGURA 3.2 Representação do arranjo de anos e meses para os dados observados de Juiz de Fora, MG.

4.2 Métodos

4.2.1 Análise estrutural

A análise estrutural compreende uma fase muito importante, pois tem como objetivo construir um modelo estatístico que descreva a continuidade da variável resposta e sua variabilidade espacial e ou temporal, por meio do semivariograma experimental e teórico.

A análise geoestatística foi aplicada de modo isotrópico (omnidirecional) e anisotrópico.

Inicialmente, foram estimados os semivariogramas, por meio dos estimadores clássico e robusto, considerando isotropia (omnidirecional) para as variáveis precipitação pluvial (dados observados e cenários futuros) e temperatura do ar em cenários futuros.

Para o ajuste do semivariograma teórico, foi utilizado o método dos

mínimos quadrados ordinários (OLS). Os modelos estatísticos comparados foram: esférico, gaussiano e “wave” que, conforme Isaaks & Srivastava (1989), são definidos por:

$$\begin{aligned}
 \text{- modelo esférico: } \gamma(h, \beta) &= \begin{cases} C_0 + C \left[\frac{3}{2} \left(\frac{h}{a} \right) - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right], & 0 \leq h \leq a, \\ C_0 + C & , h > a \end{cases} \\
 \text{- modelo gaussiano: } \gamma(h, \beta) &= C_0 + C_1 \left(1 - \exp \left(-3 \left(\frac{h^2}{a^2} \right) \right) \right), \text{ se } a > 0, \\
 \text{- modelo “wave”: } \gamma(h, \beta) &= C_0^2 + \frac{a}{h} \operatorname{sen} \left(\frac{h}{a} \right),
 \end{aligned}$$

em que $\gamma(h, \beta)$ é a semivariância para a distância h ; C_0 é o efeito pepita; $C_0 + C_1$ é o patamar e a é o alcance da dependência espacial.

Do conjunto de resultados obtidos, pelos estimadores clássico e robusto, para os três modelos, foram estimados seus parâmetros e selecionado o melhor modelo, de acordo com a aproximação para o valor do Critério de Akaike (AIC) proposta por Webster & Oliver (2001), ou seja:

$$AIC = 2p + n \cdot \ln(RSS/n),$$

em que n é o número de observações, p é o número de parâmetros e RSS é a soma de quadrados de resíduos, definida em 14. A relação $C_0/C_0 + C_1$ foi utilizada para avaliar o grau de dependência espacial das variáveis e como, neste estudo, os dados são analisados ao longo do tempo, essa relação foi chamada de grau de dependência temporal, adaptada de Cambardella et al. (1994).

Nas fases anteriores, o objetivo foi identificar o melhor modelo teórico de semivariograma isotrópico para as duas variáveis. Na segunda fase das análises, o objetivo foi estudar e caracterizar as direções (anisotropia) para as variáveis precipitação pluvial e temperatura do ar referentes aos cenários futuros. Assim, procedeu-se à análise anisotrópica, que foi orientada nas

direções correspondentes ao arranjo proposto, meses (Norte, 0°) e anos (Leste, 90°), para os modelos “wave” e gaussiano

Ao considerar anisotropia, foram realizadas apenas análises considerando o estimador clássico de Matheron, dado por:

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{j=1}^{N(h)} [z(x_j) - z(x_j + h)]^2,$$

em que $N(h)$ é o número de pares possíveis para a distância h , $\hat{\gamma}(h)$ é a semivariância para uma distância h , $z(x_j)$ e $z(x_j + h)$ são as observações de precipitação pluvial e temperatura separadas pelo vetor h e h é a distância de separação das observações, nesse caso, o tempo.

As análises dos semivariogramas direcionais foram realizadas para definir e identificar a estrutura e a magnitude da dependência temporal dos dados. Para cada cenário e período, foram calculadas as semivariâncias e o respectivo ajuste dos modelos de semivariograma teórico.

4.2.2 Interpolador geoestatístico – krigagem ordinária

A krigagem interpola valores em uma superfície contínua e faz uso explicitamente da variância entre os valores observados, representada no semivariograma.

Para realizar a interpolação por krigagem ordinária e mapear as variáveis em estudo, utilizaram-se as estimativas dos parâmetros referentes ao melhor modelo de semivariograma selecionado anteriormente. De acordo com Goovaerts (1997), o estimador linear é dado pela seguinte equação:

$$Z_{KO}^*(x) = \sum_{j=1}^{n(x)} \lambda_j(x) z(x_j),$$

em que $n(x)$ é o número de observações de $z(x_j)$ utilizadas para estimar $Z_{KO}^*(x)$ e λ_j são os pesos associados às observações $z(x_j)$. Nesse caso, para

que $Z_{KO}^*(x)$ seja não tendencioso, a soma dos pesos das observações deve ser igual a 1 e, conforme definido nas equações 16 e 17 a esperança entre o valor estimado e o observado deve ser zero e a variância da estimativa deve ser mínima, respectivamente.

A metodologia de interpolação por krigagem ordinária foi utilizada para gerar uma superfície suavizada dos mapas de contorno. Para verificar se a krigagem ordinária descreve adequadamente a variabilidade temporal das variáveis estudadas e se as hipóteses assumidas de estacionaridade foram satisfeitas, foi utilizada a validação cruzada (“cross-validation”).

Como critérios para a validação cruzada, foram considerados o erro médio (EM), definido em 19 e a razão do quadrado médio do erro (RQME), definido em 20. Espera-se que o EM seja próximo de zero e o RQME seja próximo de 1 (Webster & Oliver, 2001).

Todas as análises foram realizadas utilizando-se o pacote geoR (Ribeiro Júnior & Diggle, 2001), aplicativo R (R Development Core Team, 2007).

5 RESULTADOS E DISCUSSÃO

5.1 Análise isotrópica

Pela análise semivariográfica, foi possível detectar que as duas variáveis apresentaram-se estruturadas temporalmente, o que pode ser verificado nas Figuras 3.3, 3.4 e 3.5. Portanto, de acordo com os resultados da primeira fase, em que as semivariâncias foram calculadas pelos estimadores clássico e robusto admitindo isotropia, verificou-se que os modelos teóricos estudados representam essa estrutura de dependência temporal.

Para a estação Torreões, as estimativas dos parâmetros da precipitação pluvial são apresentados na Tabela 3.1. Verificou-se que, tanto pelo estimador clássico quanto pelo estimador robusto, o melhor ajuste é do modelo “wave”, pois houve menor valor de AIC, quando comparado com os demais modelos.

TABELA 3.1 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais clássico e robusto, relativos à precipitação pluvial de Juiz de Fora, para os dados observados.

	Estação Torreões					
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	7,21	6,23	7,47	7,52	6,53	7,78
C_0	3337,71	4518,02	4997,74	1454,40	2748,42	3151,57
$C_0 + C_1$	8666,63	7524,13	6698,65	9410,56	8173,13	7408,95
AIC	3655,98	3612,56	3579,33	3958,22	3917,38	3772,59
DT	38,51%	60,00%	74,60%	15,445%	33,62%	42,53%

O modelo “wave” apresentou uma moderada dependência temporal, de acordo com a classificação de Cambardela et al. (1994), ou seja, o valor da relação entre efeito pepita e o patamar multiplicado por 100 está entre 25% e 75%.

Os semivariogramas para os dados observados de precipitação pluvial (Figura 3.3) indicaram periodicidade, de forma semelhante aos resultados obtidos por Carvalho et al. (2004), em estudos sobre a variabilidade da precipitação pluvial no estado de São Paulo. Já Alves et al. (2005), estudando a variabilidade temporal da precipitação de Uberlândia, MG, não verificaram essa periodicidade. Os autores constaram melhor aplicação do modelo gaussiano, com alcance de 5,94 unidades, sem adotar critérios para comparar o ajuste dos modelos.

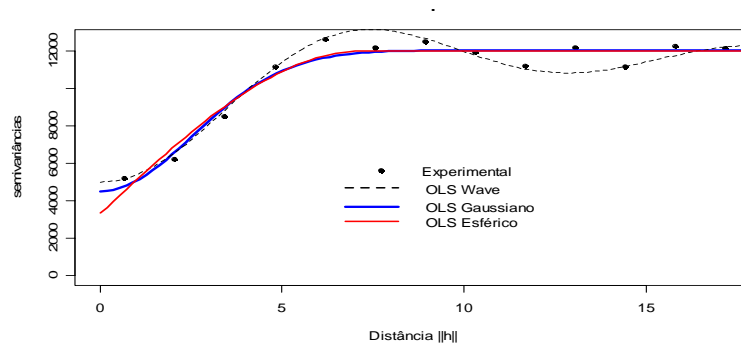


FIGURA 3.3 Semivariogramas experimentais e teóricos, pelo estimador clássico, com ajuste dos modelos, “wave”, gaussiano e esférico para os dados observados de precipitação pluvial de Juiz de Fora, MG.

Para os cenários futuros A2, A1B e B1, nos períodos P1, P2 e P3, verificou-se dependência temporal da precipitação pluvial e da temperatura, pois o valor absoluto da diferença entre as observações aumentou com o aumento da

distância até um ponto de estabilidade que separa o universo estruturado do aleatório, correspondente ao alcance, de forma a satisfazer as suposições de estacionaridade (Figuras 3.4 e 3.5).

De acordo com a aproximação do critério de informação de Akaike para o cenário A2, observou-se melhor ajuste do modelo “wave” à série de precipitação pluvial, para os três períodos em estudo. Este resultado foi observado pelo estimador clássico e robusto e estão apresentados na Tabela 3.2.

TABELA 3.2 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais clássico e robusto, relativos à precipitação pluvial de Juiz de Fora, para o cenário A2 nos três períodos.

Cenário A2 P1						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	7,08	5,84	7,51	7,7469	6,26	7,78
C_0	0,00	296,31	585,00	0,00	31,90	224,50
$C_0 + C_1$	3838,74	3554,84	3144,53	3535,68	3527,22	3212,64
AIC	3163,13	3135,58	2840,98	3462,40	3406,88	3128,28
DT	0,00%	8,33%	18,60%	0,00%	0,90%	6,00%
Cenário A2 P2						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	7,08	5,83	7,47	7,85	6,31	7,74
C_0	0,00	250,95	562,67	0,00	0,00	144,69
$C_0 + C_1$	4203,18	3966,03	3513,88	3878,70	3906,47	3620,99
AIC	3259,32	3220,31	2911,67	3593,68	3531,24	3241,52
DT	0,00%	6,00%	16,01%	0,00%	0,00%	3,90%
Cenário A2 P3						
	Semivariograma clássico			Semivariograma robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	7,14	5,83	7,56	7,88	6,31	7,78
C_0	0,00	250,954	654,92	0,00	0,00	180,63
$C_0 + C_1$	4544,04	3966,03	3756,69	4191,39	3906,47	3889,61
AIC	3300,04	3220,31	3081,55	3726,15	3625,89	3380,49
DT	0,00%	6,00%	17,43	0,00%	0,00%	4,00%

Obs: Cenário mais pessimista (A2), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2099 (P3).

Verificou-se, para o modelo “wave”, um aumento crescente dos valores de patamar, nos períodos P1, P2 e P3, para o cenário A2. Isso pode ser explicado pelo aumento dos índices de precipitação ocorridos nesse cenário ao longo dos três períodos, conforme constatado pela análise descritiva.

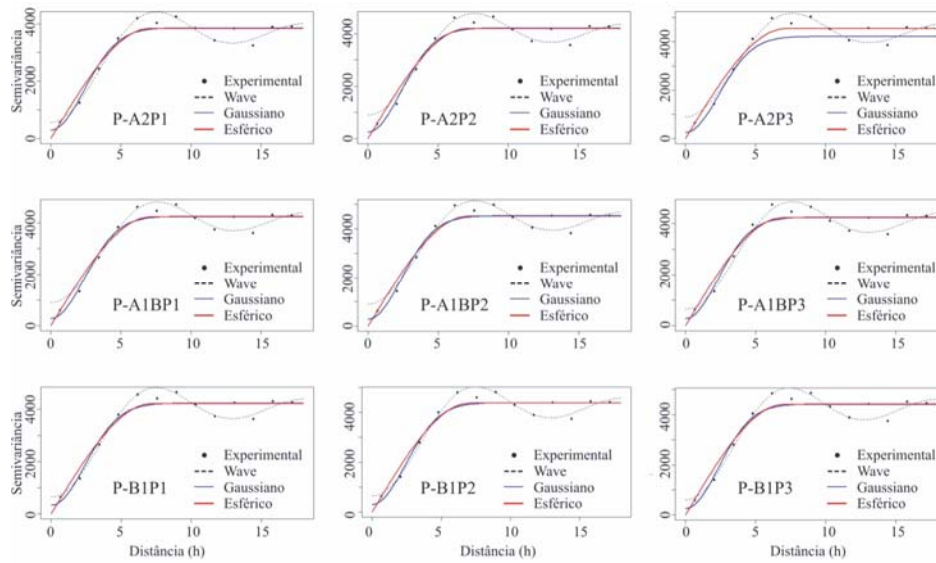


FIGURA 3.4 Semivariogramas experimentais e teóricos pelo estimador clássico para precipitação pluvial, com ajuste dos modelos isotrópicos, “wave”, gaussiano e esférico, para os cenários A2, A1B e B1.

Na Tabela 3.3 estão apresentados os resultados do cenário intermediário A1B, no qual se observou um forte grau de dependência temporal, para os três períodos analisados.

TABELA 3.3 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais (omnidirecional) clássico e robusto, relativos à precipitação pluvial de Juiz de Fora, para o cenário A1B nos três períodos.

Cenário A1B P1						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	7,14	5,86	7,47	7,96	6,36	7,78
C_0	0,00	282,58	593,66	0,00	0,00	152,19
$C_0 + C_1$	4225,23	3956,29	3504,66	3884,80	3909,79	3614,59
AIC	3248,93	3213,26	2922,47	3569,78	3505,67	3212,77
DT	0,00%	7,14	16,94%	0,00%	0,00%	4,21%
Cenário A1B P2						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	7,11	5,83	7,51	7,77	6,27	7,74
C_0	0,00	283,90	637,87	0,00	0,00	169,97
$C_0 + C_1$	4514,25	4245,38	3744,50	4204,60	4235,80	3913,89
AIC	3294,95	3256,55	2995,67	3638,54	3573,31	3281,85
DT	0,00%	8,72%	17,03%	0,00%	0,00%	4,34%
Cenário A1B P3						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	6,91	5,69	7,33	7,57	6,12	7,56
C_0	0,00	288,97	590,27	0,00	0,00	148,70
$C_0 + C_1$	4232,22	3958,92	3515,20	3995,03	4024,41	3731,45
AIC	3382,23	3351,53	2993,52	3716,27	3658,34	3315,12
DT	0,00%	7,29%	16,79%	0,00%	0,00%	3,98%

Obs: Cenário intermediário (A1B), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2099 (P3).

No cenário A1B, houve melhor ajuste para o modelo “wave”, com menor valor de AIC, quando comparado com os modelos esférico e gaussiano (Figura 3.4). Já nesse cenário não foi verificado um aumento crescente até o P3

nos valores de patamar dos semivariogramas, pois houve um aumento do P1 para o P2, seguido de diminuição para o P3, conforme o aumento dos índices de precipitação pluvial observados na análise descritiva.

Para o cenário B1, o mais otimista, os resultados apresentaram características semelhantes aos cenários A2 e A1B, com forte grau de dependência temporal e melhor ajuste do modelo “wave”, pelo estimador clássico e robusto (Tabela 3.4 e Figura 3.4).

TABELA 3.4 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais (omnidirecional) clássico e robusto, relativos à precipitação pluvial de Juiz de Fora, para o cenário B1 nos três períodos.

Cenário B1 P1						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	7,17	5,93	7,51	7,97	6,38	7,78
C_0	0,00	331,55	633,09	0,00	0,17	199,16
$C_0 + C_1$	4219,52	3901,69	3455,22	3849,61	3873,30	3526,44
AIC	3206,85	3173,23	2941,80	3514,9	3447,90	3217,29
DT	0,00%	8,49%	18,32%	0,00%	0,00%	5,65%
Cenário B1 P2						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	7,05	5,79	7,33	7,81	6,26	7,69
C_0	0,00	307,16	639,97	0,00	0,00	186,48
$C_0 + C_1$	4375,37	4082,58	3604,05	4018,26	4044,86	3711,29
AIC	3254,62	3221,33	2958,70	3572,54	3508,51	3227,81
DT	0,00%	7,52%	17,75%	0,00%	0,00%	5,02%
Cenário B1 P3						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	7,08	5,93	7,42	7,83	6,29	7,69
C_0	0,00	262,21	594,77	0,00	0,00	161,30
$C_0 + C_1$	4406,92	4159,56	3677,01	4120,34	4148,67	3837,81
AIC	3378,71	3337,50	3057,08	3729,40	3668,28	3348,04
DT	0,00%	6,30%	16,17%	0,00%	0,00%	4,20%

Obs: Cenário mais otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2099 (P3).

Nesse cenário, os valores de patamar apresentaram aumento do P1 para o P2, com tendência de estabilização do P2 para o P3, fato também constatado na análise descritiva com relação aos valores de precipitação pluvial.

Os valores de AIC e DT e as estimativas dos parâmetros dos modelos de semivariograma teórico, para a temperatura no cenário A2, são mostrados na Tabela 3.5. Verificou-se melhor ajuste do modelo “wave” pelo estimador clássico e robusto, com forte grau de dependência temporal, conforme pode ser visto na Figura 3.5.

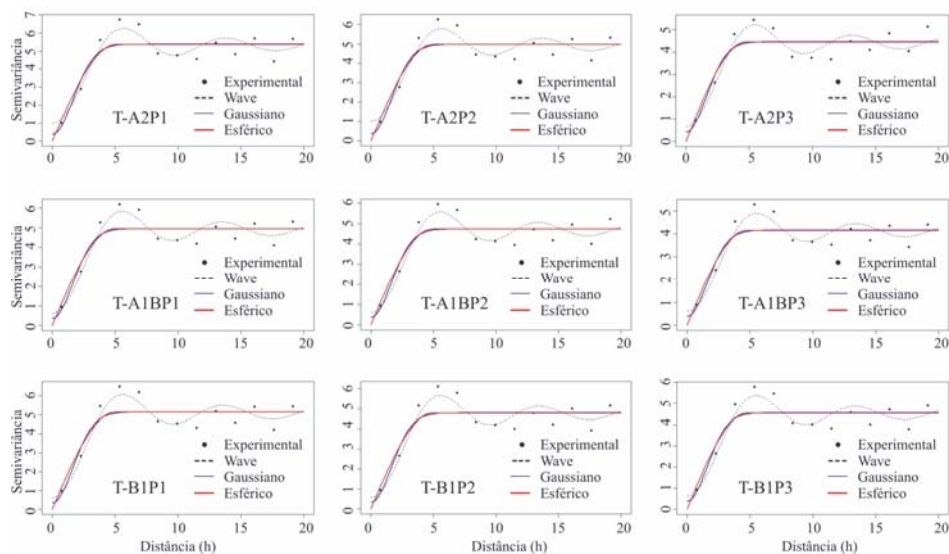


FIGURA 3.5 Semivariogramas experimentais e teóricos pelo estimador clássico para temperatura do ar, com ajuste dos modelos, “wave”, gaussiano e esférico para o cenário A2, A1B e B1, considerando isotropia.

TABELA 3.5 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais (omnidirecional) clássico e robusto, relativos à temperatura do ar de Juiz de Fora, para o cenário futuro A2 nos três períodos.

Cenário A2 P1						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	5,05	4,13	5,67	4,93	4,06	5,71
C_0	0,00	0,38	1,00	0,00	0,23	0,31
$C_0 + C$	5,37	5,00	4,33	5,33	5,07	5,03
AIC	-1618,01	-1618,30	-1959,47	-1239,04	-1239,54	-1478,87
DT	0,00%	7,60%	23,09%	0,00%	4,53%	6,16%
Cenário A2 P2						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	4,90	4,03	5,62	4,93	4,06	5,76
C_0	0,00	0,37	1,00	0,00	0,24	0,28
$C_0 + C_1$	4,96	4,60	3,93	4,84	4,60	4,57
AIC	-1674,14	-1673,47	-1996,26	-1317,32	-1318,09	-1558,55
DT	0,00%	8,04%	25,44%	0,00%	5,21%	6,12%
Cenário A2 P3						
	Semivariograma clássico			Semivariograma robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	4,71	3,94	5,44	4,79	4,06	5,53
C_0	0,00	0,42	0,67	0,00	0,24	0,34
$C_0 + C$	4,44	4,02	3,73	4,37	4,60	4,03
AIC	-1786,79	-1782,50	-2057,62	-1438,21	-1370,39	-1719,77
DT	0,00%	10,44%	17,96%	0,00%	5,21%	8,43%

Obs: Cenário mais pessimista (A2), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2098 (P3).

A periodicidade nos dados é, mais uma vez, verificada. E, para o cenário A1B e B1, também foi o modelo “wave” que melhor se ajustou aos dados, conforme pode ser verificado na Tabela 3.6 e 3.7. Os dados desses cenários apresentaram forte grau de dependência temporal, ou seja, os semivariogramas têm efeito pepita igual ou inferior a 25% do patamar (Figura 3.5).

Os dados de precipitação pluvial e temperatura do ar para a cidade de Juiz de Fora são candidatos naturais para ajuste do modelo “wave”, por serem periódicos. Entretanto, os semivariogramas obtidos pelo modelo “wave” não são restritos a apenas uma estrutura monotônica. Ele também pode apresentar segmentos cíclicos ou decrescentes, os quais são chamados de efeito buraco ou “holle effect” (Journel & Huijbregts, 1978 e Andriotti, 2004). Isso pode ser um dos principais motivos que determinaram melhor ajuste do modelo “wave” aos cenários A2, A1B e B1. Ignorar essas estruturas pode resultar em modelos não realísticos, os quais não reproduzem as variabilidades espaciais e temporais observadas.

Os resultados obtidos da análise do comportamento temporal da precipitação pluvial dos dados de previsão para os cenários futuros corroboram com aqueles apresentados por Carvalho et al. (2004), em sua pesquisa. Estes autores analisaram dados observados de precipitação na região Sudeste, no estado de São Paulo, no período de 1957 a 1997. Estes identificaram alguns episódios pluviais de caráter habitual e excepcional para caracterizar o regime das chuvas do estado, bem como o ritmo de sucessão de alguns estados cíclicos, com variações periódicas da chuva na região litorânea. Após definir as principais características do regime pluvial desta região e apresentar a distribuição das chuvas ao longo do período estudado, os autores concluíram que existe dependência espacial dos dados e que a periodicidade exibida pelos semivariogramas foi ajustada pelo modelo “wave”, assim como os dados de Juiz de Fora.

Nesta primeira fase, foram realizadas as análises pelo robusto, pois, pela análise descritiva, foi detectada a presença de alguns valores discrepantes. Porém, verificou-se que não havia necessidade de se utilizar o estimador robusto, tendo o estimador clássico fornecido melhores ajustes. Entretanto,

decidiu-se incluir esses dados discrepantes neste estudo e não tratá-los como “outliers”, por se tratar de valores que ocorreram no período de verão, quando é comum a ocorrência de chuvas intensas e altas temperaturas.

TABELA 3.6 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais clássico e robusto, relativo à temperatura do ar de Juiz de Fora, para o cenário A1B nos três períodos.

Cenário A1B P1						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	4,91	4,04	5,53	4,95	4,08	5,71
C_0	0,00	0,36	0,61	0,00	0,24	0,28
$C_0 + C_1$	4,94	4,58	4,29	4,87	4,65	4,59
AIC	-1686,71	-1686,50	-2036,61	-1341,65	-1342,79	-1587,17
DT	0,00%	7,86%	14,22%	0,00%	5,16%	6,10%
Cenário A1B P2						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	4,86	4,01	5,49	4,94	4,06	5,67
C_0	0,00	0,37	0,61	0,00	0,23	0,28
$C_0 + C_1$	4,72	4,35	4,07	4,64	4,41	4,36
AIC	-1702,70	-1700,91	-2015,85	-1372,46	-1373,31	-1611,54
DT	0,00%	8,50%	14,98%	0,00%	5,21%	6,42%
Cenário A1B P3						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	4,70	3,94	5,49	4,69	3,96	5,62
C_0	0,00	0,38	0,59	0,00	0,31	0,34
$C_0 + C_1$	4,15	3,77	3,53	4,08	3,78	3,75
AIC	-1807,91	-1803,10	-2143,10	-1534,06	-1531,48	-1712,78
DT	0,00%	10,07%	16,71%	0,00%	8,20%	9,06%

Obs: Cenário intermediário (A1B), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2098 (P3).

TABELA 3.7 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos esférico (Esf.), gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais clássico e robusto, relativos à temperatura do ar de Juiz de Fora, para o cenário futuro B1 nos três períodos.

Cenário B1 P1						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	4,94	4,04	5,58	4,93	4,04	5,67
C_0	0,00	0,34	0,60	0,00	0,18	0,23
$C_0 + C$	5,13	4,80	4,49	5,02	4,85	4,80
AIC	-1633,06	-1633,95	-1981,53	-1283,89	-1286,06	-1523,02
DT	0,00%	7,00%	13,36%	0,00%	3,71%	4,79%
Cenário B1 P2						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	4,86	4,01	5,53	4,80	4,01	5,71
C_0	0,00	0,33	0,57	0,00	0,26	0,29
$C_0 + C$	4,78	4,45	4,17	4,6213	4,37	4,35
AIC	-1662,55	-1662,17	-1985,97	-1317,57	-1317,07	-1535,36
DT	0,00%	7,41%	13,67%	0,00%	5,95%	6,67%
Cenário B1 P3						
	Estimador clássico			Estimador robusto		
	Esf.	Gaus	Wav	Esf.	Gaus	Wav
a	4,71	3,92	5,49	4,79	3,99	5,62
C_0	0,00	0,38	0,63	0,00	0,27	0,33
$C_0 + C$	4,54	4,16	3,88	4,42	4,16	4,09
AIC	-1730,86	-1727,42	-2049,41	-1486,20	-1485,41	-1731,07
DT	0,00%	9,13%	16,24%	0,00%	6,49%	8,06%

Obs: Cenário mais otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2098 (P3).

5.2 Análise Anisotrópica

Na segunda fase das análises, foi estudada a anisotropia para a variável precipitação pluvial e temperatura do ar, para os cenários futuros, no intuito de verificar a dependência temporal na direção 0° (meses) e 90° (anos).

Verificou-se, para a direção meses que a distância máxima é de,

aproximadamente, 6 meses, para as duas variáveis, precipitação pluvial e temperatura do ar, conforme pode ser visto nas Figuras 3.8 e 3.9 e na Tabela 3.8.

TABELA 3.8 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais na direção 0°, relativos à precipitação pluvial de Juiz de Fora, para os cenários A2, A1B e B1 nos períodos, P1, P2 e P3.

			a	C_0	$C_0 + C_1$	AIC	DT
A2	P1	Gaus	5,69	121,98	6348,57	2216,89	1,92%
		Wav	5,71	306,37	4754,52	2377,36	6,44%
	P2	Gaus	5,69	121,98	6348,57	2216,89	1,92%
		Wav	5,71	306,37	4754,52	2377,36	6,44%
	P3	Gaus	5,69	118,01	7519,35	2386,72	1,57%
		Wav	5,76	340,37	5629,14	2575,49	6,05%
A1B	P1	Gaus	5,60	80,27	6945,86	2233,09	1,15%
		Wav	5,71	312,00	5206,47	2486,52	5,99%
	P2	Gaus	5,58	0,09	7,57	2190,82	1,18%
		Wav	5,67	243,07	5685,95	2439,12	4,27%
	P3	Gaus	5,62	0,55	7366,32	2287,17	0,007%
		Wav	5,67	229,78	5522,92	2467,28	4,16%
B1	P1	Gaus	5,60	112,79	6849,71	2242,64	1,65%
		Wav	5,71	333,41	5135,28	2464,48	6,49%
	P2	Gaus	5,60	71,24	7215,05	2257,65	0,98%
		Wav	5,67	309,43	5409,56	2502,14	5,72%
	P3	Gaus	5,57	3,17	7421,60	2362,10	0,04%
		Wav	5,67	246,63	5571,87	2602,24	4,43%

Obs: Cenário pessimista (A2), intermediário (A1B) e otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2099 (P3).

Comparando-se os modelos gaussiano e “wave” na direção 0°, observaram-se pequenas diferenças nos resultados dos valores de AIC. Para a variável precipitação no cenário A2, A1B e B1, nos três períodos, o melhor ajuste foi para o modelo gaussiano com menor valor de AIC. Já para a temperatura, na direção 0°, observou-se melhor ajuste para o modelo “wave” com menor valor de AIC, em todos os cenários e em seus respectivos períodos (Tabela 3.9). A variável temperatura apresentou forte grau de dependência

temporal com alcance prático variando de 4,41 a 4,70 meses. Esse comportamento indicou que existe dependência temporal até essas distâncias (Figura 3.8).

TABELA 3.9 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais na direção 0°, relativos à temperatura do ar de Juiz de Fora, para os cenários, A2, A1B e B1 nos períodos, P1, P2 e P3.

			a	C_0	$C_0 + C_1$	AIC	DT
A2	P1	Gaus	4,74	0,00	10,86	-1489,29	0,00%
		Wav	4,77	0,00	8,80	-1737,79	0,00%
	P2	Gaus	4,56	0,00	9,81	-1500,75	0,00%
		Wav	4,63	0,00	8,07	-1755,62	0,00%
	P3	Gaus	4,20	0,00	8,14	-1624,06	0,00%
		Wav	4,41	0,00	6,90	-1927,88	0,00%
A1B	P1	Gaus	4,58	0,00	9,75	-1512,66	0,00%
		Wav	4,68	0,00	8,00	-1770,84	0,00%
	P2	Gaus	4,51	0,00	9,28	-1542,02	0,00%
		Wav	4,63	0,00	7,67	-1806,47	0,00%
	P3	Gaus	4,46	0,00	8,15	-1697,66	0,00%
		Wav	4,59	0,00	6,76	-1972,81	0,00%
B1	P1	Gaus	4,63	0,00	10,32	-1490,56	0,00%
		Wav	4,68	0,00	8,43	-1745,07	0,00%
	P2	Gaus	4,61	0,00	9,69	-1518,47	0,00%
		Wav	4,68	0,00	7,93	-1765,43	0,00%
	P3	Gaus	4,48	0,00	9,00	-1611,12	0,00%
		Wav	4,48	0,00	7,45	-1888,03	0,00%

Obs: Cenário pessimista (A2), intermediário (A1B) e otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2098 (P3).

Na direção 90° que corresponde a anos, verificou-se uma distância máxima de, aproximadamente, 30 anos, ou seja, próximo ao intervalo de tempo convencionalmente obtido pelas normais climatológicas (Brasil, 1992), conforme estabelecido pela Organização Meteorológica Mundial (OMM) (Cuadrat & Pita, 2004). Assim, o período de 30 anos também se aplicou bem para os dados de mudanças climáticas, cenários A2, A1B e B1, de acordo com a

dependência temporal observada nos semivariogramas “wave” anisotrópico a 90° (Figuras 3.6 e 3.7). Além disso, esses resultados estão de acordo com a definição de clima, que significa o conjunto de tendências resultantes de condições habituais durante um longo período de, no mínimo, 30 anos (Vianello & Alves, 1991; Cuadrat & Pita, 2004).

Para a precipitação pluvial, nos cenários A2 e A1B, direção 90°, verificou-se melhor ajuste do modelo gaussiano com menor valor de AIC, enquanto, para o cenário B1, nos períodos P1 e P2, observaram-se melhores resultados para o modelo “wave” e, no P3, melhor resultado para o modelo gaussiano (Tabela 3.10).

TABELA 3.10 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais na direção 90°, relativos à precipitação pluvial de Juiz de Fora, para os cenários futuros, A2, A1B e B1 nos três períodos.

			a	C_0	$C_0 + C_1$	AIC	DT
A2	P1	Gaus	21,59	360,13	3556,73	2781,38	10,12%
		Wav	23,67	496,7	2825,34	2849,73	17,58%
	P2	Gaus	20,39	312,73	3796,59	2849,17	8,24%
		Wav	22,77	473,15	3048,00	2870,28	15,52%
	P3	Gaus	19,41	332,29	3961,53	2983,01	8,38%
		Wav	22,09	524,55	3200,62	3016,41	14,16%
A1B	P1	Gaus	19,70	324,78	3703,19	2800,25	8,77%
		Wav	22,41	506,08	2978,68	2879,05	16,99%
	P2	Gaus	19,47	332,17	3943,35	2842,07	8,42%
		Wav	22,23	532,61	3173,85	2951,13	16,78%
	P3	Gaus	21,34	385,69	3987,49	2904,46	9,67%
		Wav	23,53	549,39	3168,45	3013,92	17,33%
B1	P1	Gaus	20,32	367,48	3703,41	2842,97	9,92%
		Wav	22,81	536,73	2965,96	2912,44	18,09%
	P2	Gaus	19,82	390,04	3797,99	2985,77	10,27%
		Wav	22,36	559,86	3064,66	2980,24	18,27%
	P3	Gaus	20,11	334,73	3975,29	2923,79	8,42%
		Wav	22,81	534,68	3176,15	3076,22	16,83%

Obs: Cenário pessimista (A2), intermediário (A1B) e otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2099 (P3).

O modelo escolhido para representar os dados de previsão de cenários futuros para a variável temperatura na direção de 90° foi o modelo “wave”. Este modelo, além de possuir o menor valor de AIC, possui forte grau de dependência temporal, conforme se observa na Tabela 3.11.

Considerando-se as direções 0° (Norte) e 90° (Leste) estudadas, observou-se dependência temporal ao longo dos meses e anos, para as variáveis, precipitação pluvial e temperatura do ar.

TABELA 3.11 - Estimativa dos parâmetros efeito pepita (C_0), patamar ($C_0 + C_1$), alcance (a), critério de Akaike (AIC) e grau de dependência temporal (DT) dos modelos gaussiano (Gaus) e “wave” (Wav) ajustados aos semivariogramas experimentais na direção 90°, relativos à temperatura do ar de Juiz de Fora, para os cenários futuros, A2, A1B e B1 nos períodos, P1, P2 e P3.

			a	C_0	$C_0 + C_1$	AIC	DT
A2	P1	Gaus	15,51	0,10	5,69	-2074,13	0,02%
		Wav	18,90	0,49	4,77	-2084,88	0,10%
	P2	Gaus	15,25	0,05	5,38	-2097,22	0,00%
		Wav	18,72	0,44	4,52	-2125,54	0,09%
	P3	Gaus	15,25	0,05	5,38	-2173,14	0,00%
		Wav	20,20	0,58	4,32	-2263,99	0,13%
A1B	P1	Gaus	15,22	0,09	5,28	-2144,09	0,01%
		Wav	18,63	0,46	4,44	-2169,45	0,10%
	P2	Gaus	15,43	0,10	5,10	-2115,49	0,01%
		Wav	18,85	0,44	4,30	-2262,35	0,10%
	P3	Gaus	14,68	0,13	4,29	-2273,33	0,03%
		Wav	18,09	0,43	3,65	-2417,81	0,11%
B1	P1	Gaus	15,14	0,06	5,43	-2062,21	0,01%
		Wav	18,45	0,42	4,59	-2201,49	0,09%
	P2	Gaus	15,08	0,06	5,06	-2075,98	0,01%
		Wav	18,45	0,39	4,30	-2265,38	0,09%
	P3	Gaus	14,94	0,13	4,76	-2235,36	0,02%
		Wav	18,40	0,47	4,03	-2343,14	0,11%

Obs: Cenário pessimista (A2), intermediário (A1B) e otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2098 (P3).

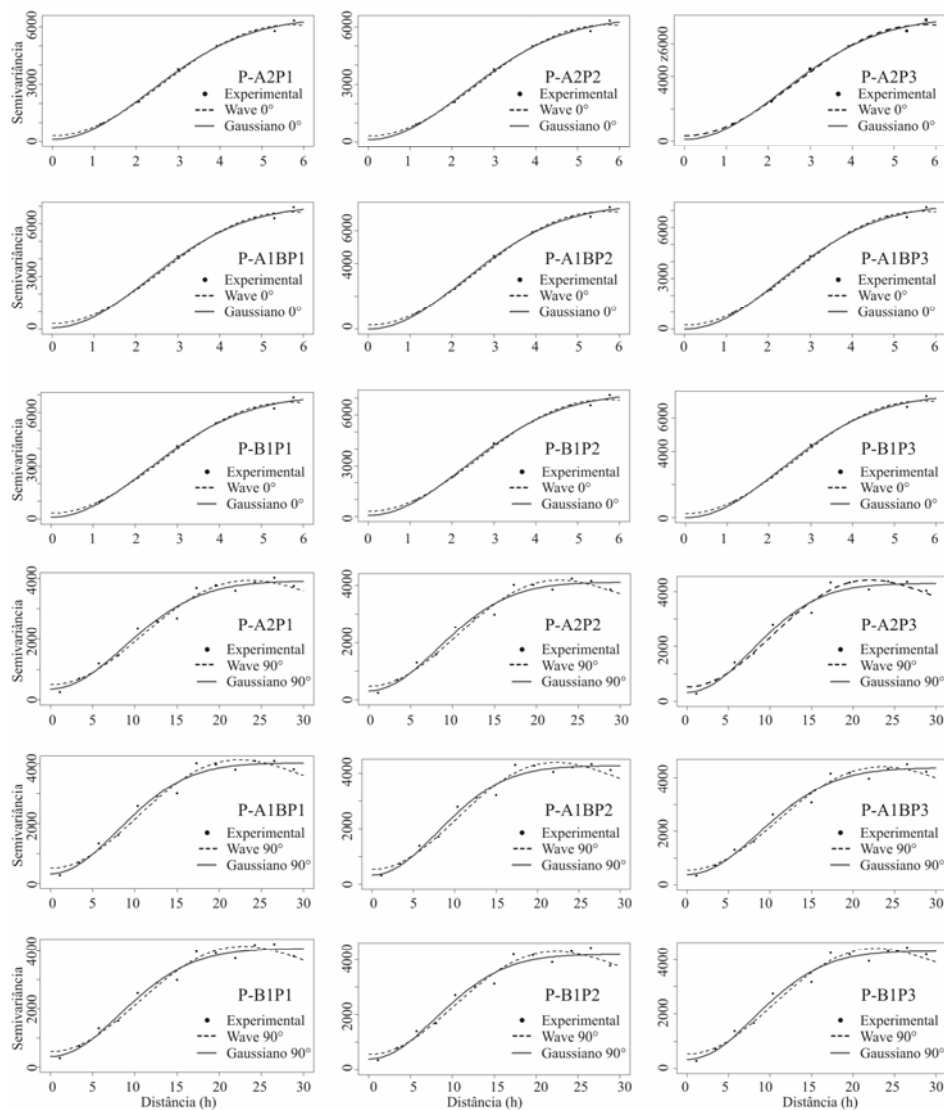


FIGURA 3.6 Semivariogramas experimentais e teóricos, pelo estimador clássico, com ajuste dos modelos “wave” e gaussiano, para precipitação pluvial referente ao cenário A2, A1B e B1, nos período P1, P2 e P3, nas direções 0° e 90°.

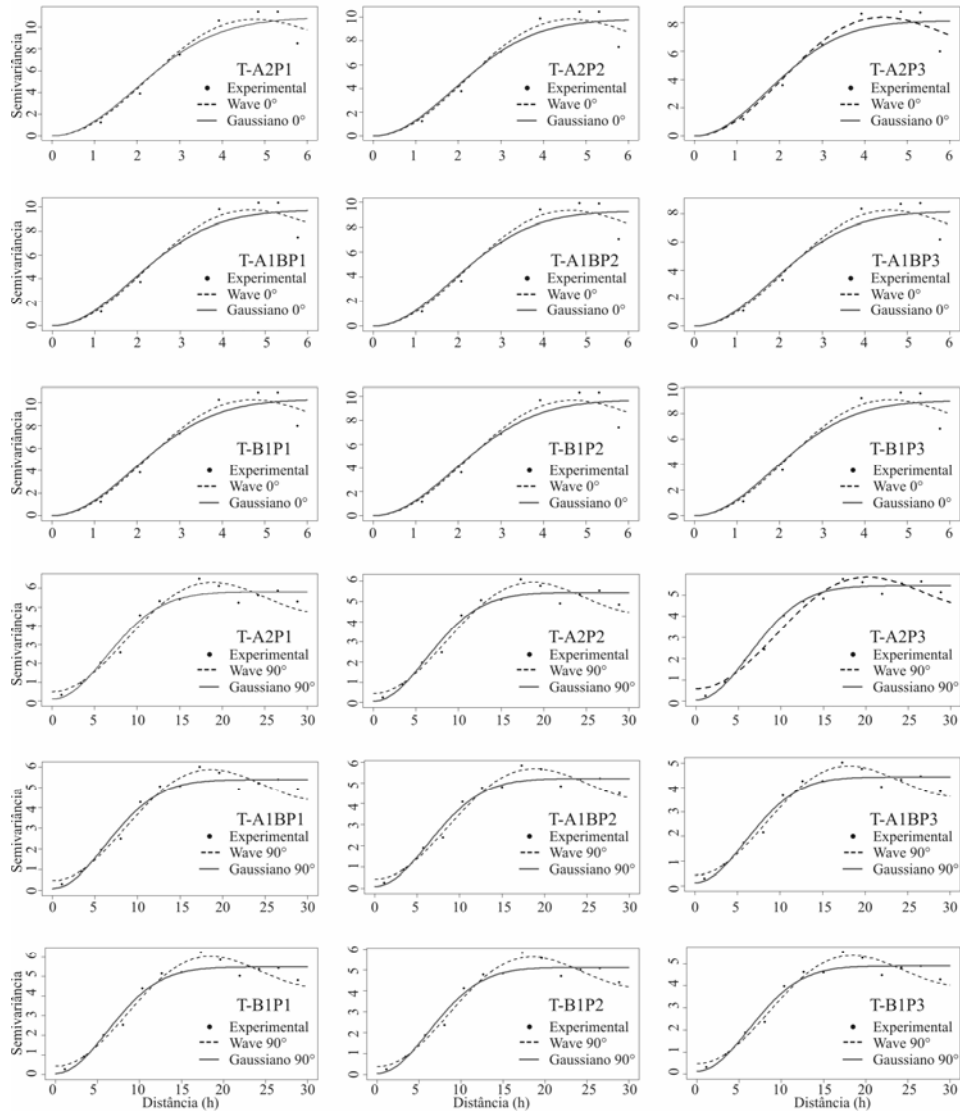


FIGURA 3.7 Semivariogramas experimentais e teóricos, pelo estimador clássico, com ajuste dos modelos “wave” e gaussiano para temperatura do ar referente ao cenário A2, A1B e B1, nos períodos P1, P2 e P3, nas direções 0° e 90°.

5.3 Análise da interpolação geoestatística

Nos mapas de krigagem isotrópicos para os cenários futuros de mudanças climáticas, apresentados na Figura 3.8, pode ser verificada a variabilidade temporal da precipitação pluvial e da temperatura do ar, em que são visíveis os principais padrões da variável, caracterizados por áreas de maior e menor concentração das chuvas e as áreas com altas e baixas temperaturas.

Com base nos mapas de krigagem da precipitação e da temperatura, observou-se tendência de menores índices de precipitação concentrados nos meses de maio a setembro, com temperaturas mais baixas. Já os índices mais elevados de precipitação se concentraram nos meses de outubro a abril, com temperaturas mais altas. Isso ocorre de acordo com o padrão climático local, pois os dados de precipitação e de temperatura avaliados são referentes a uma região geográfica com o período seco e chuvoso bem definido, conforme relatado por Marengo et al. (2007). No período chuvoso, a precipitação apresentou valores máximos próximos a 250 mm/mês; (Figura 3.8) já no período seco, o índice pluvial apresentou valores mínimos próximos de zero, para os três cenários isotrópicos.

Para o cenário A2 (Figura 3.8), a precipitação apresentou valores máximos próximos de 240 mm, durante o P1, com temperaturas de, aproximadamente, 26°C. No período seco, o índice pluvial apresentou valores próximos de 10 mm, com temperaturas baixas em torno de 17°C. Com relação à precipitação, os resultados do P2 não variaram muito quando comparados aos resultados do P1, enquanto para temperatura, de 2033 a 2055, houve valores de 17°C e, a partir daí, até 2066, houve um aumento que varia de 17°C a 18°C; já para o P3, verificaram-se, pelo mapa, mudanças nos padrões da precipitação e, para temperatura, um aumento que vai de, aproximadamente, 17°C até o ano de 2080, para 18°C e 20°C até 2098, no período seco.

Para o cenário A1B intermediário (Figura 3.8), a variável temperatura apresentou algumas mudanças em seus períodos, com aumento variando de 17°C a 21°C, no período seco, considerado mais frio. Para o período chuvoso, verificou-se verão mais quente, com precipitações entre 220 a 240 mm, nos três períodos, com mínimas, nos meses de maio a setembro, de 10 a 30 mm, aproximadamente.

No cenário B1 (Figura 3.8), as mudanças na temperatura e nos padrões de precipitação foram menores quando comparadas a dos outros dois cenários. Isso já era esperado, pois esse cenário é o mais otimista quanto às simulações futuras, dando ênfase a soluções globais para a economia e para a sustentabilidade ambiental e social. A temperatura nos períodos secos variou de 17°C a 19°C, com precipitação mínima de 10 a 30 mm e, no verão, a temperatura não variou muito, situando-se na faixa de 25°C a 26°C, entre os três períodos (P1, P2 e P3). Para a precipitação, os valores foram de, aproximadamente, 230 mm.

De acordo com os resultados obtidos pela validação cruzada, apresentados na Tabela 3.12, para as duas variáveis, verificou-se que o modelo “wave” isotrópico foi adequado para representar o padrão temporal analisado, bem como para representar esse padrão pelos mapas de contorno. Isso pode ser explicado pelos resultados dos EM e RQME, os quais, segundo Cressie (1993), devem ser próximos de zero e 1, respectivamente.

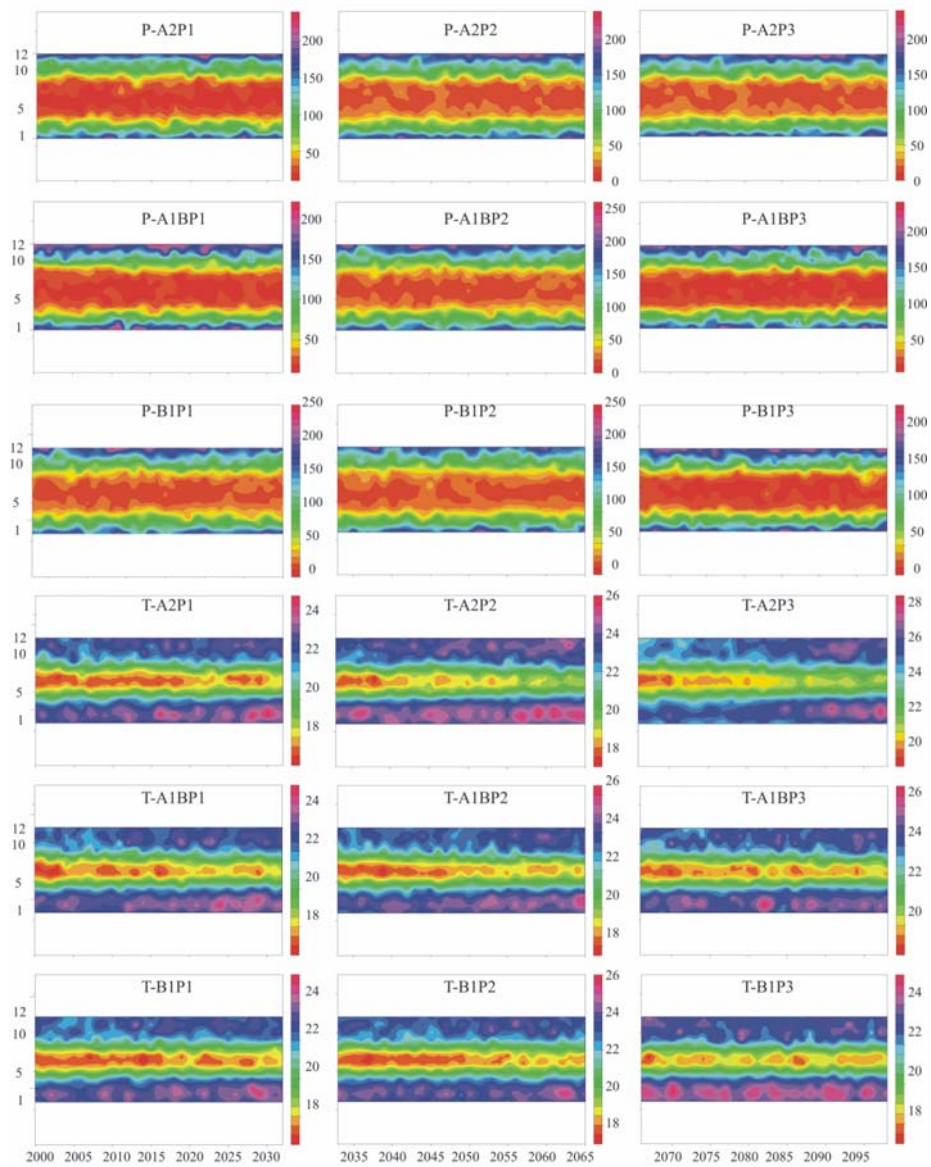


FIGURA 3.8 Mapas de krigagem da precipitação pluvial (P) e da temperatura (T), com ajuste do modelo “wave” isotrópico para o cenário A2, A1B e B1, nos períodos P1, P2 e P3.

TABELA 3.12 Erro médio (EM) e razão do quadrado médio do erro (RQME) para a krigagem ordinária (KO), utilizando-se o modelo “wave”, ajustado aos semivariogramas experimentais isotrópicos, referentes à precipitação pluvial (mm) e à temperatura (°C) de Juiz de Fora, para os cenários futuros A2, A1B e B1, nos períodos, P1, P2 e P3.

		Precipitação (mm)		Temperatura (°C)	
		EM	RQME	EM	RQME
A2	P1	0,254	0,817	0,000	0,589
	P2	0,233	0,658	0,000	0,569
	P3	0,226	0,648	0,000	0,680
A1B	P1	0,228	0,800	0,002	0,702
	P2	0,228	0,678	0,002	0,716
	P3	0,207	0,792	0,002	0,746
B1	P1	0,223	0,819	0,002	0,722
	P2	0,240	0,875	0,002	0,722
	P3	0,203	0,798	0,003	0,761

Obs: Cenário pessimista (A2), intermediário (A1B) e otimista (B1), nos períodos de 2000 a 2032 (P1), 2033 a 2065 (P2) e 2066 a 2099 (P3).

Os modelos “wave” isotrópicos apresentaram coeficientes de erros satisfatórios para caracterizar a variabilidade temporal da precipitação pluvial e da temperatura média do ar de Juiz de Fora, nos cenários de mudanças climáticas avaliados.

Com os resultados dos mapas de krigagem foi possível observar uma aparente regularidade climática para os cenários futuros do IPCC, ou seja, com distribuição interanual das chuvas em sucessão de anos de verões úmidos de outubro a março e invernos secos de abril a setembro. Sant’ Anna Neto (2005), ao estudar os dados observados no período de 1969 a 2005, de Presidente Prudente, SP, também verificou tendência de períodos mais secos entre maio a setembro, com irregularidades pluviométricas entre junho e agosto. O mesmo autor, estudando a temperatura nesse período, verificou mais regularidade para essa variável, ainda que, em alguns anos, os invernos e verões sejam mais rigorosos.

De forma geral, com o uso do interpolador geoestatístico (krigagem ordinária), construíram-se mapas de contorno para os cenários futuros de mudanças climáticas, por meio do arranjo proposto em meses e anos. Com isso, verificaram-se possíveis alterações climáticas em Juiz de Fora, ao longo dos próximos 99 anos, no tocante aos padrões de precipitação e de temperatura do ar no período estudado. Assim, tornou-se evidente que a krigagem pode ser utilizada para avaliar séries temporais em trabalhos com variáveis climáticas, conforme os resultados obtidos por meio da validação cruzada.

Goovaerts (1999) comparou a krigagem com os métodos de interpolação de polinômio de Thiessen e do inverso do quadrado a distância, para estudar a precipitação pluvial de Portugal, observando melhor performance da krigagem. Carvalho & Assad (2005) também verificaram melhores resultados para a krigagem, quando comparada a outros métodos, confirmando-se a grande vantagem do uso de um interpolador exato e preciso para estudo sobre a distribuição de precipitação pluvial anual do estado de São Paulo.

Vários pesquisadores levantaram a hipótese de que as mudanças climáticas que vêm ocorrendo ou que ocorrerão no futuro podem ser devido às atividades antrópicas (Marengo et al., 2007). Verifica-se que o homem pode e vem influenciando o clima, sobretudo com o aumento populacional e o desenvolvimento tecnológico, que ocasionam transformações no espaço. Este fato foi observado por Martins (1996), ao verificar que a intensa urbanização produziu microclimas diferenciados dentro do próprio perímetro urbano de Juiz de Fora, originando “ilhas de calor”, responsáveis por temperaturas mais elevadas na área central da cidade, além de índices pluviométricos quantitativamente maiores. Segundo Sant’ Anna Neto (2005), em estudos realizados em escala local, utilizados para avaliar possíveis alterações climáticas, verificaram-se, para os grandes centros urbanos, elevação da temperatura entre 2°C e 3°C nas últimas três décadas e, com relação à precipitação, houve aumento de cerca de 12%, no

período de 1971 a 2000, com episódios adversos que comprometem a integridade urbana. Já Steinke et al. (2005), estudando o clima do Distrito Federal em escala local, observaram que não houve tendências de mudanças climáticas nos dados, uma vez que, nos resultados, não se observou variação relevante, embora os autores admitam que, nos últimos 15 anos, houve um aumento na expansão urbana e que esse crescimento interferiu na vegetação e nos recursos hídricos.

Apesar dos resultados observados para a precipitação e para a temperatura nos cenários analisados, caracterizando situações ora pessimistas, ora otimistas, as projeções de mudanças climáticas derivadas dos modelos globais do IPCC – AR3 não são conclusivas e as incertezas ainda são grandes, de acordo com os modelos e regiões consideradas (IPCC, 2001). Além disso, as alterações climáticas são numerosas e podem ocorrer de forma variada em diferentes escalas de tempo e espaço, principalmente em escalas locais (Steinke et al., 2005). Apesar disso, a constante atualização dos cenários pelo IPCC (IPCC, 2007) sugerem aumento da confiança das previsões, à medida que novos dados observados são incorporados na análise dos modelos.

Observou-se, com os resultados obtidos pela krigagem, que este fato pode ser amplamente demonstrado com base em dados de previsão de cenários futuros do IPCC localizados no interior da divisão política do município de Juiz de Fora, de acordo com o arranjo proposto no presente estudo.

6 CONCLUSÕES

Com o modelo teórico “wave”, observou-se ajuste satisfatório para caracterizar os dados de precipitação pluvial e de temperatura do ar, tanto para o estimador de semivariograma experimental clássico quanto para o robusto, tendo, com o estimador clássico, sido obtidos melhores ajustes.

Foi possível caracterizar a estrutura e a magnitude de dependência temporal das variáveis, precipitação pluvial e temperatura, na direção de meses e anos, de acordo com o arranjo proposto para os cenários futuros de mudanças climáticas.

Com o uso da metodologia de análise geoestatística, foi possível verificar que o mapeamento da precipitação pluvial e da temperatura de Juiz de Fora, MG, utilizando-se a krigagem ordinária foi uma forma eficiente de visualizar o comportamento dessas variáveis ao longo do tempo.

Foi possível verificar, para os cenários A2, A1B e B1, possíveis mudanças nos padrões de precipitação pluvial e temperatura para os dados de previsão de mudanças climáticas, com maior alteração para o cenário mais pessimista (A2).

Observou-se, de forma geral, variabilidade temporal da precipitação pluvial e da temperatura média do ar com padrões distintos nos períodos seco e chuvoso dos anos avaliados.

7 CONSIDERAÇÕES FINAIS

Os resultados alcançados neste estudo foram satisfatórios e motivam futuras pesquisas envolvendo, também, outras variáveis climáticas e técnicas de interpolação geoestatística, como a co-krigagem, utilizando a altitude como variável co-localizada o que, certamente, trará um refinamento na acurácia das previsões.

O estudo das mudanças climáticas globais deve ser analisado de forma interdisciplinar em função da própria natureza do sistema climático, a fim de se determinar estratégias de mitigação e adaptação eficazes para enfrentar as mudanças adversas do clima. A vulnerabilidade e a adaptação devem ser tratadas de forma a considerar o desenvolvimento de novos modelos que considerem as necessidades dos países em desenvolvimento, bem como o fortalecimento das instituições desses países, no intuito de minimizar os impactos negativos das mudanças climáticas.

O desenvolvimento de métodos aplicáveis aos cenários de mudanças do clima sob escala regional, em estudos futuros, pode ser útil para avaliar os impactos das mudanças climáticas em áreas como gerenciamento de recursos hídricos, ecossistemas, atividades agrícolas e propagação de doenças, a fim de proporcionar melhoria substancial da avaliação da vulnerabilidade do Brasil a mudanças climáticas e de sua capacidade de adaptação.

8 REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, G. F.; GONZAGA, F. A. S.; GUIMARÃES, E. C.; TAVARES, M. Comportamento da precipitação mensal de Uberlândia: Análise da dependência temporal. In: ENCONTRO INTERNO DE INICIAÇÃO CIENTÍFICA, 5., 2005, Uberlândia. **Anais...** Uberlândia: PROPP/UFU, 2005. v. 1, p. 1-10. 1 CD-ROM.

AGÊNCIA NACIONAL DAS ÁGUAS. **Sistemas Hidrológicas:** Sistemas de informações hidrológicas – hidroweb. Disponível em: <<http://www.ana.gov.br>>. Acesso em: jul. 2007.

ANDRIOTTI, J. L. S. **Fundamentos da Estatística e Geoestatística.** São Leopoldo: Unisinos, 2004. 165 p.

BRASIL. Ministério da Agricultura e Reforma Agrária. Secretaria Nacional de Irrigação. Departamento Nacional de Meteorologia. **Normais climatológicas:** (1961-1990). Brasília, 1992. 84 p.

CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURCO, R. F.; KONOPKA, A. E. Fieldscale variability of soil properties in Central Iowa soils. **Soil Science Society of America Journal**, Madison, v. 58, n. 5, p. 1501-1511. Sept./Oct. 1994.

CARTER, T. R.; ROVERE, E. L. L.; JONES, R. N.; LEEMANS, R.; MEARNES, L. O.; NAKICENOVIC, N.; PITTOCK, A. B.; SEMENOV, S. M.; SKEA, J. Developing and Applying Scenarios. In: MCCARTHY, J. J.; CANZIANI, O. F.; LEARY, N. A.; DOKKEN, D. J.; WHITE, K. S. (Ed.). **Climate change 2001: impacts, adaptation, and vulnerability.** Contribution of Working Group II to the Third Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University, 2001. p. 147-190.

CARVALHO, J. R. P. de; VIEIRA, S. R.; VENDRUSCULO, L. G. **Uso da técnica de mínimos quadrados ponderados para ajuste de modelos ao semivariograma,** Campinas: Embrapa Informática Agropecuária, 2004. 15 p. (Boletim de Pesquisa e Desenvolvimento / Embrapa Informática Agropecuária;11).

CARVALHO, J. R. P.; ASSAD, E. D. Análise Espacial da precipitação pluviométrica no Estado de São Paulo: comparação de métodos de interpolação. **Engenharia Agrícola**, Jaboticabal, v. 25, n. 2, p. 377-384, maio/ago. 2005.

CUADRAT, J. M.; PITA, M. F. **Climatologia**. Lisboa: Cátedra, 2004. 496 p.

CUBASCH, U.; MEEHL, G. A.; BOER, G. J.; STOUFFER, R. J.; DIX, M.; NODA, A.; SENIOR, C. A.; RAPER, S.; YAP, K. S. The Climate System: an Overview. In: HOUGHTON, J. T.; DING, Y.; GRIGGS, D. J.; NOGUER, M.; VAN DER LINDEN, P. J.; DAI, X.; MASKELL, K.; JOHNSON, C. A. (Ed.). **Climate change 2001: projections of future climate change**. Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University, 2001. p. 87-98.

CHILÈS, J. P.; DELFINER, P. **Geostatistics: modeling spatial uncertainty** wiley series in probability and statistics applied probability and statistics. New York: John Wiley & Sons, 1999. 695 p.

GOOVAERTS, P. **Geostatistics for natural resources evaluation**. New York: Oxford University, 1997. 512 p.

GOOVAERTS, P. Performance comparison of geostatistical algorithms for incorporating elevation into the mapping of precipitation. In: International Conference on GeoComputation, 4., 1999, Fredericksburg, VA. p.1-18. Disponível em: <http://www.geovista.psu.edu/sites/geocomp99/Gc99/023/gc_023.htm>. Acesso em: dez. 2007.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE - IPCC. In: CLIMATE Change 2007: the PHYSICAL Science Basis, Summary for policy Makers. Geneva, 2007.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. In: HOUGHTON, J. T.; DING, Y.; GRIGGS, D. J.; NOGUER, N.; VAN DER LINDEN, P. J.; XIAOSU, D.; MASKELL, K.; JOHNSON, C. A. (Ed.). **Climate Change 2001: the scientific basis**. Cambridge: Cambridge University Press, 2001.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied geostatistics**. New York: Oxford University Press, 1989. 561 p.

JOURNEL, A. G.; HUIJBREGTS, CH. J. **Mining geostatistics**. London: Academic, 1991. 600 p.

MARENGO, J. A.; ALVES, L. M.; CASTRO, C. A. C.; MENDES, D. Início da estação chuvosa nas Regiões Sudeste, Centro-Oeste e sul do Nordeste do Brasil, afetadas pela crise de energia. Disponível em: <<http://www.cptec.inpe.br/energia/saiba/iniciochuvas.shtml>>. Acesso em: junho de 2007.

MARTINS, L. A. **A temperatura do ar em Juiz de Fora – MG: Influência do Sítio e da Estrutura Urbana**. 1996, 168p, Dissertação (Mestrado em Geografia) Departamento de Geografia, Instituto de Geociências e Ciências Exatas/UNESP – Rio Claro.

MATHERON, G. **Principles of geostatistics**. Economic. Geology, Lancaster, v. 58. p.1246-1266, dez. 1963.

MENDONÇA, F.; OLIVEIRA, I. M. D, **Climatologia noções básicas e climas do Brasil**, São Paulo–SP, 2007, 206 p.

NAKICENOVIC, N.; ALCAMO, J.; DAVIS, G. VRIES, B. de; FENHANN, J.; GAFFIN, S.; GREGORY, K.; GRÜBLER, A.; JUNG, T. Y.; KRAM, T.; LA ROVERE, E. L.; MICHAELIS, L.; MORI, V.; MORITA, T.; PEPPER, W. ; PITCHER, H.; PRICE, L.; RAIHI, K.; ROEHL, A.; ROGNER, H. -H.; SANKOVSKI, A.; SCHLESINGER, M.; SHUKLA, P.; SMITH, S.; SWART, R.; VAN ROOIJEN, S.; VICTOR, N.; DADI, Z. **Emissions scenarios**. A Special Report of Working Group III of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press ; Cambridge : United Kingdom and New York, 2000. 599 p.

NATIONAL CENTER FOR ATMOSPHERIC RESEARCH. **Geographic Information System (Gis) Initiative**. Boulder, Co: NCAR/UCAR/NSF, 2007. Disponível em: <<http://www.gis.ncar.edu>>. Acesso em: out. 2007.

PONTES, J. M. **A Geoestatística: aplicações em experimentação de campo**. 2002. 82 p. Dissertação (Mestrado em Agronomia/Estatística e Experimentação Agropecuária) – Universidade Federal de Lavras, Lavras.

R DEVELOPMENT CORE TEAM. **R: a language and environment for statistical computing**. Viena: R Foundation for Statistical Computing, 2007. Disponível em: <<http://www.R-project.org>>.

RIBEIRO, JÚNIOR, P. J.; DIGGLE, P. J. GeoR: a package for geostatistical analysis. **R-NEWS**, v. 1, n. 2, p. 15-18, june. 2001.

SANT' ANNA NETO, J. L. Decálogo da climatologia do Sudeste Brasileiro. **Revista Brasileira de Climatologia**. Presidente Prudente. v. 1, n. 1. p. 43-60, dez. 2005.

SILVA, A. S. da, **Modelos geoestatísticos espaços-temporais e aplicações**. 2006. 69 p. Dissertação (Mestrado em Agronomia – área de concentração: Estatística e Experimentação Agronômica). Escola Superior de Agricultura 'Luiz de Queiroz', Piracicaba.

STEINKE, E. T.; SOUZA, G. de, A.; SAITO, C. H. Análise da variabilidade da temperatura do ar e da precipitação no Distrito Federal no período de 1965/2003 e sua relação com uma possível alteração climática. **Revista Brasileira de Climatologia**. Presidente Prudente. v. 1, n. 1. p. 131-145, dez. 2005.

THIESSEN, A. H., Precipitation Average for Large Areas, **Monthly Weather**, v. 39, p. 1082-1084. 1911.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. Viçosa: Imprensa Universitária/UFV, 1991. 449 p.

WEBSTER, R.; OLIVER, M. A. **Geostatistics for Environmental Scientists**. New York: J.Wiley, 2001. 271p.