

## SELEÇÃO DE MODELOS DE PREVISÃO DE PRECIPITAÇÃO COM PADRÃO-OURO

MARCIO PAULO DE OLIVEIRA<sup>1</sup>, MIGUEL ANGEL URIBE-OPAZO<sup>2</sup>,  
JERRY ADRIANI JOHANN<sup>3</sup>, MANUEL GALEA<sup>4</sup>

<sup>1</sup> Prof. Dr. UTFPR, Toledo, (45) 3379-6800, marcioliveira@utfpr.edu.br

<sup>2</sup> Prof. Dr. UNIOESTE, Cascavel, (45) 32203228, miguel.opazo@unioeste.br

<sup>3</sup> Prof. Dr. UNIOESTE, Cascavel, (45) 32207320, jerry.johann@hotmail.com

<sup>4</sup> Prof. Dr. PUC, Santiago, Chile, (562) 2354 4000, mgalea@mat.uc.cl

Apresentado no  
XLIX Congresso Brasileiro de Engenharia Agrícola - CONBEA 2020  
23 a 25 de novembro de 2020 - Congresso On-line

**RESUMO:** Nas ciências agrárias a previsão de dados agrometeorológicos de precipitação pluviométrica é importante e se destaca devido aos impactos que o excesso ou o déficit hídrico podem causar no desenvolvimento de culturas agrícolas. O objetivo deste trabalho foi de propor uma metodologia de seleção de previsões de precipitação na presença de um padrão-ouro, medidas com erro desprezível. Nesse estudo, foram consideradas padrão-ouro os dados de precipitações obtidas das estações meteorológicas da Agência Nacional de Águas (ANA). Os métodos de previsão foram os utilizados pelos centros *Canadian Meteorological Center (CMC)*, *European Centre for Medium-Range Weather Forecasts (ECMWF)*, *National Centers for Environmental Prediction (NCEP)* e Centro de Previsão de Tempo e Estudos Climáticos (CPTEC). A mesorregião Oeste do Paraná foi a área de estudo, com dados, agrupados em decêndios, no período de outubro a março dos anos-safra de soja de 2010/2011 a 2015/2016. Os resultados mostraram que a escolha de um centro de previsão deve considerar a faixa de valores e a localização geográfica. A metodologia proposta permitiu mapear a seleção de centros de previsões em áreas de interesse.

**PALAVRAS-CHAVE:** concordância, variação espacial, previsão de precipitação.

## SELECTION OF PRECIPITATION PRECISION MODELS WITH GOLD STANDARD

**ABSTRACT:** In agrarian sciences, forecasting of agrometeorological rainfall data is important and stands out due to impacts caused by water excess or deficit on crop growth. This study aimed to propose a method for selecting rainfall forecasts in presence of a gold standard, which are reference measures with negligible error. In this study, rainfall data obtained from the National Water Agency (NWA) weather stations were considered the gold standard. The forecasting models were those used by the Canadian Meteorological Center (CMC), European Center for Medium-Range Weather Forecasts (ECMWF), National Centers for Environmental Prediction (NCEP), and Center for Weather Forecasting and Climate Studies (CPTEC). The study area was the western mesoregion of Paraná State, and data, clustered in 10-day periods, were gathered within the period between October to March in the soybean crop years from 2010/2011 to 2015/2016. Results showed that selecting a forecasting

center should consider the range of rainfall values and geographic location. The proposed method allowed mapping selection of forecast centers in areas of interest.

**KEYWORDS:** agreement, spatial variation, rainfall forecast.

**INTRODUÇÃO:** A água é um fator essencial para o desenvolvimento das culturas agrícolas, e sua disponibilidade adequada contribui para que a cultura expresse seu potencial produtivo. Battisti e Sentelhas (2015) mostraram que quebras de produtividade da cultura da soja, em diferentes regiões produtoras do Brasil apresentam variação e que, em média, 73,8% dessas são provenientes do déficit hídrico. Os modelos utilizados para o monitoramento de culturas, estimativas e previsão de produtividade são influenciados por variáveis agrometeorológicas (BATTISTI, et al., 2018). Portanto, estudos tem sido direcionados com o intuito de quantificar os efeitos que as mudanças nas variáveis agrometeorológicas tem sobre a produtividade de culturas agrícolas (BAO et al., 2015), bem como, sobre a variabilidade espacial da precipitação pluviométrica (CERA, et al., 2017). A precipitação pluviométrica pode ser obtida por meio de estações físicas (estações agrometeorológicas) ou virtuais (modelos de previsão atmosférico). As estações físicas podem ser consideradas o padrão-ouro para dados agrometeorológicos, porém, estão sujeitas a limitações. As estações meteorológicas, normalmente, são esparsas no espaço e em locais cujos dados coletados tem uso primário, como aeroportos e regiões urbanas. Já as estações virtuais possuem a vantagem de oferecer melhor cobertura espacial e temporal de dados sendo adequados para estudos de modelagem agrícola. As estações virtuais são definidas por meio dos centros climáticos mundiais que possuem modelos de previsões que abrangem variáveis agrometeorológicas, como a precipitação pluviométrica. As parametrizações utilizadas em cada centro podem produzir distintas previsões para cada localização geográfica. Assim, este trabalho teve por objetivo propor uma metodologia de comparação das previsões de precipitação pluviométrica com dados das estações no período 2010/2011 a 2015/2016 na mesorregião Oeste do Paraná devido a sua importância no cenário agrícola do estado (SEAB/DERAL, 2019).

**MATERIAL E MÉTODOS:** Os modelos de previsão da base TIGGE utilizados nesta pesquisa foram o canadense CMC, europeu ECMWF, norte americano NCEP e brasileiro CPTEC. Os dados de referência padrão-ouro foram obtidos das observações de precipitação pluviométrica diária das estações da ANA. Os dados diários de previsão de precipitação dos centros CMC, ECMWF, NCEP e CPTEC para o passo de 240 h em cada estação virtual (pixel) possuem uma área de abrangência retangular de 0,5 x 0,5°, sendo apresentados os centroides na Figura 1.

Para a correspondência espacial das estações da ANA com as virtuais foram consideradas as médias das precipitações das estações da ANA dentro da área de abrangência da estação virtual (estações com distância menor ou igual 0,36° do centroide do pixel). Para as comparações os dados foram divididos em quatro classes de mesma amplitude, da seguinte forma: na classe 1 (0,00 |– 61,09 mm) inclui eventos de chuva diária fraca e leve; na classe 2 (61,09 |– 122,18 mm) chuvas leves e moderados; na classe 3 (122,18 |– 183,27 mm) chuvas moderadas e fortes e na classe 4 (183,27 |– 244,36 mm) chuvas fortes e muito fortes (SOUZA et al., 2012).

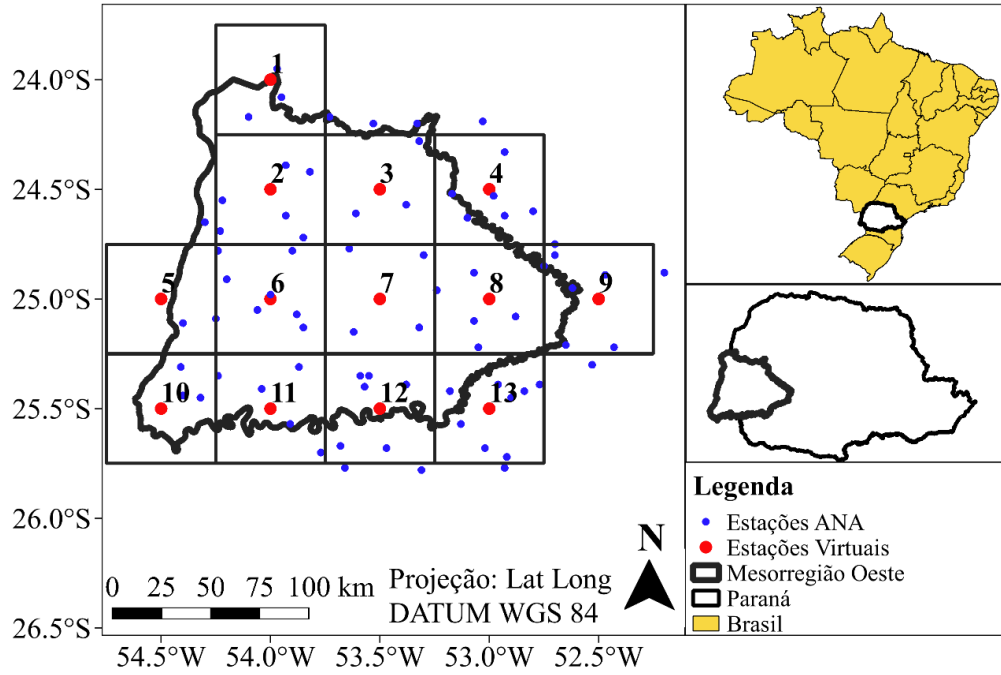


FIGURA 1. Mapa de localização da mesorregião Oeste do Paraná, contendo as estações meteorológicas ANA e estações virtuais dos modelos CMC, ECMWF, NCEP e CPTEC.

O modelo de comparação utilizado para avaliar o grau de concordância entre dois ou mais instrumentos de medição sob presença de um padrão-ouro, ou medida referência foi proposto por Laurent (1998):

$$Y_i = x_i \mathbf{1}_p + \epsilon_i \quad (1)$$

em que,

$Y_i = (y_{i1}, \dots, y_{ip})^T$  é o vetor de medidas  $p \times 1$  dos  $p$  métodos aproximados na unidade  $i$ ;

$\mathbf{1}_p$  é o vetor de uns  $p \times 1$ ;

$\epsilon_i = (\epsilon_{i1}, \dots, \epsilon_{ip})^T$  é o vetor dos erros aleatórios  $p \times 1$  dos  $p$  métodos na unidade  $i$  para  $i = 1, \dots, n$ .

Considerando  $Z_i = (x_i, Y_i^T)^T$ , o vetor  $q \times 1$ , com  $q = p + 1$  de medições feitas pelo padrão-ouro e pelos métodos aproximados na unidade  $i$ . Então, os vetores aleatórios  $Z_i$ , para  $i = 1, \dots, n$ , são independentes e identicamente distribuídos com  $E(Z_i) = \mu \mathbf{1}_q$  e  $Var(Z_i) = V$ .

Supondo  $Z_i$  para  $i = 1, \dots, n$ , são iid com  $N_q(\mu \mathbf{1}_q, V)$ , uma distribuição normal multivariada com vetor de médias  $\mu \mathbf{1}_q$  e matriz de covariância  $V$ , e a função de densidade de probabilidade de  $Z_i$  é dada por:

$$f(z_i, \theta) = (2\pi)^{-q/2} |V|^{-1/2} e^{-\delta_i/2} \quad (2)$$

em que,

$$|\mathbf{V}| = \phi |\boldsymbol{\Sigma}|;$$

$$\delta_i = \delta_i(\boldsymbol{\theta}) = (z_i - \mu \mathbf{1}_q)^T \mathbf{V}^{-1} (z_i - \mu \mathbf{1}_q) = \delta_{ig} + \delta_{ia} \text{ é à distância de Mahalanobis, sendo } \delta_{ig} = (x_i - \mu)^2 / \phi, \delta_{ia} = \mathbf{D}_i^T \boldsymbol{\Sigma}^{-1} \mathbf{D}_i, \boldsymbol{\theta} = (\mu, \phi, \boldsymbol{\sigma})^T;$$

$\boldsymbol{\sigma} = \mathbf{v}(\boldsymbol{\Sigma})$  é o vetor obtido do empilhamento das colunas da matriz  $\boldsymbol{\Sigma}$ , após a eliminação dos elementos supradiagonais, e  $\mathbf{D}_i = \mathbf{Y}_i - x_i \mathbf{1}_p$  para  $i = 1, \dots, n$ , (LAURENT, 1998).

Os estimadores de máxima verossimilhança (EMV) dos parâmetros  $\mu$ ,  $\phi$  e  $\boldsymbol{\sigma}$  são dados, respectivamente, por

$$\hat{\mu} = \bar{x} \quad (3)$$

$$\hat{\phi} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (4)$$

$$\hat{\boldsymbol{\sigma}} = \mathbf{S}_d = \frac{1}{n} \sum_{i=1}^n \mathbf{D}_i \mathbf{D}_i^T \quad (5)$$

em que,  $\bar{x} = \sum_{i=1}^n x_i / n$ .

O EMV do coeficiente de concordância  $\rho_j = \phi / (\phi + \sigma_{jj})$  entre os métodos sob teste e o padrão-ouro são dados por

$$\hat{\rho}_j = \hat{\phi} / (\hat{\phi} + \hat{\sigma}_{jj}) \quad (6)$$

com  $\hat{\sigma}_{jj} = \frac{1}{n} \sum_{i=1}^n (y_{ij} - x_i)^2$  (LAURENT, 1998). Um intervalo de confiança de 100(1 -  $\alpha$ )% é dada por  $\hat{\rho}_j - z_{\alpha} \sqrt{\frac{\hat{v}_{jj}}{n}} \leq \rho_j \leq \hat{\rho}_j + z_{\alpha} \sqrt{\frac{\hat{v}_{jj}}{n}}$  em que  $\hat{v}_{jj}$  é o EMV de  $v_{jj}$ . O *software* R foi utilizado para elaborar a rotina e obter as estatísticas.

**RESULTADOS E DISCUSSÃO:** Considerando cada classe em cada pixel os centros selecionados, os valores das concordâncias estimadas ( $\hat{\rho}$ ) e os limites inferior (L-inf) e superior (L-sup) dos intervalos de 95% de confiança são apresentados na Tabela 1 para as classe 1 (0,00 |– 61,09 mm), classe 2 (61,09 |– 122,18 mm), classe 3 (122,18 |– 183,27 mm) e classe 4 (183,27 |– 244,36 mm). O método de comparação na presença de um padrão-ouro utilizada em cada pixel para cada uma das quatro classes deste trabalho tem por finalidade avaliar a relação de variabilidade da medida padrão-ouro com os erros de previsão Lin (1989), Feng *et al.* (2015) e Chabert *et al.* (2019). Na Tabela 1 pode ser observado que para os valores mais elevados de precipitação, na classe 4, foi obtido a maior concordância de 0,47 com o CPTEC no pixel 8. O intervalo de confiança permite inferir uma concordância entre 0,322 a 0,619 com 95% de confiança. A menor concordância na classe 4 a foi obtida no pixel 8 para o centro CMC com valor 0,295 e intervalo de 95% confiança variando de 0,125 a 0,466. Nas seleções por concordância na Tabela 1 para a classe 1 foi obtido: 7,7% do CMC; 15,4% no NCEP e 76,9% no CPTEC. Na seleção para classe 2 foi obtido: 15,4% do CMC; 38,5% no ECMWF; 15,4% no NCEP e 30,8% no CPTEC. Na classe 3 na seleção por concordância foi obtido: 23,1% do CMC; 15,4% no ECMWF; 38,5% no NCEP e 23,1% no CPTEC. Para as concordâncias da classe 4, na seleção, foi obtido: 30,8% do CMC; 38,5% no ECMWF e 30,8% no CPTEC. As seleções de centros de previsão de chuva podem apresentar variabilidade (OLIVEIRA, et al., 2020).

TABELA 1. Concordâncias estimadas e limites inferior e superior dos intervalos de 95% de confiança dos centros selecionados nas classes nos 13 pixels da mesorregião oeste do Paraná.

	EV	Centro	$\hat{\rho}$	IC <sub>Inf</sub>	IC <sub>Sup</sub>		Centro	$\hat{\rho}$	IC <sub>Inf</sub>	IC <sub>Sup</sub>
Classe 1	1	CPTEC	0,308	0,257	0,358	Classe 2	CPTEC	0,351	0,288	0,415
	2	CPTEC	0,330	0,277	0,384		ECMWF	0,378	0,312	0,444
	3	CPTEC	0,316	0,266	0,366		ECMWF	0,396	0,326	0,466
	4	CPTEC	0,335	0,285	0,385		NCEP	0,347	0,279	0,416
	5	CPTEC	0,319	0,270	0,368		ECMWF	0,324	0,264	0,384
	6	CPTEC	0,338	0,289	0,387		ECMWF	0,382	0,311	0,454
	7	CPTEC	0,317	0,267	0,367		CMC	0,397	0,324	0,470
	8	CPTEC	0,327	0,276	0,378		CPTEC	0,367	0,293	0,441
	9	CPTEC	0,299	0,251	0,347		CMC	0,316	0,251	0,380
	10	NCEP	0,350	0,297	0,403		NCEP	0,355	0,281	0,428
	11	CPTEC	0,306	0,259	0,354		CPTEC	0,349	0,269	0,428
	12	CMC	0,367	0,311	0,422		CPTEC	0,332	0,263	0,402
	13	NCEP	0,338	0,288	0,387		ECMWF	0,369	0,300	0,437
Classe 3	1	ECMWF	0,338	0,229	0,448	Classe 4	CPTEC	0,384	0,204	0,564
	2	CPTEC	0,333	0,237	0,430		CMC	0,447	0,236	0,658
	3	CMC	0,343	0,235	0,452		CMC	0,344	0,183	0,504
	4	NCEP	0,372	0,257	0,486		ECMWF	0,331	0,156	0,505
	5	CPTEC	0,366	0,237	0,495		ECMWF	0,416	0,012	0,844
	6	CPTEC	0,293	0,189	0,398		CMC	0,381	0,125	0,638
	7	NCEP	0,338	0,236	0,441		ECMWF	0,441	0,274	0,608
	8	CMC	0,385	0,279	0,491		CPTEC	0,470	0,322	0,619
	9	NCEP	0,348	0,245	0,451		CMC	0,295	0,125	0,466
	10	NCEP	0,354	0,249	0,460		CPTEC	0,303	0,191	0,414
	11	ECMWF	0,407	0,297	0,518		ECMWF	0,325	0,207	0,444
	12	NCEP	0,330	0,241	0,420		CPTEC	0,428	0,285	0,571
	13	CMC	0,306	0,199	0,413		ECMWF	0,452	0,169	0,735

Nota: EV: Estação Virtual, Centro: centro selecionado,  $\hat{\rho}$ : concordância estimada, IC: intervalo de 95% para  $\rho$  populacional, IC<sub>Inf</sub>: limite inferior, IC<sub>Sup</sub>: limite superior.

Diversos estudos indicam que o déficit de água é o responsável principal por perdas sofridas no cultivo da soja. Nessa cultura a disponibilidade de água é importante, principalmente, em dois períodos de desenvolvimento, germinação-emergência e floração-enchimento de grãos. Em áreas de cultivo que não contam com irrigação são mais afetadas pelo déficit de água gerado por estiagens (SOUZA et al., 2016).

Os modelos utilizados para o monitoramento de culturas, estimativas e previsão de produtividade são influenciados por variáveis agrometeorológicas (GROSSI, et al., 2015). Portanto, estudos tem sido direcionados com o intuito de quantificar os efeitos que as mudanças nas variáveis agrometeorológicas tem sobre a produtividade de culturas agrícolas (BAO et al., 2015), bem como, sobre a variabilidade espacial da precipitação pluviométrica (CARBONE et al., 2003; CERA, et al., 2017).

**CONCLUSÕES:** A escolha de um centro de previsão, para os modelos de estimativa ou previsão de produtividade de soja, deve considerar a classe de valores de precipitação e a localização geográfica, na qual as previsões são obtidas, independentemente do centro CMC, ECMWF, NCEP e CPTEC. As classes com valores mais elevados de precipitação apresentaram maior concordância com o padrão-ouro, o que sugere que os centros de previsão em estudo possuem parametrizações que favorecem a detecção de eventos extremos.

**AGRADECIMENTOS:** Os autores agradecem a UTFPR, UNIOESTE, CAPES – Código de Financiamento 001, CNPq e Laboratório de Estatística Espacial (LEE).

## **REFERÊNCIAS:**

BAO, Y.; HOOGENBOOM, G.; MCCLENDON, R. W.; PAZ, J. O. Potential adaptation strategies for rainfed soybean production in the south-eastern USA under climate change based on the CSM-CROPGRO-Soybean model. **The Journal of Agricultural Science**, v. 153, v. 2015/03/11, n. 5, p. 798–824, 2015.

BATTISTI, R.; SENTELHAS, P. C. Drought tolerance of brazilian soybean cultivars simulated by a simple agrometeorological yield model. **Experimental Agriculture**, v. 51, n. 2, p. 285–298, 2015.

BATTISTI, R.; SENTELHAS, P. C.; BOOTE, K. J. Sensitivity and requirement of improvements of four soybean crop simulation models for climate change studies in Southern Brazil. **International Journal of Biometeorology**, v. 62, n. 5, p. 823–832, 2018.

CARBONE, G. J.; KIECHLE, W.; LOCKE, C.; MEARN, L. O.; MCDANIEL, L.; DOWNTON, M. W. Response of Soybean and Sorghum to Varying Spatial Scales of Climate Change Scenarios in the Southeastern United States. **Climatic Change**, v. 60, n. 1, p. 73–98, 2003.

CERA, J. C.; STRECK, N. A.; FENSTERSEIFER, C. A. J.; FERRAZ, S. E. T.; BEXAIRA, K. P.; SILVEIRA, W. B.; CARDOSO, Â. P. Soybean yield in future climate scenarios for the state of Rio Grande do Sul, Brazil, **Pesquisa Agropecuária Brasileira**, v. 52, n. 6, 2017.

CHABERT, A.; AMOSSÉ, A.; SARTHOU, J.-P. Assessing landscape composition using visual assessment: accuracy of rapid description compared to digital mapping. **Landscape Research**, v. 44, n. 1, p. 6–18, 2019.

FENG, D.; BAUMGARTNER, R.; SVETNIK, V. A Robust Bayesian Estimate of the Concordance Correlation Coefficient. **Journal of Biopharmaceutical Statistics**, v. 25, n. 3, p. 490–507, 2015.

GROSSI, M. C.; JUSTINO, F.; RODRIGUES, R. de Á.; ANDRADE, C. L. T. **Sensitivity of the sorghum yield to individual changes in climate parameters: modelling based approach**, scielo, 2015.

LAURENT, R. T. St. Evaluating Agreement with a Gold Standard in Method Comparison Studies. **Biometrics**, v. 54, n. 2, p. 537–545, 1998.

LIN, L. I.-K. A Concordance Correlation Coefficient to Evaluate Reproducibility. **Biometrics**, v. 45, n. 1, p. 255–268, 1989.

OLIVEIRA, M. P.; URIBE-OPAZO, M. A.; GALEA, M.; JOHANN, J. A. Concordance Modeling With a Gold Standard for Variables From the Three-Parameter Gamma Distribution. *Journal of Agricultural Studies*, v. 8, n. 2, p. 284-305, 2020.

SEAB/DERAL. SECRETARIA DA AGRICULTURA E DO ABASTECIMENTO DO PARANÁ/DEPARTAMENTO DE ECONOMIA RURAL. **Banco de Dados da Produção Agropecuária no Paraná**. Disponível em: <<http://www.agricultura.pr.gov.br/deral/safras>>.

SOUZA, P. J. de O. P. De; ORTEGA-FARIAS, S.; ROCHA, E. J. P. Da; SOUSA, A. M. L. De; SOUZA, E. B. De. CONSUMO HÍDRICO DA SOJA NO NORDESTE PARAENSE. **Brazilian Journal of Irrigation and Drainage**, p. 218–231, 2016.

SOUZA, W. M.; AZEVEDO, P. V.; ARAÚJO, L. E. Classificação da Precipitação Diária e Impactos Decorrentes dos Desastres Associados às Chuvas na Cidade do Recife-PE. **Revista Brasileira de Geografia Física**, v. 5, n. 2, p. 250–268, 2012.