

VARIABILIDADE ESPACIAL DA PRECIPITAÇÃO NO CULTIVO DE MILHO SEGUNDA SAFRA NO PARANÁ UTILIZANDO O MODELO WAVE

**PAULO GAMERO¹; MIGUEL ANGEL URIBE-OPAZO²; FERNANDA DE
BASTIANI³; JERRY ADRIANI JOHANN² E LUCIANA PAGLIOSA CARVALHO
GUEDES²**

¹ *Doutorando no Programa de Pós-Graduação em Engenharia Agrícola – PGEAGRI, Centro de Ciências Exatas e Tecnológicas, Universidade Estadual do Oeste do Paraná - UNIOESTE, Rua Universitária, n° 2069, Jardim Universitário, CEP: 85819-110, Cascavel, PR, Brasil, e-mail: paulogamero94@gmail.com*

² *Professor e Pesquisador do PGEAGRI, Centro de Ciências Exatas e Tecnológicas, Universidade Estadual do Oeste do Paraná - UNIOESTE, Rua Universitária, n° 2069, Jardim Universitário, CEP: 85819-110, Cascavel, PR, Brasil, e-mails: miguel.opazo@unioeste.br; jerry.johann@hotmail.com; luciana.guedes@unioeste.br*

³ *Professora e Pesquisadora do Programa de Pós-Graduação em Estatística – PPGE, Departamento de Estatística, Universidade Federal de Pernambuco - UFPE, Av. Prof. Moraes Rego, n° 1235, Cidade Universitária, CEP: 50670-901, Recife, PE, Brasil, e-mail: fernandadebastiani@gmail.com*

1 RESUMO

Compreender o padrão espaço-temporal da precipitação é fundamental para a agricultura, pois afeta a produtividade. O Paraná um dos maiores produtores de milho do país, realizando o cultivo em duas épocas (1ª e 2ª safra). Sendo assim, este trabalho avaliou o padrão espacial da precipitação, no período do cultivo de 2ª safra do milho, nos anos de 1996 a 2015. Utilizaram-se dados de estações pluviométricas acumulados decenalmente da Agência Nacional das Águas (ANA), e de estações virtuais do *Europe Center for Medium-Range Weather Forecasts* (ECMWF). O padrão espacial da precipitação no tempo, foi avaliado com o modelo geostatístico *wave*. Na estimação de parâmetros usou-se o método de máxima verossimilhança e os mapas gerados por krigagem. A validação cruzada indicou bons resultados para o modelo *wave* quando comparado aos modelos exponencial, Gaussiano, Mátern $k=1$ e $k=1,5$. Em todos os anos analisados houve dependência espacial, com frequência de 0 a 100 mm no 3º decêndio de maio na maioria dos anos analisados. O período médio ideal para a semeadura o milho 2ª safra no Paraná é o 1º decêndio de março, visto que a cultura atingirá o máximo desenvolvimento vegetativo no 3º decêndio de maio, com uma precipitação ideal para o cultivo.

Palavras-chave: Dependência Espacial, Geoestatística, Krigagem.

**GAMERO, P.; URIBE-OPAZO, M. A.; DE BASTIANI, F.; JOHANN, J. A.; GUEDES,
L. P. C.**

**SPATIAL VARIABILITY OF PRECIPITATION IN SECOND CROP CORN
CULTIVATION IN THE STATE OF PARANÁ USING THE WAVE MODEL**

2 ABSTRACT

Understanding the spatio-temporal behavior of rainfall is important for agriculture, because it affects productivity. Paraná is one of the largest corn producers in the country, and cultivates corn in two seasons (1st and 2nd crop). Thus, this work evaluated rainfall spatial pattern spatial

during the 2nd corn crop period of cultivation in the years 1996 to 2015. Accumulated ten-year data from the National Water Agency (ANA) rainfall stations, and Europe Center for Medium-Range Weather Forecasts (ECMWF) virtual stations were used. The spatial behavior of rainfall over time was analyzed using the geostatistical wave model. In the estimate parameters the maximum likelihood method was used and maps were generated by kriging. Cross-validation indicated good results for the wave model compared to those of the exponential, Gaussian, Matérn $k = 1$, $k = 1.5$ models. For all years analyzed there was spatial dependence, with a frequency of 0 to 100 mm in the 3rd ten-day period of May in most of the years analyzed. The ideal average period for sowing the 2nd crop corn in Paraná is the 1st ten-day period in March, when the crop will reach its vegetative peak in the 3rd ten-day period in May, with space and time of ideal rainfall for cultivation.

Keywords: Spatial Dependence, Geostatistic, Kriging.

3 INTRODUÇÃO

Pela importância do agronegócio brasileiro, cada vez mais tem se desenvolvido pesquisas para o avanço da produção agrícola, visando aumento da produtividade associadas a aplicação de novas tecnologias, como a agricultura digital (SRIVASTAVA et al., 2019; ROY E DE, 2020). Dessa forma, o conhecimento e a existência de dados sobre as variáveis meteorológicas cada vez mais têm tido importância no meio agrícola (BECK et al., 2017; ZUO et al., 2019; AGUIAR E LOBO JR, 2020). Entre as variáveis meteorológicas, a precipitação é, sem dúvida, a que mais influencia o desenvolvimento das culturas (TORRES; HOWITT; RODRIGUES, 2019; CAVALCANTE et al., 2020). Sua deficiência representa redução na produtividade e, por consequência, impactos na produção de alimentos, podendo afetar o abastecimento da população mundial (TORRES; HOWITT; RODRIGUES, 2016; DINKU, 2020).

Portanto, o conhecimento sobre padrões de precipitação e sua variabilidade no espaço e tempo, em uma determinada região, tem grande relevância, pois proporciona a oportunidades de um melhor planejamento agrícola, uma vez que apresenta alta variabilidade (ARAI et al.,

2010), permitindo tomadas de decisões mais assertivas, por exemplo, quanto a melhor época de cultivo, visando maiores produtividades. Um dos maiores produtores mundiais de milho (*Zea mays*), o Brasil tem cultivo em duas épocas, no período de primavera-verão (milho 1^a safra) e no período verão-inverno (milho 2^a safra). Sendo o segundo maior produtor de milho do país, o Paraná teve uma produção de 12,05 milhões de toneladas em uma área de 2,41 milhões de hectares no ano-safra 2017/18, dos quais, tem 76% da produção ocorreram na 2^a safra (PARANÁ, 2020), o que demonstra que esta é a época de cultivo mais importante para o estado (MEIRELLES E ZÁRATE, 2015).

O milho 2^a safra, na maioria das vezes é semeado logo após finalizado o cultivo da safra da soja, tornando-se uma interessante alternativa de rentabilidade ao agricultor, por permitir a realização de pelo menos duas safras anuais. Porém, devido a época de cultivo, pode passar por riscos de perda da lavoura ou queda de produtividade, quando não se realiza a semeadura no período apropriado, devido às condições meteorológicas (CARDOSO; FARIA; FOLEGATTI, 2004; LANGE et al., 2014). Uma das causas é a deficiência hídrica em certos períodos, como no estágio do pendoamento, que pode levar a redução de

25 a 32% da produtividade, na fase posterior à fecundação (FANCELLI, 2015).

Contudo, adotando-se métodos analíticos apropriados para entendimento do padrão espacial das variáveis que influenciam a produtividade, como a Geoestatística, que quantifica a variabilidade espacial e permite uma interpolação de qualidade, é possível prever com maior confiabilidade os riscos envolvidos (DIGGLE E RIBEIRO JUNIOR, 2007; PARDO-IGÚZQUIZA E DOWD, 2013; KESTRING et al., 2015), visto que permite o entendimento da variabilidade espacial da precipitação no tempo (MOTA et al., 2008; BENOIT E MARIETHOZ, 2017; SANTOS et al., 2017). Dentre os modelos geoestatísticos existentes para representação espacial dos dados, o modelo *wave*, tem comportamento não monotônico e decrescente com o aumento da distância (MOTA et al., 2008), padrão conhecido como “*hole effect*”, em que valores elevados podem sistematicamente estarem cercados por valores baixos, e vice versa, o que é uma característica de dados de precipitação (CHILÈS E DELFINER, 2012).

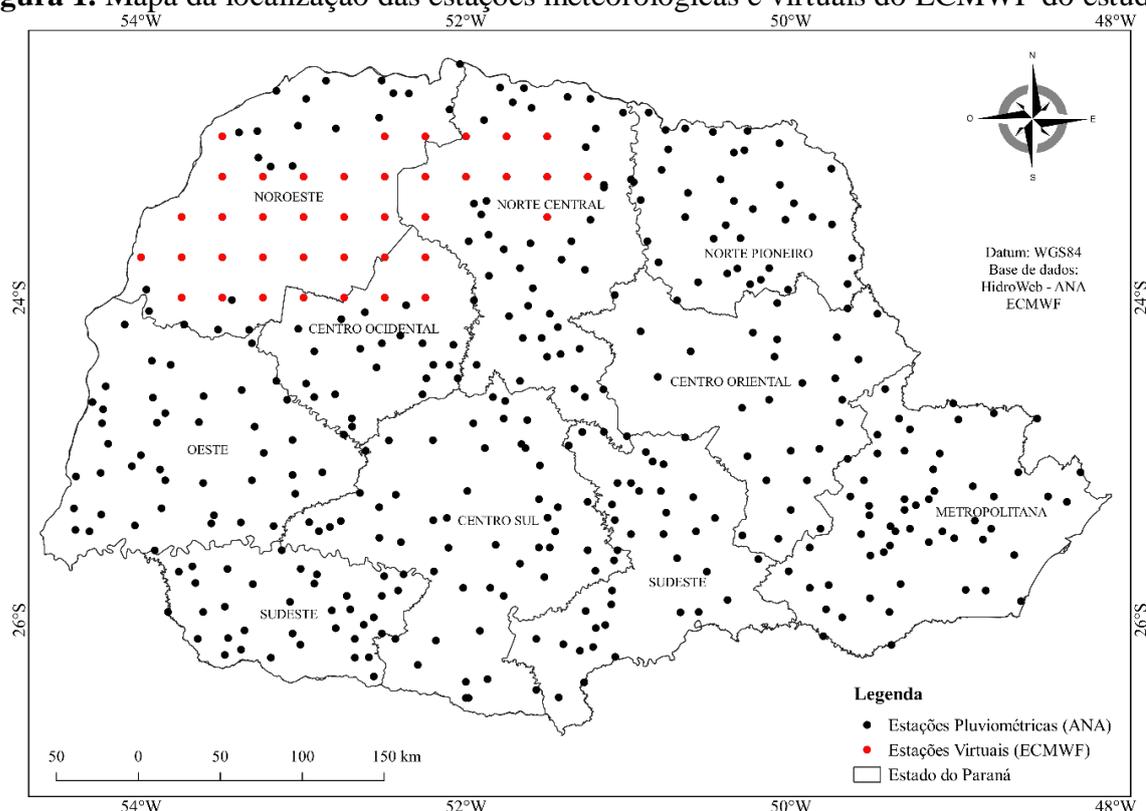
Assim, o objetivo deste estudo foi modelar a variabilidade espacial da precipitação com o modelo geoestatístico

wave, para o período de cultivo de milho de 2ª safra, no estado do Paraná, bem como identificar a estrutura de dependência espacial, visando identificar períodos ideais para a semeadura do milho de 2ª safra.

4 MATERIAL E MÉTODOS

4.1 Área de estudo

A área de estudo é o estado do Paraná (Figura 1) o qual é predominantemente agrícola, e está localizado na região sul do Brasil, com uma extensão territorial aproximada de 200.000 km² (IBGE, 2017). Segundo Aparecido et al. (2016), com a classificação climática KT, o estado possui dois diferentes grupos climáticos (A e C) com quatro classes (Aw, Cwa, Cfa e Cfb), sendo predominante a classe Cfa (clima temperado úmido com verão quente) com 50% do território estadual, e por segundo Cfb (clima temperado úmido com verão moderadamente quente) com 39,8% do território. As classes Aw e Cwa têm predominância na região norte do estado, com 5,7 e 4,3% da área total, respectivamente.

Figura 1. Mapa da localização das estações meteorológicas e virtuais do ECMWF do estudo

4.2 Base de dados

Os dados de precipitação foram obtidos na base de dados livre do HidroWeb da Agência Nacional das Águas (ANA, 2017). No total, foram utilizados 426 pontos amostrais (Figura 1), sendo 387 deles de estações meteorológicas de várias entidades nacionais e 39 estações virtuais (pixels do *raster*) adquiridos na base de dados do modelo ECMWF (*European Center for Medium-Range Weather Forecast*) (ECMWF, 2017), aproveitadas para preencher a região noroeste do estado, da qual não havia dados disponíveis.

4.3 Determinação do período crítico do milho 2ª safra para análise da variabilidade espacial da precipitação

A escala utilizada foi decendial (dez dias) para o período definido pela estimativa de datas do ciclo fenológico do milho 2ª safra, em que o início médio (70º dia) do

estágio reprodutivo do milho, no estado do Paraná, foi no primeiro decêndio de abril até a colheita média (primeiro decêndio de outubro) nos anos de 1996 a 2015. Este período foi definido baseado em imagens do índice de vegetação EVI (*Enhanced Vegetation Index*) dos produtos MOD13Q1 e MYD13Q1 do sensor MODIS a bordo dos satélites Terra e Aqua, respectivamente, com resolução espacial de 250 m e resolução temporal de 16 dias. Utilizaram-se os mapeamentos do milho 2ª safra, dos anos de 2012 a 2014 obtidos por Santos et al. (2019), para a delimitação da área de cultivo. Com a série temporal de dados de satélite, foram gerados o padrão espectro-temporal de EVI do sensor MODIS, e destes, estimou-se as datas do ciclo fenológico do milho (semeadura, máximo desenvolvimento vegetativo e colheita), conforme metodologia empregada por Johann et al. (2016).

4.4 Análise exploratória

A análise exploratória proporciona uma compreensão sobre os dados, auxiliando a tomada de decisão sob a necessidade de adaptação dos mesmos, fazendo com que os dados representem a informação adequada para ajustes de modelos geostatísticos. Assim, com a inexistência de normalidade nos dados, transformou-se os dados pelo método de Box e Cox (1964), apresentado na Equação 1.

$$Y(s_i) = \begin{cases} \ln(Z(s_i)), & \lambda = 0 \\ \frac{Z(s_i)^\lambda - 1}{\lambda}, & \lambda \neq 0 \end{cases} \quad (1)$$

Em que λ é o parâmetro que define a transformação estimada para os dados; $Z(s_i)$ é o valor dos dados originais, para $i = 1, \dots, n$; $Y(s_i)$ é o valor dos dados processados, para $i = 1, \dots, n$.

4.5 Variabilidade espacial

A variabilidade espacial da precipitação no tempo, proporcionam tomadas de decisões relevantes em diversas áreas que possuem dependência desta variável, como a agricultura. Com o uso da geostatística, é possível avaliar a variabilidade espacial, possibilitando a representação de variáveis climáticas, dada por métodos de estimações de parâmetros, como o método de Máxima Verossimilhança (ML) (URIBE-OPAZO; BORSSOI; GALEA, 2012; CRESSIE, 2015), que possibilita a identificação de uma estrutura de dependência espacial dos dados.

O estimador clássico da função de semivariância de Matheron (Equação 2) é aplicado em análises de dependência espacial, indicando a variabilidade dos dados, bem como a autocorrelação existente entre os mesmos, por via de uma distância euclidiana (CRESSIE, 2015).

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

Em que $Z(s_i)$ são os valores observados na posição $s_i = (x_i, y_i) \in \mathcal{S} \subset \mathbf{R}^2$, na qual \mathcal{S} é o espaço paramétrico, \mathbf{R}^2 o espaço euclidiano bidimensional, e $N(h)$ é o número de pares separados pela distância h .

Utilizando o pacote geoR (DIGGLE E RIBEIRO JUNIOR, 2007) pode-se analisar essa variabilidade espacial, bem como determinar a estrutura de dependência espacial, indicando intervalos de ocorrência da variável em um determinado espaço, bem como encontrando possíveis tendências direcionais que caracterizam o ajuste de um modelo anisotrópico. Havendo anisotropia (Fa) é possível definir o grau desta tendência direcional, como a razão entre a maior e a menor direção de continuidade espacial (GUEDES et al., 2008).

Dentro da geostatística, existem variados modelos teóricos, sendo os mais comuns os Gaussiano, exponencial, esférico e família Matérn. No entanto, existem outros modelos com aplicações específicas, como o modelo *wave* (Equação 3), usualmente aplicável a variáveis meteorológicas (ISAAKS E SRIVASTAVA, 1989; CRESSIE, 2015).

$$\gamma(h) = \begin{cases} \varphi_1 + \varphi_2 \left(1 - \frac{\varphi_3}{h} \sin\left(\frac{h}{\varphi_3}\right)\right), & h > 0 \\ 0, & h = 0 \end{cases} \quad (3)$$

Em que os parâmetros φ_1 é denominado de efeito pepita (nugget), φ_2 de contribuição, $C = \varphi_1 + \varphi_2$ é o patamar, a é o alcance (range), sendo $a = g(\varphi_3)$ é uma função senoidal em torno de h , dependente do parâmetro φ_3 , o qual h é a distância euclidiana entre os pontos (ISAAKS E SRIVASTAVA, 1989; CHILÈS E DELFINER, 2012; WEBSTER E OLIVER, 2007). O modelo *wave* permite autocorrelação positiva e negativa. Ele

flutua sobre a contribuição, ou seja, atinge a contribuição periodicamente, e as flutuações diminuem com o aumento da distância entre as observações.

Com os semivariogramas gerados, os modelos teóricos foram ajustados, para posteriormente construir os mapas espaciais decendiais da precipitação, por meio da interpolação por krigagem, que estima valores em regiões que não se tem dados, com variância mínima. A partir dos parâmetros ajustados dos modelos, foram determinados o Índice de Dependência Espacial ($IDE = \frac{\varphi_1}{\varphi_1 + \varphi_2} \times 100$), que classifica a dependência espacial em três classes: se o valor do índice for $IDE \leq 25\%$ caracteriza uma forte dependência espacial; se estiver entre $25 < IDE \leq 75\%$ tem-se uma moderada dependência espacial, e se $IDE > 75\%$ a variável apresenta uma baixa dependência espacial (CAMBARDELLA et al., 1994).

De acordo com Isaak e Srivastava (1989), é possível avaliar os erros de estimação, indicando a eficiência do ajuste do modelo teórico com base no semivariograma, com o uso da validação cruzada apresentada na Equação 4 (DE BASTIANI et al., 2015).

$$VC = \frac{1}{n} \sum_{i=1}^n \left\{ \frac{z(s_i) - \hat{z}_{(i)}(s_i)}{1 - h_{ii}} \right\}^2, \quad (4)$$

Em que, $\hat{z}_{(i)}(s_i)$ é a predição obtida por krigagem na localização s_i sem considerar a i -ésima observação, h_{ii} é o i -ésimo componente da diagonal da matriz de projeção $\mathbf{H} = \mathbf{1}(\mathbf{1}^T \hat{\Sigma}^{-1} \mathbf{1})^{-1} \mathbf{1}^T \hat{\Sigma}^{-1}$, para $i = 1, \dots, n$.

5 RESULTADOS E DISCUSSÃO

5.1 Determinação do período crítico de cultivo do milho 2ª safra no Paraná

A distribuição espacial da produção do milho 2ª safra no Paraná é heterogênea, com maior concentração nas regiões oeste, centro ocidental e norte central (Figura 2). Os mapas ainda apresentam a estimativa dos períodos de semeadura (Figuras 2a), máximo desenvolvimento vegetativo (Figuras 2b) e colheita (Figuras 2c), obtidas por meio da análise do perfil espectral-temporal do EVI, para os mapeamentos da cultura no estado. Pode-se observar que nos três anos analisados (Figura 2), que houve semeadura a partir do final do mês de janeiro até o início do mês de abril, a qual ocorreu, provavelmente, logo após o cultivo da safra de soja, corroborando com Johann et al. (2016), que obtiveram datas estimadas de colheita de soja variando entre a metade do mês de janeiro e primeiro decêndio de abril, no estado do Paraná, para os anos 2011/2012.

O período reprodutivo do milho 2ª safra se dá aproximadamente aos 70 dias após a emergência (MAGALHÃES E DURÃES, 2006). Como a diferença entre as datas mínimas de semeadura e as datas de máximo desenvolvimento vegetativo foi de 98 dias para o estado (Tabela 1), bem como o tempo para a cultura atingir o período reprodutivo, considerou-se três decêndios antes dos 98 dias, como o início do período de análise. As datas mínimas, máximas e médias da semeadura, máximo desenvolvimento vegetativo e colheita para todo estado são detalhadas na Tabela 1.

Figura 2. Mapas das datas estimadas da (a) semeadura, (b) máximo desenvolvimento vegetativo e (c) colheita, para os anos 2012, 2013 e 2014

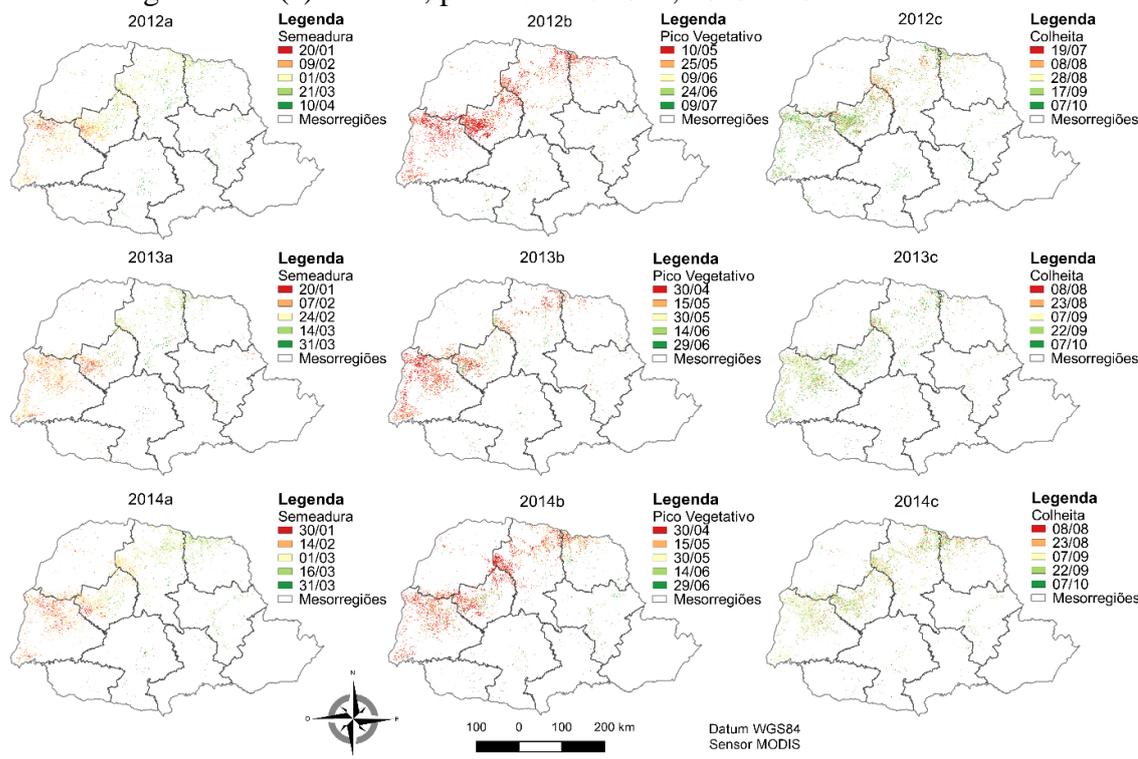


Tabela 1. Datas estimadas do ciclo fenológico do milho 2ª safra, por meio de imagens do sensor MODIS

		Data Estimada	Decêndio
Semeadura	Mínimo	29/jan	3°Dec
	Máximo	31/mar	3°Dec
	Médio	02/mar	1°Dec
Máximo Desenvolvimento Vegetativo	Mínimo	07/mai	1°Dec
	Máximo	06/jul	1°Dec
	Médio	27/mai	3°Dec
Colheita	Mínimo	09/ago	1°Dec
	Máximo	06/out	1°Dec
	Médio	10/set	1°Dec

Dec.: Decêndio.

Assim, o intervalo definido foi do primeiro decêndio de abril até o primeiro decêndio de outubro, que foi a data máxima de colheita no estado. Os anos utilizados na série histórica foram de 1996 a 2015, totalizando então 380 decêndios. Com o período de análise definido, deu-se sequência nas análises geoestatísticas individualmente a cada decêndio.

5.2 Análise estatística descritiva da precipitação

Conforme a Tabela 2, cada estatística indica-se um valor mínimo e um máximo, considerando todos os 380 decêndios. A variação mínima decendial da precipitação no período foi de 0 a 35,40 mm, e a variação máxima de 1,50 a 564,60 mm. As amplitudes da média e mediana estiveram próximas, indicando que a média da série

histórica analisada esteve próxima ao valor central do conjunto de dados.

Tabela 2. Análise descritiva dos dados de precipitação (mm) dos anos de 1996 até 2015

Estatísticas	Valor Mín.	Dec. Mín.	Valor Máx.	Dec. Máx.
Mínimo	0	*	35,40	3º/05/2004
Máximo	1,5	2º/08/2004	564,60	3º/04/1998
1º Quartil	0	*	153,67	3º/06/2013
Mediana	0	*	199,85	3º/06/2013
3º Quartil	0	*	278,87	1º/06/2014
Média	0,01	2º/08/2004	202,85	3º/06/2013
Variância	0,01	2º/08/2004	16.971,68	1º/06/2014
D.P.	0,11	2º/08/2004	130,27	1º/06/2014
C.V.	26,70%	1º/09/1996	1.080,50%	1º/08/2001
Assimetria	-0,25	2º/07/2009	17,83	1º/08/2001
Curtose	-1,02	2º/08/2011	340,60	1º/08/2001

Min.: Mínimo; Máx.: Máximo; Dec.: Decêndio; D.P.: Desvio Padrão; C.V.: Coeficiente de variação; *: Mais de um decêndio com o mesmo valor; Xº/Y/Z: 1º ou 2º decêndio/de qual mês/em qual ano.

A dispersão dos dados (desvio padrão) dos valores mínimos de precipitação (Tabela 2) mostrou variação de 0,11 a 130,27 mm, com coeficiente de variação de 26,70%, enquadrado como média dispersão (PIMENTEL-GOMES, 2009), indicando homogeneidade. Ao contrário, o valor máximo da precipitação teve um coeficiente de variação alto (1.080,50%), enquadrando-se como heterogêneo.

A maioria dos decêndios não apresentaram-se assimétricos a 5% de significância (JONES, 1969), levando a não normalidade dos dados, semelhante ao encontrado por Carvalho; Vieira; Grego (2009), que ao analisarem dados anuais de precipitação, no estado de São Paulo, também constataram inexistência de normalidade nos dados. Sendo assim, houve

a necessidade de transformação nos dados pelo método de Box e Cox (Equação 1), ajustando o valor do parâmetro $\hat{\lambda} = 0,27$, para que os dados passassem a ter normalidade, para as análises subsequentes.

5.3 Variabilidade espacial

Por meio do modelo geoestatístico *wave* foram ajustados, para os 380 decêndios, os parâmetros geoestatísticos que descrevem a variabilidade. Entre todos os decêndios, 188 deles apresentaram tendências direcionais. Assim, a estatística descritiva dos parâmetros ajustados dos modelos, representam esta variação temporal (Tabela 3).

Tabela 3. Estatística descritiva dos parâmetros estimados do modelo geoestatístico *wave* ajustado para os decêndios (1º Dec. de abril a 1º Dec. de outubro) analisados da série histórica (1996 a 2015)

Estatísticas	$\hat{\varphi}_1$	$\hat{\varphi}_2$	$\hat{\varphi}_3$	Fa	\hat{a} (km)
Mínimo	0,00	0,00	0,89	1,00	2,68
Máximo	78.342,00	18.188,37	159,74	17,05	477,87
Mediana	173,28	353,02	29,78	1,00	89,09
Média	474,62	975,50	34,02	1,74	101,69
D.P.	4.016,11	1.821,27	21,16	1,69	63,39

D.P.: Desvio Padrão; $\hat{\varphi}_1$: Efeito Pepita estimado; $\hat{\varphi}_2$: Contribuição estimada; $\hat{\varphi}_3$: Parâmetro estimado, em função do alcance; Fa: Fator de Anisotropia; \hat{a} : Alcance estimado em km.

Percebe-se que o raio de dependência espacial estimada (\hat{a}) entre todos os decêndios variou de 2,68 a 477,87 km, com um desvio padrão de 63,39 km entorno da média. A dependência espacial média que foi de 101,69 km esteve próxima à mediana, indicando que a média esteve próxima ao meio dos valores analisados.

Considerando o fato do estado do Paraná possuir aproximadamente 650 km de um extremo ao outro, contata-se que a maior dependência espacial estimada (477,87 km) se aproximou da extensão total da área de

estudo, corroborando com Baú et al. (2006), que analisando a região oeste do Paraná, também encontraram uma dependência espacial máxima aproximada a extensão máxima da área de estudo.

Como o decêndio médio em que a cultura do milho 2ª safra atinge o máximo desenvolvimento vegetativo é o 3º decêndio de maio (Tabela 1), ajustaram-se os parâmetros (Tabela 4) e os mapas (Figura 3) para todos os 3º decêndios de maio da série histórica (1996 a 2015).

Tabela 4. Parâmetros estimados do modelo geoestatístico *wave* para o 3º decêndio de maio, entre 1996 e 2015

Anos	$\hat{\varphi}_1$	$\hat{\varphi}_2$	$\hat{\varphi}_3$	Fa	\hat{a} (km)	$\hat{\varphi}_1 + \hat{\varphi}_2$	IDE
1996	163,70	434,79	30,26	-	90,53	598,49	27,35%
1997	783,84	3.722,92	60,85	1,00	182,02	4.506,76	17,39%
1998	98,23	85,54	34,17	-	102,21	183,77	53,45%
1999	123,03	686,99	87,45	1,00	261,60	810,02	15,19%
2000	47,23	62,16	19,93	1,88	59,63	109,39	43,18%
2001	360,53	556,66	25,87	1,84	77,38	917,19	39,31%
2002	389,37	710,15	25,77	1,27	77,10	1.099,52	35,41%
2003	77,46	195,82	14,37	-	42,98	273,28	28,34%
2004	527,15	1.072,44	36,63	-	109,57	1.599,59	32,96%
2005	693,03	662,87	34,91	-	104,43	1.355,90	51,11%
2006	39,84	69,61	25,65	2,04	76,74	109,45	36,40%
2007	462,06	722,37	65,82	1,34	196,90	1.184,43	39,01%
2008	99,24	194,90	19,33	-	57,82	294,14	33,74%
2009	467,07	1.917,65	36,20	1,00	108,29	2.384,72	19,59%
2010	62,50	205,72	54,42	1,00	162,81	268,22	23,30%
2011	33,69	9,35	9,03	-	27,01	43,04	78,27%
2012	246,78	402,35	17,05	-	51,02	649,13	38,02%
2013	512,92	1.400,97	41,99	1,00	125,61	1.913,89	26,80%
2014	493,57	519,78	49,03	-	146,67	1.013,35	48,71%
2015	854,98	1.600,70	122,88	1,11	367,58	2.455,68	34,82%

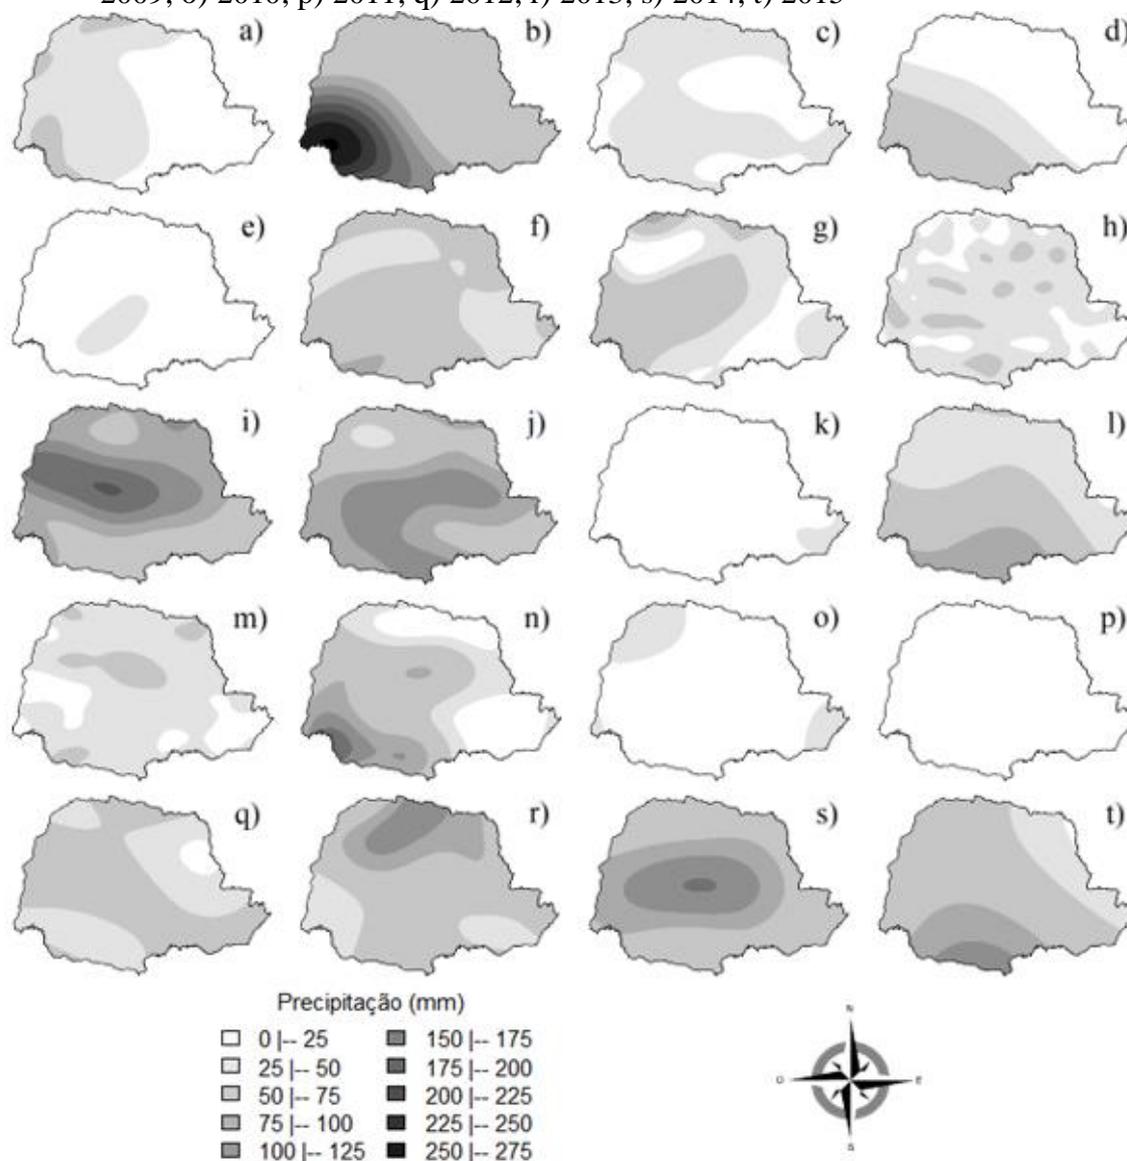
$\hat{\varphi}_1$: Efeito Pepita estimado; $\hat{\varphi}_2$: Contribuição estimada; $\hat{\varphi}_3$: Parâmetro estimado, em função do alcance; \hat{a} : Alcance estimado em km; $\hat{\varphi}_1 + \hat{\varphi}_2$: Patamar; IDE: Índice de dependência espacial.

A variação de dependência espacial estimada (\hat{a}) foi de 27,01 a 367,58 km nesses decêndios (Tabela 4), apresentando na maioria deles um IDE equivalente a uma moderada dependência espacial, com exceção nos anos 1997, 1999, 2009 e 2010, nos quais houve uma forte dependência

espacial e o ano de 2011 que apresentou uma baixa dependência espacial.

Ainda nota-se que a maioria dos decêndios do o máximo desenvolvimento vegetativo do milho 2ª safra, apresentaram uma tendência direcional, indicando um comportamento anisotrópico (Tabela 4).

Figura 3. Mapas de precipitação (mm) pelo método de krigagem ordinária para o decêndio médio (3° Dec. de Maio), para série histórica: a) 1996; b) 1997; c) 1998; d) 1999; e) 2000; f) 2001; g) 2002; h) 2003; i) 2004; j) 2005; k) 2006; l) 2007; m) 2008; n) 2009; o) 2010; p) 2011; q) 2012; r) 2013; s) 2014; t) 2015



A precipitação no 3° decêndio de maio apresentou variações espaço-temporal, sem comportamentos padrões ano após ano. Para maioria dos anos, houve concentrações de precipitação entre 0 a 100 mm. Os anos 1997, 2004, 2005, 2009, 2013 a 2015 tiveram maior variação, atingindo máximas acima de 150 mm, com destaque no ano de 1997 que teve precipitação máxima acima de 250 mm na região oeste do estado do Paraná, indicando um ano fora do padrão de precipitação neste decêndio.

Como o milho necessita de mais água no seu período reprodutivo (FANCELLI, 2015), o período médio de semeadura (1° decêndio de março) é uma data média viável para que a planta inicie seu ciclo fenológico para que no 3° decêndio do mês de maio a cultura atinja o máximo desenvolvimento vegetativo, considerando que ao longo do tempo, neste período, houve a ocorrência de precipitação praticamente em todo o estado do Paraná.

A realidade das variáveis que influenciam no desenvolvimento da cultura, além da precipitação e da época da colheita da soja, permitindo a troca do cultivo para o milho, varia de uma mesorregião para outra. Contudo, em escala estadual, nota-se também, com base nos mapas (Figura 3), que algumas regiões possuem maiores ocorrências de precipitação, podendo melhorar os resultados da produção.

5.4 Validação cruzada dos modelos

Com a validação cruzada analisou-se o ajuste do modelo *wave* para a precipitação no 3º decêndio de maio do ano de 2015 (Tabela 5), para comparar por meio da validação cruzada o ajuste com os demais modelos geoestatísticos mais conhecidos (exponencial, Gaussiano, Mátern k=1 e k=1,5) (DE BASTIANI et al., 2015).

Tabela 5. Validação cruzada para comparação do modelo *wave* com os demais modelos

Modelos	Validação Cruzada
Wave	1636,97
Exponencial	1641,14
Gaussiano	1633,09
Mátern k=1	1636,17
Mátern k=1.5	1634,96

A análise de validação cruzada do modelo *wave* apresentou bons resultados em comparação aos demais modelos (Tabela 5), indicando que o modelo *wave* é um modelo adequado para ser utilizado na análise da variabilidade da precipitação como é estudado por Mota et al. (2008).

6 CONCLUSÕES

Com o modelo geoestatístico *wave*, foi possível demonstrar que o padrão da precipitação é heterogêneo, tanto de forma espacial como temporal, indicando anos com frequência de precipitação de 0 a 100 mm no 3º decêndio de maio e, outros ultrapassando a máxima de 150 mm, como o ano de 1997 que foi atípico quanto ao padrão espaço-temporal do período analisado, e que atingiu uma máxima acima de 250 mm concentrado na região oeste do estado do Paraná. A dependência espacial da precipitação no estado do Paraná foi moderada para a maioria dos anos do 3º decêndio de maio, com alcance variando de 50 a 367 km. Isto indica forte dependência espacial para os anos 1997, 1999, 2009 e 2010, com alcance de 182, 261, 108, e 162 km,

respectivamente. Apenas 2011 apresentou baixo índice de dependência espacial, com alcance de 27 km.

Conclui-se que o período médio ideal, para a semeadura de milho 2ª safra, no estado do Paraná, é o 1º decêndio de março, visto que com isto cultura atingirá o máximo desenvolvimento vegetativo no 3º decêndio de maio, que foi o período com a melhor condição espaço-temporal de precipitação para o milho.

A validação cruzada, demonstrou que o modelo *wave*, é apropriado para representar o padrão da precipitação.

7 AGRADECIMENTOS

Agradecemos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001, pelo auxílio, a Universidade Estadual do Oeste do Paraná (UNIOESTE), Laboratório de Estatística Espacial-LEE/UNIOESTE, a Agência Nacional das Águas (ANA) e ao *Europe Centre for*

Medium-Range Weather Forecasts
(ECMWF) pela base de dados.

8 REFERÊNCIAS

- AGÊNCIA NACIONAL DAS ÁGUAS. **HidroWeb**: Sistemas de informações hidrológicas. Brasília: ANA, 2017. Disponível em: <<https://www.snirh.gov.br/hidroweb/>>. Acesso em: 06 nov. 2017.
- AGUIAR, J. T.; LOBO JR, M. Reliability and discrepancies of rainfall and temperatures from remote sensing and Brazilian ground weather stations. **Remote Sensing Applications: Society and Environment**, New York, v. 18, n. 2, p. 1-9, abr. 2020.
- APARECIDO, L. E. O.; ROLIM, G. S.; RICHETTI, J.; SOUZA, P. S.; JOHANN, J. A. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. **Ciência e Agrotecnologia**, Lavras, v. 40, n. 4, p. 405–417, 2016.
- ARAI, F. K.; GONÇALVES, G. G. G.; PEREIRA, S. B.; COMUNELLO, É.; VITORINO, A. C. T.; DANIEL, O. Espacialização da precipitação e erosividade na Bacia Hidrográfica do Rio Dourados - MS. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 5, p. 922-931, 2010.
- BAÚ, A. L.; GOMES, B. M.; QUEIROZ, M. M. F.; OPAZO, M. A. U.; SAMPAIO, S. C. Comportamento Espacial da precipitação pluvial mensal provável da mesorregião oeste do estado do Paraná. **Irriga**, Botucatu, v. 11, n. 2, p. 150-168, 2006.
- BECK, H. E.; VERGOPOLAN, N.; PAN, M.; LEVIZZANI, V.; DIJK, A. I. J. M.; WEEDON, G. P.; BROCCA, L.; PAPPENBERGER, F.; HUFFMAN, G. J.; WOOD, E. F. Global-scale evaluation of 22 precipitation datasets using gauge observations and hydrological modeling. **Hydrology and Earth System Sciences**, Göttingen, v. 21, n. 12, p. 6201–6217, 2017.
- BENOIT, L.; MARIETHOZ, G. Generating synthetic rainfall with geostatistical simulations. **WIRES Water**, New York, v. 4, n. 2, p. 1-16, 2017.
- BOX, G. E. P.; COX, D. R. An analysis of transformations. **Journal of the Royal Statistical Society**, Londres, v. 26, n. 2, p. 211-252, 1964.
- CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURCO, R. F.; KONOPKA, A. E. Field-Scale Variability of Soil Properties in Central Iowa Soils. **Soil Science Society of America Journal**, Madison, v. 58, n. 5, p. 1501-1511, 1994.
- CARDOSO, C. O.; FARIA, R. T.; FOLEGATTI, M. V. Simulação do rendimento e riscos climáticos para o milho safrinha em Londrina - PR, utilizando o modelo CERES-Maize. **Engenharia Agrícola**, Jaboticabal, v. 24, n. 2, p. 291–300, 2004.

CARVALHO, J. R. P.; VIEIRA, S. R.; GREGO, C. R. Comparação de métodos para ajuste de modelos de semivariograma da precipitação pluvial anual. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 13, n. 4, p. 443-448, 2009.

CAVALCANTE, R. B. L.; FERREIRA, D. B. S.; PONTES, P. R. M.; TEDESCHI, R. G.; COSTA, C. P. W.; SOUZA, E. B. Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia. **Atmospheric Research**, Amsterdã, v. 238, n. 1, p. 1-12, 2020.

CHILÈS, J.-P.; DELFINER, P. **Geostatistics: Modeling Spatial Uncertainty**. New York: John Wiley and Sons, 2012, 734 p.

CRESSIE, N. A. C. **Statistics for Spatial Data**. Canada: Wiley, 2015, 903 p.

DE BASTIANI, F.; CYSNEIROS, A. H. M.; URIBE-OPAZO, M. A.; GALEA, M. Influence diagnostics in elliptical spatial linear models. **TEST: Na Official Journal of the Spanish Society of Statistics and Operations Research**, Madrid, v. 24, n. 2, p. 322-340, 2015.

DIGGLE, P. J.; RIBEIRO JUNIOR, P. J. **Model-based Geostatistics**. New York: Springer, 2007, 230 p.

DINKU, T. The Value of Satellite Rainfall Estimates in Agriculture and Food Security. *In*: Levizzani V., Kidd C., Kirschbaum D., Kummerow C., Nakamura K., Turk F. (eds) **Satellite Precipitation Measurement**. Springer, Cham, v. 69, 2020. p. 1113-1129.

EUROPEAN CENTRE FOR MEDIUM-RANGE WEATHER FORECASTS. **What we do**. Reading: ECMWF, 2017. Disponível em: <<https://www.ecmwf.int/en/about/what-we-do>>. Acesso em: 24 mai. 2017.

FANCELLI, A. L. Cultivo racional e sustentável requer maior conhecimento sobre planta do milho. **Revista Visão Agrícola**, Piracicaba, v. 1, n. 13, p. 20-23, 2015.

GUEDES, L. P. C.; URIBE-OPAZO, M. A.; JOHANN, J. A.; SOUZA, E. G. Anisotropia no estudo da variabilidade espacial de algumas variáveis químicas do solo. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 32, n. 6, p. 2217-2226. 2008.

IBGE. **Território e Ambiente: Área da unidade territorial**. Curitiba: IBGE, 2017. Disponível em: <<https://cidades.ibge.gov.br/brasil/pr/panorama>>. Acesso em: 05 abr. 2018.

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

JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. Uso de imagens do sensor orbital modis na estimação de datas do ciclo de desenvolvimento da cultura da soja para o estado do Paraná - Brasil. **Engenharia Agrícola**, Jaboticabal, v. 36, n. 1, p. 126-142, 2016.

JONES, T. A. Skewness and kurtosis as criteria of normality in observed frequency distributions. **Journal of Sedimentary Research**, Tusla, v. 39, n. 4, p. 1622–1627. 1969.

LANGE, A.; CAIONE, G.; SCHONINGER, E. L.; SILVA, R. G. Productivity of outonal-corn intercropped with grass marandu according to nitrogen sources and rates. **Revista Brasileira de Milho e Sorgo**, Sete Lagoas, v. 13, n. 1, p. 35-47, 2014.

KESTRING, F. B. F.; GUEDES, L. P. C.; DE BASTIANI, F.; URIBE-OPAZO, M. A. Comparação de mapas temáticos de diferentes grades amostrais para a produtividade da soja. **Engenharia Agrícola**, Jaboticabal, v. 35, n. 4, p. 733-743, 2015.

MAGALHÃES, P. C.; DURÃES, F. O. M. **Fisiologia da Produção de Milho**. Sete Lagoas: Embrapa, 2006.

MEIRELLES, W. C. L.; ZÁRATE, L. E. Data mining in the reduction of the number of places of experiments for plant cultivates. **Computers and Electronics in Agriculture**, New York, v. 113, n.4, p. 136-147, 2015.

MOTA, V. C.; LIMA, R. R.; ALVES, M. C.; OLIVEIRA, M. S.; CARVALHO, L; G. Dependência temporal da precipitação pluvial e da temperatura do ar em Juiz de Fora, MG, por meio de análises geoestatísticas. **Revista Brasileira de Agrometeorologia**, São José dos Campos, v. 16, n. 3, p. 249–258, 2008.

PARANÁ. Secretaria da Agricultura e do Abastecimento. **Levantamento da Produção Agropecuária**. Curitiba: Celepar, 2020. Disponível em: <<http://www.agricultura.pr.gov.br/deral/ProducaoAnual>>. Acesso em: 24 mai. 2020.

PARDO-IGÚZQUIZA, E.; DOWD, P. A. Comparison of inference methods for estimating semivariogram model parameters and their uncertainty: The case of small data sets. **Computers and Geosciences**, New York, v. 50, n. 1, p. 154-164, 2013.

PIMENTEL-GOMES, F. **Curso de estatística experimental**. 15 ed. Piracicaba: FEALQ, 2009.

ROY, S. K.; DE, D. Genetic Algorithm based Internet of Precision Agricultural Things (IopAT) for Agriculture 4.0. **Internet of Things**, v. 9, n. 1, p. 1-19, 2020.

SANTOS, L. D. C.; JOSÉ, J. V.; ALVES, D. S.; NITSCHKE, P. R.; REIS, ELTON, FIALHO.; BENDER, F. D. Space-time variability of evapotranspiration and precipitation in the State of Paraná, Brazil. **Ambiente e Agua: An Interdisciplinary Journal of Applied Science**, Taubaté, v. 12, n. 5, p. 743-759, 2017.

SANTOS, R. N., MERCANTE, E., JOHANN, J. A., SOUZA, C. H. W., CATTANI, C. E. V., PALUDO, A. Mapping of Winter Crops and Second-Crop Corn in the Paraná State-Brazil, Using Multitemporal Images From MODIS Sensor. **Journal of Agricultural Science**, Ottawa, v. 11, n. 2, p. 477-488. 2019.

SRIVASTAVA, K.; BHUTORIA, A. J.; SHARMA, J. K.; SINHA, A.; PANDEY, P. C. UAVs technology for the development of GUI based application for precision agriculture and environmental research. **Remote Sensing Applications: Society and Environment**, New York, v. 16, n. 4, p. 1-14, 2019.

TORRES, M. O.; HOWITT, R.; RODRIGUES, L. N. Modeling the economic benefits and distributional impacts of supplemental irrigation. **Water Resources and Economics**, Amsterdam, v. 14, n. 2, p. 1–12, 2016.

TORRES, M.; HOWITT, R.; RODRIGUES, L. Analyzing rainfall effects on agricultural income: Why timing matters. **EconomiA**, Niterói, v. 20, n. 1, p. 1–14, 2019.

URIBE-OPAZO, M. A.; BORSSOI, J. A.; GALEA, M. Influence diagnostics in Gaussian spatial linear models. **Journal of Applied Statistics**, Abingdon, v. 39, n. 3, p. 615-630, 2012.

WEBSTER, R.; OLIVER, M. A. **Geostatistics for Environmental Scientists**. Ed. 2, Madison: John Wiley & Sons, Ltd, 2007, 321 p.

ZUO, D.; CAI, S.; XU, Z.; PENG, D.; KAN, G.; SUN, W.; PANG, B.; YANG, B. Assessment of meteorological and agricultural droughts using in-situ observations and remote sensing data. **Agricultural Water Management**, Amsterdam, v. 222, n. 12, p. 125–138, 2019.