



ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: www.ufpe.br/rbgfe



O Uso da Geoestatística Espaço-Temporal na Predição da Temperatura Máxima do Ar

Rosane Soares Moreira Viana¹, Gérson Rodrigues dos Santos², Demerval Soares Moreira³,
João Marcos Louzada⁴, Lidiane Maria Ferraz Rosa⁵

¹Doutoranda em Estatística Aplicada e Biometria, Universidade Federal de Viçosa (UFV), Viçosa – MG. E-mail: rsmviana21@gmail.com (autor correspondente); ²Professor-Doutor, Departamento de Estatística, Universidade Federal de Viçosa (UFV), Viçosa – MG. E-mail: gerson.santos@ufv.br; ³Professor-Doutor, Departamento de Física, Universidade Estadual Paulista (Unesp), Faculdade de Ciências, Bauru – SP. E-mail: demerval.moreira@unesp.br; ⁴Professor-Doutor, Instituto Federal do Espírito Santos (IFES, Itapina – ES. E-mail: louzada.geostat@gmail.com; ⁵Professora-Doutora, Colégio de Aplicação/COLUNI, Universidade Federal de Viçosa (UFV), Viçosa – MG. Email: lidianeferraz@gmail.com.

Artigo submetido em 17/05/2018 e aceite em 14/12/2018

RESUMO

Processos estocásticos de natureza espaço-temporais consistem de fenômenos que são caracterizados por meio da variabilidade espacial e temporal. Atualmente, é uma das áreas de maior crescimento com diversas aplicações em ciências ambientais, geográficas, biológicas, epidemiológicas, entre outras. Certamente, os métodos da estatística convencional não são adequados para modelar estruturas autocorrelacionadas no espaço e no tempo. De fato, ainda há grandes desafios no tange à implementação computacional da metodologia geoestatística para análise de processos espaços-temporais, com destaque para o pacote *spacetime* do programa R, utilizado neste estudo. Assim, este trabalho tem como objetivo aplicar a metodologia geoestatística espaço-temporal de funções de covariância a fim de inferir acerca da temperatura máxima do ar do Estado de Minas Gerais de 1996 a 2016, visando contribuir com desafios, tais como aquecimento global, urbanização descontrolada, escassez de recursos naturais, epidemias e catástrofes naturais. Utilizando os dados de 61 estações meteorológicas foi realizada a análise geoestatística espaço-temporal, no qual o modelo de covariância somamétrico foi o mais adequado, considerando-se o critério do Erro Quadrático Médio. Dessa forma, foi possível elaborar mapas de predições das temperaturas máximas do ar no estado de Minas Gerais por meio da krigagem ordinária, assumindo-se estacionariedade de primeira ordem do processo estocástico avaliado. Pode-se observar que os modelos da geoestatística espaço-temporal mostraram ser eficientes nos estudos espaço-temporais das temperaturas máximas do ar. Palavras-chave: Modelagem de Dados Espaço-Temporal, Covariância, variograma, Krigagem Ordinária.

The Use of Space-Temporal Geostatistics in the Prediction of Maximum Air Temperature

ABSTRACT

Stochastic processes of spatio-temporal nature consist of phenomenons that are characterized by spatial and temporal variability. Currently, it is one of the great growing areas with diverse applications in environmental, geographic, biological, epidemiological sciences, among others. Certainly, conventional statistical methods are not adequate to modeling self-correlated structures in space and time. In fact, there are still major challenges regarding the computational implementation of the geostatistical methodology for the analysis of space-time processes, with emphasis on the *spacetime* package of the R program used in this study. Thus, this work aims to apply the geostatistical methodology of covariance functions in order to infer about the maximum air temperature of the State of Minas Gerais from 1996 to 2016, aiming to contribute with challenges such as heating uncontrolled urbanization, scarcity of natural resources, epidemics and natural disasters. Using the data from 61 meteorological stations, the geostatistical space-time analysis was performed, in which the sum-metric covariance model was the most adequate, considering the criterion of the Mean Squared Error. Thus, it was possible to prepare maps of predictions of maximum air temperatures in the state of Minas Gerais through of ordinary kriging, assuming first order stationarity of the evaluated stochastic process. It can be observed

that the models of space-time geostatistics have shown to be efficient in the space-time studies of maximum air temperatures.

Keywords: Spatial-temporal Data Modeling, Covariance, Variogram, Ordinary Kriging.

Introdução

Dados espaço-temporais são observações tomadas em diferentes localizações no espaço e, para cada localização, em diferentes tempos. Existem três formas distintas de análise de processos espaço-temporais: análise espacial para cada tempo; análise temporal para cada ponto no espaço; e análise espacial e temporal conjunta. As duas primeiras possibilidades isolam a parte espacial ou a parte temporal e aplicam-se as técnicas padrões para o tipo de processo resultante. A terceira possibilidade considera as variações espaciais e temporais conjuntamente.

Na literatura pode-se citar trabalhos recentes para o estudo e análise de dados espaço-temporais tais como, Reboita et al. (2015), Raja et al. (2017), Moreira et al. (2017) e Varouchakis (2018).

Nos últimos anos essa área teve um grande crescimento científico, acompanhado de uma diversificação das temáticas abordadas, com diversas aplicações práticas em uma ampla variedade de ramos da ciência, tais como, climatologia, meteorologia, agricultura ou qualquer outra área preocupada com o estudo de fenômenos que ocorrem tanto no espaço quanto no tempo.

Em Climatologia, segundo o quinto relatório do *Intergovernmental Panel on Climate Change* (IPCC, 2014) uma elevação na temperatura média do planeta poderá causar consequências devastadoras para o nosso planeta Terra e conseqüentemente, para os seres vivos, incluindo animais e vegetais. Entre essas consequências, pode-se citar: derretimento de grande parte das calotas polares; elevação do nível médio do mar; submersão de ilhas oceânicas e ameaça de desaparecimento de cidades litorâneas que atualmente estão em níveis próximos ao nível médio do mar; e, aumento de eventos extremos, tais como tornados, furacões, tempestades severas e secas prolongadas, incluindo desertificação de algumas regiões. É de consenso da grande maioria dos pesquisadores que o efeito estufa é o principal fator que tem contribuído para o aquecimento global que já vem sendo observado nas últimas décadas.

O estudo da variável temperatura do ar é de suma importância para a comunidade científica

poder quantificar o efeito estufa causado principalmente por atividades antrópicas.

A temperatura do ar atmosférico é uma variável meteorológica que possui grande dependência temporal devido principalmente aos movimentos de rotação e translação da terra, fazendo com que a energia recebida pela Terra varie durante o dia e o ano, respectivamente. A temperatura também possui variações espaciais, dependendo, por exemplo, dos movimentos das massas de ar e de variações na superfície, como cobertura do solo, albedo, altitude e umidade.

Devido ao grande custo de instalação e manutenção de estações meteorológicas, elas são bem escassas, principalmente em regiões de difícil acesso como oceanos e florestas. Normalmente, são instaladas em locais mais acessíveis, mas não equidistantes, principalmente as convencionais que necessitam de observadores para coletar os dados regularmente (Figura 1). Portanto, na maioria das vezes é necessário utilizar métodos matemáticos para estimar os valores de temperatura nos pontos de uma grade regular. Também é comum observar falhas na série de dados, devido à falta da observação ou a problemas no instrumento ou na transmissão e armazenamento dos dados. Desta forma, em muitas situações é comum o emprego de métodos para deixar a série sem falhas tanto espacial quanto temporal.

Na literatura são encontrados diversos estudos com abordagens distintas para estimar as temperaturas do ar, em diferentes estados e regiões brasileiras (Gomes et al., 2014; Garcia e Andre, 2015; Medeiros et al., 2015). Esses estudos, embora trabalharam com dados espaço-temporais, não exploram a interação entre os componentes espaciais e temporais conjuntamente.

A geoestatística espaço-temporal, via modelagem da estrutura de covariância, é um dos procedimentos para análise de dados espaço-temporais que leva em consideração as interações existentes entre os componentes espaciais e temporais e permite interpolações no tempo e no espaço.

Assim, o objetivo deste trabalho é o de aplicar a metodologia geoestatística espaço-temporal de funções de covariância com a finalidade de inferir acerca da temperatura máxima do ar do estado de Minas Gerais, visando contribuir com desafios tais como, aquecimento global,

urbanização descontrolada, escassez de recursos naturais, epidemias e catástrofes naturais.

Material e métodos

A região de estudo é o Estado de Minas Gerais (MG), localizado na região sudeste do Brasil, com área de 586.520,732 km². A região de trabalho é delimitada pelas latitudes 14°13'58" S e 22°54'00" S e longitude 39°51'32" W e 51°02'35" W.

O estado de MG é subdividido em 853 municípios com distância linear entre os pontos extremos de 986 km no sentido norte-sul e, de 1248 km, no leste-oeste (MG.GOV.BR, 2017). Abrange os fusos 22, 23 e 24. Adotou-se o fuso 23 como principal e as coordenadas do fuso 22 e 24 foram projetadas para o fuso 23, permitindo juntar todas as estações utilizadas em um plano único. Assim, as coordenadas geográficas, em graus decimais, foram convertidas para metros usando a projeção de coordenadas UTM (Universal Transversa de Mercator), Zona 23 Sul, Datum WGS84.

O conjunto de dados foi obtido do Banco de Dados Meteorológicos para Ensino e Pesquisa do Instituto Nacional de Meteorologia (INMET, 2018). Foram registros de 61 estações meteorológicas convencionais de observações de superfícies que se encontram distribuídas nas regiões ou estados circunvizinhos a MG. Nota-se na Figura 1 que a distribuição espacial das estações é bastante irregular. Esta figura foi gerada pelo aplicativo Grid Analysis and Display System (GrADS: Doty e Kinter, 1993) e a topografia, com resolução de 5 km, foi proveniente do United States Geological Surveys (USGS) vinculado ao Earth Resources Observation Systems (EROS) (Gesch et al., 1999).

A variável em estudo é a temperatura máxima diária do ar. Cada estação está associada a uma série temporal de 7671 tempos distintos representando os dias entre janeiro de 1996 a dezembro de 2016. No entanto, existem algumas falhas ao longo da série.

Para execução das análises descritivas e geoestatística foi utilizado o software livre R versão 3.5.0 (Team, 2018) com os pacotes *gstat* (Pebesma e Graeler, 2018), *sp* (Pebesma e Bivand, 2005), *spacetime* (Pebesma, 2018), *geoR* (Ribeiro e Diggle, 2016), *lattice* (Sarkar, 2017), *xts* (Ryan e Ulrich, 2018), *maptools* (Bivand e Lewin-Koh, 2017) e *rgdal* (Bivand et al., 2018), que são essenciais para se trabalhar com a geoestatística espaço-temporal.

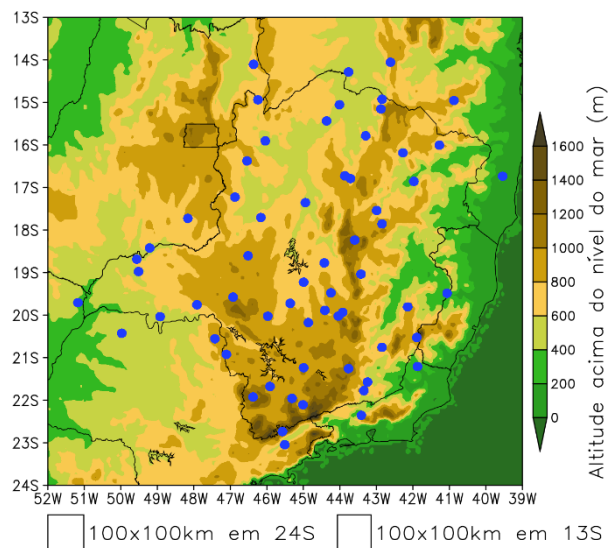


Figura 1. Localizações das 61 estações meteorológicas convencionais utilizadas neste estudo e que estão instaladas em Minas Gerais e estados circunvizinhos (pontos azuis). As cores representam a topografia da região.

A Tabela 1 apresenta o formato padrão de uma base de dados espaço-temporal. São devidamente identificadas as coordenadas e municípios das estações meteorológicas, como também a data das medições das temperaturas máxima do ar. Os valores figurados com NA são valores perdidos por falhas de medição e foram tratados, segundo a função *na.locf* do pacote *spacetime* do R.

Tabela 1. Formato Padrão de uma Base de dados Espaço-Temporal.

Data	Mun.	ID	Lat	Lon	T _M
01-01-1996	Belo Horizonte	83587	-19,9	-43,9	24,4
01-01-1996	Viçosa	83642	-20,7	-42,8	24,6
...
01-01-1996	Juiz de Fora	83692	-21,7	-43,3	23,8
...
31-12-2016	Juiz de Fora	83692	-21,7	-43,5	NA

Mun.: Nome do município de localização da instalação, ID: Código da estação meteorológica convencional, Lat: Latitude (°), Lon: Longitude (°) e T_M: Temperatura máxima do ar (°C). Fonte: INMET (2018).

Para plotagem dos mapas do estado de MG foi utilizado o arquivo vetorial obtido no portal de mapas do Instituto Brasileiro de Geografia e Estatística (IBGE, 2016).

A modelagem geoestatística espaço-temporal via funções de covariâncias espaço-temporais foi utilizada para obter as previsões da temperatura máxima diária do ar. O método de interpolação utilizado foi a krigagem ordinária.

As equações para krigagem no domínio espaço-temporal são exatamente as mesmas que as equações de krigagem padrão. Detalhes das equações de krigagem ordinária podem ser encontradas em Varouchakis (2018).

Das 61 estações utilizadas, 48 estão localizadas nos municípios do estado de MG e 13 nos estados circunvizinhos a MG para que os mapas de predição da temperatura máxima do ar do estado de MG tenham valores interpolados também nos limites do estado.

Os mapas dos valores observados da temperatura máxima diária do ar medida nas estações meteorológicas do estado de MG, apresentados na Figura 2, têm como objetivo fornecer uma ideia inicial da distribuição dos valores da temperatura. Opta-se, por simples critério, a apresentação desses mapas apenas para o dia 15 de janeiro, para os anos de estudo.

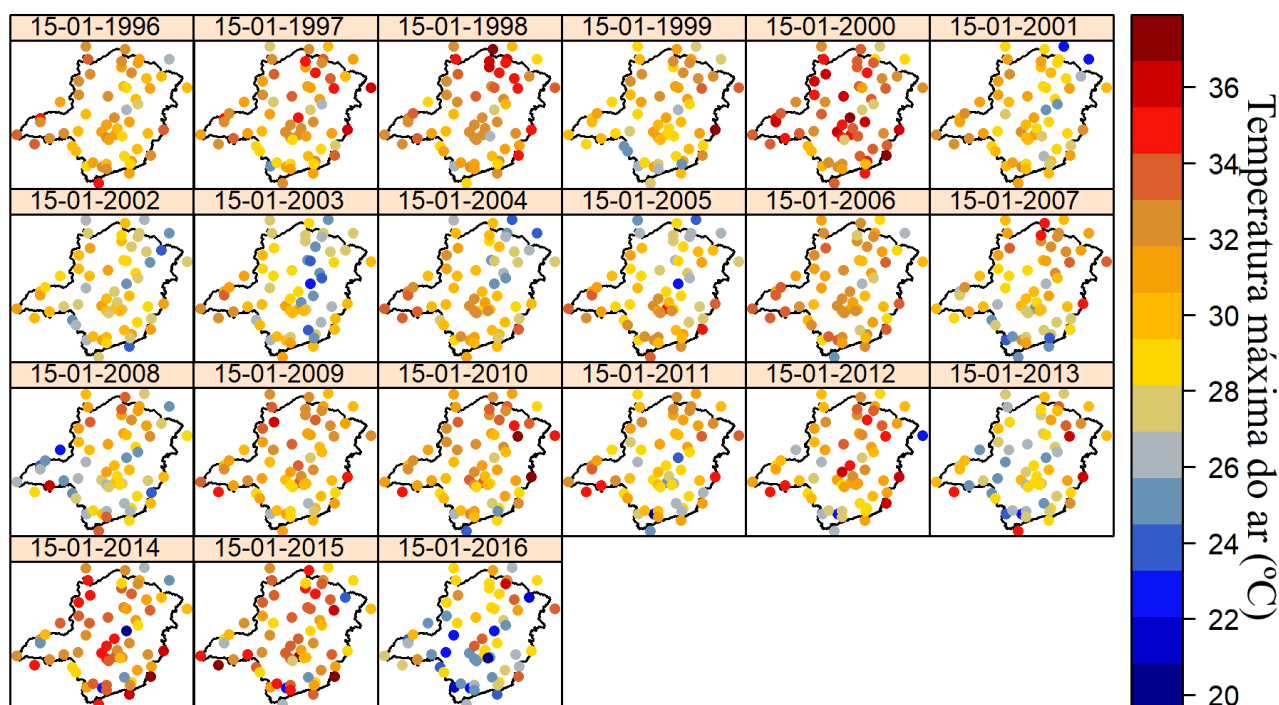


Figura 2. Localização das estações meteorológicas estudadas no presente trabalho e valores amostrais da temperatura do ar máxima registrada no dia 15 de janeiro (1996 a 2016).

Para traçar isolinhas que possibilitam visualizar regiões de máximos, mínimos e gradientes, é necessário que os dados estejam em grade regular.

Dessa forma, para obter um campo regular, a partir dos dados observados, é necessário utilizar métodos matemáticos que estimam os valores nos pontos de grade. Esses métodos de interpolação também têm como objetivo preencher falhas nos dados, tanto espacial quanto temporal, que normalmente existem devido à problemas no instrumento de medida, na sua coleta, na transmissão ou no armazenamento.

Entre as classes de funções de covariância espaço-temporais disponíveis na literatura, destaca-se, segundo De Iaco (2013), as classes de funções de Gneiting e segundo Gräler et al. (2016), as classes de funções de covariâncias separáveis (modelo soma e modelo produto) e não-separáveis (modelos soma-produto, métrico, soma-métrico e soma-métrico simplificado).

Em todo este estudo, denota-se \mathbb{R}^d o espaço euclidiano d -dimensional, $D \subset \mathbb{R}^d$ o domínio espacial, $T \subset \mathbb{R}$ o domínio temporal, \mathbf{h} o vetor distância de separação espacial, u a distância temporal e (\mathbf{h}, u) um lag espaço-temporal em

$D \times T$. A função aleatória $Z(s_i, t_j)$ representa a temperatura máxima diária do ar, em °C, na localização espacial $s_i, i = 1, 2, \dots, 61$, e no tempo $t_j, j = 1, 2, \dots, 7671$.

Segundo Montero et al. (2015) e Varouchakis (2018), sob as suposições de estacionariedade apropriadas, um estimador, obtido pelo método dos momentos, das funções de variograma espaço-temporal $2\hat{\gamma}(\mathbf{h}, u)$ e covariância $C(\mathbf{h}, u)$, respectivamente, é dado por:

$$2\hat{\gamma}(\mathbf{h}, u) = \frac{1}{N(\mathbf{h}, u)} \sum_{i=1}^{N(\mathbf{h}, u)} [Z(s_i, t_i) - Z(s_i + \mathbf{h}, t_i + u)]^2 \quad (1)$$

e

$$\hat{C}(\mathbf{h}, u) = \frac{1}{N(\mathbf{h}, u)} \sum_{i=1}^{N(\mathbf{h}, u)} [Z(s_i, t_i) - \bar{Z}][Z(s_i + \mathbf{h}, t_i + u) - \bar{Z}] \quad (2)$$

em que $\hat{\gamma}(\mathbf{h}, u)$ são as semivariâncias estimadas entre pares de observações $Z(s_i, t_i)$ e $Z(s_i + \mathbf{h}, t_i + u)$, separados espacialmente pelo vetor \mathbf{h} , em cada defasagem u no tempo; $N(\mathbf{h}, u)$ é o número de pares encontrados de localizações espaço-temporais e $\bar{Z} = \frac{1}{n} \sum_i Z(s_i, t_i)$ é um estimador da média do campo aleatório espaço-temporal $\{Z(s, t) : s \in D, t \in T\}$.

A representação gráfica de $\hat{\gamma}(\mathbf{h}, u)$, obtida da Equação (1) para cada lag (\mathbf{h}, u) espaço-temporal, permite gerar uma superfície suavizada denominada variograma experimental espaço-temporal.

Os principais modelos de covariância espaço-temporal utilizados neste estudo, de acordo com Montero et al. (2015) e Gräler et al. (2016), foram:

Modelos separáveis (modelo soma e modelo produto):

Não considera a interação entre o espaço e o tempo. Assume que a função de covariância espaço-temporal, C_{sep} , pode ser representada como soma ou produto de uma componente puramente espacial e outra puramente temporal, respectivamente, como:

$$C_{sep}((s_i, t_i), (s_j, t_j)) = C_s(s_i, s_j) + C_t(t_i, t_j) \quad (3)$$

e

$$C_{sep}((s_i, t_i), (s_j, t_j)) = C_s(s_i, s_j) C_t(t_i, t_j) \quad (4)$$

para todo $s_i, s_j \in D$ e $t_i, t_j \in T$ sendo C_s e C_t funções de covariâncias puramente espacial e puramente temporal, respectivamente.

Se C_s e C_t são estacionárias de segunda ordem, os modelos soma e produto tornam-se, respectivamente:

$$C_{sep}(\mathbf{h}, u) = C_s(\mathbf{h}) + C_t(u) \quad (5)$$

e

$$C_{sep}(\mathbf{h}, u) = C_s(\mathbf{h}) C_t(u) \quad (6)$$

para todo $(\mathbf{h}, u) \in D \times T$.

Quanto a função variograma espaço-temporal γ_{sep} , no caso estacionário, os modelos soma e produto tomam-se, respectivamente, a forma:

$$\begin{aligned} \gamma_{sep}(\mathbf{h}, u) &= C_{sep}(\mathbf{0}, 0) - C_{sep}(\mathbf{h}, u) \\ &= C_s(\mathbf{0}) + C_t(0) \\ &\quad - C_s(\mathbf{h}) - C_t(u) \\ &= \gamma_{sep}(\mathbf{h}) + \gamma_{sep}(u) \end{aligned} \quad (7)$$

e

$$\begin{aligned} \gamma_{sep}(\mathbf{h}, u) &= C_s(\mathbf{0}) C_t(0) \\ &\quad - C_s(\mathbf{h}) C_t(u) \\ &= C_s(\mathbf{0}) C_t(0) \\ &\quad - [C_s(\mathbf{0}) \\ &\quad - \gamma_s(\mathbf{h})][C_t(0) \\ &\quad - \gamma_t(u)] \\ &= C_s(\mathbf{0}) \gamma_t(u) \\ &\quad + C_t(0) \gamma_s(\mathbf{h}) \\ &\quad - \gamma_s(\mathbf{h}) \gamma_t(u) \end{aligned} \quad (8)$$

em que γ_s e γ_t são os variogramas puramente espacial e puramente temporal correspondentes a C_s e C_t , respectivamente.

Modelo soma-produto

No caso estacionário, as funções de covariância C_{sp} e variograma γ_{sp} tomam-se, respectivamente, as formas:

$$C_{sp}(\mathbf{h}, u) = k_1 C_s(\mathbf{h}) C_t(u) + k_2 C_s(\mathbf{h}) + k_3 C_t(u) \quad (9)$$

e

$$\begin{aligned} \gamma_{sp}(\mathbf{h}, u) &= C_{sp}(\mathbf{0}, 0) - C_{sp}(\mathbf{h}, u) \\ &= (k_2 + k_1 C_t(0)) \gamma_s(\mathbf{h}) \\ &\quad + (k_3 + k_1 C_s(\mathbf{0})) \gamma_t(u) - k_1 \gamma_s(\mathbf{h}) \gamma_t(u) \\ &= (k_2 + k_1 sill_t) \gamma_s(\mathbf{h}) \\ &\quad + (k_3 + k_1 sill_s) \gamma_t(u) - k_1 \gamma_s(\mathbf{h}) \gamma_t(u) \end{aligned} \quad (10)$$

em que C_s e C_t , são funções de covariância espacial e temporal, γ_s e γ_t os correspondentes variogramas espacial e temporal, $k_1 > 0$, $k_2 \geq 0$ e $k_3 \geq 0$ são constantes para assegurar a validade de C_{sp} .

Nota-se que, estimar e modelar as funções $\gamma_{sp}(\mathbf{h}, 0)$ (variograma marginal espacial) e $\gamma_{sp}(\mathbf{0}, u)$ (variograma marginal temporal) é equivalente a estimar e modelar, respectivamente, as funções de variograma puramente espacial $\gamma_s(\mathbf{h})$ e puramente temporal $\gamma_t(u)$, já que

$$\gamma_{sp}(\mathbf{h}, 0) = (k_2 + k_1 C_t(0)) \gamma_s(\mathbf{h}) = k_s \gamma_s(\mathbf{h}) \quad (11)$$

e

$$\gamma_{sp}(\mathbf{0}, u) = (k_3 + k_1 C_s(0)) \gamma_t(u) = k_t \gamma_t(u) \quad (12)$$

Da Equação (9) resulta que o patamar geral $C_{sp}(\mathbf{0}, 0)$, denotado por $sill_{st}$, é dado por:

$$\begin{aligned} sill_{st} &= k_1 C_s(\mathbf{0}) C_t(0) + k_2 C_s(\mathbf{0}) + k_3 C_t(0) \\ &= k_1 sill_s sill_t + k_2 sill_s + k_3 sill_t \end{aligned} \quad (13)$$

em que os parâmetros k_1 , k_2 e k_3 , satisfazem as equações

$$\begin{cases} k_1 C_t(0) + k_2 = k_s \\ k_1 C_s(\mathbf{0}) + k_3 = k_t \\ k_1 C_s(\mathbf{0}) C_t(0) + k_2 C_s(\mathbf{0}) + k_3 C_t(0) = C_{ps}(\mathbf{0}, 0) \end{cases} \quad (14)$$

Esses parâmetros, expressos em termos dos patamares $C_{sp}(\mathbf{0}, 0)$, $C_s(\mathbf{0})$, $C_t(0)$ e dos coeficientes k_s e k_t , tornam-se:

$$\begin{cases} k_1 = \frac{k_s C_s(\mathbf{0}) + k_t C_t(0) - C_{sp}(\mathbf{0}, 0)}{C_s(\mathbf{0}) C_t(0)} \\ k_2 = \frac{C_{sp}(\mathbf{0}, 0) - k_t C_t(0)}{C_s(\mathbf{0})} \\ k_3 = \frac{C_{sp}(\mathbf{0}, 0) - k_s C_s(\mathbf{0})}{C_t(0)} \end{cases} \quad (15)$$

Assim, a função variograma espaço-temporal do modelo soma-produto, expressa com um único parâmetro, torna-se:

$$\begin{aligned} \gamma_{sp}(\mathbf{h}, u) &= k_s \gamma_s(\mathbf{h}) + k_t \gamma_t(u) - k_1 \gamma_s(\mathbf{h}) \gamma_t(u) \\ &= \gamma_{sp}(\mathbf{h}, 0) + \gamma_{sp}(\mathbf{0}, u) - k_1 \frac{\gamma_{sp}(\mathbf{h}, 0) \gamma_{sp}(\mathbf{0}, u)}{k_s k_s} \\ &= \gamma_{sp}(\mathbf{h}, 0) + \gamma_{sp}(\mathbf{0}, u) - k \gamma_{sp}(\mathbf{h}, 0) \gamma_{sp}(\mathbf{0}, u) \end{aligned} \quad (16)$$

em que

$$\begin{aligned} k &= \frac{k_1}{k_s k_t} \\ &= \frac{k_s C_s(\mathbf{0}) + k_t C_t(0) - C_{sp}(\mathbf{0}, 0)}{(k_s C_s(\mathbf{0})) (k_t C_t(0))} \end{aligned} \quad (17)$$

Modelo métrico:

Combina as distâncias espacial, temporal e espaço-temporal por uma correção de anisotropia espaço-temporal $\kappa > 0$ (número de unidades espaciais equivalentes a uma unidade temporal), resultando em um único modelo de covariância conjunto C_{st} para as covariâncias espacial e temporal, com possíveis mudanças no alcance.

Segundo Montero et al. (2015), a função de covariância espaço-temporal para o modelo métrico, no caso estacionário, toma-se a forma

$$C_m(\mathbf{h}, u) = C_{st}(\|\mathbf{h}\| + \kappa|u|), \quad (18)$$

em que $\|\mathbf{h}\| + \kappa|u|$ é uma métrica em $\mathbb{R}^d \times \mathbb{R}$.

Uma alternativa para o modelo métrico é utilizar a métrica equivalente $\|\mathbf{h}\|^2 + \kappa|u|^2$ ou a métrica $\sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}$ (Figura 3). Nesse caso,

$$C_m(\mathbf{h}, u) = C_{st}(\|\mathbf{h}\|^2 + \kappa^2|u|^2) \quad (19)$$

ou

$$C_m(\mathbf{h}, u) = C_{st}(\sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}). \quad (20)$$

Assim, independente das métricas, as funções de covariância marginal espacial e marginal temporal obedecem ao mesmo tipo de modelo e patamar, mesmo que possam vir a ter alcances diferentes.

Quanto à função de variograma espaço-temporal γ_m , no caso estacionário, o modelo métrico toma-se a forma

$$\gamma_m(\mathbf{h}, u) = \gamma_{st}(\|\mathbf{h}\| + \kappa|u|) \quad (21)$$

ou

$$\gamma_m(\mathbf{h}, u) = \gamma_{st}(\|\mathbf{h}\|^2 + \kappa^2|u|^2) \quad (22)$$

ou ainda,

$$\gamma_m(\mathbf{h}, u) = \gamma_{st}(\sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}) \quad (23)$$

em que γ_{st} é o variograma conjunto, associado a C_{st} , que inclui o efeito pepita.




Figura 3. Representação da distância espacial \mathbf{h} , da distância temporal u e da distância espaço-temporal $m_{st} = \sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}$ em $\mathbb{R}^2 \times \mathbb{R}$, sendo κ uma correção de anisotropia espaço-temporal. Fonte: adaptado de Montero et al. (2015), com permissão do Licenciante através do PLSclear.

Modelo soma-métrico

O modelo de covariância soma-métrico é uma combinação do modelo soma e do modelo métrico, com todas as componentes configuradas independentemente. No caso estacionário, utilizando a métrica $\sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}$, a função covariância é dada por:

$$C_{sm}(\mathbf{h}, u) = C_s(\mathbf{h}) + C_t(u) + C_{st}(\sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}) \quad (24)$$

em que $\kappa > 0$.

Quanto à função de variograma, ela é representada por:

$$\gamma_{sm}(\mathbf{h}, u) = \gamma_s(\mathbf{h}) + \gamma_t(u) + \gamma_{st}(\sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}) \quad (25)$$

em que γ_s , γ_t e γ_{st} são os correspondentes variogramas puramente espacial, puramente temporal e conjunto, respectivamente, com parâmetros configurados independentes.

Formas equivalentes das funções de covariância e variograma podem ser obtidas utilizando as métricas $\|\mathbf{h}\| + \kappa|u|$ ou $\|\mathbf{h}\|^2 + \kappa^2|u|^2$. Por exemplo, utilizando a Equação (24), a expressão da função de covariância soma-métrico exponencial é dada por

$$C_{sm}(h, u) = C_s(\mathbf{0})\exp\left(-\frac{\|\mathbf{h}\|}{a_s}\right) + C_t(0)\exp\left(-\frac{|u|}{a_t}\right) + C_{st}(\mathbf{0}, 0)\exp\left(-\frac{\sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}}{a}\right) \quad (26)$$

Modelo soma-métrica simplificado:

É uma forma mais simples que o modelo soma-métrico porém, ao invés de flexibilidade total para cada componente, adicionalmente introduz-se um único efeito pepita, denotado por C_o . Nesse caso, utilizando a métrica $\sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}$, a função variograma é dada por:

$$\gamma_{ssm}(\mathbf{h}, u) = C_o + \gamma_s(\mathbf{h}) + \gamma_t(u) + \gamma_{st}(\sqrt{\|\mathbf{h}\|^2 + \kappa^2|u|^2}) \quad (27)$$

A estimação do modelo teórico de variograma espaço-temporal baseia-se no variograma experimental que é derivado dos dados observados. De acordo com Gräler et al. (2016), os melhores ajustes dos modelos espaço-temporais podem sugerir diferentes famílias de variogramas e parâmetros para os modelos puramente espacial e puramente temporal.

Uma medida usada frequentemente na verificação da acurácia das predições por meio da interpolação é o Erro Quadrático Médio (em inglês, Mean Squared Error- MSE), indicando métodos mais precisos para valores mais baixos.

O *MSE* é definido, via magnitude dos erros, por:

$$MSE = \frac{1}{N} \sum_{i=1}^N [Z^*(s_i, t_i) - Z(s_i, t_i)]^2 \quad (28)$$

em que $Z^*(s_i, t_i) - Z(s_i, t_i)$ é a diferença entre o valor predito e o valor observado pelo modelo na localização espaço-temporal (s_i, t_i) e N é o número de localizações e tempos que se deseja fazer a predição.

Resultados e discussão

Inicialmente, foi realizada uma análise descritiva dos dados com o objetivo de obter padrões que auxiliam no processo de modelagem geoestatística espaço-temporal (Tabela 2).

Com base no critério de classificação proposto por Garcia (1989), o atributo temperatura máxima do ar apresentou média dispersão dos dados ($10\% < CV < 20\%$).

Tabela 2. Estatística Descritiva dos valores Observados da Temperatura Máxima Diária do Ar de 01 de janeiro 1996 a 31 de dezembro 2016 nas 61 estações de estudo.

Estatísticas	Resultados
Média (\bar{Z})	29,29 °C
Desvio Padrão (S)	3,76 °C
Mínima	9,0 °C
Máxima	42,6 °C
Primeiro Quartil (Q_1)	27,0 °C
Mediana (M_d)	29,5 °C
Terceiro Quartil (Q_3)	31,9 °C
Coefficiente de Variação (CV)	12,85%
Coefficiente de Assimetria (C_a)	-0,32
Coefficiente de Curtose (C_m)	3,14

Os resultados sugerem uma possível distribuição simétrica para os dados de temperatura máxima do ar em MG, já que a distribuição de frequência apresentou média e mediana semelhante, além de um coeficiente de assimetria próximo de zero.

Segundo Yamamoto e Landim (2015), para dados que apresentem distribuição normal ou coeficiente de assimetria negativa, não há necessidade de nenhuma transformação dos dados e a krigagem ordinária pode ser aplicada diretamente sobre os dados observados. Dessa forma, as estimativas geoestatísticas foram

realizadas usando o preditor krigagem ordinária, sem nenhuma transformação nos dados.

Com base nas semivariâncias estimadas pela equação (1) em que $Z(s_i, t_j)$ representa os valores da temperatura máxima diária do ar, em °C, na localização espacial s_i , $i = 1, 2, \dots, 61$, e no tempo t_j , $j = 1, 2, \dots, 7671$, foram gerados série dos variogramas experimentais para 12 lags temporais (Figura 4a) e a superfície suavizada tridimensional do variograma espaço-temporal experimental (Figura 5a).

Em seguida, foram ajustados às semivariâncias estimadas, modelos de variogramas teóricos espaço-temporais utilizando funções de covariâncias da família de Gneiting (2002) e os modelos separáveis e não separáveis apresentados neste estudo. A seleção dos modelos e métodos de ajuste foi efetuada quanto ao critério do *MSE*, conforme sugerido por Pebesma e Gräler (2018).

Além da seleção da família de modelos de variogramas espaço-temporal, cada componente do modelo (puramente espacial, puramente temporal ou conjunto) foram ajustadas a partir de modelos de variogramas isotrópicos unidimensional.

Já a estimação dos parâmetros dessas componentes foram obtidas conjuntamente, via procedimentos numéricos iterativos., com valores iniciais retirados do variograma experimental.

Para o ajuste da componente puramente espacial a série na defasagem de tempo lag0 foi utilizada e para a componente temporal o variograma marginal temporal $\hat{\gamma}(\mathbf{0}, u)$.

Os modelos produto, soma-produto, métrico, soma-métrico e soma-métrico simplificado de variogramas teóricos espaço-temporais ajustados apresentaram, respectivamente, os valores do *MSE* de 2,86; 0,37; 1,34; 0,24 e 0,49. Pode-se observar que, os *MSE*'s de todos os modelos ajustados foram relativamente baixos, devido ao fato dos dados observados apresentarem variações pequenas e cada modelo tomar-se como base a média dos dados.

Para uma comparação visual do ajuste dos modelos foram geradas, para 12 lags temporais, as séries dos variogramas teóricos (Figura 4b-4f) e sua superfície tridimensional, para cada modelo (Figura 5b-5f).

Observa-se que o modelo de covariância espaço-temporal produto não foi adequado para ser utilizado na predição da temperatura máxima diária do ar no estado de MG, pois não ocorreu dependência espacial e temporal (modelo de pepita puro) (Figura 4b e Figura 5b).

Dentre os modelos teóricos espaço-temporal analisados, o mais apropriado para ser utilizado na predição da temperatura máxima do ar no estado de MG, no período de 1996 a 2016, foi o soma-métrico por apresentar-se o mais acurado,

com menor erro quadrático médio ($MSE = 0,24$), além de aspecto visual da série dos variogramas (Figura 4e) e superfície tridimensional (Figura 5e), que mais se aproxima do experimental.

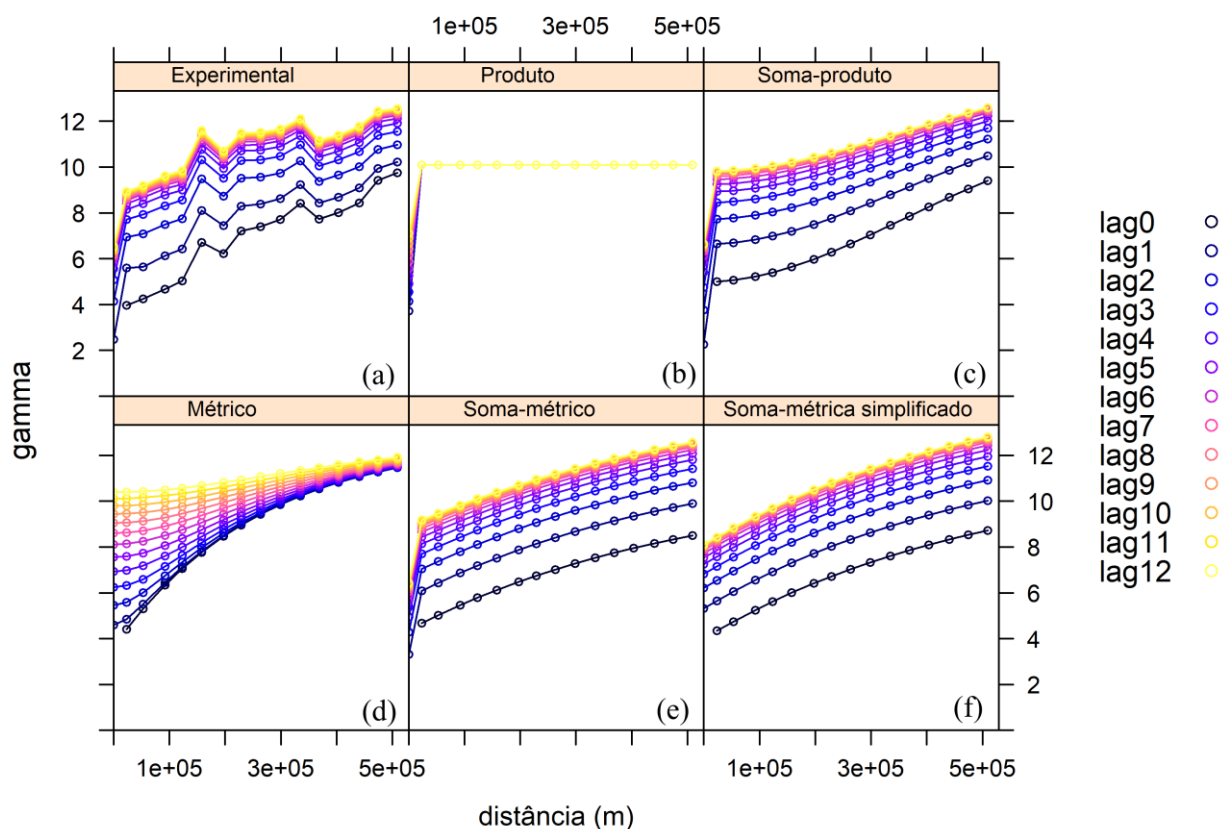


Figura 4. Série dos variogramas para 12 lags temporais (a) Experimental, (b)-(f) Teóricos ajustados às semivariâncias estimadas.

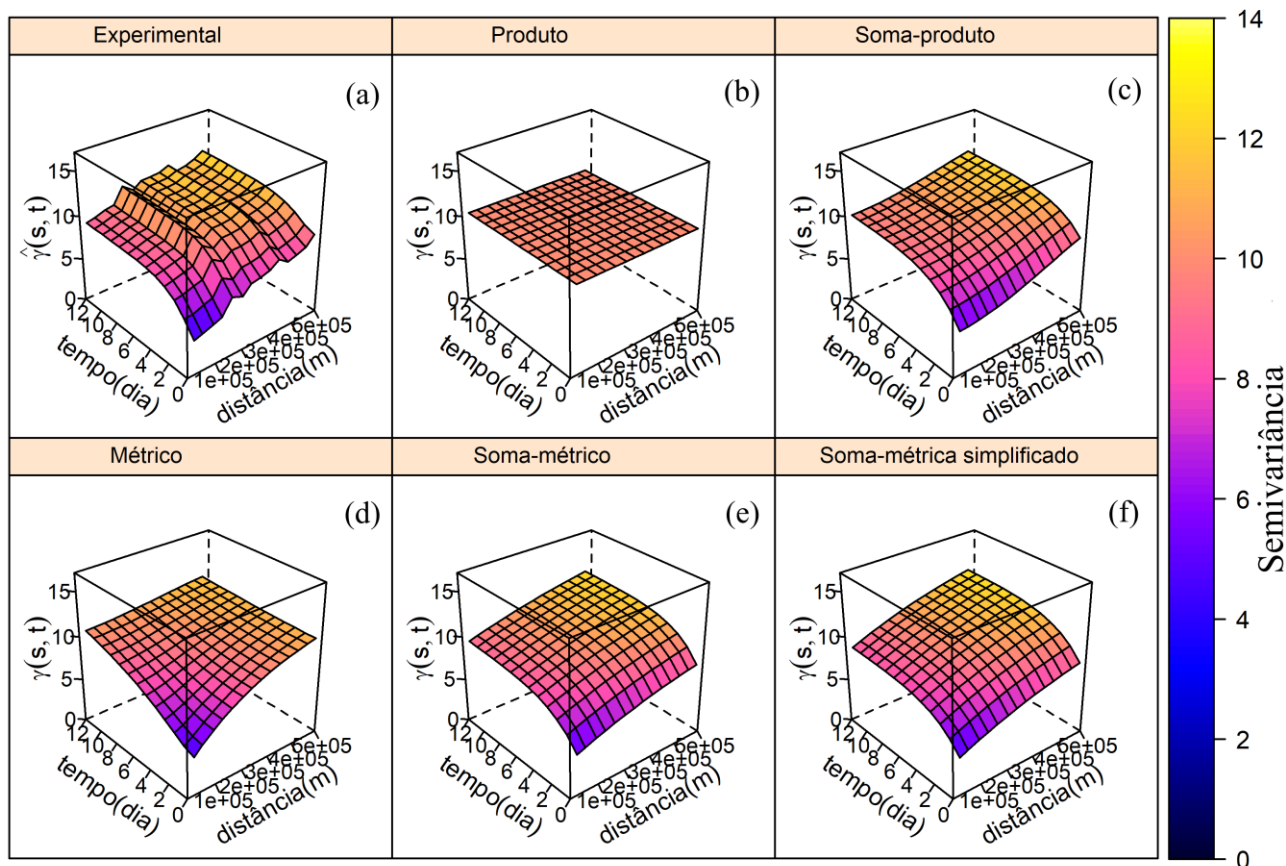


Figura 5. Superfície dos variogramas espaço-temporais. (a) Experimental; (b)-(f) Modelos teóricos ajustados às semivariâncias estimadas.

A Tabela 3 apresentam as estimativas dos parâmetros dos variogramas estacionários puramente espacial, puramente temporal e conjunto do modelo soma-métrico, sendo todos exponenciais.

Tabela 3. Parâmetros ajustados aos dados do modelo soma-métrico exponencial.

	C_0	C_1	a
Esp.	2,5	5,1	500 km
Temp.	0	4	2,4 dias
Conj.	1,9	1,3	500 km

C_0 : efeito pepita, C_1 : contribuição, a : alcance, Esp.: espacial, Temp.: temporal, Conj.: conjunto.

Dessa forma, utilizando os valores dos parâmetros apresentados na Tabela 3 e considerando uma estimativa do fator de anisotropia $\kappa = 22,3 \text{ km/dia}$ e o modelo de variograma teórico exponencial unidimensional, tem-se que a função do modelo ajustado do variograma espaço-temporal soma-métrico, segundo Equação (25), é dada por

$$\begin{aligned}
 \gamma_{sm}(\mathbf{h}, u) &= \gamma_s(\mathbf{h}) + \gamma_t(u) \\
 &+ \gamma_{st} \left(\sqrt{\|\mathbf{h}\|^2 + \kappa^2 |u|^2} \right) \\
 &= 2,5 + 5,1 \left[1 - \exp \left(-\frac{\|\mathbf{h}\|}{500000} \right) \right] \\
 &+ 4 \left[1 - \exp \left(-\frac{|u|}{2,4} \right) \right] + 1,9 \\
 &+ 1,3 \left[1 - \exp \left(-\frac{\sqrt{\|\mathbf{h}\|^2 + (22300)^2 |u|^2}}{500000} \right) \right]
 \end{aligned} \tag{29}$$

Então, após a caracterização do padrão espaço-temporal das temperaturas, aplicou-se o interpolador linear da Geoestatística, krigagem ordinária, usando o modelo de covariância soma-métrico, com 50 vizinhos espaço-temporais, para gerar campos interpolados em uma grade regular, com predição da temperatura máxima do ar para o estado de MG, nos dias 15 de cada mês, ao longo dos 21 anos analisados.

Ressalta-se que, os métodos aqui apresentados também podem ser aplicados para outros dias do mês ou, até mesmo, para todos os

dias do ano. No entanto, o custo computacional para a obtenção das temperaturas preditas em uma grade regular com 5869 pontos, abrangendo todo o estado de Minas Gerais ($1240\text{ km} \times 1000\text{ km}$) é relativamente alto. Em uma máquina com processador Intel core I7 de 2,40 GHz, o tempo de processamento, para cada dia, foi de aproximadamente 5,2 minutos.

Os valores médios preditos nos 5869 pontos de grade foram comparados com a média dos dados observados nas 61 estações (Figura 6).

Observa-se na Figura 6 que há um bom ajuste entre as médias dos dados observados e preditos, embora nos últimos anos a diferença foi mais acentuada, provavelmente devido ao fato de que nos últimos anos aumentou consideravelmente o número de falhas, uma vez que algumas das estações foram desativadas. No último ano analisado (2016) ocorreram 34,8% de falhas nos dados observados. Essas falhas afetam tanto as médias preditas quanto as observadas.

Nota-se que nos meses de dezembro e janeiro há uma tendência de queda na temperatura máxima do ar no estado de MG, considerando os 21 anos analisados. No entanto, é possível observar que a partir de 2004 é evidenciado um aumento da média da temperatura máxima para toda a estação de verão (Figura 6a - 6c).

Para os meses de março a maio (outono) não se observam tendências de aquecimento ou resfriamento (Figura 6d - 6f).

Nos meses de junho a agosto (inverno) observa-se uma tendência de aumento, aproximadamente de 1°C , na média da temperatura máxima, a cada 10 anos. Isso pode ser um indício de que a estação mais fria do ano está ficando cada vez mais quente (Figura 6g - 6i).

Já na primavera, também notou-se tendência de aquecimento, principalmente nos meses de setembro e outubro (Figura 6j - 6l).

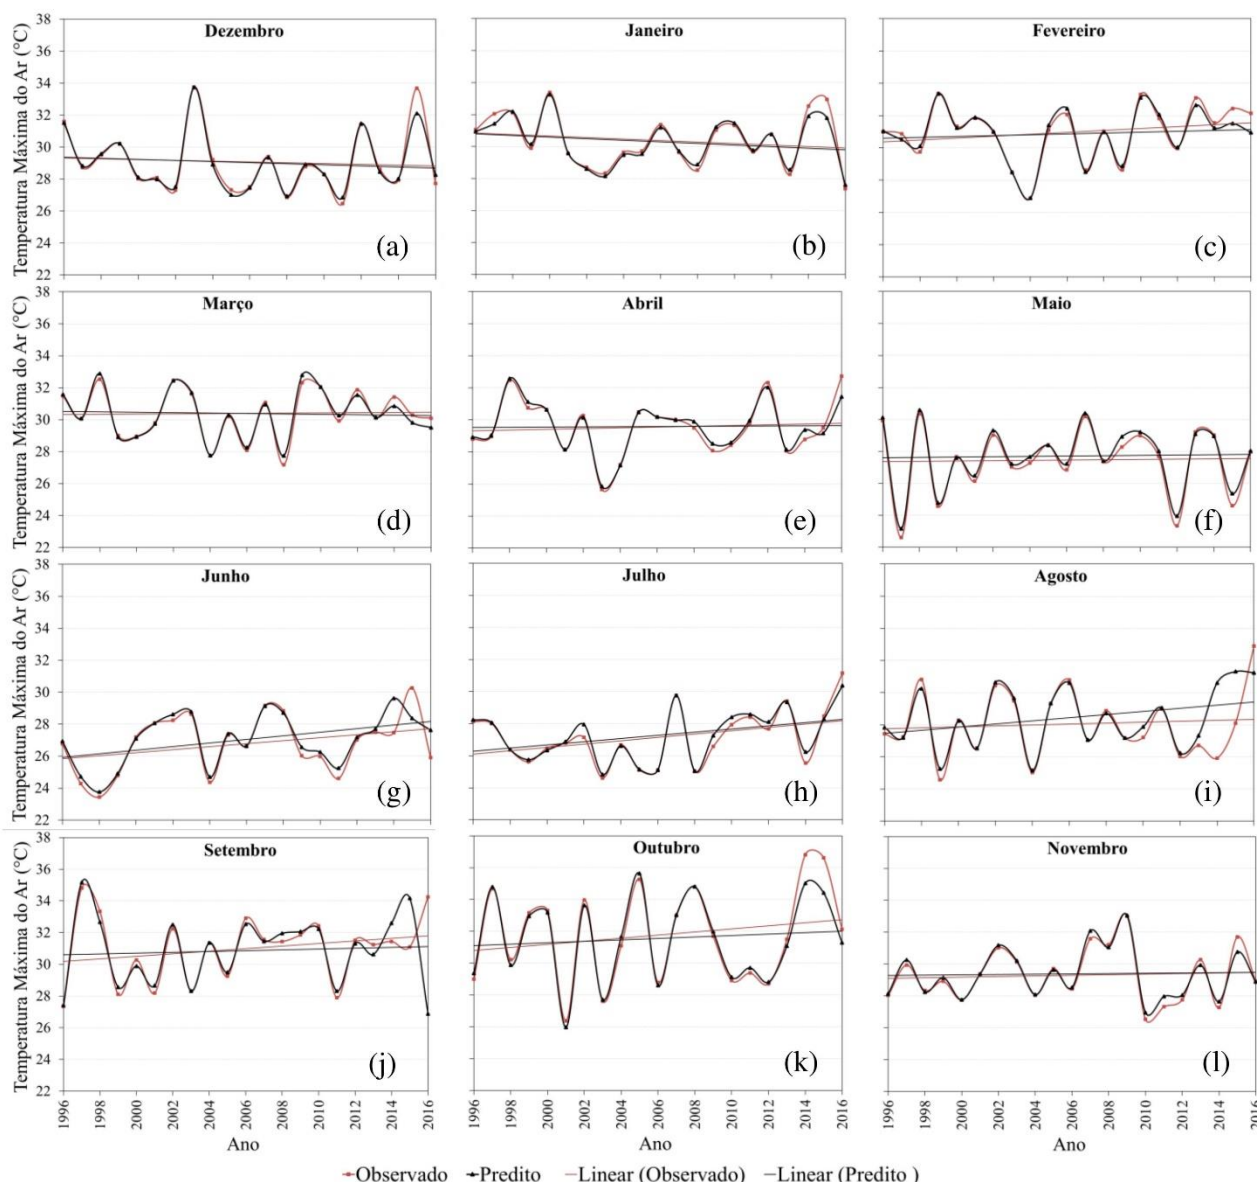


Figura 6. Médias dos dados observados e das previsões de temperatura máxima diária do ar no estado de MG, no período 1996 – 2016, para o dia 15 dos meses de (a) Dezembro, (b) Janeiro, (c) Fevereiro, (d) Março, (e) Abril, (f) Maio, (g) Junho, (h) Julho, (i) Agosto, (j) Setembro, (k) Outubro, (l) Novembro.

Ao considerar todos os meses do ano observa-se que prevalece leve tendência de aumento da média da temperatura máxima nas duas últimas décadas (Figura 7).

Essa tendência de aumento no valor da temperatura máxima pode estar relacionada ao aquecimento global, onde estudos mostram que já vem ocorrendo nas últimas décadas (IPCC, 2014). Contudo, avaliando os gráficos das médias das previsões dos valores de temperatura máxima diária do ar ao longo dos anos, seria necessário o estudo de um período maior para uma análise do aquecimento global.




Figura 7. Média anual dos dados observados e das previsões de temperatura máxima diária do ar no estado de MG para o dia 15, no período 1996 – 2016.

A Figura 8 apresenta os mapas das previsões espaço-temporais dos valores de temperatura máxima do ar no estado de MG para o dia 15 de janeiro ao longo dos 21 anos analisados.

Nota-se nos mapas que em determinadas situações, podem ocorrer altas variações espaciais nos valores de temperatura máxima do ar, como pode-se observar no dia 15 de janeiro de 2003 em que a região do Triângulo Mineiro a temperatura máxima foi em torno de 32° e na região Metropolitana de Belo Horizonte abaixo de 26°.

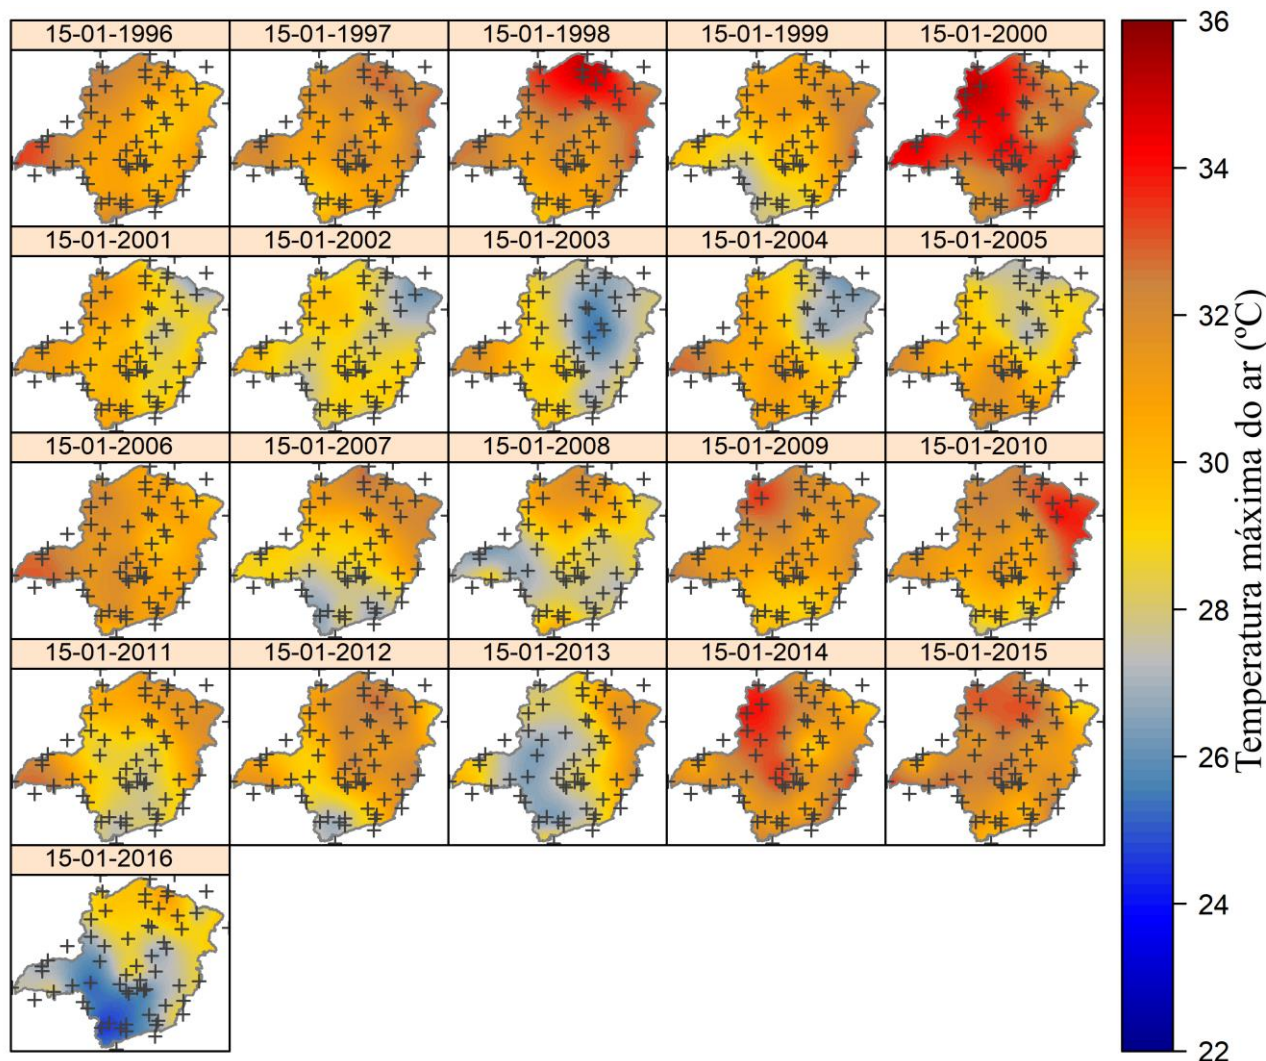


Figura 8. Predição espaço-temporal dos valores de temperatura máxima do ar do estado de MG para o dia 15 de janeiro, no período de 1996 a 2016.

Observa-se ainda que o dia 15 de janeiro de 2016 foi bastante frio, principalmente no sul do estado de MG. No entanto, ao analisar dias próximos a este, pode-se notar que este baixo valor de temperatura máxima provavelmente foi devido à chegada de uma frente fria, uma vez que no dia 10 o estado de MG estava com temperaturas altas e foi resfriando, do sul para o norte, até o dia 17 (Figura 9).

Então, devido a alta variabilidade da temperatura, tanto espacial quanto temporal, justifica-se a necessidade de utilizar grade com alta resolução e uma interpolação que considera as variações espaciais e temporais simultaneamente.

Dessa forma, ficou evidenciada a adequabilidade do uso da geoestatística espaço-temporal, via funções de covariância, para estimar

a temperatura máxima do ar no estado de MG no período de 1996 a 2016.

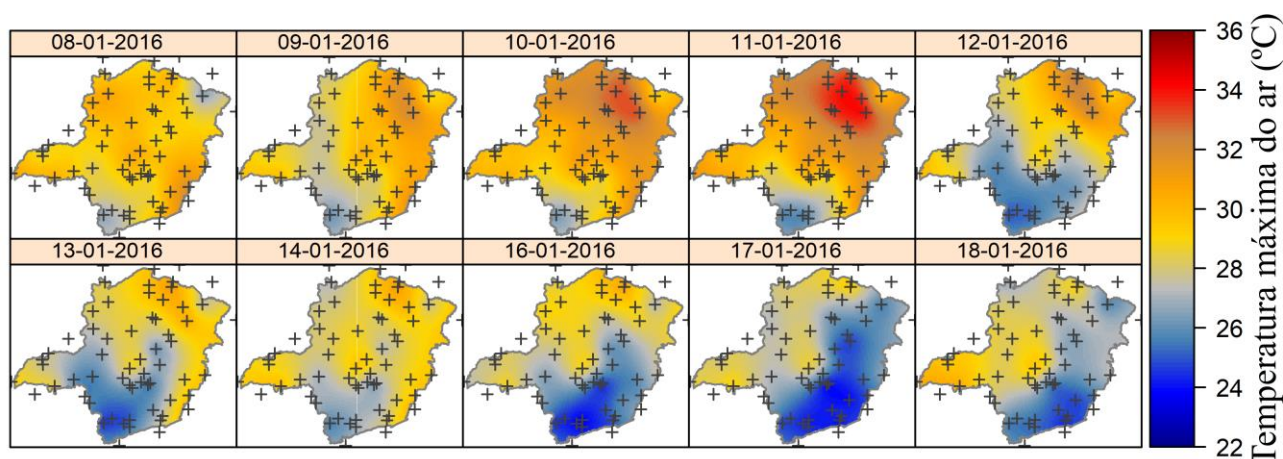


Figura 9. Predição espaço-temporal dos valores de temperatura máxima do ar do estado de MG nos dias 12, 13, 14, 16, 17 e 18, de janeiro de 2016.

Conclusão

Com base no critério *MSE*, o modelo de covariância soma-métrico é o que melhor se ajustou aos dados ($MSE=0,24$), quando comparados com os demais candidatos aqui avaliados. Já o modelo de covariância espaço-temporal produto não é adequado para o conjunto de dados aqui utilizados, pois ele não possui dependência espacial nem temporal.

As médias espaciais dos dados preditos ficaram muito próximas das médias dos dados observados nas 61 estações utilizadas, com exceção dos últimos três anos avaliados, por conter muitas falhas nas observações. Este resultado comprova que as predições realizadas foram bem sucedidas. Desta forma, os campos espaciais gerados, em grade regular, possibilitaram visualizar o comportamento da temperatura máxima do ar sobre o estado de Minas Gerais.

Foram observadas evidências do efeito do aquecimento global no estado de Minas Gerais, principalmente nos meses da estação de inverno, onde fica evidenciado uma tendência de aumento da temperatura máxima do ar ao longo dos anos analisados. No entanto, para uma melhor avaliação desse efeito é necessário um estudo de um período maior para certificar que as tendências encontradas não foram causadas por variações naturais do clima.

Este trabalho mostrou que é possível obter campos espaciais para a temperatura máxima diária do ar na região que engloba o estado de MG com alta qualidade ao utilizar a metodologia da

geoestatística espaço-temporal que considera tanto as variabilidades espaciais quanto temporais. Ademais, esta metodologia não é restrita aos dados aqui utilizados. O código desenvolvido, utilizando o pacote *spacetime*, permite gerar campos espaço-temporais com grades regulares para qualquer resolução, localização ou variáveis. Logo, mostrou-se uma poderosa ferramenta adequada para a modelagem conjunta espaço-temporal, disponível para o programa de código aberto R.

Agradecimentos

Ao Instituto Nacional de Meteorologia (INMET) pela disponibilização das bases de dados meteorológicos históricos inseridos no Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) e aos Coordenadores Editoriais da editora Oficina de Textos e da editora internacional John Wiley & Sons Limited, por suas permissões do pedido solicitado para uso de materiais licenciados no estudo.

Referências

- Bivand, R., Lewin-Koh, N., 2017. *maptools*: Tools for reading and handling spatial objects. R package version 0.9-2.
- Bivand, R., Keitt, T., Rowlingson, B., 2018. *rgdal*: Bindings for the geospatial data abstraction library. R package version 1.3-3.
- De Iaco, S., Posa, D., Myers, D. E., 2013. Characteristics of some classes of space-time

- covariance functions. *Journal of Statistical Planning and Inference*, 143(11), 2002-2015.
- Doty, B., Kinter, J. L. III, 1993. The grid analysis and display system (GrADS): a desktop tool for earth science visualization., In AmericanGeophysical Union. Fall Meeting, San Fransico, CA, 6–10 December. Disponível: <http://cola.gmu.edu/grads/> Acesso: 03 de jun 2018.
- Garcia, A., Andre, R. G. B., 2015. Variabilidade temporal da temperatura do ar em Jaboticabal–SP. *Nucleus*, v. 12, n. 1, p. 189-198.
- Garcia, C. H., 1989, Tabelas para classificação do coeficiente de variação. Piracicaba: IPEF. (Circular Técnica, 171). 12p.
- Gesch, D. B., Verdin, K. L., Greenlee, S. K., 1999. New land surface digital elevation model covers the Earth. *EOS, Transactions American Geophysical Union*, 80(6), 69-70.
- Gomes, D. P., Carvalho, D. F., de Oliveira Neto, D. H., dos Santos, C. A. B., 2014. Estimativa da temperatura do ar e da evapotranspiração de referência no estado do Rio de Janeiro. *Irriga*, v. 19, n. 2, p. 302.
- Gräler, B., Pebesma, E., Heuvelink, G., 2016. Spatio-temporal interpolation using gstat. *RFID Journal*, v. 8, n. 1, p. 204-218.
- IBGE. Instituto Brasileiro de Geografia e Estatística, 2016. Disponível: <https://portaldemapas.ibge.gov.br/portal.php#homepage>. Acesso: 23 jun. 2017.
- IPCC - Intergovernmental Panel in Climate Change, 2014: Summary for policymakers. In: *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [Field, C.B., V.R. Barros, D.J. Dokken, K.J. Mach, M.D. Mastrandrea, T. E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea, and L.L. White (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, pp. 1-32. Disponível: https://www.ipcc.ch/pdf/assessment-report/ar5/wg2/ar5_wgII_spm_en.pdf . Acesso: 21 jun. 2018.
- INMET. Instituto Nacional de Meteorologia, 2018. Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP). Disponível: <http://www.inmet.gov.br/portal>. Acesso: 02 abr. 2018.
- Medeiros, R. M., Francisco, P. R. M., Santos, D., Silva, L. L., Bandeira, M. M., 2015. Variabilidade da Temperatura Média do Ar no Estado da Paraíba-Brasil. *Revista Brasileira de Geografia Física*, v. 8, n. 01, p. 128-135.
- MG.GOV.BR. Governo de Minas Gerais, 2017. Governo do Estado de Minas Gerais. conheça Minas Gerais – geografia. Disponível: <http://mg.gov.br/conheca-minas/geografia>. Acesso: 12 jun. 2018.
- Montero, J.M., Fernández-Avilés, G., Mateu, J., 2015. Spatial and spatio-temporal geostatistical modeling and kriging. John Wiley e Sons, Chennai, India.
- Moreira, D. S., Longo, K. M., Freitas, S. R., Yamasoe, M. A., Mercado, L. M., Rosário, N. E., Gloor, E., Viana, R. S. M., Miller, J. B., Gatti, L. V., Wiedemann, K. T., Domingues, L. K. G., Correia, C. C. S., 2017. Modeling the radiative effects of biomass burning aerosols on carbon fluxes in the Amazon region. *Atmospheric Chemistry and Physics*, v. 17, n. 23, p.14785-14810. Disponível: <https://doi.org/10.5194/acp-17-14785-2017>. Acesso: 12 de dez 2017.
- Pebesma, E., 2016. Handling and analyzing spatial, spatiotemporal and movement data., Disponível: <https://edzer.github.io/UseR2016/>. Acesso: 30 de março 2018.
- Pebesma, E., Gräler, B., 2018. gstat: Spatial and spatio-temporal geostatistical modelling, prediction and simulation. R package version, 1.1-6.
- Pebesma, E., 2018. spacetime: Classes and methods for spatio-temporal data. R package version, 1.2-2.
- Pebesma, E., Gräler, B., 2018. Introduction to Spatio-Temporal Variography.
- Raja, N. B., Aydin, O., Türkoğlu, N., Çiçek, I., 2017. Space-time kriging of precipitation variability in Turkey for the period 1976–2010. *Theoretical and Applied Climatology*, 129(1-2), 293-304.
- Reboita, M. S., Rodrigues, M., Silva, L. F., Alves, M. A., 2015. Aspectos climáticos do estado de Minas Gerais (climate aspects in minas gerais state). *Revista Brasileira de Climatologia*, 17.
- Ribeiro Jr, P. J., Diggle, P. J., 2016. geoR: Analysis of geostatistical data. R package version, 1.7-5.2.
- Ryan, J. A., Ulrich, J. M., 2018. xts: extensible time series. R package version 0.11-0.

Sarkar, D., 2017. lattice: Trellis Graphics for R. R package version 0.20-35.

Team, R. C., 2018. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Disponível: <https://www.R-project.org/>. Acesso: 23 de abril 2018.

Yamamoto, J. K., Landim, P. M. B., 2015. Geoestatística: conceitos e aplicações. Oficina de Textos, São Paulo.

Varouchakis, E. A., 2018. Spatiotemporal geostatistical modelling of groundwater level variations at basin scale: a case study at Crete's Mires Basin. Hydrology Research, 49(4), 1131-1142.