

III Encontro Internacional de Gestão, Desenvolvimento e Inovação

10 a 13 de setembro de 2019 | Naviraí - MS



**Performance do modelo ECMWF para estimar a temperatura do ar e precipitação pluvial em
Mato Grosso do Sul**

**José Reinaldo da Silva Cabral de Moraes,
Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso do Sul- Campus
Naviraí
jose.moraes@ifms.edu.br**

**Lucas Eduardo de Oliveira Aparecido,
Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso do Sul- Campus
Naviraí
lucas.aparecido@ifms.edu.br**

**Cícero Teixeira da Silva Costa,
Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso do Sul- Campus
Naviraí
cicero.costa@ifms.edu.br**

**Leucivaldo Carneiro Morais,
Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso do Sul- Campus
Naviraí
leucivaldo.morais@ifms.edu.br**

**Pedro Antônio Lorençone,
Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso do Sul- Campus
Naviraí
pedroantonio.lorencone@gmail.com**

RESUMO

Avaliou-se neste trabalho a performance do modelo de circulação de atmosfera geral (GCM) do Centro Europeu de Previsão Meteorológica de Médio Prazo (ECMWF) para estimar a temperatura do ar (T) e precipitação pluvial (P) em 72 locais do Estado do Mato Grosso do Sul (MS). Foram coletados os dados de T e P do European Centre for Medium Range Weather Forecasts (ECMWF) com resolução espacial de 25 x 25 km (longitude x latitude). O software ENVI foi manipulado para extrair os valores de T e P, correspondentes aos locais que possuem estações de superfície do INMET, em operação. Os dados de T e P foram comparados com dados do Instituto Nacional de meteorologia (INMET), entre 1990 a 2017, separando-se em escala mensal. Foram gerados mapas por meio do software ArcGis para temperatura e precipitação pluvial nas estações do ano, observando-se a variabilidade desses elementos para MS. A estatística utilizada para avaliar o desempenho dos ajustes foram a precisão pelo coeficiente de determinação (R^2). A performance do modelo ECMWF apresentou maiores precisões em períodos de menores amplitudes térmicas e hídricas, com valores de R^2 que chegam a 0,95 para chuva e 0,88 para temperatura.

Palavras-chave: Modelos globais; Agrometeorologia; Análise de regressão; Mapeamento meteorológico.

1 INTRODUÇÃO

A produção agrícola brasileira tem um peso determinante na economia do país e no aumento da demanda mundial de alimentos, logo a disponibilidade de informações precisas, eficientes e fornecidas em tempo apropriado sobre as safras é altamente relevante para o planejamento estratégico da agricultura (GASQUES et al., 2014).

A melhor forma de sintetizar quantitativamente os efeitos das condições climáticas no desenvolvimento e produtividade de cultivos agrícolas é por meio de modelos de cultivos, que necessitam de informações climáticas de forma temporal e homogênea. Contudo, o Brasil ainda não apresenta uma rede de estações meteorológicas que atendam às suas necessidades, dificultando a pesquisa e o desenvolvimento de modelos precisos.

Surge, então, a necessidade de alternativas para a fonte desses dados. Uma opção consistente é a utilização de dados meteorológicos provenientes de Modelos de Circulação Geral (GCM), sendo ferramentas importantes para previsões climáticas e pesquisa sobre mudanças no clima global (SATO, 2014), atuando como um dos componentes mais importantes de um modelo de sistema terrestre (WANG et al., 2017), sendo significativamente melhorados nas últimas décadas.

As estimativas destes dados meteorológicos são derivadas, em geral, de sistemas complexos e sofisticados, que integram dados de satélites (imageadores e não imageadores), dados de radar, modelos matemáticos, sendo calibradas com dados observados em estações meteorológicas.

Diante ao exposto, objetivou-se gerar modelos de calibração para estimação de dados mensais de temperatura do ar a 2 m e precipitação pluvial, a partir de dados provenientes de Modelos de Circulação Geral (GCM), em Mato Grosso do Sul.

2 REVISÃO DA LITERATURA

A superfície da terra é um importante colaborador para previsão do tempo e do clima (ORTH e SENEVIRATNE, 2014; ORTH et al., 2016). Interagindo com a atmosfera através da troca de água e energia, constitui uma parte essencial do sistema climático (ORTH et al., 2016), podendo acumular e manter anomalias induzidas por forças atmosféricas (AQUILA et al., 2016).

Ao mesmo tempo a produção agrícola é muito afetada pela variabilidade climática e eventos extremos (CEGLAR et al., 2016) e a deficiência de modelos de previsão estão parcialmente relacionadas com observações esparsas e a heterogeneidade espacial dos solos e

vegetação na superfície terrestre (ORTH et al., 2016).

Ocupando uma área de 357.125 km², Mato Grosso do Sul (MS), é o quinto maior produtor de grãos do Brasil e o terceiro no abate de gado (IBGE, 2018), contudo, assim como no território brasileiro, não se tem uma rede de estações meteorológicas de superfície que atenda todas as necessidades agrícolas, apresentando uma densidade de estações meteorológicas de aproximadamente uma estação a cada 900 hectares (INMET, 2018), levando a uma menor previsibilidade dos cultivos devido a grande falha de dados existentes nas séries temporais de superfície (PEREIRA et al., 2002) e limitando o uso de informações abrangentes e completas necessárias para inicializar modelos numéricos e desenvolver estimativas de energia e equilíbrio hídrico e agrícola satisfatórios (MARENGO, 2005).

Uma opção para esse monitoramento meteorológico são os modelos de circulação gerais (GCM) que utilizam informações de superfície, aviões, bóias nos oceanos e de satélites de todo o planeta.

O European Centre for Medium Range Weather Forecasts (ECMWF), gera previsões de clima em grid e vem sendo aplicado em diversas áreas como para a indústria, turismo, seguros e agricultura. O modelo ECMWF colabora substancialmente no fornecimento de dados em regiões com poucas estações meteorológicas de superfície (ALESSANDRINI et al., 2013; CEGLAR et al., 2016) e potencializando o uso de ferramentas de análise geoestatística.

Alguns trabalhos mostraram que determinados elementos meteorológicos estimados pelo ECMWF apresentam subestimação ou superestimação significativos em relação as estações meteorológicas de superfície e/ou outros modelos de assimilação de dados (ALBERGEL et al., 2015; HUIJNEN et al., 2016).

Bechtold et al. (2008) demonstraram que as integrações de clima com o ECMWF utilizando as resoluções horizontais, normalmente usados em previsões numéricas de tempo, levam a melhorias moderadas quando comparadas com a baixa resolução, pelo menos em aspectos de macro escala.

Na Amazônia a aplicação de modelos do ECMWF vem sendo realizadas, objetivando identificar as características atmosféricas de macro e meso escalas que expliquem os padrões climáticos da região (CAVALCANTI et al., 2016; COUTINHO et al., 2016; MARENGO, 2005).

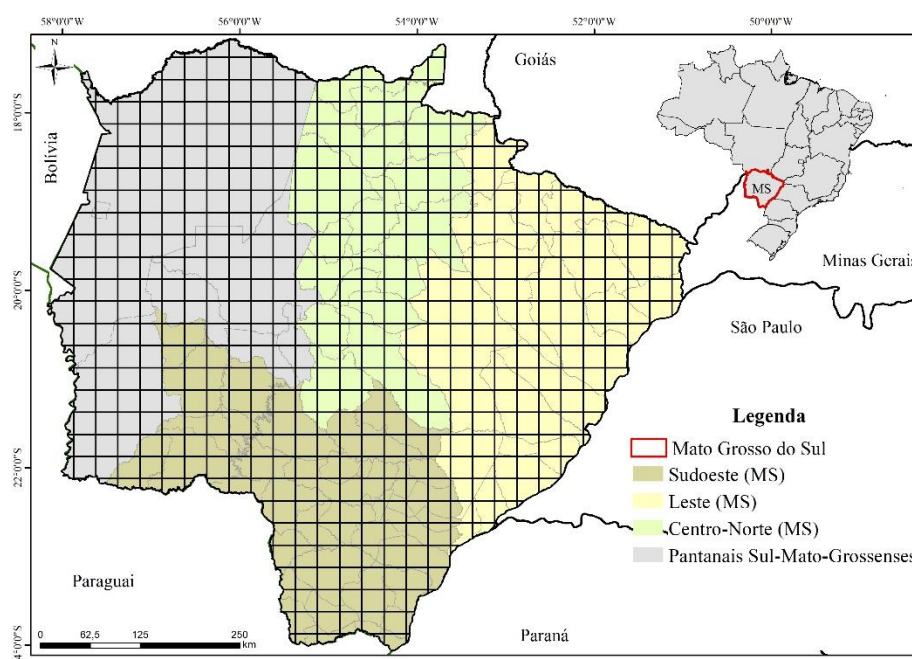
Outros trabalhos como os de Person e Grazziani (2007) e Deppe et al. (2007) identificaram subestimação ou superestimação do modelo ECMWF em comparação as estações

meteorológicas de superfície. Dessa forma, se faz importante uma avaliação prévia para uso dos dados do ECMWF como representativos das condições meteorológicas da região que se deseja trabalhar, como Mato Grosso do Sul, que se situa como uma importante região na produção de grãos e outras culturas agrícolas no Brasil.

3 METODOLOGIA

Utilizou-se dados decendiais de precipitação pluvial (P) (mm) estimados pelo modelo European Center for Medium-Range Weather Forecast (ECMWF) entre os anos de 1990 a 2010. Os dados do modelo ECMWF, são coletados em grid, contendo cada grid uma informação meteorológica com uma resolução espacial de 0,25 graus ($\pm 25 \times 25$ km) em escala dencendial. Foram utilizados para o Estado do Mato Grosso do Sul, 566 pontos meteorológicos em grid de estações globais (Figura 1). Esses dados foram comparados com estações meteorológicas de superfície disponível no estado do Mato Grosso do Sul, totalizando 72 estações com informações de chuva e temperatura.


Figura 1: Mapa de localização do estado do Mato Grosso do Sul e GRID de estações do modelo ECMWF.



4 DISCUSSÃO E ANÁLISE DOS DADOS

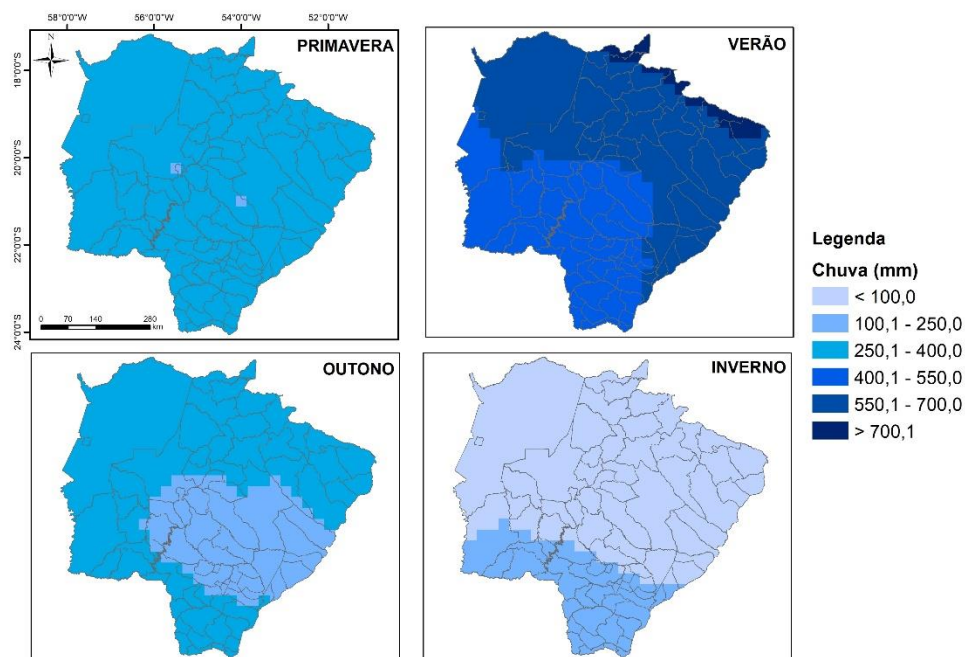
Os dados mensais de precipitação pluvial (P) de Mato Grosso do Sul encontram-se na figura 2. Os meses de dezembro a março caracterizam-se como meses de maiores médias mensais de P, com valores acima de 150 mm, com médias podendo chegar a 225 mm no mês de janeiro. Durante esses períodos, são observadas P máximas de 270 mm em dezembro e mínimas de 110 mm em março (Figura 2). Entre junho a agosto observa-se as menores ofertas de P, com valores abaixo de 50 mm (Figura 2).

Figura 2: Variabilidade da precipitação pluvial no estado do Mato Grosso do Sul.



Por meio da espacialização de P em MS, é possível observar que a costa norte em direção ao leste, são as áreas de maiores ofertas hídricas no verão, estação do ano de maior P, com valores acima de 550 mm (Figura 3). No inverno, meses com menores P, o leste, norte e oeste, concentram chuvas abaixo de 100 mm. No entanto, no sudoeste, sul e parte do sudeste, esses valores encontram-se entre 100,1 a 250 mm, caracterizando um regime hídrico diferente das outras regiões do Estado.

Figura 3: Variabilidade da precipitação pluvial no estado do Mato Grosso do Sul entre as estações do ano.



Os dados mensais de temperatura do ar de Mato Grosso do Sul podem ser observados na figura 4. Os meses de outubro a março caracterizam-se como meses de maiores médias mensais de temperatura (T), com valor acima de 25 °C. Nesse mesmo período, suas T máximas e mínimas encontra-se entre 28 e 22 °C, respectivamente. Entre maio a agosto, as T apresentam as menores médias do ano, com valores próximos a 20 °C no mês de julho, valores médios esses que podem chegar a 15 °C conforme observado em certas regiões do Estado (Figura 5).

Figura 4: Variabilidade da temperatura do ar no estado do Mato Grosso do Sul.


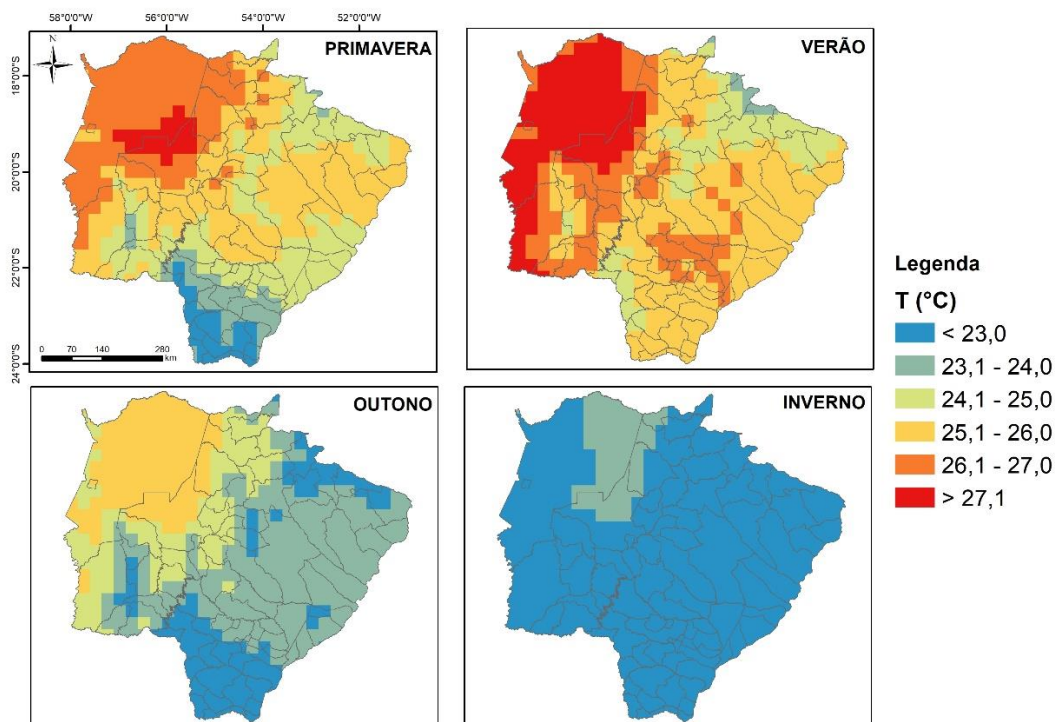


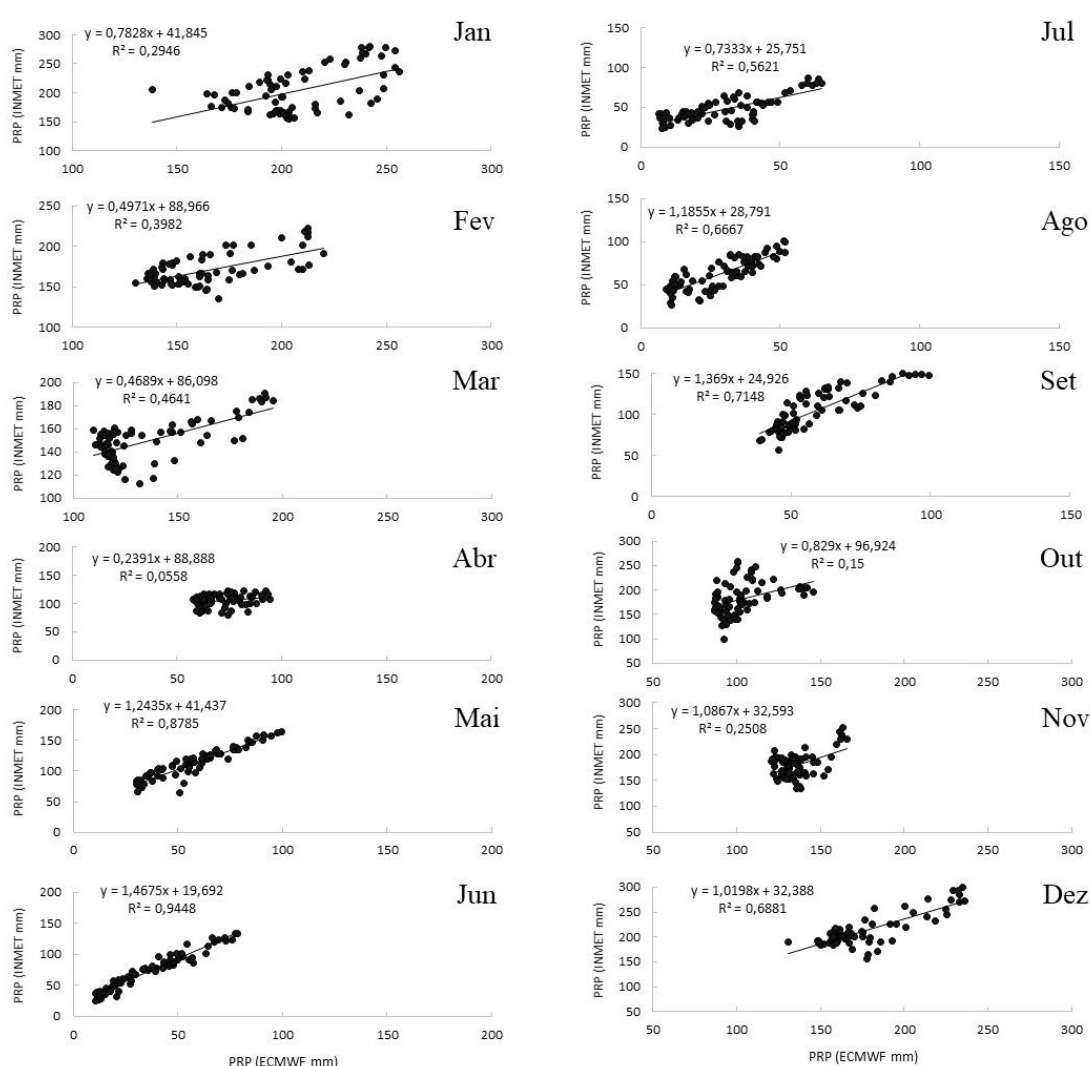
Figura 5: Variabilidade da temperatura do ar em Mato Grosso do Sul entre as estações do ano.



Na figura 6 é possível observar a performance da chuva do modelo ECMWF em relação as estações de superfície. Entre os meses mais chuvosos, janeiro a abril, o modelo apresenta

resultados de menores precisões, com menor valor de R^2 no mês de abril (0,046). Contudo, no período de menores precipitações no Estado, o modelo ECMWF tende a ter maiores precisões, com R^2 próximo a 0,95 no mês de junho. Esta baixa precisão entre os meses chuvosos e alta entre os meses menos chuvosos, ocorre pela baixa alta e baixa variabilidade da precipitação pluvial, respectivamente.


Figura 6: Análise de performance da precipitação pluvial entre as estações do INMET e ECMWF entre os meses do ano.



Para temperatura, devido a baixa variabilidade em comparação aos dados de chuva na região, as precisões de R^2 tendem a ter valores com menores variações entre os meses do ano, apresentando entre dezembro a março, as menores precisões e de julho a setembro as maiores precisões. Em março observou-se os menores R^2 com 0,53 e em setembro os maiores com 0,88

(Figura 7).

Figura 7: Análise de performance da temperatura entre as estações do INMET e ECMWF entre os meses do ano.



5 CONCLUSÕES

O Estado do Mato Grosso do Sul apresenta grande variação na distribuição da precipitação pluvial;

Ocorrem chuvas acima de 100 mm na estação do ano de menor oferta hídrica nas regiões sudoeste, sul e parte do sudeste;

A variabilidade na temperatura do ar destaca-se para região noroeste e oeste como

regiões de maiores temperaturas e o nordeste, sudoeste e sudeste de menores;

A performance do modelo ECMWF apresenta maiores precisões em períodos de menores amplitudes térmicas e hídricas, com valores de R^2 que chegam a 0,95 para chuva e 0,88 para temperatura.

REFERÊNCIAS

ALBERGEL, C.; DUTRA, E.; MUÑOZ-SABATER, J.; HAIDEN, T.; BALSAMO, G.; BELJAARS, A.; ISAKSEN, L.; ROSNAY, P.; SANDU, I.; WEDI, N. 2015. Soil temperature at ECMWF: An assessment using ground-based observations. *J. Geophys. Res. Atmos.* 120:1361–1373, doi:10.1002/2014JD022505.

ALESSANDRINI, S.; SPERATI, S.; PINSON, P. 2013. A comparison between the ECMWF and COSMO Ensemble Prediction Systems applied to shortterm wind power forecasting on real data. *Appl. Energy* 107, 271–280. doi.org/10.1016/j.apenergy.2013.02.041.

AQUILA, V.; SWARTZ, W. H.; WAUGH, D. W.; COLARCO, P. R.; PAWSON, S.; POLVANI, L. M.; STOLARSKI, R. S. 2016. Isolating the roles of different forcing agents in global stratospheric temperature changes using model integrations with incrementally added single forcings, *J. Geophys. Res. Atmos.*, (121) 8067–8082, doi:10.1002/2015JD023841.

BECHTOLD, P.; KOHLER, M.; JUNG, T.; DOBLAS-REYES, F.; RODWELL, M.J.; VIART, F.; BALSAMO, G. Advances in simulating atmospheric variability with the ECMWF model: From synoptic to decadal time-scales. *Q.J.R. Meteorol. Soc.* v. 134, p. 1337-1351, 2008.

CAVALCANTI, I. F. A.; MARENGO, J. A.; ALVES, L. M.; COSTA, D. F. On the opposite relation between extreme precipitation over west Amazon and southeastern Brazil: observations and model simulations. *Int. J. Climatol.* 2016.

CEGLAR, A.; TORETI, A.; LECERF, R.; VELDE, M.V.; DENTENER, F. 2016. Impact of meteorological drivers on regional inter-annual crop yield variability in France. *Agricultural and Forest Meteorology* 216: 58–67. doi.org/10.1016/j.agrformet.2015.10.004.

CEGLAR, A.; TORETI, A.; LECERF, R.; VELDE, M. V. D.; DENTENER, F. Impact of meteorological drivers on regional inter-annual crop yield variability in France. *Agricultural and Forest Meteorology*. V.216, p.58–67, 2016.

COUTINHO, M. D. L.; LIMA, K. C.; SILVA, C. M. S. Regional climate simulations of the changes in the components of the moisture budget over South America. *Int. J. Climatol.*, v. 36, p. 1170–1183, 2016. Available in: <<http://doi.org/10.1002/joc.4411>>.

DEPPE, F.; MARTINI, L.; LONHMANN, M.; CALVETTI, L.; ADAMI, M. Comparação de estimativas de precipitação com dados observados (estações meteorológicas). In: XII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR). Florianópolis/SC. Anais... São José dos Campos: INPE, p.3319-3326, 2007.

GASQUES, J.; BASTOS, E.; VALDES, C.; BACCHI, M. Produtividade da agricultura: Resultados para o Brasil. *Revista de Política Agrícola*, ano XXIII, n. 3, p. 87-98, 2014

HARMAN, B.I.; KOSEOGLU, H.; YIGIT, C. O. 2016. Performance evaluation of IDW, Kriging and 599 multiquadric interpolation methods in producing noise mapping: A case study at the city 600 of Isparta, Turkey. *Applied Acoustics*. 112: 147–157, 601 doi:org/10.1016/j.apacoust.2016.05.024.

HOAGLIN, D.; WELSCH, R. 1978. The hat matrix in regression and ANOVA. *Am Stat*, 32: 604 17-22.

HUIJEN, V.; FLEMMING, J.; CHABRILLAT, S.; ERRERA, Q.; CHRISTOPHE. Y.; ANNE-MARLENE B. A.; RICHTER, A.; ESKES, H. 2016. C-IFS-CB05-BASCOE: stratospheric chemistry in the Integrated Forecasting System of ECMWF. *Geosci. Model Dev* 9:3071–3091. doi:10.5194/gmd-9-3071-2016.

IBGE- Instituto Brasileiro de Geografia e estatística, 2016. Disponível em: <<http://www.ibge.gov.br>>. Access in: julho de 2018.

INMET – INSTITUTO NACIONAL DE METEOROLOGIA, 2017: BDMEP - Banco de Dados

Meteorológicos para Ensino e Pesquisa. Disponível em:
<<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>. Access in: julho de 2018.

LIU, G.; GUO, Z. 2016. A clustering-based differential evolution with random-based sampling and Gaussian sampling. *Neurocomputing* 205: 229–246. doi.org/10.1016/j.neucom.2016.04.040.

MARENGO, J. A. 2005. Characteristics and spatio-temporal variability of the Amazon River Basin Water Budget. *Climate Dynamics* 24: 11–22. doi:10.1007/s00382-004-0461-6.

ORTH, R.; DUTRA, E.; TRIGO, I. F.; BALSAMO, G. 2016. Advancing land surface model development with satellite-based Earth observations. *Hydrol. Earth Syst. Sci. Discuss.*, doi:10.5194/hess-2016-628.

ORTH, R.; SENEVIRATNE, S. I. 2014. Using soil moisture forecasts for sub-seasonal summer temperature predictions in Europe. *Climate Dynamics*, 43 (12), 3403-3418.

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

PERSON, A.; GRAZZIANI, F. *User guide to ECMWF forecast products*. Meteorological Bulletin M3.2. Reading, UK: ECMWF, 153p. 2007.

ROLIM, G. S.; APARECIDO, L. E. O. Camargo, Köppen and Thornthwaite climate classification systems in defining climatical regions of the state of São Paulo, Brazil. *International Journal of Climatology*. 36:636-643, 2015.

SATOH, M. Standard experiments of atmospheric general circulation models, in: *Atmospheric Circulation Dynamics and General Circulation Models*. Springer, Berlin, Heidelberg. p. 689–702. 2014.

WANG, Y.; JIANG, J.; ZHANG H.; DONG, X.; WANG, L.; RANJAN, R.; ZOMAYAF, A. Y. A scalable parallel algorithm for atmospheric general circulation models on a multi-core cluster. *Future Generation Computer Systems*. v. 72, p.1–10, 2017.