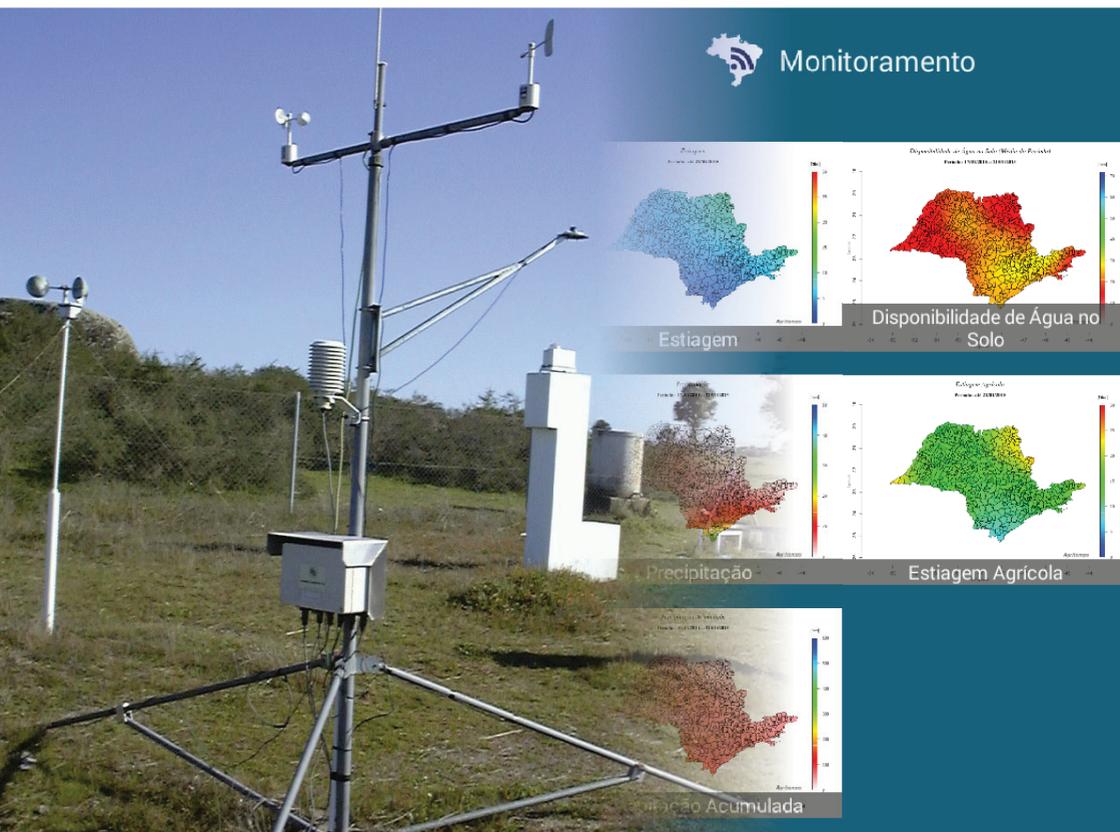


## Modelagem espaço-temporal para imputação de dados em séries de precipitação diária





*Empresa Brasileira de Pesquisa Agropecuária  
Embrapa Informática Agropecuária  
Ministério da Agricultura, Pecuária e Abastecimento*

# ***Boletim de Pesquisa e Desenvolvimento 39***

## **Modelagem espaço-temporal para imputação de dados em séries de precipitação diária**

*José Ruy Porto de Carvalho*

*Alan Massaru Nakai*

*José Eduardo Boffino de Almeida Monteiro*

**Embrapa Informática Agropecuária**  
Avenida André Tosello, 209 - Barão Geraldo  
C. Postal 6041 - 13083-886 - Campinas, SP  
Telefone: (19) 3211-5700  
www.embrapa.br/informatica-agropecuaria  
sac: www.embrapa.br/fale-conosco/sac/

#### **Comitê de Publicações**

Presidente: *Silvia Maria Fonseca Silveira Massruhá*

Secretária: *Carla Cristiane Osawa*

Membros: *Adhemar Zerlotini Neto, Stanley Robson de Medeiros Oliveira, Thiago Teixeira Santos, Maria Goretti Gurgel Praxedes, Adriana Farah Gonzalez, Neide Makiko Furukawa, Carla Cristiane Osawa*

Membros suplentes: *Felipe Rodrigues da Silva, José Ruy Porto de Carvalho, Eduardo Delgado Assad, Fábio César da Silva*

Supervisor editorial: *Stanley Robson de Medeiros Oliveira, Neide Makiko Furukawa*

Revisor de texto: *Adriana Farah Gonzalez*

Normalização bibliográfica: *Maria Goretti Gurgel Praxedes*

Editoração eletrônica/Capa: *Neide Makiko Furukawa*

Imagens da capa: *disponível em <<http://www.google.com.br>>*

#### **1ª edição**

on-line 2015

#### **Todos os direitos reservados.**

A reprodução não autorizada desta publicação, no todo ou em parte, constitui violação dos direitos autorais (Lei nº 9.610).

#### **Dados Internacionais de Catalogação na Publicação (CIP)**

Embrapa Informática Agropecuária

---

Carvalho, José Ruy Porto de.

Modelagem espaço-temporal para imputação de dados em séries de precipitação diária / José Ruy Porto de Carvalho, Alan Massaru Nakai, José Eduardo Boffino de Almeida Monteiro.- Campinas : Embrapa Informática Agropecuária, 2015.

19 p. il.: 14,8 cm x 21 cm. - (Boletim de pesquisa e desenvolvimento / Embrapa Informática Agropecuária, ISSN 1677-9266; 39).

1. Modelagem estatística. 2. Dados de precipitação. 3. Krigagem ordinária. 4. Cokrigagem ordinária. 5. Estatística skill score. I. Nakai, Alan Massaru. II. Monteiro, José Eduardo Boffino de Almeida. III. Embrapa Informática Agropecuária. IV. Título. V. Série.

CDD 21 ed. 519.5

© Embrapa 2015

## **Sumário**

<b>Resumo</b> .....	5
<b>Abstract</b> .....	7
<b>Introdução</b> .....	8
<b>Material e métodos</b> .....	10
<b>Resultados e discussão</b> .....	14
<b>Conclusões</b> .....	16
<b>Referências</b> .....	17



# Modelagem espaço-temporal para imputação de dados em séries de precipitação diária

---

José Ruy Porto de Carvalho<sup>1</sup>

Alan Massaru Nakai<sup>2</sup>

José Eduardo Boffino de Almeida Monteiro<sup>3</sup>

## Resumo

Neste trabalho, o modelo espaço-temporal foi usado na estimativa de dados diários de precipitação. Foram utilizados dados provenientes dos registros pluviométricos de diversas estações meteorológicas, obtidos junto ao Sistema de Monitoramento Agroecológico (Agritempo), para as regiões brasileiras. Com o objetivo de validar os valores obtidos pela aplicação do modelo espaço-temporal, fixou-se dois tempos, 1º de janeiro de 2009 e 1º de maio de 2009 para as regiões brasileiras em estudo. Para este tempo fixo usaram-se as técnicas geoestatísticas de krigagem e cokrigagem ordinária, com altitude como variável auxiliar para comparação. A aplicação do modelo espaço-temporal, no geral, foi superior em mais de 7% em relação às técnicas geoestatísticas de krigagem e cokrigagem para produzir estimativas da precipitação diária, para as regiões Sul, Sudeste, Centro-Oeste e Nordeste no período estudado. Especificamente, na região Sul foi supe-

---

<sup>1</sup> Estatístico, Ph.D. em Estatística, pesquisador da Embrapa Informática Agropecuária, Campinas, SP

<sup>2</sup> Cientista da computação, doutor em Ciência da Computação, analista da Embrapa Informática Agropecuária, Campinas, SP

<sup>3</sup> Engenheiro agrônomo, doutor em Agrometeorologia, pesquisador da Embrapa Informática Agropecuária, Campinas, SP

rior a 22%, na Sudeste acima de 7%, na Centro-Oeste acima de 38%, e na Nordeste acima de 12%.

Termos para indexação: modelos espaço-temporais, dados de precipitação, krigagem ordinária, cokrigagem ordinária, estatística skill score.

## **Spatio-temporal modeling of data imputation for daily precipitation series**

---

### **Abstract**

*In this study, a spatio-temporal model was used to estimate daily rainfall data. Precipitation records from several weather stations, obtained from the Agritempo agrometeorological monitoring system for the Brazilian regions, were used. Precipitation values obtained for two fixed dates (January 1 and May 1, 2009) using the spatio-temporal model were compared with the geostatisticals techniques of ordinary kriging and ordinary cokriging with altitude as auxiliary variable. The spatio-temporal model was more than 7% better at producing estimates of daily precipitation compared to kriging and cokriging in the Southern, Southeastern, Midwestern and Northeastern study region. Specifically, the model was 22% better in the southern region, 7% better in the southeastern region, 38% better in the Midwestern region and 12% better in the northeastern region.*

*Index terms: spatio-temporal model, rainfall data, ordinary kriging, ordinary cokriging, skill score statistic.*

## Introdução

A agricultura é a atividade humana que mais depende das condições do tempo e do clima. As condições meteorológicas afetam todas as etapas das atividades agrícolas e, adversidades no clima levam constantemente a graves impactos sociais e a enormes prejuízos econômicos, muitas vezes difíceis de serem quantificados. Como as condições adversas do tempo são frequentes e muitas vezes difíceis de serem controladas, a agricultura constitui-se em atividade de grande risco (PEREIRA et al., 2002). É nesse sentido que o monitoramento do clima e a previsão do tempo vêm ganhando cada vez mais espaço nas tomadas de decisão do agronegócio.

A pesquisa em Agrometeorologia depende de um banco de dados com dados meteorológicos completos, consistidos e bem distribuídos, coletados a partir de estações meteorológicas, sensoriamento remoto ou modelos climáticos. Por banco de dados completo, entenda-se sem falhas ou sem interrupções das séries temporais.

Devido à natureza quase sempre sequencial dos cálculos nas simulações de modelos de culturas, a interrupção ou a falta de dados em qualquer momento da série temporal de um ciclo de cultivo inviabiliza a conclusão da simulação daquele ciclo ou daquela safra. Logo, erros desse tipo implicam, quase sempre, na perda dos resultados e da análise de todo um ciclo, da safra ou do ano de simulação, num dado local.

Os bancos de dados meteorológicos formados por diversas instituições brasileiras, como o Instituto de Meteorologia (INMET) e o Centro de Previsão do Tempo e Estudos Climáticos (CPTEC) do Instituto Nacional de Pesquisa Espaciais (Inpe), por exemplo, frequentemente apresentam dados ausentes. Isso exige que as séries com falhas sejam reconstruídas para suas aplicações fim e análises posteriores.

Muitas abordagens têm sido utilizadas para o preenchimento de séries de tempo, por exemplo, análise discriminante múltipla (YOUNG, 1992), análise do vizinho mais próximo (VICENTE-SERRANO et al., 2010), métodos de regressão (PRESTI et al., 2010), métodos geoestatísticos (BAJAT et al., 2013; JEFFREY, 2001), regressão linear múltipla ou redes neurais (FOWLERET et al., 2007).

A formação de uma sólida base de dados meteorológicos requer, muitas vezes, um processo de reconstrução de séries temporais, o que envolve métodos de controle de qualidade, inclusive com preenchimento de falhas ou imputação de dados (VICENTE-SERRANO et al., 2010). Na maioria dos casos, o preenchimento de lacunas que faltam em dados de precipitação diária é uma tarefa difícil. Dados de precipitação observados em vários locais ao longo de diferentes momentos no tempo, tipicamente variam no espaço e no tempo, sendo uma característica intrínseca da variável.

Um exemplo típico seria o de uma rede de monitoramento de estações meteorológicas na qual os dados são coletados em intervalos regulares, diários, semanais, mensais ou anuais. A análise de dados tem que considerar a dependência espacial entre as estações, mas também considerar que as observações em cada estação normalmente não são independentes, mas formam uma série temporal. Portanto, as correlações temporais e espaciais têm que ser consideradas na análise.

Muitas vezes, o interesse primordial na análise de dados espaço-temporais é suavizar e prever a evolução do tempo da variável resposta sobre um determinado domínio espacial (LASINIO et al., 2005). Nos últimos anos, tem havido um crescimento nas pesquisas sobre modelos estatísticos e técnicas para resolver este problema.

Modelos espaço-temporais têm sido aplicados com sucesso em diversas áreas. Em hidrologia (AMISIGO; GIESEN, 2005; ROUHANI; MYERS, 1990), em meteorologia (HASLETT, 1989; SOARES et al., 2014) e para sistemas ambientais (FASSÒ; CAMELETTI, 2009, 2010; GOODALL; MARDIA, 1994; MARDIA et al., 1998).

Estes modelos podem ser representados na forma espaço de estados e seus parâmetros podem ser estimados usando filtro de Kalman (CRESSIE; WIKLE, 2002). No entanto, na configuração mais usual, onde os parâmetros do modelo são desconhecidos, a abordagem padrão usa o algoritmo Expectation-Maximization (EM), para estimar os parâmetros (SHUMWAY ; STOFFER, 1982).

Neste trabalho, o modelo espaço-temporal será utilizado na estimativa de dados de precipitação diários. Serão usados dados de estações meteoro-

lógicas situadas nos estados das regiões Norte, Nordeste, Centro-Oeste, Sudeste e Sul do Brasil. Os resultados obtidos serão comparados para um tempo fixado com técnicas geoestatísticas de krigagem e cokrigagem.

## Material e métodos

Foram utilizados dados provenientes dos registros pluviométricos de diversas estações meteorológicas para as regiões brasileiras, obtidos junto ao Sistema Agritempo (AGRITEMPO, 2014). O Agritempo é um sistema de Monitoramento Agrometeorológico que permite aos usuários o acesso, via internet, às informações meteorológicas e agrometeorológicas de diversos municípios e estados brasileiros.

Para cada conjunto de dados de cada região foi ajustado o modelo espaço-temporal usando programas desenvolvidos na linguagem R (R CORE TEAM, 2014) com o apoio da biblioteca Spatio-temporal models in R (Stem), (CAMELETTI, 2009). Com o objetivo de melhorar as estimativas dos parâmetros do modelo, utilizou-se a altitude das estações como covariável.

O modelo espaço-temporal é discutido a seguir conforme Fassò e Cameletti (2009). Seja  $Z(s, t)$  um processo escalar espaço-temporal observado no tempo  $t$  e localização geográfica  $s$ . Seja  $Z_t = \{Z(s_1, t), \dots, Z(s_n, t)\}$  um conjunto de dados no tempo  $t$  e para  $n$  localizações geográficas  $s_1, \dots, s_n$ . Além disso, seja  $Y_t = \{Y_1(t), \dots, Y_p(t)\}$  um vetor de dimensão  $p$  do processo temporal não observado no tempo  $t$  com  $p \leq n$ . O modelo hierárquico de três estágios para  $t = 1, \dots, T$  é definido a seguir:

$$Z_t = U_t + \varepsilon_t \quad (1)$$

$$U_t = X_t \beta + KY_t + \omega_t \quad (2)$$

$$Y_t = GY_{t-1} + \eta_t \quad (3)$$

Na equação (1), o erro de medida  $\varepsilon_t$  é introduzido de tal forma que  $U_t$  é visto como uma versão suavizada do processo espaço-temporal  $Z_t$ . Na equação (2), o processo espaço-temporal não observado  $U_t$  é definido como a soma de três componentes: a matriz  $X_t$  de covariáveis observadas para o tempo  $t$  e para  $n$  localizações, o processo espaço-temporal latente  $Y_t$  e o erro do modelo  $\omega_t$ . Finalmente, na equação (3) é modelado como um processo autorregressivo onde  $G$  é a matriz de transição e  $\eta_t$  é o erro de inovação. Os erros  $\varepsilon_t$ ,  $\omega_t$  e  $\eta_t$  têm média zero e são independentes no tempo e entre si. Substituindo (2) em (1) resulta no seguinte modelo hierárquico de dois estágios:

$$Z_t = X_t \beta + KY_t + \varepsilon_t \quad (4)$$

$$Y_t = GY_{t-1} + \eta_t \quad (5)$$

As equações (4) e (5) são as equações do modelo espaço-estado (DURBIN; KOOPMAN, 2001; CARVALHO et al., 2011; CHUI; CHEN, 2009). A equação (4) é a equação de medidas e a equação (5) é a equação de estado. O processo temporal  $Y_t$  pode ser estimado usando o filtro de Kalman ou Kalman suavizado.

Na equação (4) o erro  $e_t = \omega_t + \varepsilon_t$  tem distribuição Normal com média zero e matriz de variância e covariância

$$\Sigma e = \sigma_\omega^2 \Gamma(|s_i - s_j|), i, j = 1, \dots, n \quad (6)$$

Onde  $\Gamma$  é a função de covariância espacial definida como

$$\Gamma_{\delta, \theta}(h) = \begin{cases} 1 + \delta h = 0 \\ C_\theta(h) h > 0 \end{cases} \quad (7)$$

e

$$\delta = \frac{\sigma_\varepsilon^2}{\sigma_\omega^2} \quad (8)$$

O erro  $\sigma_\varepsilon^2$  é, em Geoestatística, o efeito pepita (nugget) do processo espacial  $e(s, t)$  para um  $t$  fixo. O vetor de parâmetros a ser estimado é  $\{\beta, \sigma_\omega^2, G, \Sigma^n, \mu_n, \sigma_\varepsilon^2 = \log \delta, \theta\}$ . Onde

$\beta$  = matriz de regressão

$\sigma_{\omega}^2$  = variância espacial

G = matriz de transição do processo autoregressivo

$\Sigma_n$  = matriz de variância e covariância do filtro de Kalman

$\mu_n$  = média filtro de Kalman

$\sigma_{\epsilon}^2$  = efeito pepita

$\theta$  = processo espacial

Dentre as abordagens conhecidas para realizar a estimação dos parâmetros, pode-se citar os métodos de máxima verossimilhança envolvendo o uso das técnicas de scoring ou Newton-Raphson para resolver as equações não-lineares que resultam da diferenciação da função de log-verossimilhança. Os métodos de verossimilhança geralmente possuem várias características indesejáveis como inversão de grandes matrizes Hessianas, da instabilidade do processo de maximização numérico e as resultantes matrizes positiva não definida (FASSÒ; CAMELETTI 2009, 2010). Para evitar estes contratemplos, a biblioteca Stem usa o algoritmo EM (MCLACHLAN; KRISHNAN, 1997; SHUMWAY; STOFFER, 1982) que é muito usado principalmente para problemas com valores perdidos, como é o caso das equações (4) e (5) onde o componente de valores perdidos é dado pela variável latente  $Y_t$ .

Uma vez que o algoritmo EM não usa matriz Hessiana na função de log-verossimilhança, ele não fornece erros padrão para uso das estimativas dos parâmetros, como o algoritmo do tipo Newton-Raphson faz. Daí o bootstrap é utilizado principalmente na estimativa de EM para obter uma estimativa dos erros padrão.

Métodos de Bootstrap (EFRON; TIBSHIRANI, 1993) são métodos computacionais intensivos de análise estatística que usa simulação para calcular erros-padrão e intervalos de confiança. Os métodos são aplicados a

qualquer nível de modelagem, e assim podem ser usados tanto na análise paramétrica quanto na não paramétrica.

Para validar os valores obtidos pela aplicação do modelo espaço-temporal, fixou-se aleatoriamente dois tempos, 1 de janeiro de 2009 e 1 de maio de 2009 para as regiões brasileiras em estudo. Para este tempo fixo usaram-se as técnicas geoestatísticas de krigagem o cokrigagem (YAMAMOTO; LANDIM, 2013) ordinária, com altitude como covariável, para estimar os valores perdidos por meio da validação cruzada onde se supõem que um elemento da amostra, não foi observado.

O primeiro tempo corresponde à época chuvosa para as regiões Sul, Sudeste, Centro-Oeste e Norte. Para a região Nordeste é época seca. Para o segundo tempo, as relações se invertem e é época seca para as regiões Sul, Sudeste, Centro-Oeste e Norte e chuvosa para a região Nordeste. De acordo com este critério, o melhor interpolador, para cada variável, é aquele que apresenta o menor valor do Quadrado Médio do Erro (QME), ou seja, a relação entre a diferença ao quadrado entre o valor observado e o valor estimado dividido pelo número de observações.

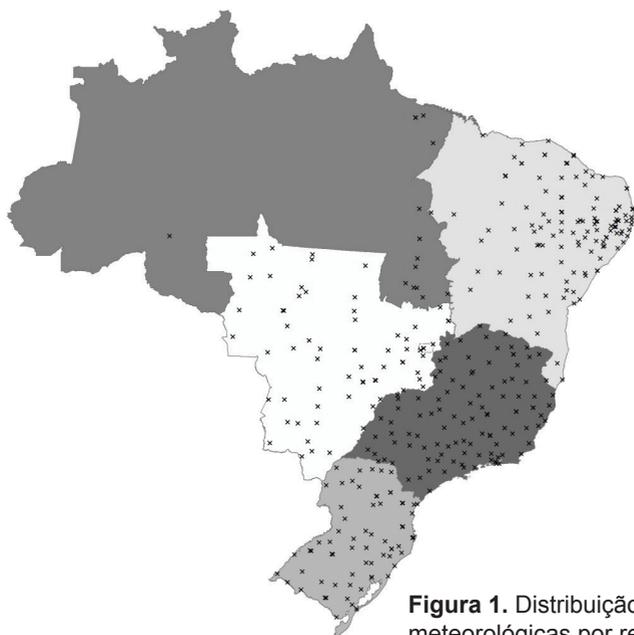
Espera-se com a fixação de dois períodos de tempo, observar o desempenho das estimativas obtidas pelo modelo espaço-temporal.

A estatística SS (Skill Score) quantifica a variação relativa do quadrado médio do erro do modelo espaço-temporal ( $QME_2$ ), relativamente à krigagem e cokrigagem ( $QME_1$ ). Valores positivos de SS indicam que o modelo melhorou as previsões, enquanto que valores negativos indicam que o modelo piorou as previsões (CARVALHO et al., 2011; LIBONATI et al., 2008)

$$SS = \frac{QME_1 - QME_2}{QME_1} \times 100 \quad (9)$$

## Resultados e discussão

Para a região Sul no ano de 2009 foram selecionadas 68 estações meteorológicas com séries de dados completas, sem falhas, apresentando 365 dias com valores de precipitação. Para a região Sudeste foram selecionadas 108 estações meteorológicas, 69 estações para a região Centro-Oeste, 125 estações para a região Nordeste e 15 estações para a região Norte. A Figura 1 mostra a distribuição espacial das estações meteorológicas usadas neste estudo, por região.



**Figura 1.** Distribuição espacial das estações meteorológicas por região.

Aleatoriamente foram retiradas para as regiões Sul, Sudeste, Centro-Oeste e Nordeste, os valores amostrados de dez estações meteorológicas, e obteve-se a estimativa dos mesmos valores pelo modelo espaço-temporal e pelos interpoladores geoestatísticos, usando os valores dos pontos vizinhos. Devido ao pequeno número de estações completas para a região Norte, somente o valor de uma estação meteorológica foi usado no processo de validação cruzada.

As estimativas de precipitação diária pelo modelo espaço temporal, por krigagem ou por cokrigagem, para o tempo fixado em 1º de janeiro de 2009, estão apresentadas na Tabela 1. Para o tempo fixado em 1º de maio de 2014 na Tabela 2.

**Tabela 1.** Quadrado médio do erro, para as estimativas do valor perdido, obtido pelo modelo espaço-temporal (QEMod), krigagem (QMEkrig) e cokrigagem (QMEcokrig) para 1º de janeiro de 2014. SS é a estatística de skill-score quando compara o modelo com krigagem, e SS1 quando compara o modelo com cokrigagem.

Região	QEMod	QMEkrig	SS (%)	QMEcokrig	SS1 (%)
Sul	9,07	11,66	22,23	11,73	22,68
Sudeste	3,09	5,55	44,31	5,10	39,35
Centro-Oeste	3,69	6,28	41,20	6,02	38,52
Nordeste	6,39	8,51	24,94	7,33	12,92
Norte	37,83	40,80	7,28	40,54	6,69

**Tabela 2.** Quadrado médio do erro, para as estimativas do valor perdido, obtido pelo modelo espaço-temporal (QEMod), krigagem (QMEkrig) e cokrigagem (QMEcokrig) para 1º de maio de 2014. SS é a estatística de skill-score quando compara o modelo com krigagem, e SS1 quando compara o modelo com cokrigagem.

Região	QEMod	QMEkrig	SS (%)	QMEcokrig	SS1 (%)
Sul	6,81	9,55	28,75	9,57	28,87
Sudeste	5,22	5,87	11,10	5,63	7,29
Centro-Oeste	8,52	22,04	61,35	21,69	60,73
Nordeste	8,36	10,97	23,83	11,73	28,76
Norte	34,73	46,01	24,51	45,37	23,45

A estatística de Skill Score (SS) (equação 9) é usada para quantificar, em porcentagem, a melhora ocorrida na estimativa da precipitação diária, para os dois tempos fixados, do modelo espaço-temporal em relação as estimativas obtidas pela krigagem e cokrigagem. Para o primeiro tempo, a estimativa obtida pelo modelo espaço-temporal foi 22,23% melhor do que a estimativa obtida pela krigagem (SS) e 22,68% em relação a estimativa obtida pela cokrigagem (SS1) para a região Sul. Para o segundo tempo fixado foi de 28,75%, e 28,87% para a mesma região.

Para as demais regiões, as estimativas obtidas pelo modelo espaço-temporal sempre foram melhores do que as estimativas obtidas pela krigagem e cokrigagem. Em todas as situações, os quadrados médios dos erros obtidos pelo modelo (QMEmod) foram consideravelmente menores do que os quadrados médios obtidos pela krigagem (QMEkrig) e os obtidos pela cokrigagem (QMEcokrig).

A tendência dos resultados obtidos pelo modelo espaço-temporal parece ser independente da época do ano, seja chuvosa ou seca, para todas as regiões. Na região Centro-Oeste, em particular, pode ser visto que houve uma diferença de desempenho do modelo, em função da época analisada. Enquanto na análise de 1º de janeiro de 2014 o QME do modelo foi 3,69% e os de krigagem e cokrigagem foram 6,28% e 6,02%, respectivamente, na análise de 1º de maio de 2014 do modelo foi de 8,52% e os de krigagem e cokrigagem foram 22,04% e 21,69%, respectivamente. O mês de maio está compreendido em uma época pouco chuvosa na região Centro-Oeste, mas ocorrências muito esporádicas de precipitação podem ocorrer, o que se revela na típica irregularidade de precipitação dessa época e local. Dessa forma, o período fixado em 1º de maio de 2014 coincidiu com um momento atípico em que o modelo espaço-temporal parece ter sido especialmente melhor que os demais para refletir essa condição específica.

Mesmo para a região Norte onde foram analisadas somente quinze estações com 365 dias de dados, o resultado foi melhor. Entretanto, deve-se levar em consideração que devido ao pequeno número de estações, as estimativas dos valores perdidos pelos métodos geoestatísticos podem estar subestimadas.

## Conclusões

- A aplicação do modelo espaço-temporal foi melhor para produzir estimativas da precipitação diária em comparação com o obtido pelas técnicas geoestatísticas de krigagem e cokrigagem para o período de estudo.

- O modelo espaço-temporal provou ser uma técnica versátil, adaptando-se às diferentes estações do ano, e deve ser considerada como uma das alternativas para preencher dados perdidos em séries temporais.
- Os quadrados médios do erro obtido pelo modelo foram consideravelmente menores do que os quadrados médios obtidos pela krigagem e cokrigagem.
- As previsões obtidas pelo modelo espaço-temporal foram acima de 7% melhores para as regiões Sul, Sudeste, Centro-Oeste e Nordeste, para os dois períodos estudados, em relação às previsões obtidas pelas técnicas geoestatísticas.

## Referências

- AGRITEMPO. **Sistema de Monitoramento Agrometeorológico**. [2014]. Disponível em: <<http://www.agritempo.gov.br/agritempo/index.jsp>>. Acesso em: 20 jun. 2014.
- AMISIGO, B. A.; GIESEN, N. C. van de. Using a spatio-temporal dynamic state-space model with the EM algorithm to patch gaps in daily riverflow series. **Hydrology and Earth System Sciences**, v. 9, n. 3, 209-224, 2005.
- BAJAT, B.; PEJOVIĆ, M.; LUKOVIĆ, J.; MANOJLOVIĆ, P.; DUCIĆ, V.; MUSTAFIĆ, S. Mapping average annual precipitation in Serbia (1961-1990) by using regression kriging, **Theoretical and Applied Climatology**, v. 112, n. 1-2, p. 1-13, Apr. 2013. DOI: 10.1007/s00704-012-0702-2.
- CAMELETTI, M. **Spatio-temporal models in R**. 2009. Disponível em: <<http://cran.r-project.org/web/packages/Stem/index.html>>. Acesso em: 15 nov. 2014.
- CARVALHO, J. R. P de; ASSAD, E. D.; PINTO, H. S. Kalman filter and correction of the temperatures estimated by PRECIS model, **Atmospheric Research**, v. 102, n. 1-2, p. 218-226, Oct. 2011. DOI: 10.1016/j.atmosres.2011.07.007.
- CHUI, C. K.; CHEN, G. **Kalman filtering with real-time applications**. 4<sup>th</sup> ed. New York: Springer-Verlag, 2009. 227 p.
- CRESSIE, N.; WIKLE, C. K. Space-time kalman filter. In: EL-SHAARAWI, A. H.; PIEGORSCH, W. W. (Ed.). **Encyclopedia of Environmetrics**. New York: J. Wiley, 2002. v. 4, p. 2045-2049.

DURBIN, J.; KOOPMAN, S. **Time series analysis by state space methods**. New York: Oxford University, 2001. 253 p. ill.

EFRON, B.; TIBSHIRANI, R. J. **An introduction to the bootstrap**. London. Chapman and Hall, 1993. 436 p. ill. (Monographs on statistics and applied probability, 57).

FASSÒ, A.; CAMELETTI, M. A. The EM algorithm in a distributed computing environment for modelling environmental space-time data. **Environmental Modelling & Software**, v. 24, n. 9, 1027-1035, Sept. 2009. DOI: 10.1016/j.envsoft.2009.02.009.

FASSÒ, A.; CAMELETTI, M. A. A unified statistical approach for simulation, modeling, analysis and mapping of environmental data. **Simulation**, v. 86, n. 3, 139-154, 2010.

FOWLER, H. J.; BLENKINSOP, S.; TEBALDI, C. Linking climate change modelling to impacts studies: Recent advances in downscaling techniques for hydrological modelling. **International Journal Climatology**, v. 27, n. 12, p. 1547-1578, Oct. 2007. DOI:10.1002/joc.1556.

GOODALL, C.; MARDIA, K. V. Challenges in multivariate spatio-temporal modeling. In: INTERNATIONAL BIOMETRIC CONFERENCE, 17., 1994, Hamilton. **Proceedings...** Hamilton: McMaster University, 1994. p. 1-17.

HASLETT, J. Space-time modelling in meteorology - a review. **Bulletin of the International Statistical Institute**, v. 51, p. 229-246, 1989.

LASINIO, G. J.; SAHU, S. K.; MARDIA, K. V. **Modeling rainfall data using a Bayesian Kriged-Kalman model**. 2005. Disponível em: <<http://eprints.soton.ac.uk/30052/1/kkfrainfall.pdf>>. Acesso em: 20 jun. 2014.

LIBONATI, R.; TRIGO, I.; DACAMARA, C. C. Corrections of 2 m-temperature forecasts using Kalman filtering technique. **Atmospheric Research**, v. 87, n. 2, p. 183-197, Feb. 2008. DOI: doi:10.1016/j.atmosres.2007.08.006.

MCLACHLAN, G. J.; KRISNAN, T. **The EM algorithm and extensions**. New York: Wiley-Interscience, 1997. 274 p. ill. (Wiley series in probability and statistics. Applied probability and statistics).

MARDIA, K. V.; GOODALL, C.; REDFERN, E. J.; ALONSO, F. J. The Kriged Kalman filter (with discussion). **Test**, v. 7, n. 2, p. 217-252, 1998.

PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. **Agrometeorologia: fundamentos e aplicações práticas**. Guaíba: Agropecuária, 2002. 478 p.

PRESTI, R. L.; BARCA, E.; PASSARELLA, G. A methodology for treating missing data applied to daily rainfall data in the Candelaro River Basin (Italy). **Environmental Monitoring and Assessment**, v. 160, n. 1-4, p. 1-22, Jan. 2010. DOI: 10.1007/s10661-008-0653-3.

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna: Foundation for Statistical Computing, 2014. Disponível em: <<http://www.R-project.org/>>. Acesso em: 20 jun. 2014.

ROUHANI, S.; MYERS, D. E. Problems in space-time kriging of geohydrological data. **Mathematical Geology**, v. 22, p. 611-623, 1990.

SHUMWAY, R. H.; STOFFER, D. S. An approach to time series smoothing and forecasting using the EM algorithm. **Journal of Time Series Analysis**, v. 3, n. 4, p. 253-264, July, 1982. DOI: DOI: 10.1111/j.1467-9892.1982.tb00349.x.

SOARES, F. S.; FRANCISCO, C. N.; SENNA, M. C. A. Distribuição espaço-temporal da precipitação na região hidrográfica da baía da Ilha Grande - RJ. **Revista Brasileira de Meteorologia**, v. 29, n. 1, p. 125-138, 2014.

VICENTE-SERRANO, S. M.; BEGUERÍA, S.; LÓPEZ-MORENO, J. I.; GARCÍA-VERA, M. A.; STEPANEK, P. A complete daily precipitation database for northeast Spain: reconstruction, quality control, and homogeneity. **International Journal Climatology**. v. 30, n. 8, p. 1146-1163, June, 2010.

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística conceito e aplicações**. São Paulo, Oficina de Textos, 2013. 215 p.

YOUNG, K. C. A three-way model for interpolating for monthly precipitation values. **Monthly Weather Review**, v. 120, n. 2, p. 2561-2569, Feb. 1992.



---

*Informática Agropecuária*



Ministério da  
Agricultura, Pecuária  
e Abastecimento

