

PABLO FRANCISCO BENITEZ BARATTO

**ESPACIALIZAÇÃO DE ELEMENTOS METEOROLÓGICOS DIÁRIOS EM
BACIAS HIDROGRÁFICAS DO SUL DO ESPÍRITO SANTO**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Aplicada, para obtenção do título de *Magister Scientiae*.

Orientador: Roberto Avelino Cecílio

Coorientador: Sidney Sara Zanetti

**VIÇOSA - MINAS GERAIS
2020**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

B226e
2020 Baratto, Pablo Francisco Benitez, 1995-
Espacialização de elementos meteorológicos diários em
bacias hidrográficas do Sul do Espírito Santo / Pablo Francisco
Benitez Baratto. – Viçosa, MG, 2020.
91 f.: il. (algumas color.) ; 29 cm.

Inclui apêndice.

Orientador: Roberto Avelino Cecílio.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Evapotranspiração. 2. Precipitação (Meteorologia).
3. Meteorologia - Processamentos de dados. I. Universidade
Federal de Viçosa. Departamento de Engenharia Agrícola.
Programa de Pós-Graduação em Meteorologia Aplicada.
II. Título.

CDD 22. ed. 551.572

PABLO FRANCISCO BENITEZ BARATTO

**ESPACIALIZAÇÃO DE ELEMENTOS METEOROLÓGICOS DIÁRIOS EM
BACIAS HIDROGRÁFICAS DO SUL DO ESPÍRITO SANTO**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Aplicada, para obtenção do título de *Magister Scientiae*.

APROVADA: 31 de julho de 2020.

Assentimento:



Pablo Francisco Benitez Baratto
Autor



Roberto Avelino Cecílio
Orientador

AGRADECIMENTOS

A Deus.

Aos meus pais.

À Universidade Federal de Viçosa, pela oportunidade de fazer o curso.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos - processo nº 134462/2018-1.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES).

“Você nunca sabe que resultados virão da sua ação. Mas se você não fizer nada, não existirão resultados”.

(Mahatma Gandhi)

RESUMO

BARATTO, Pablo Francisco Benitez, M.Sc., Universidade Federal de Viçosa, julho de 2020. **Espacialização de elementos meteorológicos diários em bacias hidrográficas do Sul do Espírito Santo.** Orientador: Roberto Avelino Cecílio. Coorientador: Sidney Sara Zanetti.

Dados espacializados de elementos meteorológicos diários (precipitação e evapotranspiração de referência) são fundamentais em diversas aplicações relacionadas à hidrologia e à meteorologia aplicada, tais como a detecção de mudanças climáticas, estudo de inundações, compreensão da interação do clima com os processos hidrológicos e biogeoquímicos, planejamento e tomada de decisão com relação a agricultura irrigada, produção de água, recomposição florestal etc. Todavia, para cada região, as formas de espacialização de cada variável meteorológica devem ser criteriosamente analisadas a fim de obterem-se mapas que representem, da melhor maneira possível, a distribuição espacial dos elementos meteorológicos. Nesse sentido, este trabalho objetivou, para as bacias hidrográficas do Sul do Espírito Santo, a seleção de métodos de interpolação espacial mais adequados para a elaboração de mapas dos elementos meteorológicos precipitação e evapotranspiração de referência, em escala diária. Também objetivou-se, após a seleção dos interpoladores, a criação de uma base de dados espaciais deste elementos meteorológicos, em formato *grid*. A avaliação dos interpoladores foi feita por meio de validação cruzada, na qual o método da Distância Angular Ponderada (ADW) apresentou melhor desempenho na espacialização da precipitação e o método *Random Forest* (RF) apresentou o melhor desempenho na espacialização da evapotranspiração de referência. A aplicação do ADW e RF para todos os dias do período entre 1980 e 2018, originou duas bases de dados de precipitação e evapotranspiração diária em formato *grid*, com resolução espacial de $0,01^\circ$ (1111,33 m) e $0,004^\circ$ (444,53 m), respectivamente. Finalmente, procedeu-se à comparação das bases criadas com outras bases de dados em formato *grid*. As bases de dados criadas tiveram desempenho semelhante à de Xavier et al. (2015) para a representação espacial das chuvas e evapotranspiração de referência na região, sendo melhor que outras também avaliadas.

Palavras-chave: Precipitação. Evapotranspiração de referência. Validação cruzada. Random Forest. ADW.

ABSTRACT

BARATTO, Pablo Francisco Benitez, M.Sc., Universidade Federal de Viçosa, July, 2020. **Spatialization of daily meteorological elements in hydrographic basins in the south of Espírito Santo.** Advisor: Roberto Avelino Cecílio. Co-advisor: Sidney Sara Zanetti.

Spatialized data of daily meteorological elements (precipitation and reference evapotranspiration) are fundamental in several applications related to hydrology and applied meteorology, such as the detection of climate changes, the study of floods, understanding of the interaction of climate with hydrological and biogeochemical processes, planning and decision making about irrigated agriculture, water production, forest restoration. However, for each region, the forms of spatialization of each meteorological variable must be carefully analyzed to obtain maps that represent, in the best possible way, the spatial distribution of meteorological elements. In this sense, this work aimed for the hydrographic basins of the Center-South region of Espírito Santo, the selection of spatial interpolation methods most suitable for the elaboration of maps of the meteorological elements precipitation and reference evapotranspiration, on a daily scale. After selecting the interpolators, it was also aimed to create a spatial database of these meteorological elements in a grid format. The evaluation of the interpolators was carried out using means of cross-validation, in which the Weighted Angular Distance (ADW) method presented the best performance in the spatialization of precipitation and the Random Forest (RF) method presented the best performance in the spatialization of evapotranspiration of reference. The application of ADW and RF for every day of the period between 1980 and 2018, originated two databases of precipitation and daily evapotranspiration in a grid format, with a spatial resolution of 0.01° (1111.33 m) and 0.004° (444.53 m), respectively. Finally, the bases created were compared with other databases in a grid format. The databases created had a performance similar to that of Xavier et al. (2015) for the spatial representation of rainfall and reference evapotranspiration in the region, being better than others also evaluated.

Keywords: Precipitation. Reference evapotranspiration. Cross validation. Random Forest. ADW.

LISTA DE ILUSTRAÇÕES

Figura 1 – Figura 1 – Bacias hidrográficas do Sul do Espírito Santo	17
Quadro 1. Bases de dados de chuva diária, em formato grid, avaliadas no presente estudo.....	25
Figura 2 – Percentual dos dias em que cada interpolador apresentou o melhor desempenho.....	26
Figura 3 – Gráfico de dispersão da precipitação diária observada e interpolada no mês de janeiro de todos os anos da série histórica utilizada	27
Figura 4 – Gráfico de dispersão da precipitação diária observada e interpolada no mês de julho de todos os anos da série histórica utilizada	28
Figura 5 – Estatísticas médias anuais para a interpolação do total precipitado diário nas bacias hidrográficas do Sul do Espírito Santo	29
Figura 6 – Estatísticas médias mensais para a interpolação do total precipitado diário nas bacias hidrográficas do Sul do Espírito Santo	30
Figura 7 – Espacializações da precipitação diária do Sul do Espírito Santo em 09/11/2018.....	31
Figura 8 – Espacializações da precipitação diária do Sul do Espírito Santo em 01/08/2018.....	32
Quadro 2. Especificações da base de dados de precipitação diária para as bacias hidrográficas do Sul do Espírito Santo-BR	33
Figura 9 – Estatísticas médias mensais do total precipitado diário, para as bases de dados em formato grid nas bacias hidrográficas do Sul do Espírito Santo	34
Figura 10 – Estações meteorológicas do INMET nas áreas em estudo do Sul do Espírito Santo.....	57
Quadro 3. Bases de dados meteorológicos utilizados para comparação no presente estudo.....	64
Figura 11 – Percentual dos dias em que cada interpolador apresentou o melhor desempenho para a espacialização do da ET_0 total diária.....	65
Figura 12 – Gráfico de Dispersão da ET_0 diária observada e interpolada durante o verão de todos os anos da série histórica utilizada, do Sul do Espírito Santo	67
Figura 13 – Gráfico de Dispersão da ET_0 diária observada e interpolada durante o inverno de todos os anos da série histórica utilizada, do Sul do Espírito Santo	68
Figura 14 – Resultados estatísticos médios diários da interpolação da ET_0 diária nas bacias hidrográficas do Sul do Espírito Santo	69
Figura 15 – Espacializações da ET_0 diária do Sul do Espírito Santo em 15/01/2010	70
Figura 16 – Espacializações da ET_0 diária do Sul do Espírito Santo em 01/08/2010	71
Quadro 4. Especificações da base de dados de ET_0 diária disponibilizada para as bacias hidrográficas do Sul do Espírito Santo-BR.....	72
Figura 17 – Resultados estatísticos médios anuais para a interpolação da ET_0 diária nas bacias hidrográficas do Sul do Espírito Santo.....	73

LISTA DE TABELAS

Tabela 1. Estatísticas utilizados para avaliação do desempenho dos interpoladores usados na espacialização dos totais precipitados diários	26
Tabela 2. Resultados estatísticos da comparação de todas as bases de dados utilizadas no estudo.	33
Tabela 3. Estações meteorológicas do INMET (convencionais), cujas bases de dados meteorológicos diários foram utilizadas no presente estudo	58
Tabela 4. Índices estatísticos utilizados para avaliação do desempenho dos interpoladores usados na espacialização da ET_0 diária nas bacias hidrográficas do Sul do Espírito Santo.....	66
Tabela 5. Resultados estatísticos da comparação de todas as bases de dados utilizadas no estudo.....	72

LISTA DE SIGLAS E ABREVIATURAS

ABNT	Associação Brasileira de Normas Técnicas.
ADW	Distância Angular Ponderada.
AGERH	Agência Estadual de Recursos Hídricos – ES.
ANA	Agência Nacional de Águas.
BDMEP	Banco de Dados Meteorológicos para Ensino e Pesquisa.
BIAS	Desvio sistemático do valor real.
BR	Brasil.
d	Índice de concordância de Willmott.
CDD	Distância de decaimento de correlação.
CHIRPS	<i>Climate Hazards center InfraRed Precipitation with Station data.</i>
E	Valor estimado.
EPSG	<i>European Petroleum Survey Group.</i>
ES	Espírito Santo.
ET ₀	Evapotranspiração de Referência.
ETP	Evapotranspiração Potencial.
FAO	Organização das Nações Unidas para Alimentação e Agricultura.
IDW	Inverso da Distância Ponderada.
INMET	Instituto Nacional de Meteorologia.
MAPE	Erro percentual absoluto médio.
MMA	Ministério do Meio Ambiente.
NASA	National Aeronautics and Space Administration.
O	Valor observado.
OK	Krigagem Ordinária.
OMM	Organização Meteorológica Mundial.
RF	<i>Random Forest.</i>
RMSE	Raiz do Erro médio Quadrático.
SCR	Sistema Cartográfico de Referência.
SM2RAIN	<i>Algorithm Detecting rainfall from the bottom up.</i>
TRMM	<i>Tropical Rainfall Measuring Mission.</i>

LISTA DE SÍMBOLOS

m	Metros.
mm	Milímetro.
mm dia ⁻¹	Milímetro por dia.
km	Quilômetro.
%	Porcentagem.
°	Graus decimais.

SUMÁRIO

INTRODUÇÃO GERAL	12
CAPÍTULO I - Espacialização da precipitação diárias em bacias hidrográficas do Sul do Espírito Santo	14
1. INTRODUÇÃO	15
2. METODOLOGIA	16
3. RESULTADOS	25
4. DISCUSSÃO	35
5. CONCLUSÕES	41
REFERÊNCIAS BIBLIOGRÁFICAS	42
CAPÍTULO II - Random Forest para a espacialização de evapotranspiração potencial diária: estudo de caso de bacias hidrográficas na Mata Atlântica	53
1. INTRODUÇÃO	53
2. METODOLOGIA	56
3. RESULTADOS	65
4. DISCUSSÃO	74
5. CONCLUSÕES	79
REFERÊNCIAS BIBLIOGRÁFICAS	80
CONCLUSÕES GERAIS	88
REFERÊNCIAS	89
APÊNDICE A	91

INTRODUÇÃO GERAL

O conhecimento do comportamento espacial e temporal de variáveis meteorológicas diárias é essencial para boa parte dos estudos ambientais, como monitoramento de secas ou inundações, manejo de bacias hidrográficas, gerenciamento da água, classificação climática, detecção de mudanças climáticas, além de possibilitar a compreensão de como o clima interage com os processos hidrológicos e biogeoquímicos (HOFSTRA et al., 2008; MADSEN et al., 2014; SCHUMACHER, 2016; TRENBERTH, 2011; ASLAMI et al., 2019; WANG et al., 2017). As variáveis meteorológicas podem ser medidas de diversas maneiras; todavia, registros pontuais de estações de superfície fornecem os meios mais precisos para obter informações sobre o clima (FRANCO & BONUMÁ, 2017; SIMPSON et al., 2017). No entanto, na maior parte do Brasil, a rede meteorológica é espacialmente esparsa e os registros, muitas vezes, são falhos ou incompletos, dificultando o uso das informações em escala temporal diária (ALMEIDA et al., 2015; MAIDMENT et al., 2017).

Devido à pouca disponibilidade de séries de dados consistentes e suficientemente longos, medidos por estações meteorológicas no Brasil, torna-se necessário encontrar alternativas para o estudo de variáveis meteorológicas no país (BIER et al., 2017). Nesse sentido, a utilização de dados em formato de grade (*grid*), oriundos de sensoriamento remoto, servem para obter-se informações de parâmetros climáticos onde não há estações (DARAND et al., 2017). Todavia, os produtos gerados por estas bases de dados em *grid* cobrem uma extensa região do globo terrestre, conseqüentemente, sua resolução espacial geralmente é pequena (*pixels* grandes), impossibilitando desta forma a sua ampla utilização, principalmente em estudos cuja região estudada é de pequena escala, a exemplo de pequenas bacias hidrográficas (FALK et al., 2016; HE et al., 2016; KRAJEWSKI et al., 2019).

A fim de contornar os problemas relacionados à falta de informações climáticas medidas na superfície e, à baixa resolução espacial das bases de dados em *grid*, o uso de interpolação espacial de variáveis meteorológicas diárias torna-se uma alternativa viável (ZHANG et al., 2020). Contudo, como a performance dos interpoladores não é necessariamente igual, ou parecida, para qualquer elemento meteorológico em uma mesma região (CASTRO et al., 2010), fica evidente a necessidade de avaliação do desempenho dos interpoladores espaciais antes de utilizá-los como base de dados. Ademais, a precisão dos dados climáticos espacializados em grade depende da disponibilidade da rede de pluviômetros, variabilidade espaço temporal do fenômeno, dentre outros fatores que influenciam os padrões climáticos na área em estudo (YEGGINA et al., 2019). Desta forma, para definir qual método de interpolação é o mais

indicado para a espacialização de cada variável meteorológica diária em uma determinada região, é necessário analisar o desempenho de diferentes interpoladores espaciais antes de aplicá-los (CHEN et al., 2017; YIN et al., 2019).

Nesse contexto, a região Central Sul do Espírito Santo foi escolhida como área em estudo neste trabalho, devido à sua importância no cenário agrícola estadual e nacional, com diversificada cadeia agrícola de produção. Nesta área, destacam-se a produção de café, eucalipto de fibra curta, frutas, em especial o mamão papaya, algumas hortaliças, dentre outros (RODY et al., 2010). Além disso, a área em estudo situa-se dentro do bioma Mata Atlântica, o qual possui a maior diversidade de flora do mundo, além de uma fauna com enorme quantidade de espécies endêmicas (MMA, 2010).

Desta forma, o presente trabalho de dissertação dividiu-se em dois capítulos, que serão apresentados na sequência. O primeiro capítulo estuda a espacialização da precipitação diária e o segundo capítulo refere-se à espacialização da evapotranspiração de referência diária, na área em estudo.

CAPÍTULO I

Espacialização da precipitação diária em bacias hidrográficas do Sul do Espírito Santo

RESUMO: Dados espacializados de precipitação diária são úteis para diversas aplicações relacionadas à meteorologia aplicada e à hidrologia, tais como a detecção de mudanças climáticas, estudo de inundações, e compreensão da interação do clima com os processos hidrológicos e biogeoquímicos. Contudo, cada espacialização da chuva deve ser avaliada para uma determinada região específica antes de sua ampla utilização. Nesse sentido, o presente trabalho objetivou, para as bacias hidrográficas do Sul do Espírito Santo (bioma Mata Atlântica), a avaliação de métodos de interpolação espacial, a criação de uma base de dados espaciais de precipitação diária em formato *grid*, e a comparação desta base com outras bases de dados de precipitação diária em formato *grid*. A avaliação dos interpoladores foi feita por meio de validação cruzada, na qual o método da Distância Angular Ponderada (ADW) apresentou melhor desempenho. A aplicação do ADW, para todos os dias do período entre 1980 e 2018, originou uma base de dados de precipitação diária em formato *grid* com resolução espacial de 0,01°. A base de dados criada teve desempenho semelhante à de Xavier et al. (2015) para a representação espacial das chuvas na região, sendo melhor que outras também avaliadas.

Palavras-chave: ADW, CHIRPS, interpolação, precipitação.

Spatialization of daily rainfall in hydrographic basins in the South of Espírito Santo

ABSTRACT: Spatialized daily precipitation data are useful for several applications related to applied meteorology and hydrology, such as detecting climate change, studying floods, and understanding the interaction of climate with hydrological and biogeochemical processes. In addition, each spatialization of rain must be analyzed for a given region. In this sense, the work aimed for the hydrographic basins of the South of Espírito Santo, the evaluation of spatial interpolation methods, the creation of a spatial database of daily precipitation in a grid format, and the comparison of this base with other daily precipitation databases in a grid format. The hydrographic basins were chosen because they are located within the Atlantic Forest biome. The evaluation of the interpolators was carried using means of cross-validation, in which the Weighted Angular Distance (ADW) method presented the best performance. The application of ADW for every day of the period between 1980 and 2018, originated a database of daily precipitation in a grid format and with a spatial resolution of 0.01 °. The database created had a performance similar to that of Xavier et al. (2015) for the spatial representation of rainfall in the region, being better than others also evaluated.

Keywords: ADW, CHIRPS, interpolation, precipitation.

1. INTRODUÇÃO

O conhecimento dos comportamentos espacial e temporal da precipitação é essencial para a maioria dos estudos ambientais, como o monitoramento de secas, o planejamento e manejo de bacias hidrográficas (Aslami et al., 2019), a detecção de mudanças climáticas (Salviano et al., 2016; Trenberth, 2011), a prevenção contra inundações (Madsen et al., 2014; Schumacher, 2016), e o entendimento da interação meteorológica com os processos terrestres hidrológicos e biogeoquímicos (Hofstra et al., 2008). Portanto, medições confiáveis da precipitação são essenciais. Estas medições podem ser feitas de diversas formas; todavia, registros de estações de medidos em superfície são considerados os mais precisos para obter informações sobre os totais precipitados (Pessi et al., 2019; Simpson et al., 2017). No entanto, a rede pluviométrica espacialmente esparsa e os registros muitas vezes incompletos dificultam o uso destas informações em base diárias (Almeida et al., 2015; Maidment et al., 2017), em especial, no Brasil.

Devido a esta escassez dos dados de precipitação diária medidos no Brasil, torna-se necessário encontrar alternativas para o estudo das chuvas no país, como o uso dos *grids* contendo dados de chuva obtidos por sensoriamento remoto, ou por interpolação espacial de dados de chuva medidos em estações (Bier et al., 2017; Guo et al., 2020).

Os dados de chuvas em formato de grade (*grid*), oriundos de sensoriamento remoto, podem fornecer informações de precipitação onde não há estações (Darand et al., 2017). O uso destes dados é necessário devido à heterogeneidade temporal e espacial das chuvas, sendo imprescindível extrapolar as medições pontuais (estações *in situ*) para obtenção de informações em locais sem medição (Sloat et al., 2018; Wang et al., 2011). No que tange às informações climáticas, existem bases de dados de precipitação disponíveis, criadas em projetos de pesquisa específicos. Estas bases estão disponibilizadas no formato *grid*, a exemplo do CHIRPS, SM2RAIN-ASCAT e TRMM (Brocca et al., 2014; Ceccherini et al., 2015; Prakash, 2019).

Todavia, os produtos gerados por estas bases de dados cobrem uma extensa região do globo terrestre e, por consequência, sua resolução espacial é pequena (*pixels* grandes). Mesmo com os avanços tecnológicos dos últimos anos, a baixa resolução dificulta sua ampla utilização (Falck et al., 2016; He et al., 2016), sendo necessária a realização de estudos que evidenciem sua adequabilidade para regiões específicas.

Com relação à interpolação espacial de variáveis diárias, especificamente a chuva, sua viabilidade depende da disponibilidade da rede de pluviômetros e da seleção de um método de interpolação espacial apropriado. Tal método deve considerar a variabilidade da chuva relacionada com outros fatores que influenciem os padrões de precipitação na região de interesse, como mudanças nos regimes de precipitação devido ao uso da terra e características topográficas e meteorológicas (Yeggina et al., 2019). Desta forma, para definir qual método de interpolação é o mais indicado para a espacialização da precipitação diária em determinada região, é necessário analisar o desempenho de diferentes interpoladores espaciais (Chen et al., 2017; Yin et al., 2019) antes de aplicá-los.

Desta forma, o presente trabalho teve como objetivo geral o estudo da espacialização de dados diários de precipitação do Sul do Espírito Santo, no período de 1980 a 2018. Como objetivos específicos, estabeleceram-se: a) a avaliação de diferentes interpoladores espaciais para a espacialização dos totais precipitados diários; b) a criação de uma base dados de precipitação diária, em formato *grid* e com resolução espacial de 0,01°; c) a comparação da base de dados criada com outras bases de dados de precipitação diária atualmente existentes.

2. METODOLOGIA

2.1. ÁREA EM ESTUDO

A área em estudo consistiu em bacias hidrográficas do Sul do estado do Espírito Santo (Benevente; Guarapari; Itabapoana; Itapemirim; Jucu; Rio Novo e Santa Maria da Vitória), que

possuem uma área de drenagem de 14.604 km² (AGERH, 2019), cerca de 31,70% da área total do Estado. Estão localizadas entre os paralelos 39°41'17" e 41°52'47" S e entre os meridianos 17°53'30" e 21°18'06" W, conforme apresenta a Figura 1.

Ademais, a Tabela contendo todas as estações pluviométricas apresentadas na Figura 1, encontram-se no Apêndice A.

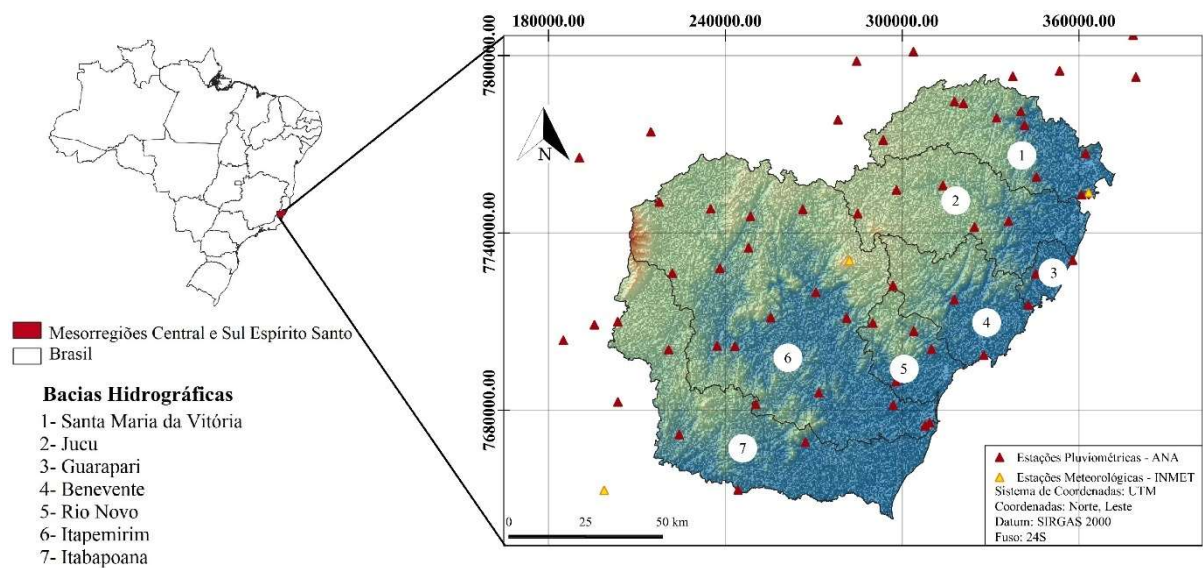


Figura 1 – Estações pluviométricas e meteorológicas nas bacias hidrográficas do Sul do Espírito Santo.

As áreas em estudo estão situadas no bioma Mata Atlântica, que possui grande importância nacional e internacional, por conter, segundo MMA (2010), a maior diversidade de flora do mundo por unidade de área. Em relação à fauna, o fato mais expressivo é a enorme quantidade de espécies endêmicas, ou seja, que não podem ser encontradas em nenhum outro lugar do planeta.

O bioma Mata Atlântica está distribuído ao longo de quase toda a faixa continental Atlântica leste do Brasil. Originalmente, mais de 1,3 milhões de km² em 17 estados do território brasileiro era cobertos por florestas, porém, atualmente, restam cerca de 29% de sua cobertura original, devido ao desmatamento e queimadas (Jesus et al., 2020; MMA, 2018).

Contudo, apesar da pouca extensão territorial, o Espírito Santo apresenta uma variabilidade climática significativa, a qual se deve à presença de suas duas distintas regiões naturais: o litoral, que se estende na direção norte-sul por 400 km, e o planalto (Regoto et al., 2018), situado a oeste, após o litoral. Segundo Alvares et al. (2013). A classificação climática de Köppen-Geiger é Aw e ocorre em toda a região costeira, juntamente com as classificações Am e Af, contornando os vales e planaltos em altitudes inferiores a 450 m, porque acima dessa elevação a temperatura média anual é inferior a 18°C (Alvares et al., 2013).

2.2. DADOS

Utilizaram-se dados diários de total precipitado, para o período de 1980 a 2018, medidos em 72 estações pluviométricas e, ou meteorológicas apresentadas na Figura 1. Os dados de precipitação foram obtidos de forma direta através da consulta ao portal HidroWeb da ANA (2020) e, através do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do INMET (2020). Ademais, os dados utilizados no presente trabalho são dados consistidos pela ANA e, dados brutos (em raros casos).

2.3. AVALIAÇÃO DOS INTERPOLADORES ESPACIAIS

Avaliaram-se diferentes interpoladores espaciais indicados na literatura: o Inverso da Distância Ponderada (IDW), a Distância Angular Ponderada (ADW), a Krigagem Ordinária (OK) e *Random Forest* (RF) (Cai et al., 2019; Camera et al., 2014; Hengl et al., 2018; Mendez et al., 2019; Xavier et al., 2015).

Para a avaliação utilizou-se a técnica de validação cruzada, a qual, segundo Li et al. (2018), é uma técnica de avaliação de erros de estimativas que consiste na comparação de valores estimados com os observados. A validação cruzada foi aplicada utilizando-se o procedimento *leave one out*, no qual uma estação específica é retirada da base de dados, sendo a interpolação

realizada e o valor de precipitação estimado no local da estação removida. Posteriormente a estação retorna à base de dados e o procedimento é repetido para todas as demais estações disponíveis (Faraco et al., 2008). Este procedimento foi aplicado para cada interpolador em cada dia da série histórica.

Finalmente, a partir dos valores de totais precipitados observados (O_i) e estimados (E_i) por cada interpolador, calcularam-se as estatísticas de desempenho descritas nas equações 1 a 3 (Ceccherini et al., 2015; Machado et al., 2015; Santos et al., 2019; Xavier et al., 2015).

$$d = 1 - \left[\frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - \bar{O}| + |O_i - \bar{O}|)^2} \right] \quad (1)$$

$$\text{BIAS} = \frac{1}{n} \sum_{i=1}^n O_i - E_i \quad (2)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (E_i - O_i)^2} \quad (3)$$

em que, d é o índice de concordância de Willmott, adimensional; BIAS é o desvio sistemático do valor real, mm; RMSE é a raiz do quadrado médio do erro, mm; E_i são os totais precipitados diários estimados, mm; O_i são os totais precipitados diários observados, mm; \bar{O} é a média dos valores observados, mm; e n indica o número total de dias.

As métricas estatísticas descritas nas equações 1 a 3 foram utilizadas para eleger o melhor interpolador e a melhor base de dados de precipitação diária em *grid* de acordo com o método descrito em Schumacher et al. (2020).

2.3.1. Distância Angular Ponderada (ADW)

A ponderação de distância angular (ADW) é uma abordagem comum para interpolação de uma rede irregular de observações meteorológicas em uma grade regular. Uma versão amplamente usada do ADW emprega a distância de decaimento de correlação (CDD) para selecionar estações que devem contribuir para cada estimativa do ponto de grade e definir o componente de distância dos pesos das estações (Hofstra & New, 2009). Esta ponderação das estações vizinhas é calculada usando as distâncias e os ângulos entre as estações vizinhas (O_k) e a estação desconhecida (E_k) (Xavier et al., 2015). O ângulo, a distância e os pesos foram combinados para chegar a um peso de distância angular (W_{Ek}) para estação E_k (New et al., 2000):

$$W_{E_k} = w_k(1 - a_k) \quad (4)$$

Onde o peso a_k é calculado na eq. (5) e está associado a cada estação de apoio para interpolação. Este peso foi determinado pelo isolamento direcional (angular) de cada um dos n_j pontos dos dados selecionados. Onde $\theta_j(k, l)$ é o ângulo formado pelas estações O_l e O_k com o vértice no ponto de interpolação de interesse (E_j), calculado em coordenadas esféricas. O w_l é o peso da distância nos ponto de dados observados (O_l e O_k). Outro fator associado ao peso da distância é o peso angular (um k , eq. 5) para cada uma das $n_j = 8$ (utilizado neste trabalho) estações seleccionadas para a interpolação:

$$a_k = \frac{\sum_{l=1}^{n_j} w_l(1 - \cos \theta_j(k, l))}{\sum_{l=1}^{n_j} w_l}, l \neq k \quad (5)$$

Ao calcular o peso w_k , utiliza-se a eq. (6). Pode-se notar que o peso decai para valores mais altos de m . Sabendo que m é o expoente para cada variável que será interpolada, o valor de m foi selecionado durante a validação cruzada, sendo neste trabalho $m=4$, conforme sugere New et al. (2000).

$$w_k = r^m \quad (6)$$

O peso da distância é calculado usando uma função de decaimento de correlação (CDD), em que CDD é derivado empiricamente (New et al., 2000). Onde, x é a distância do ponto em grade de interesse (dado que será estimado) e uma estação meteorológica nas proximidades (dados observados) e, para cada estação calcula-se a correlação (r) em todas as outras estações (Eq. 7).

$$r = e^{-x/CDD} \quad (7)$$

2.3.2. Inverso da Distância Ponderada (IDW)

O método IDW consiste na interpolação espacial de um conjunto conhecido de pontos dispersos. Os valores atribuídos aos pontos desconhecidos são calculados a partir da média ponderada pelo inverso da distância dos valores dos dados dentro de uma região (Mello & Silva, 2013; Mendez et al., 2019). Este método é caracterizado pela magnitude da potência utilizada, que geralmente varia de 1 a 3, a fim de não penalizar muito a contribuição para a estimativa de pontos distantes (Camera et al., 2014).

No presente estudo, todos os vizinhos foram usados no modelo (Eq. 8):

$$E = \frac{\sum_{i=1}^n (O_i h_i^{-p})}{\sum_{i=1}^n (h_i^{-p})} \quad (8)$$

Em que, O é o valor observado na posição i , e E é estimado com base na potência (p) e distância (h) entre as observações.

2.3.3. Krigagem Ordinária (OK)

A krigagem ordinária utiliza informações a partir de um semivariograma para encontrar os pesos ótimos a serem associados às amostras com valores conhecidos que irão estimar pontos desconhecidos (Cai et al., 2019; Pezzoni Filho et al., 2018). A variação espacial da interpolação na Krigagem é quantificada por um semivariograma, que consiste em um gráfico de dispersão da semivariância versus a distância dos pontos amostrados (Cai et al., 2019). Depois de ajustando o variograma, a estatística de Krigagem é feita calculando os pesos de cada localização nas proximidades do ponto a ser previsto (Lundgren et al., 2017).

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [O(x_i) - O(x_i - h)]^2 \quad (9)$$

Em que, $\hat{\gamma}(h)$ é a semivariância; n é o número de pares de valores medidos $O(x_i)$ e $O(x_i + h)$ observados; e h é o vetor de separação de pares.

Os modelos testados foram esféricos (SPH), exponenciais (EXP) e gaussianos (GAU). Os cálculos foram realizados para cada dia de forma automática utilizando a função *autofitVariogram* do pacote Automap do programa R, sendo o ajuste do semivariograma avaliado pelo método dos mínimos quadrados ordinários (OLS).

2.3.4. Random Forest (RF)

As previsões finais do RF são a média das previsões de árvores individuais (Breiman, 2001; Prasad, Iverson & Liaw, 2006; Biau & Scornet, 2016):

$$\hat{\theta}^B(\mathbf{x}) = \frac{1}{B} \sum_{b=1}^B t_b^*(\mathbf{x}) \quad (10)$$

em que b é a amostra de *bootstrap* individual, B é o número total de árvores e t_b^* é o aprendiz individual, ou seja, a árvore de decisão individual:

$$t_b^*(\mathbf{x}) = t(\mathbf{x}; z_{b1}^*, \dots, z_{bk}^*) \quad (11)$$

em que z_{bk}^* ($k = 1 \dots K$) é a k enésima amostra de treinamento com pares de valores para a variável alvo (y) e covariáveis (x): $z_{bi}^* = (x_k, y_k)$.

O RF é uma árvore de decisão, uma técnica de aprendizado de máquina. Uma descrição simples seria a divisão de um grupo complexo usando os métodos mais independentes e variáveis em grupos menores e mais simples, através de métodos condicionais, que podem levar a uma solução mais fácil de ser interpretada (Zhang et al., 2012).

Funciona como uma árvore em que a raiz e cada nó interno são rotulados com uma condição, esta condição é verificada, e caso seja atendida, a árvore de decisão seguirá pelo ramo correspondente, caso contrário, por outro iterativamente, até que a condição seja atendida e a árvore finalizada (Chen et al., 2010). Cada folha representa uma previsão de uma solução para o problema (Zhang et al., 2012). Esta metodologia tenta encontrar uma relação entre variáveis de entrada e saída (Gharaei-Manesh et al., 2016). Ele mapeia as observações de um item para obter conclusões do seu valor alvo (Chen et al., 2010).

Muitas variáveis de entrada que podem contribuir para a previsão são utilizadas, e em cada nó da árvore de decisão, a variável mais importante é então selecionada (Li et al., 2011).

Por ser um algoritmo baseado em dados, o RF requer apenas uma entrada limitada do usuário (Hengl et al., 2018). Nesse sentido, foram utilizadas variáveis climáticas e topográficas para permitir a decisão da árvore. Isso ocorre porque variáveis meteorológicas, como temperatura, juntamente com características topográficas, são importantes para a definição de chuvas (Chávez & Takahashi, 2017; Reboita et al., 2012). As variáveis meteorológicas (temperaturas máxima e mínima do ar, e classificação climática de Köppen–Geiger) foram obtidas do *World Clim* (<http://worldclim.org/version2>), um conjunto de camadas climáticas globais em grade, com uma resolução espacial de cerca de 1 km². O Modelo Digital de Elevação (DEM) oriundo da *Shuttle Radar Topography Mission* (SRTM) foi utilizado, obtido pelo *Earth Explorer* (<https://earthexplorer.usgs.gov/>), com uma resolução espacial de 30 m. Utilizaram-se as seguintes informações topográficas obtidas a partir do MDE: altitude, declividade, orientação das encostas, distância até o mar, índice de convergência, índice de robustez do terreno, direção de escoamento, sombreamento analítico e vetor do terreno.

Os cálculos foram realizados no ambiente R, usando o pacote *randomForest*.

2.4. BASE DE DADOS EM FORMATO GRID

Após a avaliação dos interpoladores espaciais e escolha do interpolador com melhor desempenho, utilizando os procedimentos estatísticos demonstrados nas equações 1 a 3 do item 2.3, elaborou-se uma base de dados espacializada de precipitação diária, com resolução espacial de 0,01°, compreendendo o período entre 1980 e 2018.

2.5. COMPARAÇÃO COM OUTRAS BASES DE DADOS DISPONÍVEIS

Compararam-se bases de dados de precipitação diária em formato *grid*, amplamente utilizadas (Quadro 1), com a base de dados elaborada neste trabalho. Para tal avaliação

calcularam-se as mesmas estatísticas descritas nas equações 1 a 3, de acordo com o método descrito em Schumacher et al. (2020), onde os valores de precipitação diária utilizados nas comparações foram extraídos diretamente dos *grids* das bases de dados, a partir das coordenadas geográficas referentes às estações pluviométricas.

Quadro 1. Bases de dados de chuva diária, em formato grid, avaliadas no presente estudo.

Bases de dados de precipitação	Série histórica	Resolução espacial	Fonte
CHIRPS 2.0	1981-2020	0,05°	Funk et al. (2015)
SM2RAIN-ASCAT	2007-2020	0,25°	Brocca et al. (2014)
TRMM/TMPA	1998-2020	0,25°	NASA (2020)
Xavier et al. (2015)	1980-2016	0,25°	Xavier et al. (2015)

Devido ao período comum entre todas as bases de dados em formato *grid* ser entre os anos (2007-2016), as comparações basearam-se neste período, para que houvesse uma equidade entre as análises, evitando o benefício das bases de dados com uma série histórica maior em detrimento das demais.

3. RESULTADOS

3.1. RESULTADOS DA ESPACIALIZAÇÃO DA PRECIPITAÇÃO DIÁRIA

Na Figura 2 apresenta-se o percentual de dias, durante toda a série histórica, em que cada interpolador apresentou melhor desempenho, de acordo com os índices estatísticos “d” e “RMSE”.

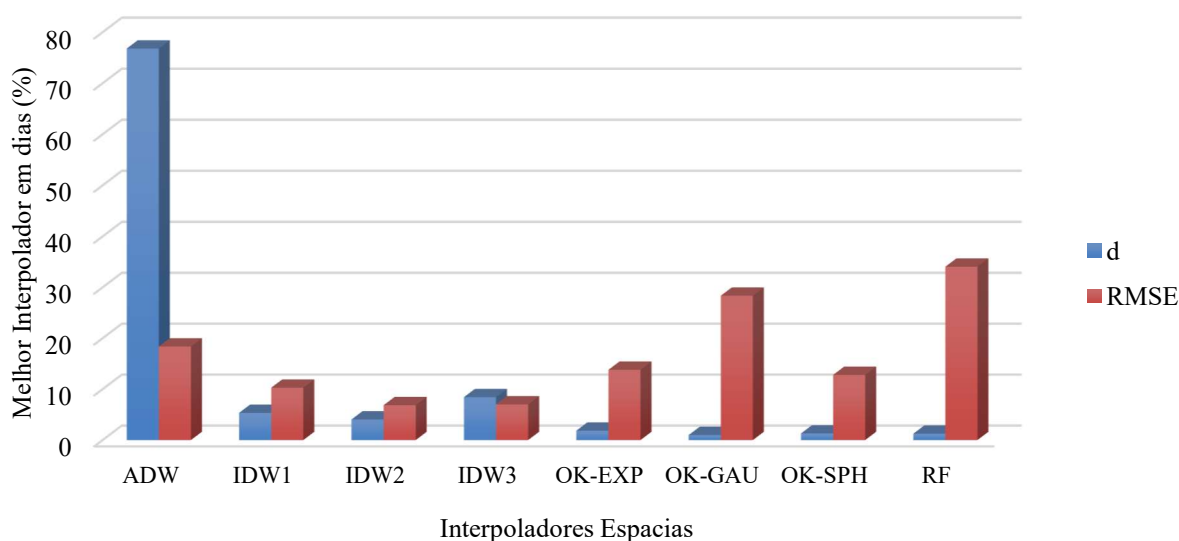


Figura 2 – Percentual dos dias em que cada interpolador apresentou o melhor desempenho para a espacialização do total precipitado diário nas bacias hidrográficas do Sul do Espírito Santo, de acordo com os índices “d” e “RMSE”.

Na Tabela 1 são apresentados os resultados médios das estatísticas utilizadas na avaliação dos interpoladores para espacialização dos totais precipitados diários nas bacias hidrográficas do Sul do Espírito Santo.

Tabela 1. Estatísticas utilizados para avaliação do desempenho dos interpoladores usados na espacialização dos totais precipitados diários nas bacias hidrográficas do Sul do Espírito Santo.

Índice estatístico	ADW	IDW1	IDW2	IDW3	OK-Exp	OK-Gau	OK-Sph	RF
d (adimensional)	0,77	0,68	0,70	0,71	0,56	0,50	0,49	0,53
RMSE (mm)	5,15	5,18	5,30	5,42	5,40	5,32	5,24	5,23
BIAS (mm)	0,03	0,07	0,04	0,03	0,01	-0,09	0,16	0,27

Nas Figuras 3 e 4 são apresentados os gráficos de dispersão (valores observados vs. valores estimados) de todos os interpoladores para os meses de janeiro de todos os anos e, para os meses de julho de todos os anos, respectivamente. A apresentação dos gráficos em períodos distintos foi adotada somente para fins de comparação do período chuvoso com o período de estiagem.

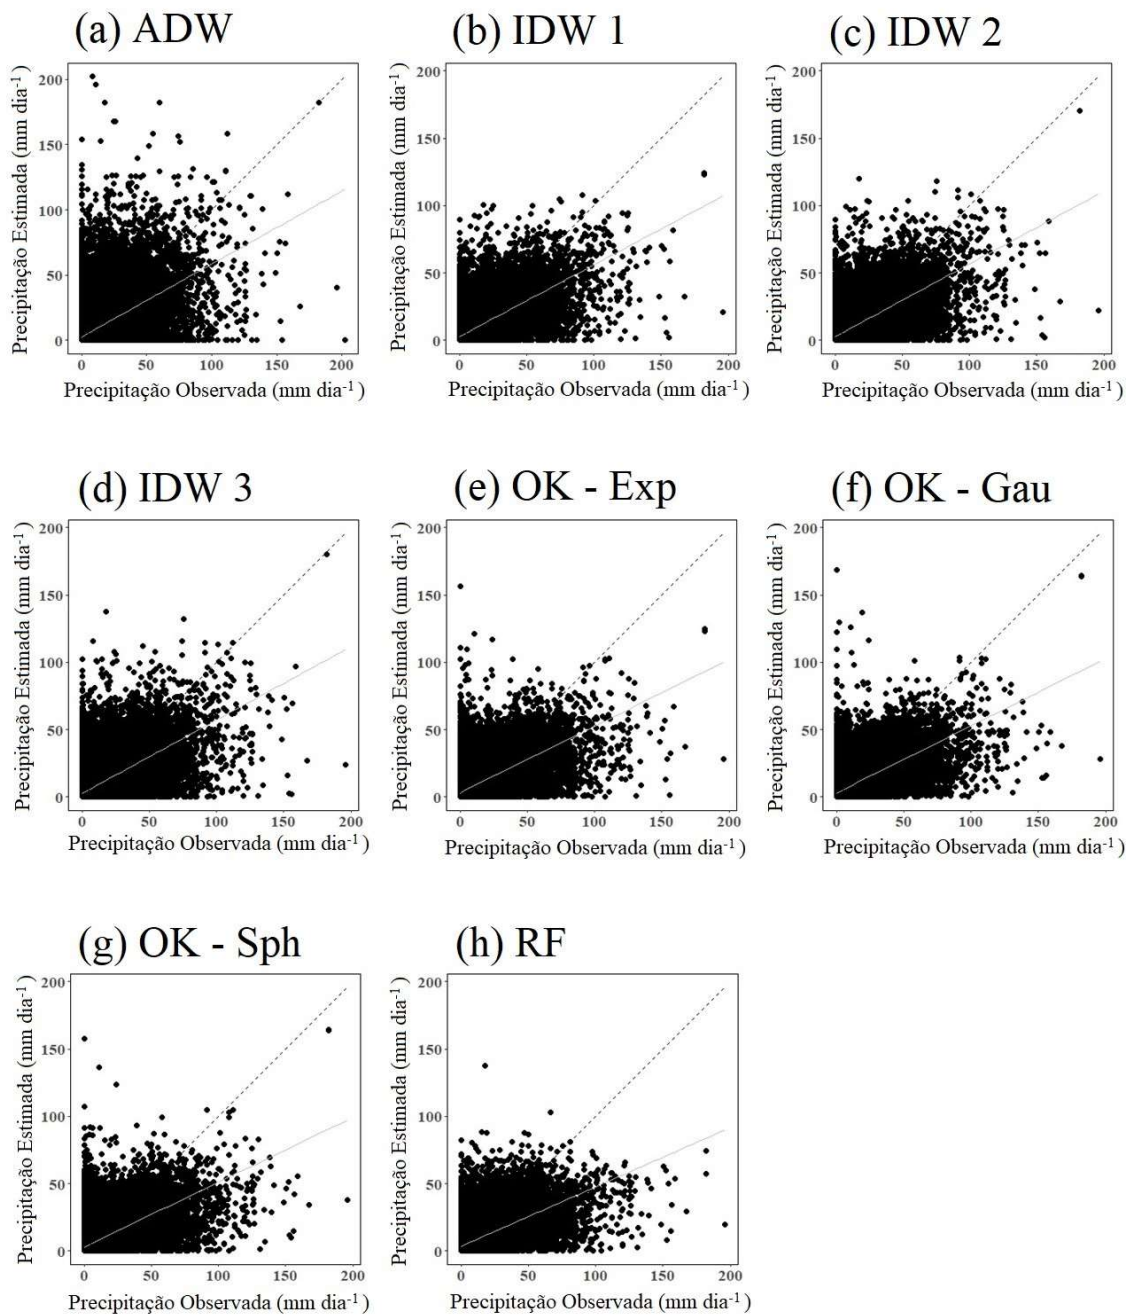


Figura 3 – Gráfico de dispersão da precipitação diária observada e interpolada no mês de janeiro de todos os anos da série histórica utilizada, do Sul do Espírito Santo.

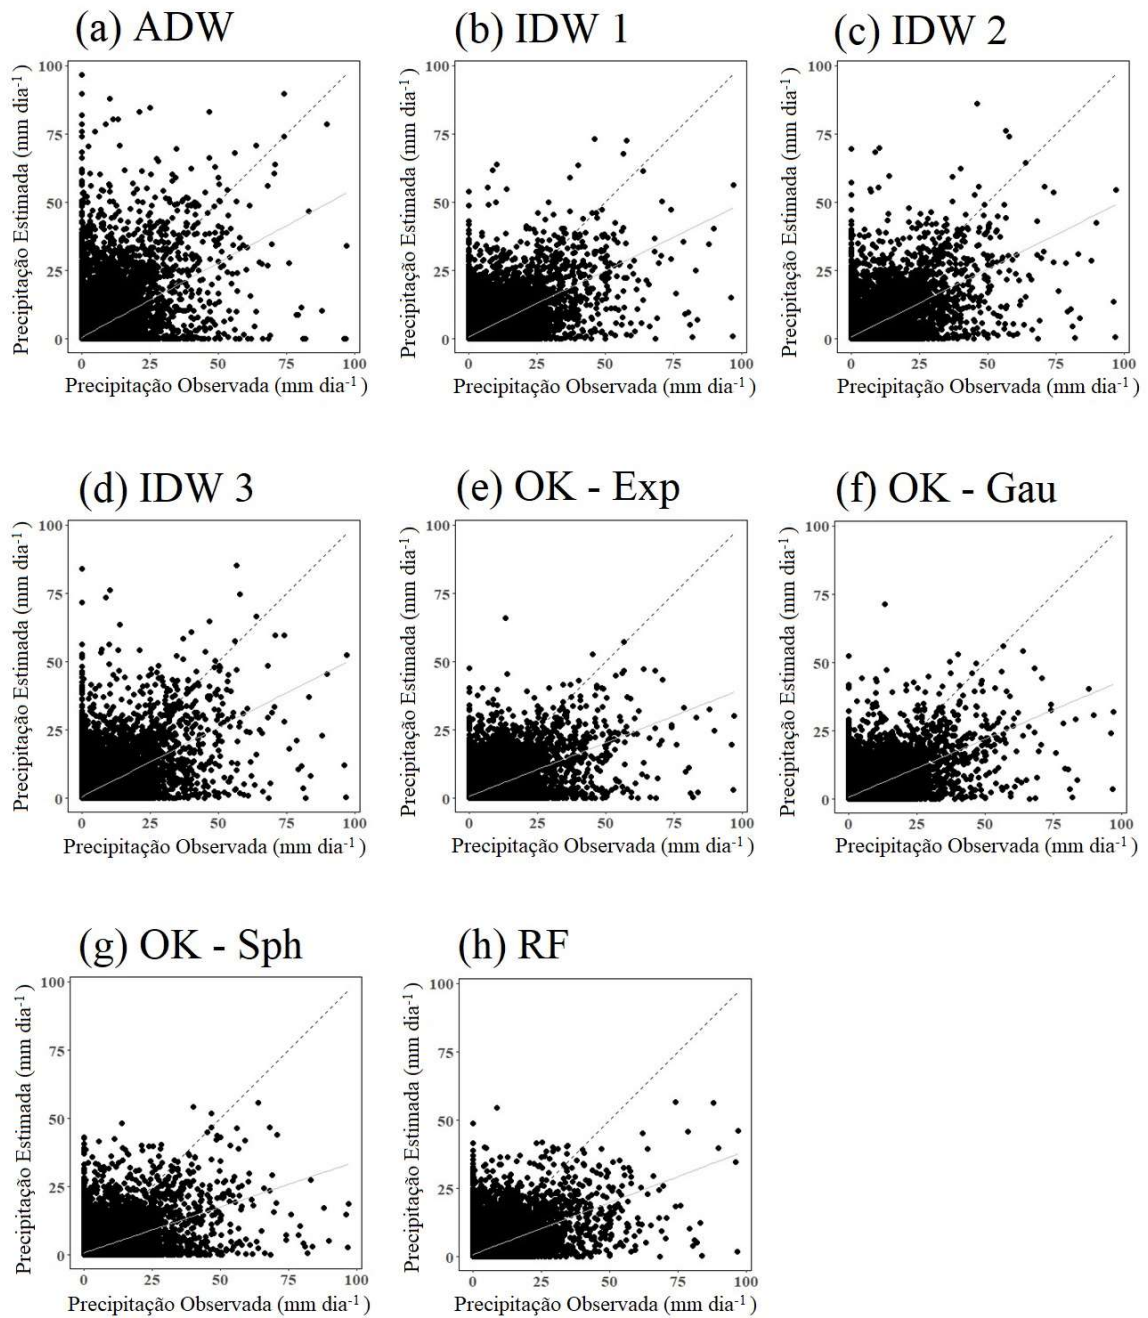


Figura 4 – Gráfico de dispersão da precipitação diária observada e interpolada no mês de julho de todos os anos da série histórica utilizada, do Sul do Espírito Santo.

Nas Figuras 5 e 6 apresenta-se a variação dos valores médios anuais e mensais das estatísticas no período em estudo.

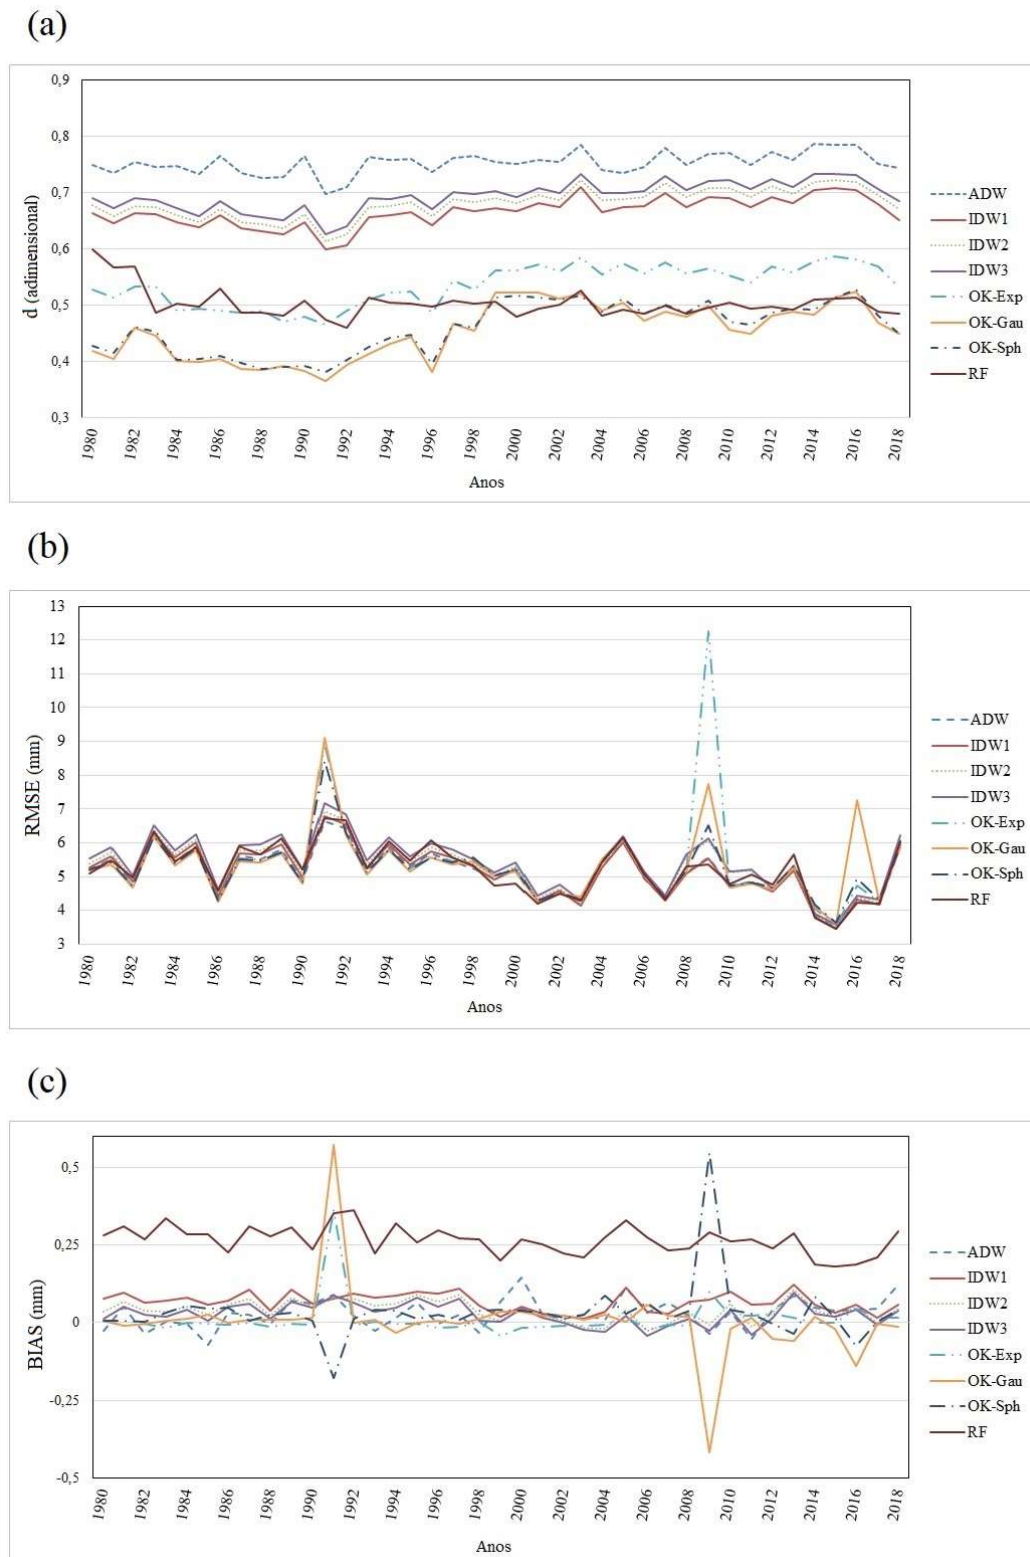


Figura 5 – Estatísticas médias anuais para a interpolação do total precipitado diário nas bacias hidrográficas do Sul do Espírito Santo: a) “d”, b) “RMSE” e c) “BIAS”.

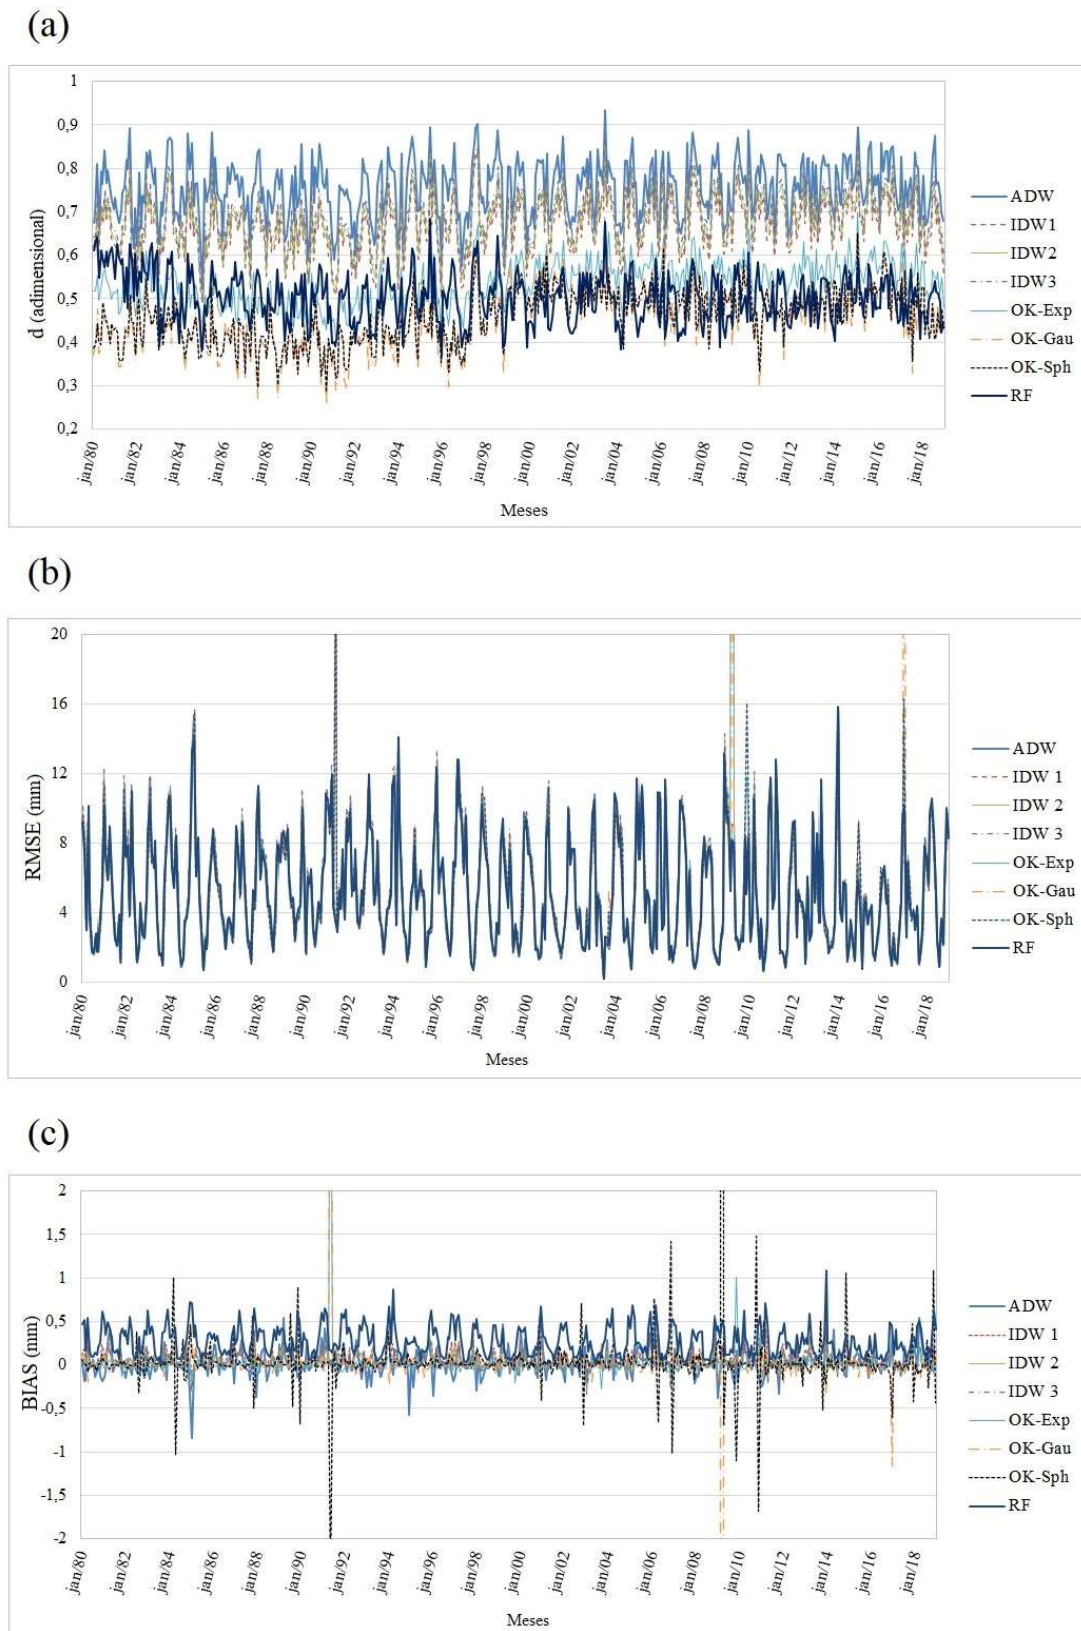


Figura 6 – Estatísticas médias mensais para a interpolação do total precipitado diário nas bacias hidrográficas do Sul do Espírito Santo: a) “d”, b) “RMSE” e c) “BIAS”.

Nas Figuras 7 e 8 são apresentadas as espacializações da precipitação de todos os interpoladores na área em estudo, para um dia de muita chuva, e para um dia de pouca chuva no ano de 2018, respectivamente.

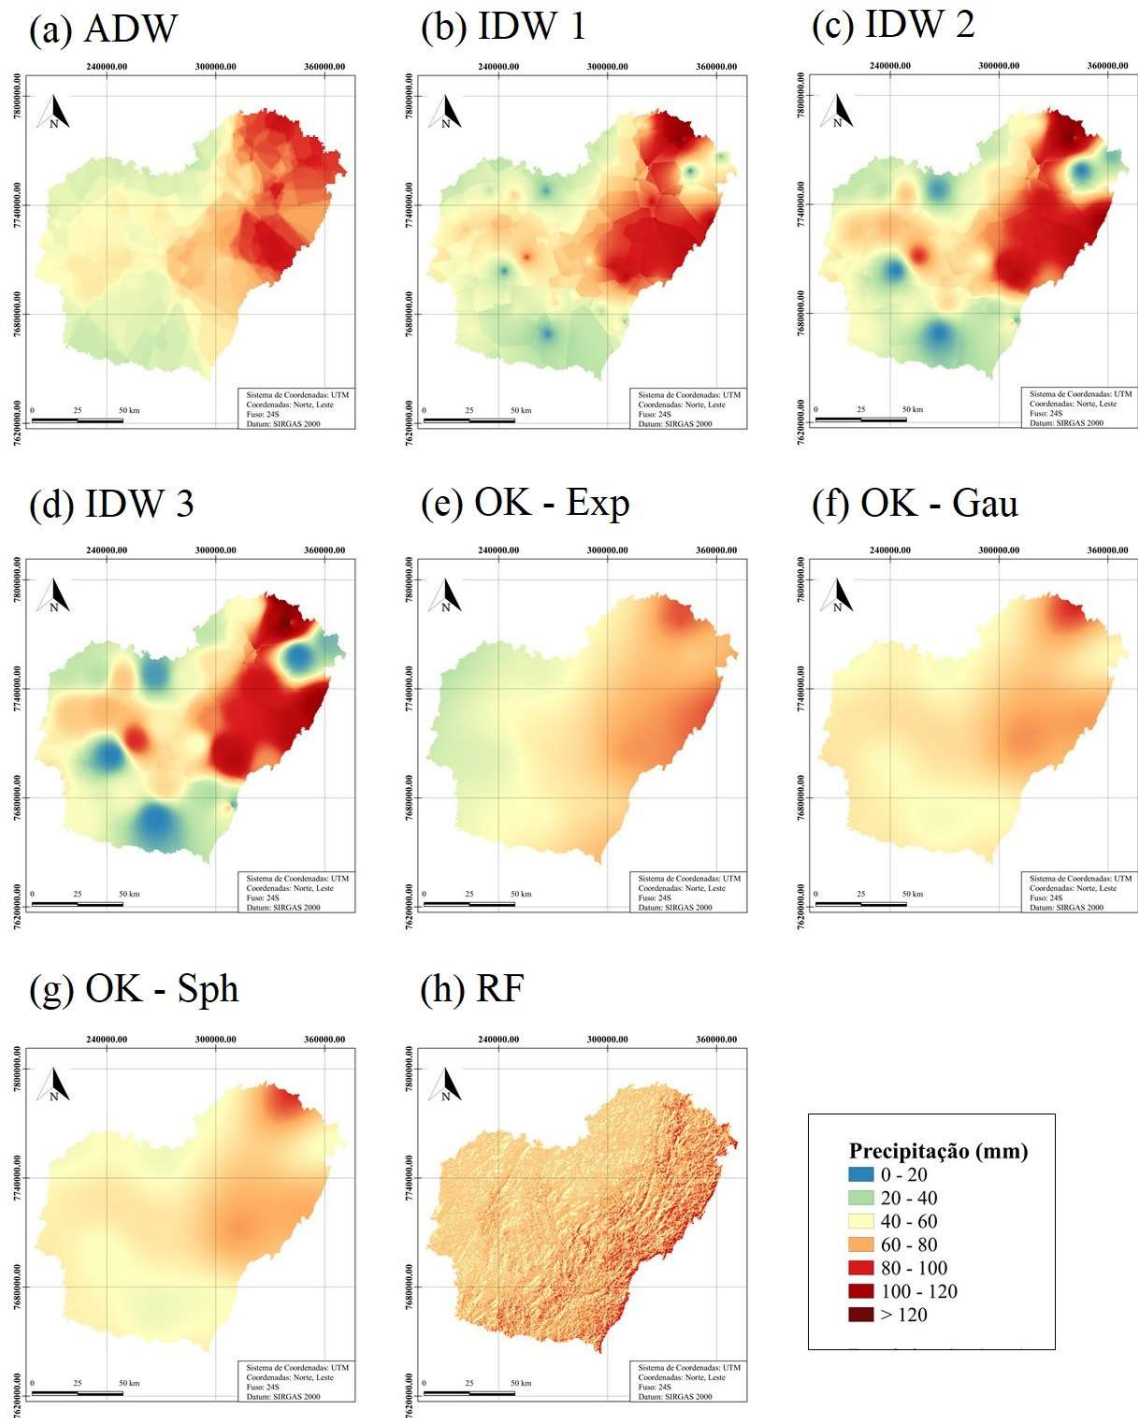


Figura 7 – Espacializações da precipitação diária do Sul do Espírito Santo em 09/11/2018, pelos métodos de interpolação.

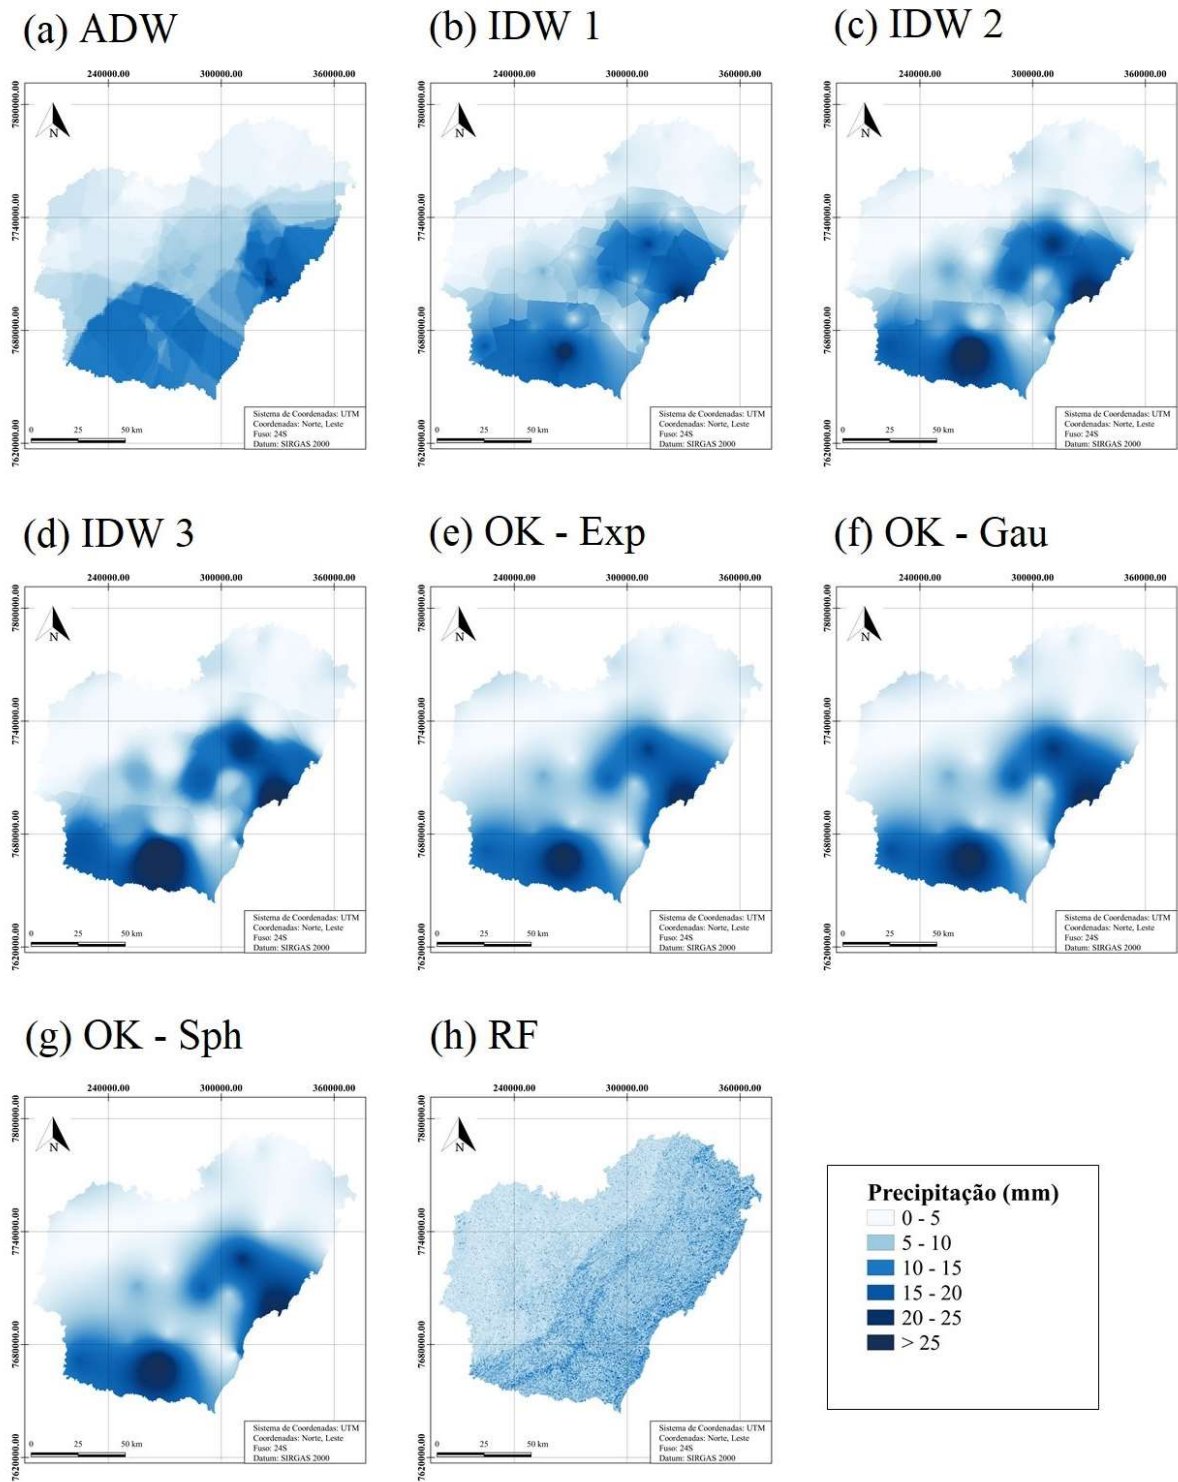


Figura 8 – Espacializações da precipitação diária do Sul do Espírito Santo em 01/08/2018, pelos métodos de interpolação.

3.2. BASE DE DADOS DE PRECIPITAÇÃO DIÁRIA EM FORMATO GRID

A partir da aplicação do método com melhor desempenho, foi criada e disponibilizada uma base de dados contendo os mapas de precipitação diária do Sul do Espírito Santo-Brasil, com as especificações técnicas expostas no Quadro 2. A base de dados está disponibilizada em: <http://dx.doi.org/10.17632/jdbwhxzw5h.2>.

Quadro 2. Especificações da base de dados de precipitação diária para as bacias hidrográficas do Sul do Espírito Santo-BR.

Formato	Série histórica	Escala temporal	Resolução espacial	Datum	SCR (Código EPSG)
GeoTIFF	1980-2018	Diária	0,01°	SIRGAS 2000	31984

3.3. COMPARAÇÃO ENTRE BASES DE DADOS DE PRECIPITAÇÃO DIÁRIA

A Tabela 2 apresenta os resultados numéricos (*BIAS*, *d* e *RMSE*) da comparação entre bases de dados em formato *grid*, conforme metodologia descrita em Schumacher et al. (2020). A Figura 9 demonstra as médias mensais para o período em análise (2007-2016), obtidas na comparação das bases de dados, utilizando o interpolador ADW.

Tabela 2. Resultados estatísticos da comparação de todas as bases de dados utilizadas no estudo.

Indicador	ADW	CHIRPS	SM2RAIN	TRMM	XAVIER
d (adimensional)	0,87	0,73	0,67	0,67	0,84
RMSE (mm)	3,77	7,07	5,67	8,65	3,78
BIAS (mm)	0,05	-0,30	-0,24	-0,17	0,04

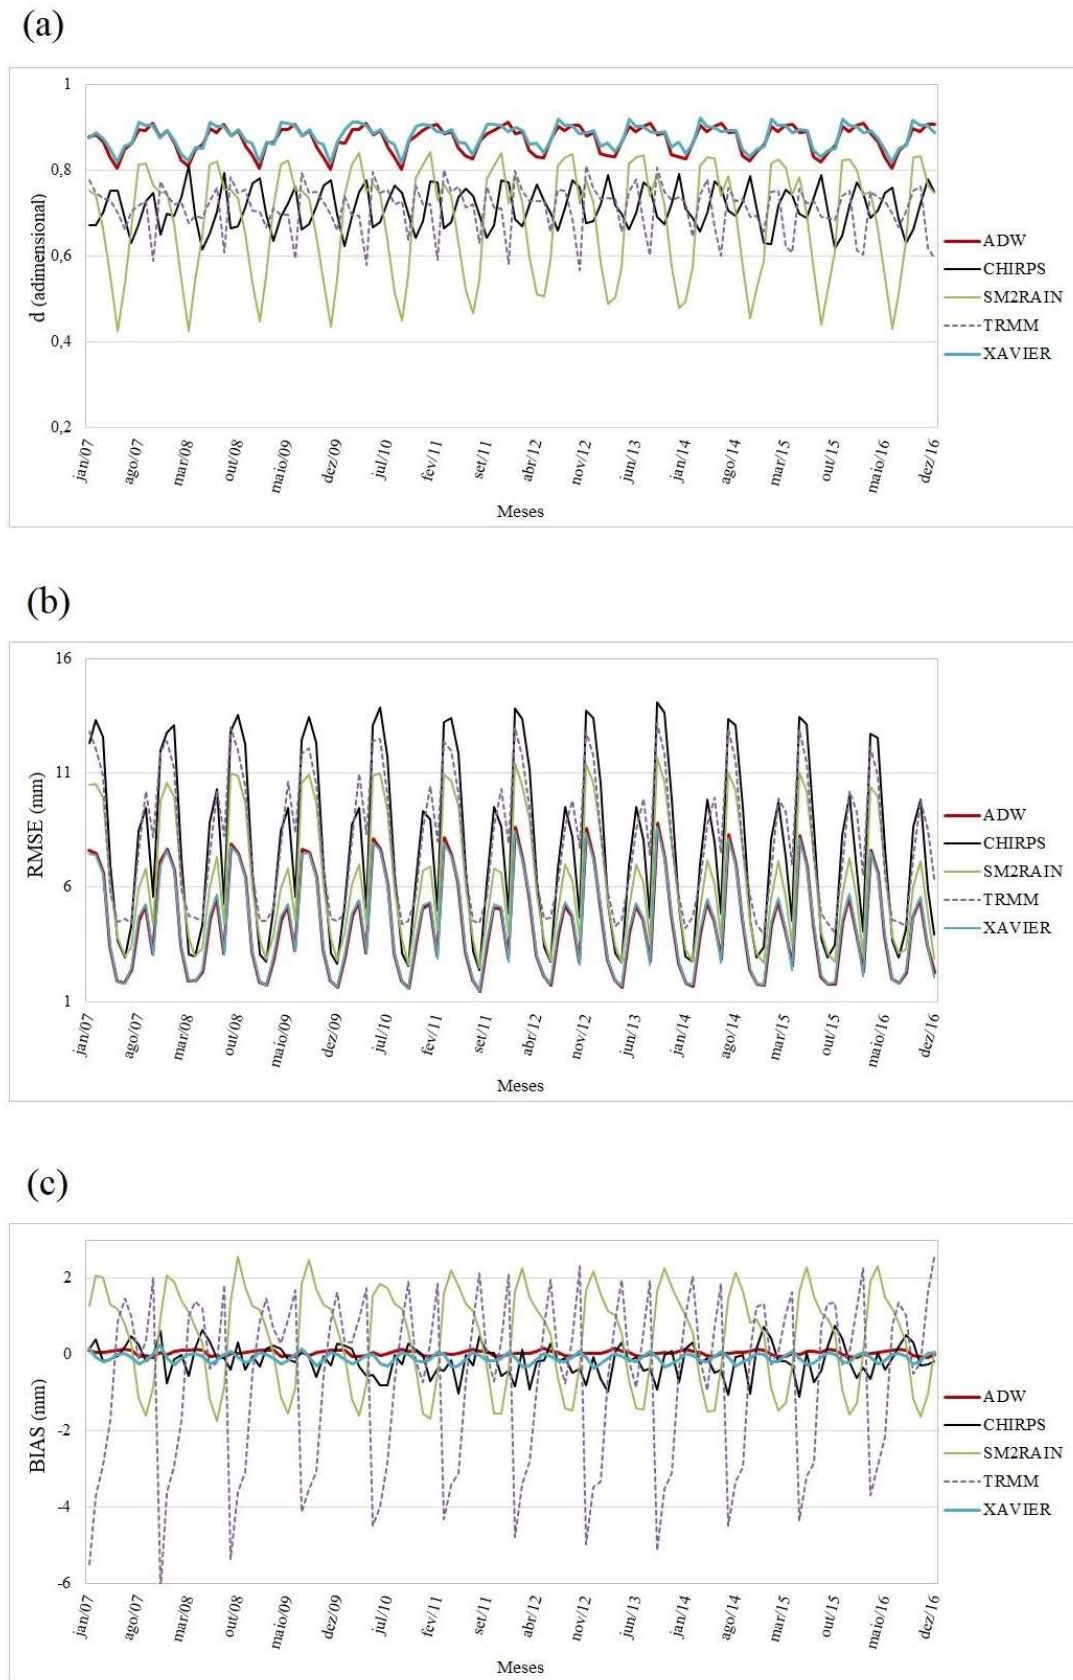


Figura 9 - Estatísticas médias mensais do total precipitado diário, para as bases de dados em formato grid nas bacias hidrográficas do Sul do Espírito Santo: a) “d”, b) “RMSE” e c) “BIAS”.

4. DISCUSSÃO

Na Figura 2 é possível observar que o ADW apresentou o melhor desempenho para a espacialização dos totais pluviométricos diários na maioria absoluta dos dias, de acordo com o índice “d”. Em contrapartida, quando se observa o RMSE, percebe-se que o RF é o interpolador com maior destaque; contudo, conforme será descrito na sequência, o método RF apresentou estatísticas (anuais e mensais) que denotam um desempenho inferior ao ADW, permitindo inferir que o método ADW é globalmente melhor que os demais interpoladores. Todavia, os valores de RMSE têm grande variação, devido à magnitude das chuvas diárias. Deste modo, o índice RMSE não é o mais adequado para determinar qual foi o melhor interpolador do total precipitado diário, sendo utilizado neste trabalho somente para fins de comparação com outros trabalhos semelhantes da literatura (Guo et al., 2020; Khouider et al., 2020; Lelis et al., 2018). Nesse sentido, devido ao índice “d” sempre variar entre 0 e 1, além de ser bastante utilizado para avaliar dados climáticos (precipitação) brasileiros (Saldanha et al., 2015; Silva et al., 2016; Tostes et al., 2017), optou-se por utilizá-lo como o mais adequado para a análise de desempenho.

Conforme a Tabela 1, Figura 5 e Figura 6 é possível observar que os interpoladores ADW e IDW (potências 1 a 3) obtiveram melhor desempenho na espacialização da precipitação diária, assim como também evidenciado para a Europa (Hofstra et al., 2008) e para o Brasil (Xavier et al., 2016). Nota-se, ainda, que apenas os interpoladores ADW e IDW3 obtiveram valores médios de “d” superiores a 0,7 (Tabela 1), considerados bons por Pereira et al. (2009).

As Figuras 5a e 6a mostram que os valores médios anuais e mensais desta estatística quase sempre foram superiores ao limite de 0,7 para o ADW, demonstrando, de maneira mais clara, a superioridade deste interpolador, seguido pelo IDW e finalmente pelo OK e RF.

Todos os interpoladores obtiveram valores médios de RMSE muito próximos (Tabela 1), os quais variaram próximos a 5 mm dia^{-1} , dentro das faixas ($4,7 - 8,9 \text{ mm dia}^{-1}$) encontradas por

Gadêlha (2018) que realizou seu estudo em todo território brasileiro, analisou 4911 estações, para o ano de 2016, apenas; Lucas et al. (2013), que realizou um estudo no município de Belo Horizonte-MG, fez uso de 16 estações, para dois dias distintos, no ano de 2017; e Xavier et al. (2016), que realizou um estudo em todo território brasileiro, analisou 3625 estações, entre os anos de 1980 até 2016. Esses valores significam que a precisão média é adequada e equivalente a uma chuva diária fraca, segundo Souza et al. (2012). A mesma proximidade entre os valores de RMSE de cada interpolador é notada nas Figuras 5b e 6b, demonstrando a dificuldade de identificar qual o melhor interpolador a partir da aplicação exclusiva deste índice, conforme também relatado por Portalés et al. (2010) e Wang et al. (2014). Ambas as Figuras ainda mostram que, durante alguns períodos (ex.: anos de 1991 e de 2009), apenas os interpoladores OK e RF apresentaram valores de RMSE bem superiores aos demais interpoladores, denotando, para tais períodos, maiores erros de estimativa da precipitação diária. Isto pode ter sido ocasionado por algumas chuvas consideravelmente altas em certas regiões, medidas por poucas estações, durante os meses de inverno, onde todas as demais regiões da área em estudo tiveram valores baixos ou nulos de precipitação diária, dificultando uma representação mais realística da precipitação pelos métodos OK e RF.

Por fim, os valores absolutos de BIAS (Tabela 1) não demonstraram grande diferença entre os interpoladores, pois todos demonstraram resultados semelhantes em (mm dia^{-1}). De modo geral, as previsões subestimaram os dados amostrais (BIAS positivo), com exceção da OK (gaussiana). Semelhante ao RMSE, os BIAS apresentados nas Figura 5c e 6c demonstram dificuldade em eleger, a partir do gráfico, qual foi o melhor interpolador, pois a maioria dos valores variaram dentro da mesma faixa. A exceção foi o RF, o qual tendeu a apresentar maiores BIAS e, conseqüentemente, maiores subestimativas das chuvas diárias. Na maior parte dos dias, os valores de BIAS variaram entre - 0,1 e + 0,1, valores semelhantes aos observados em Wagner

et al. (2012). Assim como evidenciado para o RMSE, os valores de BIAS para OK e RF, nos anos de 1991 e 2009, foram superiores aos dos demais interpoladores.

A Figura 6 mostra que nos meses de inverno há uma diminuição dos erros de estimativa comparativamente aos meses de verão. Esse comportamento pode estar relacionado à sazonalidade meteorológica, devido às lâminas precipitadas diárias serem menores e com menor variabilidade espacial no inverno, conseqüentemente diminuindo a magnitude dos erros. Este comportamento é comum em análises de dados diários, principalmente de chuva (Hofstra et al., 2008; Wüest et al., 2009; Yang et al., 2019). No Estado do Espírito Santo há concentração de chuvas no verão (Cheval et al., 2011; Mello et al., 2012), em que há maiores lâminas precipitadas, associadas a uma maior variabilidade espacial, especialmente devido às chuvas convectivas, as quais são mais difíceis de serem adequadamente representadas por meio de interpolação espacial (Shen et al., 2001). Além disso, os erros são menores no inverno devido à uma grande quantidade de observações de precipitação iguais a zero, fazendo com que as predições nesses meses sejam de pequena magnitude, conseqüentemente, diminuindo a diferença entre os valores estimados e observados.

Nos gráficos de dispersão apresentados nas Figuras 3 (verão) e 4 (inverno), observa-se que não houve um ajuste adequado entre os valores observados e estimados. Porém, este comportamento já era esperado, semelhante aos encontrados por Yang et al. (2019) e Bozzini & Mélo Junior (2020), estando associado à grande variabilidade espaço-temporal de eventos hidrológicos aleatórios, como a chuva diária (Hartmann et al., 2011; Sanches et al., 2013). Todavia, apesar desta limitação, os dados diários de precipitação obtidos através da espacialização são úteis para diversas aplicações, incluindo a detecção de mudanças climáticas (Salviano et al., 2016; Trenberth, 2011) e estudo de inundações (Madsen et al., 2014; Schumacher, 2016), na modelagem hidrológica, em especial manejo integrado de bacias hidrográficas (Romero & Ortiz, 2008; Tundisi, 2008), além possibilitar a compreensão de como

o clima interage com os processos terrestres, hidrológicos e biogeoquímicos (Hofstra et al., 2008), entre outros.

Ainda nas Figuras 3 e 4, pode-se observar que o valor calculado pelos métodos OK e RF apresenta menor amplitude entre os valores máximos e mínimos que os demais métodos, pois ambos métodos representaram a variação de valores estimados entre 0 e 100 mm dia⁻¹; todavia, os dados observados variam entre 0 a 200 mm dia⁻¹, como foi corretamente expressa no método ADW. Isso ocorre porque OK e RF suavizam os valores reais da variável, buscando a variância mínima (Cressie, 1983), o que promove uma maior homogeneidade da superfície. Nesse sentido, a suavização também é responsável pelo comportamento dos resultados encontrados nas Figuras 5 e 6. Os efeitos de suavização levam os valores pequenos a serem superestimados e os valores grandes a serem subestimados (Yamamoto, 2005). Ademais, a suavização causa a perda dos valores originais (medidos), tornando estes métodos não recomendados para determinadas aplicações, como por exemplo o estudo de chuvas extremas, estimativa de erosão e de escoamento superficial, em especial no planejamento ambiental/hidrológico.

Na Figura 7 observam-se semelhanças entre alguns interpoladores em um dia típico de verão. O ADW e o IDW apresentam uma fraca suavização das chuvas, diferentemente dos demais métodos, explicitando sua superioridade na representação de chuvas diárias. Isto porque quanto menor a escala temporal, mais heterogênea (abrupta) será a representação espacial das chuvas, uma vez que a precipitação é um fenômeno com grande variabilidade espaço-temporal (Nery et al., 2017; Nunes et al., 2018; Shi et al., 2014), em especial devido aos eventos convectivos, comuns no verão. A maior suavização decorrente do OK e do RF deixou os mapas visualmente mais homogêneos. Essa maior suavização da superfície de resposta também foi relatada em outras pesquisas (Yamamoto, 2005; Zhu, 2013), as quais alertam para um problema decorrente: subestimativa dos grandes valores (chuvas intensas). Esta subestimativa é prejudicial, por exemplo, para a modelagem chuva-vazão, pois podem estar apresentando uma precipitação

acumulada não real, baseada na média encontrada na área em estudo, não havendo uma nítida distinção entre as áreas com altos e baixos índices pluviométricos (Cunha et al., 2014; Sousa et al., 2010). O resultado serão valores de vazão também subestimadas, as quais são indesejáveis para aplicações em dimensionamento de obras hidráulicas de engenharia, como obras de barragens e drenagem urbana (Batista & Boldrin, 2018; Souza-Cruz-Buenaga et al., 2019).

A partir dos mapas apresentados na Figura 8 observou-se que todos os interpoladores possuem um desempenho semelhante, considerado bom, para dias com pouca chuva. Desta forma, reforçam-se as análises realizadas sobre a Figura 3, quando se afirmou que, para a área em estudo, os interpoladores apresentam melhores resultados no inverno. Esta afirmação coincide com outros estudos, cujas regiões também apresentam índices pluviométricos menores no inverno e maiores no verão (Chen et al., 2010; Xavier et al., 2015). Nesse sentido, pode-se dizer que para dias pouco chuvosos qualquer interpolador espacial utilizado no presente trabalho pode ser utilizado, principalmente para estudos referentes a disponibilidade hídrica do solo (Guerra et al., 2013; Sales et al., 2017).

Finalmente, a análise em conjunto das Figuras 2 a 8 e da Tabela 1, possibilita eleger o ADW como melhor interpolador da chuva diária do Sul do estado do Espírito Santo-BR. Desta forma, para a criação da base de dados em formato *grid*, neste trabalho, utilizou-se o interpolador ADW. Os melhores resultados do ADW podem estar relacionados ao fato de que este método não pode extrapolar a magnitude do valor mais alto/mais baixo nos pontos de dados contribuintes e, portanto, não está sujeito a ultrapassar os mesmos (New et al. 2000). Outro fator importante no método ADW, que o diferencia dos demais, é a sua simplicidade, semelhante ao IDW.

A superioridade do ADW também ocorre devido às características intrínsecas ao método, como a consideração do raio de influência, usado na interpolação, que varia em função da densidade do conjunto de pontos observacionais, cuja distância é definida pelos CDDs. Desta

forma, este raio de influência pode aumentar em áreas onde a variabilidade espacial das estações é alta, e diminuir onde a variabilidade é menor (New et al., 2000), consequentemente utilizando valores reais e, que, muitas vezes, possuem alta correlação.

Nota-se, na Tabela 2 e Figura 9, que a base de dados obtida neste trabalho (denominada base ADW) e a de XAVIER (Xavier et al., 2015) apresentaram performance de estimativa dos totais pluviométricos diários superior às demais. Na Figura 9a, observa-se que as bases de dados ADW e XAVIER foram as que mais se destacaram, com “d” sempre superior a 0,8, seguidas de CHIRPS e TRMM/SM2RAIN. Contudo, estes resultados mostram que ADW, XAVIER e CHIRPS tem um desempenho considerado bom para o índice “d” ($>0,70$), uma vez que, quanto mais próximos de 1 os valores de “d”, maior é a concordância entre os valores estimados e observados (Tostes et al., 2017). Já na Figura 9b, observa-se que, novamente, as bases ADW e XAVIER encontram-se visualmente sobrepostas, seguidas por SM2RAIN, TRMM e CHIRPS. A base de dados CHIRPS é a que apresenta maior variação entre os valores máximos e mínimos de RMSE. A partir da análise visual dos valores obtidos para RMSE, constata-se que todas as bases de dados encontram-se dentro dos valores esperados para o Brasil ($4,7 - 8,9 \text{ mm dia}^{-1}$), encontrados em Gadêlha (2018) e Lucas et al. (2013). Por fim, a Figura 9c mostra que o TRMM foi a base com maior variação absoluta entre os valores mínimos e máximos de BIAS.

A Figura 9 também demonstra que nos meses de inverno, os picos mínimos do RMSE são menores, demonstrando uma nítida diminuição deste erro. Isto está relacionado à sazonalidade da chuva do Sul do Espírito Santo-BR, já apresentadas neste trabalho (Hofstra et al., 2008; Wüest et al., 2009; Yang et al., 2019). Ou seja, tanto as interpolações quanto as bases de dados obtidas por satélites estão sujeitas à sazonalidade das amostras, fazendo com que, de forma geral, todas as bases de dados consigam representar melhor os eventos de precipitação nos meses mais secos (inverno), em comparação aos meses de verão, devido às flutuações da

velocidade do vento e temperatura do ar, na área em estudo, onde há concentração de chuvas no verão (Cheval et al.,2011; Mello et al., 2012).

A tendência do melhor desempenho das bases ADW e XAVIER está relacionada à semelhança do método de elaboração de ambas as bases de dados, que espacializaram dados pontuais medidos diretamente em estações pluviométricas (da ANA), e utilizaram o mesmo interpolador espacial. Todavia, a maior diferença entre a base de dados ADW e XAVIER é a resolução espacial, onde a base ADW possui uma resolução de $0,01^\circ$, possuindo um nível de detalhamento maior que às demais bases de dados. Devido às bases de dados CHIRPS, SM2RAIN-ASCAT e TRMM serem produtos de sensoriamento remoto, que estimam a chuva com base em observações de diferentes variáveis medidas por satélites e não por espacialização de medições pontuais (Brocca et al., 2014; Funk et al., 2015; NASA, 2020), houve esta diferença entre os resultados destas bases e as bases ADW e XAVIER. Contudo, isso não significa que estas bases de dados são inferiores, ou até mesmo inadequadas, pois seu índice “d” foi muito próximo ou superior a 0,7. Ressalta-se que estas bases são amplamente utilizadas na atualidade por diversos estudos (Amini et al., 2019; Ciabatta et al.,2018; Jalilvand et al., 2018; Jesus et al., 2016; Massari et al., 2018; PACA et al.,2020; Rivera et al.,2019; Young-Sik et al., 2019; Yuan et al., 2019), em especial quando há indisponibilidade de dados medidos em estações meteorológicas.

5. CONCLUSÕES

Com base nos resultados obtidos no presente trabalho, para espacialização da precipitação diária, através das diversas análises (matemáticas, visuais) realizadas, concluiu-se que o melhor método de interpolação espacial do Sul do Espírito Santo-BR foi o ADW.

A partir da definição do melhor interpolador espacial (ADW), foi elaborada uma base de dados de precipitação diária (1980-2018) com resolução espacial de $0,01^\circ$, que cobre as bacias

hidrográficas do Sul do estado do Espírito Santo, situadas no bioma Mata Atlântica. Esta base de dados foi disponibilizada on-line em um endereço específico.

Por meio da comparação das bases de dados de precipitação diária em formato *grid*, conclui-se que as melhores bases de dados foram ADW e Xavier et al. (2015), respectivamente.

REFERÊNCIAS BIBLIOGRÁFICAS

ABNT - Associação Brasileira de Normas Técnicas. **NBR14.166: Rede de Referência Cadastral Municipal - Procedimento**. São Paulo, 1998.

AGERH, Agência Estadual de Recursos Hídricos. **Comitês de Bacias Hidrográficas** Disponível em < <https://agerh.es.gov.br/documentos-dos-comites>>. Acesso em 20 mai. 2020.

ALMAGRO, A.; OLIVEIRA, P. T. S.; NEARING, M. A.; HAGEMANN, S. Projected climate change impacts in rainfall erosivity over Brazil. **Scientific Reports**, v.7, 2017.

ALMEIDA, C.T.; DELGADO, R.C.; OLIVEIRA JUNIOR, J.F.; GOIS, G.; CAVALCANTI, A.S. Avaliação das Estimativas de Precipitação do Produto 3B43-TRMM do Estado do Amazonas. **Floresta e Ambiente**, v.22, 279–286, 2015.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2014.

AMINI, A.; ABDEH KOLAHCHI, A.; AL-ANSARI, N.; KARAMI MOGHADAM, M.; MOHAMMAD, T. Application of TRMM Precipitation Data to Evaluate Drought and Its Effects on Water Resources Instability. **Applied Sciences**, v. 9, 2019.

AMORIM, R. C. F.; RIBEIRO, A.; LEITE, C. C.; LEAL, B. G.; SILVA, J. B. G. Avaliação do desempenho de dos métodos de espacialização da precipitação pluvial para o estado de Alagoas. **Acta Scientiarum Technology**, v.30, n.1, p.87-91, 2008.

ASLAMI, F.; GHORBANI, A.; SOBHANI, B.; ESMALI, A. Comprehensive comparison of daily IMERG and GSMaP satellite precipitation products in Ardabil Province, Iran. **International Journal of Remote Sensing**, v.40, p.3139-3153, 2019.

AVILA, F. B.; DONG, SIYAN.; MENANG, K.P.; RAJCZAK, JAN.; RENOM, M.; DONAT, M.G.; ALEXANDER, L.V. Systematic investigation of gridding-related scaling effects on annual statistics of daily temperature and precipitation maxima: A case study for south-east Australia. **Weather and Climate Extremes**. v.9, p. 6-16, 2015.

BATISTA, J. A. N.; BOLDRIN, A. J. Avaliação do desempenho hidráulico de um sistema de drenagem de águas pluviais urbanas. **Eng. Sanit. Ambient.**, v. 23, n. 2, p. 263-273, 2018.

BIAU, G.; SCORNET, E. A random forest guided tour. **TEST**, v.25, ed. 2, p.197–227, 2016.

BIER, A.A.; FERRAZ, S.E.T.; BIER, A.A.; FERRAZ, S.E.T. Comparação de Metodologias de Preenchimento de Falhas em Dados Meteorológicos para Estações no Sul do Brasil. **Revista Brasileira de Meteorologia**, v.32, p.215-226, 2017.

BOZZINI, P. L.; MELLO JUNIOR, A. V. Previsões de Precipitação de Modelos Atmosféricos como Subsídio à Operação de Sistemas de Reservatórios. **Revista Brasileira de Meteorologia**, v.35, n.1, p.99-109, 2020.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, ed. 1, p. 5–32, 2001.

BROCCA, L.; CIABATTA, L.; MASSARI, C.; MORAMARCO, T.; HAHN, S.; HASENAUER, S.; KIDD, R.; DORIGO, W.; WAGNER, W.; LEVIZZANI, V. Soil as a natural rain gauge: Estimating global rainfall from satellite soil moisture data. **Journal of Geophysical Research: Atmospheres**, v. 119, p. 5128–5141, 2014.

CAI, X.; WANG, X.; JAIN, P.; FLANNIGAN, M. D. Evaluation of gridded precipitation data and interpolation methods for forest fire danger rating in Alberta, Canada. **Journal of Geophysical Research: Atmospheres**, v. 124, p. 3-17, 2019.

CAMARGO, A. P.; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, v.5, n.1, p.89-97, 1997.

CAMERA, C.; BRUGGEMAN, A.; HADJINICOLAOU, P.; PASHIARDIS, S.; LANGE, M. A. Evaluation of interpolation techniques for the creation of gridded daily precipitation ($1 \times 1 \text{ km}^2$); Cyprus, 1980–2010. **Journal of Geophysical Research: Atmospheres**, v.119, ed.2, p.693-712, 2014.

CASTRO, F. S.; PEZZOPANE, J. E.M.; CECÍLIO, R. A.; PEZZOPANE, J. R. M.; XAVIER, A. C. Avaliação do desempenho dos diferentes métodos de interpoladores para parâmetros do balanço hídrico climatológico. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n.8, 2010.

CECCHERINI, G.; AMEZTOY, I.; HERNÁNDEZ, C.P.R.; MORENO, C.C. High-Resolution Precipitation Datasets in South America and West Africa based on Satellite-Derived Rainfall, Enhanced Vegetation Index and Digital Elevation Model. **Remote Sensing**, v.7, ed. 5, p.6454-6488, 2015.

CHEN, D.; OU, T.; GONG, L.; XU, C.-Y.; LI, W.; HO, C.-H.; QIAN, W. Spatial interpolation of daily precipitation in China: 1951–2005. **Adv. Atmos. Sci.** v.27, p.1221-1232, 2010.

CHEN, T.; REN, L.; YUAN, F.; YANG, X.; JIANG, S.; TANG, T.; LIU, Y.; ZHAO, C.; ZHANG, L. Comparison of Spatial Interpolation Schemes for Rainfall Data and Application in Hydrological Modeling. **Water**, v.9, n.342, 2017.

CECONI, D. E.; PICCILLI, D. G. A.; BERNARDI, F.; FENSTERSEIFER, P. Analysis of vulnerability for environmental planning of a water supply basin. **Ambiente & Sociedade**, v.21, 2018.

CHAVES, H. M. L.; SANTOS, L. B. Ocupação do solo, fragmentação da paisagem e qualidade da água em uma pequena bacia hidrográfica. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, p.922-930, 2009.

CHAVEZ, S. P.; TAKAHASHI, K. Orographic rainfall hot spots in the Andes-Amazon transition according to the TRMM precipitation radar and in situ data, **Journal of Geophysical Research: Atmospheres**, v.122, p.5870-5882, 2017.

CHEN, H.Y.; HOU, T.W.; CHUANG, C.H. Applying data mining to explore the risk factors of parenting stress. **Expert Systems with Applications**, v.37, p.598-601, 2010.

CHEVAL, S.; BACIU, M.; DUMITRESCU, A.; BREZA, T.; LEGATES, D. R.; CHENDEŞ, V. Climatologic adjustments to monthly precipitation in Romania. **International Journal of Climatology**, v. 31, p.704-714, 2011.

CIABATTA, L.; MASSARI, C.; BROCCA, L.; GRUBER, A.; REIMER, C.; HAHN, S.; PAULIK, C.; DORIGO, W.; KIDD, R.; WAGNER, W. SM2RAIN-CCI: a new global long-term rainfall data set derived from ESA CCI soil moisture. **Earth System Science Data**, v. 10, p.267-280, 2018.

CRESSIE, N. Kriging Nonstationary Data. **Journal of the American Statistical Association**, v. 81, p.625-634, 1983.

CRUZ, P. P. N.; GREEN, T. R.; FIGUEIREDO, R. O.; PEREIRA, A. S.; KIPKA, H.; SAAD, S. Y.; SILVA, J. M.; GOMES, M. A. F. Hydrological modeling of the Ribeirão das Posses - An assessment based on the Agricultural Ecosystem Services (AgES) watershed model. **Revista Ambiente & Água**, v.12, n.3, 2017.

CUNHA, A. C.; VILHENA, J. E. S.; SANTOS, E. S.; SARAIVA, J. M. B.; KUHN, P. A. F.; BRITO, D. C.; SOUZA, E. B.; ROCHA, E. P.; CUNHA, H. F. A.; BRITO, A. U.; JÚNIOR, A. C. P. B.; PACA, V. H. M.; SANTOS, P. V. C. J. Evento extremo de chuva-vazão na bacia hidrográfica do rio Araguari, Amapá, Brasil. **Revista Brasileira de Meteorologia**, v.29, 2014.

CUNHA, P. C. R.; NASCIMENTO, J. L.; SILVEIRA, P. M.; ALVES JUNIOR, J. A. Eficiência de métodos para o cálculo de coeficientes do tanque classe A na estimativa da evapotranspiração de referência. **Pesquisa Agropecuária Tropical**, v. 43, n. 2, p. 114-122, 2013.

DARAND, M.; AMANOLLAHI, J.; ZANDKARIMI, S. Evaluation of the performance of TRMM Multi-satellite Precipitation Analysis (TMPA) estimation over Iran. **Atmos. Res.** v.190, p.121-127, 2017.

DAS, S. Extreme rainfall estimation at ungauged sites: Comparison between region-of-influence approach of regional analysis and spatial interpolation technique. **International Journal of Climatology**, v. 39, 2018.

DI PIAZZA, A.; LO CONTI, F.; NOTO, L. V.; VIOLA, F.; LA LOGGIA, G. Comparative analysis of different techniques for spatial interpolation of rainfall data to create a serially complete monthly time series of precipitation for Sicily, Italy. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, ed. 3, p. 396-408, 2011.

FALCK, A.S.; VILA, D.; TOMASELLA, J.; MAGGIONI, V.; DINIZ, F.L.R.; FALCK, A.S.; VILA, D.; TOMASELLA, J.; MAGGIONI, V.; DINIZ, F.L.R. Avaliação de um Modelo Estocástico de Erro Multidimensional Aplicado a Estimativas de Precipitação por Satélite. **Rev. Bras. Meteorol.** v.31, p.52-63, 2016.

FANG, G.; YANG, J.; CHEN, Y.; LI, Z.; JI, H.; MAEYER, P. D. How Hydrologic Processes Differ Spatially in a Large Basin: Multisite and Multiobjective Modeling in the Tarim River Basin. **Journal of Geophysical Research: Atmospheres**, v.123, n.14, p.7098-7113, 2018.

FEIL, A. A.; STRASBURG, V. J.; SPILKI, F. R. Variáveis intervenientes na existência de comitês de bacias hidrográficas no Brasil. **Revista Ambiente & Água**, v.12, n.2, p.340-350, 2017.

FRAZIER, A. G.; GIAMBELLUCA, T. W.; DIAZ, H. F.; NEEDHAM, H. L. Comparison of geostatistical approaches to spatially interpolate month-year rainfall for the Hawaiian Islands. **International Journal of Climatology**, v. 36, p.1459-1470, 2016.

FUENTES, I.; PADARIAN, J.; OGTROP, F.; VERVOORT, R.W. Comparison of Surface Water Volume Estimation Methodologies That Couple Surface Reflectance Data and Digital Terrain Models. **Water**, v.11, 2019.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations-a new environmental record for monitoring extremes. **Scientific Data**, n.2, 2015.

GADÊLHA, A.N. **Análise da missão GPM (Global Precipitation Measurement) na estimativa da precipitação sobre território brasileiro**. 2018. 82f. Dissertação (Mestrado em Engenharia Civil e Ambiental) – Centro de Tecnologia, Universidade Federal da Paraíba, João Pessoa, 2018.

GHARAEI-MANESH, S.; FATHZADEH, A.; TAGHIZADEH-MEHRJARDI, R. Comparison of artificial neural network and decision tree models in estimating spatial distribution of snow depth in a semi-arid region of Iran. **Cold Regions Science and Technology**, v.122, p.26-35, 2016.

GUERRA, V.; MOREIRA, V.; PEDROSO, D.; ROBERTI, D.R.; FERRAZ, S.E.T.; BATTISTI, A. Análise Das Componentes Hídricas, Precipitação, Evapotranspiração E Umidade Na Superfície Do Solo Representadas Pelo Modelo Climático Regional Regcm3, Para Uma Região De Cultivo De Soja. **Ciência e Nat.** p.452-454, 2013.

GUO, B.; ZHANG, J.; MENG, X.; XU, T.; SONG, Y. Long-term spatio-temporal precipitation variations in China with precipitation surface interpolated by ANUSPLIN. **Sci. Rep.** v.10, n.81, 2020.

HARRIS, I.; OSBORN, T.J.; JONES, P.; LISTER, D. Version 4 of the CRU TS monthly high-resolution gridded multivariate climate dataset. **Scientific Data**, v.7, 2020.

HARTMANN, M.; MOALA, F. A.; MENDONÇA, M. A. Estudo das precipitações máximas anuais em Presidente Prudente. **Revista Brasileira de Meteorologia**, v.26, n. 4, p.561-568, 2011.

HE, X.; CHANEY, N.W.; SCHLEISS, M.; SHEFFIELD, J. Spatial downscaling of precipitation using adaptable random forests. **Water Resour. Res.** v.52, p.8217-8237, 2016.

HENGL, T.; NUSSBAUM, M.; WRIGHT, M. N.; HEUVELINK, G. B.M.; GRÄLER, B. Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. **PeerJ**. 2018.

HOFSTRA, N.; HAYLOCK, M.; NEW, M.; JONES, P.; FREI, C. Comparison of six methods for the interpolation of daily, European climate data. **Journal of Geophysical Research**, v.113, 2008.

HOFSTRA, N.; NEW, M. Spatial variability in correlation decay distance and influence on angular-distance weighting interpolation of daily precipitation over Europe. **International Journal of Climatology**, v.29, p.1872-1880, 2009.

IBGE, Instituto Brasileiro de Geografia e Estatística. **Espírito Santo**. 2018. Disponível em <<https://cidades.ibge.gov.br/brasil/es>>. Acesso em 20 mai. 2020.

IBRAHIM, G. R. F.; RASUL, A.; HAMID, A.A.; ALI, Z.F.; DEWANA, A.A. Suitable Site Selection for Rainwater Harvesting and Storage Case Study Using Dohuk Governorate. **Water**, v.11, 2019.

ISOTTA, F. A.; BEGERT, M.; FREI, C. Long-Term Consistent Monthly Temperature and Precipitation Grid Data Sets for Switzerland Over the Past 150 Years. **Journal of Geophysical Research: Atmospheres**, v.123, 2019.

JALILVAND, E.; TAJRISHY, M.; BROCCA, L.; MASSARI, C.; GHAZI ZADEH HASHEMI, S.A.; CIABATTA, L. Estimating the drainage rate from surface soil moisture drydowns: Application of DfD model to in situ soil moisture data. **Journal of Hydrology**, p.489–501, 2018.

JESÚS, A.; BREÑA-NARANJO, J.; PEDROZO-ACUÑA, A.; ALCOCER YAMANAKA, V. The Use of TRMM 3B42 Product for Drought Monitoring in Mexico. **Water**, v.8, n.325, 2016.

JESUS, J. B.; ROSA, C. N.; BARRETO, I. D. C.; FERNANDES, M. M. Análise da incidência temporal, espacial e de tendência de fogo nos biomas e unidades de conservação do Brasil. **Ciência Florestal**, v.30, n.1, p.176-191, 2020.

JOIA, P. R.; ANUNCIACAO, V. S.; PAIXAO, A. A. Implicações do uso e ocupação do solo para o planejamento e gestão ambiental da Bacia Hidrográfica do Rio Aquidauana, Mato Grosso do Sul. **Interações (Campo Grande)**, v.19, n.2, p.343-358, 2018.

KATIRAIE-BOROUJERDY, P.; ASANJAN, A. A.; CHAVOSHIAN, A.; HSU, K. Assessment of seven CMIP5 model precipitation extremes over Iran based on a satellite-based climate data set. **International Journal of Climatology**, 2019.

KHOUIDER, B.; SABEERALI, C.T.; AJAYAMOHAN, R.S.; PRAVEEN, V.; MAJDA, A.J.; PAI, D.S.; RAJEEVAN, M. A Novel Method for Interpolating Daily Station Rainfall Data Using a Stochastic Lattice Model. **J. Hydrometeorol.** v.21, p.909-933, 2020.

KRAJEWSKI, A.; SIKORSKA-SENONER, A. E.; RANZI, R.; BANASIK, K. Long-Term Changes of Hydrological Variables in a Small Lowland Watershed in Central Poland. **Water**, v.11, n.564, 2019.

LI, J.; HEAP, A.D.; POTTER, A., DANIELL, J.J. Application of machine learning methods to spatial interpolation of environmental variables. **Environmental Modelling & Software**, v.26, p.1647-1659, 2011.

LIPPER, L.; THORNTON, P.; CAMPBELL, B. M.; BAEDEKER, T.; BRAIMOH, A.; BWALYA, M.; CARON, P.; CATTANEO, A.; GARRITY, D.; HENRY, K.; HOTTLE, R.; JACKSON, L.; JARVIS, A.; KOSSAM, F.; MANN, W.; MCCARTHY, N.; MEYBECK, A.;

- NEUFELDT, H.; REMINGTON, T.; SEN, P. T.; SESSA, R.; SHULA, R.; TIBU, A.; TORQUEBIAU, E. F. Climate-smart agriculture for food security. **Nature Climate Change**, v.4, p.1068-1072, 2014.
- LIU, W.; WANG, L.; SUN, F.; LI, Z.; WANG, H.; LIU, J.; YANG, T.; ZHOU, J.; QI, J. Snow Hydrology in the Upper Yellow River Basin Under Climate Change: A Land Surface Modeling Perspective. **Journal of Geophysical Research: Atmospheres**, v.123, n.22, p.676-691, 2018.
- LUCAS, T.P.B.; PLEC, D.; ABREU, M.L.; PARIZZI, M.G. Identificação De Interpoladores Adequados a Dados De Chuva a Partir De Parâmetros Estatísticos. **Rev. Bras. Climatol.** v.13, p.7-21, 2014.
- LUNDGREN, W. J. C.; SILVA, J. A. A.; FERREIRA, R. L. C. Estimação do Volume de Eucaliptos por Krigagem e Cokrigagem no Semiárido Pernambucano. **Floresta e Ambiente**, v. 24, 2017.
- MACHADO, N. G.; MEIRELLES, T.; DANELICHEN, V. H. M.; QUERINO, C. A. S.; BIUDES, M. S. Estimation of Rainfall by Neural Network Over a Neotropical Region. **Revista Brasileira de Climatologia**, v. 17, p.44-54, 2015.
- MADSEN, H.; LAWRENCE, D.; LANG, M.; MARTINKOVA, M.; KJELDTSEN, T.R. Review of trend analysis and climate change projections of extreme precipitation and floods in Europe. **J. Hydrol.** p.3634-3650, 2014.
- MAIDMENT, R.I.; GRIMES, D.; BLACK, E.; TARNAVSKY, E.; YOUNG, M.; GREATREX, H.; ALLAN, R.P.; STEIN, T.; NKONDE, E.; SENKUNDA, S.; ALCÁNTARA, E.M.U. A new, long-term daily satellite-based rainfall dataset for operational monitoring in Africa. **Sci. Data.** v.4, 2017.
- MARENGO, J. A.; NOBRE, C. A.; SELUCHI, M. E.; CUARTAS, A.; ALVES, L. M.; MENDIONDO, E. M.; OBREGÓN, G.; SAMPAIO, G. A seca e a crise hídrica de 2014-2015 em São Paulo. **Revista USP.** n. 106, p. 31-44, 2015.
- MASSARI, C.; CAMICI, S.; CIABATTA, L.; BROCCA, L. Exploiting satellite-based surface soil moisture for flood forecasting in the Mediterranean area: State update versus rainfall correction. **Remote Sens.** v.10, 2018.
- MEDEIROS, F. J.; LIMA, K. C.; CAETANO, D. A.; SILVA, F. J. O. Impacto da Variabilidade Interanual da Precipitação nos Reservatórios do Semiárido do Nordeste do Brasil. **Anuário do Instituto de Geociências**, v. 41, n.3, p. 731-741, 2018.
- MELLO, C. R. de; SILVA, A. M. da. **Hidrologia: princípio e aplicações em sistemas agrícolas.** Lavras: UFLA, 2013. 455 p.
- MELLO, C. R.; VIOLA, M. R.; BESKOW, S. Vazões máximas e mínimas para bacias hidrográficas da região alto Rio Grande, MG. **Ciência e Agrotecnologia.** v.34, n.2, p. 494-502, 2010.
- MELLO, C. R.; VIOLA, M. R.; CURTI, N.; SILVA, A. M. Distribuição espacial da precipitação e da erosividade da chuva mensal e anual no Estado do Espírito Santo. **Revista Brasileira de Ciência do Solo**, v.36, n.6, p.1878-1891, 2012.

MENDEZ, M.; CALVO-VALVERDE, L. A.; MAATHUIS, B.; ALVARADO-GAMBOA, L. F. Generation of Monthly Precipitation Climatologies for Costa Rica Using Irregular Rain-Gauge Observational Networks. **Water**, v. 11, 2019.

MMA. Ministério do Meio Ambiente. **Biomás**. Disponível em: <http://www.mma.gov.br/biomás>. Acesso em: 9 out. 2020.

MMA. Ministério do Meio Ambiente. **Mata Atlântica**. Disponível em: https://www.mma.gov.br/estruturas/202/_arquivos/adequao_ambiental_publicao_web_202.pdf. Acesso em: 10 jun. 2020.

MONDAL, A.; LAKSHMI, V.; HASHEMI, H. Intercomparison of trend analysis of Multisatellite Monthly Precipitation Products and Gauge Measurements for River Basins of India. **Journal of Hydrology**, v. 565, p. 779-790, 2018.

MONTEIRO, J. A. F.; STRAUCH, M.; SRINIVASAN, R.; ABBASPOUR, K.; GÜCKER, B. Accuracy of grid precipitation data for Brazil: application in river discharge modelling of the Tocantins catchment. **Hydrological Processes**, v. 30, ed. 9, p. 1419–1430, 2016.

MOREIRA, L. L.; SCHWAMBACK, D.; RIGO, D. Sensitivity analysis of the Soil and Water Assessment Tools (SWAT) model in streamflow modeling in a rural river basin. **Revista Ambiente & Água**, v.13, n.6, 2018.

NASA. National Aeronautics and Space Administration. **TRMM**. Disponível em https://disc2.gesdisc.eosdis.nasa.gov/data/TRMM_L3/TRMM_3B42_Daily.7/. Acesso em 10 jan. 2020.

NASHWANA, M. S.; SHAHID, S. Symmetrical uncertainty and random forest for the evaluation of gridded precipitation and temperature data. **Atmospheric Research**, v.230, 2019.

NERY, J.T.; CARFAN, A.C.; MARTIN-VIDE, J. Analysis of Rain Variability Using the Daily and Monthly Concentration Indexes in Southeastern Brazil. **Atmos. Clim. Sci.** v.7, p.176-190, 2017.

NEW, M.; HULME, M.; JONES, P. Representing Twentieth-Century Space–Time Climate Variability. Part II: Development of 1901–96 Monthly Grids of Terrestrial Surface Climate. **Journal of Climate**, v. 13, p. 2217-2238, 2000.

NUNES, A. A.; PINTO, E.J. A.; BAPTISTA, M.B. Detection of trends for extreme events of precipitation in the Metropolitan Region of Belo Horizonte through statistical methods. **RBRH**, v.23, 2018.

PACA, V.H. M.; ESPINOZA-DÁVALOS, G.; MOREIRA, D.; COMAIR, G. Variability of Trends in Precipitation across the Amazon River Basin Determined from the CHIRPS Precipitation Product and from Station Records. **Water**, v.12, 2020.

PERIN, E. B.; VIANNA, L. F.; RICCE, W. S.; MASSIGNAM, A. M.; PANDOLFO, C. Interpolação Das Variáveis Climáticas Temperatura do Ar e Precipitação: Revisão dos Métodos Mais Eficientes. **Geografia**, v.40, p.269-289, 2015.

PESSI, D. D.; SANTOS, C. S. A.; NONATO, J. J.; DOURADO, L. G. A.; SILVA, O. P.; BASSINI, R. T.; JOSÉ, J. V. Validação das estimativas de precipitação do satélite TRMM no Estado de Mato Grosso, Brasil. **Revista de Ciências Agrárias**, v.42, n.1, p.81-90, 2019.

- PINHEIRO, A. G.; SOUZA, T. E. M. S.; MONTENEGRO, S. M. G. L.; MONTENEGRO, A. A. A.; GUERRA, S. M. S. Rainfall pattern and erosion potential in the physiographic regions of the state of Pernambuco, Brazil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.22, n.12, p.849-853, 2018.
- PORTALÉS, C.; BORONAT, N.; PARDO-PASCUAL, J. E.; BALAGUER-BESER, A. Seasonal precipitation interpolation at the Valencia region with multivariate methods using geographic and topographic information. **International Journal of Climatology**, v. 30, p.1547-1563, 2010.
- PRAKASH, S., Performance assessment of CHIRPS, MSWEP, SM2RAIN-CCI, and TMPA precipitation products across India. **Journal of Hydrology**, v. 571, p. 50-59, 2019.
- PRASAD, A. M.; IVERSON, L. R.; LIAW, A. Newer classification and regression tree techniques: bagging and random forests for ecological prediction. **Ecosystems**, v. 9, ed. 2, p.181-199, 2006.
- REBOITA, M. S.; KRUSCHE, N.; AMBRIZZI, T.; ROCHA, R. P. Entendendo o tempo e o clima na América do Sul. **Terrae Didática**, v. 8, p. 34-50, 2012.
- REGOTO, P.; DEREZYNSKI, C.; SILVA, W. L.; SANTOS, R.; CONFALONIERI, U. Tendências de Extremos de Precipitação para o Estado do Espírito Santo. **Anuário do Instituto de Geociências**, v.41, n.1, p.365-381, 2018.
- RIVERA, J. A.; HINRICHS, S.; MARIANETTI, G. Using CHIRPS Dataset to Assess Wet and Dry Conditions along the Semiarid Central-Western Argentina. **Adv. Meteorol.** 2019.
- ROBINSON, T. P.; METTERNICHT, G. Testing the performance of spatial interpolation techniques for mapping soil properties. **Computers and Electronics in Agriculture**, v.50, n.2, p.97-108, 2006.
- ROMERO, H. A. I.; ORTIZ, L. F. Ajuste metodológico al índice de escasez de água propuesto por el ideam en el plan de ordenación y manejo de la cuenca del Río Pamplonita, norte de Santander, Colombia. **Colombia Forestal**, v.11, n.1, p. 165-173, 2008.
- SANCHES, F.O.; VERDUM, Roberto; FISCH, Gilberto. Estudo de tendência de luvas de longo prazo. **Revista Ambiente & Água**, v.8, n.3, p. 214-228, 2013.
- SALDANHA, C. B.; RADIN, B.; CARDOSO, M. A. G.; RIPPEL, M. L.; FONSECA, L. L.; RODRIGUEZ, F. Comparação dos dados de precipitação gerados Pelo gpcp vs observados para o estado do rio grande do sul. **Rev. Bras. Meteorol.** v.30, p.415-422, 2015.
- SALES, M. A. L.; ROMÁN, R. M. S.; SINOBAS, L.R.; MONTEIRO, R. N. F.; SOUZA, J. V. R. S. Avaliação da disponibilidade hídrica na sub-bacia do boi branco através do balanço hídrico climatológico e de cultivo. **Irriga**, v.22, 2017.
- SALVIANO, M. F.; GROppo, J. D.; PELLEGRINO, G. Q. Análise de Tendências em Dados de Precipitação e Temperatura no Brasil. **Rev. Bras. Meteorol.** v.31, p.64-73, 2016.
- SANTOS, L. O. F.; QUERINO, C. S. A.; QUERINO, J. K. A. S.; PEDREIRA, J. A. L.; MOURA, A. R. M.; MACHADO, N. G.; BIUDES, M. S. Validation of rainfall data estimated by GPM satellite on Southern Amazon region. **Revista Ambiente & Água**, v. 14, n.1, 2019.

SANTOS, P. V. C. J.; CUNHA, A. C. Potencial de vazão ambiental: método participativo para estimar vazão ambiental em rios na Amazônia. **Engenharia Sanitaria e Ambiental**, v.23, n.1, p.137-150, 2018.

SCHUMACHER, R. S. The Studies of Precipitation, Flooding, and Rainfall Extremes across Disciplines (SPREAD) Workshop: An Interdisciplinary Research and Education Initiative. **Bull. Am. Meteorol. Soc.** v.97, p.1791-1796, 2016.

SCHUMACHER, V.; JUSTINO, F.; FERNÁNDEZ, A.; MESEGUER'RUIZ, O.; SARRICOLEA, P.; COMIN, A.; VENANCIO, L. P.; ALTHOFF, D. Comparison between observations and gridded datasets over complex terrain in the Chilean Andes: precipitation and temperature. **International Journal of Climatology**, v.1, 2020.

SHEN, S. S. P.; DZIKOWSKI, P. G. LI.; GRIFFITH, D. Interpolation of 1961–97 Daily Temperature and Precipitation Data onto Alberta Polygons of Ecodistrict and Soil Landscapes of Canada. **J. Appl. Meteor.**, v.40, p.2162–2177, 2001.

SHEPARD, D. S. A two-dimensional interpolation function for irregularly-spaced data. **Proceedings of the 1968 ACM National Conference**, p.517-524, 1968.

SHI, P.; QIAO, X.; CHEN, X.; ZHOU, M.; QU, S.; MA, X.; ZHANG, Z. Spatial distribution and temporal trends in daily and monthly precipitation concentration indices in the upper reaches of the Huai River, China. **Stoch. Environ. Res. Risk Assess.** v.28, p.201-212, 2014.

SILVA, A. M.; OLIVEIRA, P. M.; MELLO, C. R.; PIERANGELI, C. Vazões mínimas e de referência para outorga na região do Alto Rio Grande, Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.10 n.2, 2006.

SILVA, E. C.; CABRAL, J. J. S. P.; FERNANDES, R. C.; GUSMÃO, L. O.; AZEVEDO, J. R. G. Spatial variability of precipitation correlated with relief in Recife metropolitan region and surrounding areas. **J. Hyperspectral Remote Sens.** v.6, p.225-234, 2016.

SIMPSON, M. J.; HIRSCH, A.; GREMLER, K.; LUPO, A. The importance of choosing precipitation datasets. **Hydrol. Process.** v.31, p.4600-4612, 2017.

SLOAT, L. L.; GERBER, J. S.; SAMBERG, L. H.; SMITH, W. K.; HERRERO, M.; FERREIRA, L. G.; GODDE, C. M.; WEST, P.C. Increasing importance of precipitation variability on global livestock grazing lands. **Nat. Clim. Chang.** v.8, p.214-218, 2018.

SOUSA, W. S.; SOUSA, F. A. S. Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, n.2, 2010.

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. **Rev. Bras. Geogr. Física**, v.2, p.250-268, 2012.

SOUZA-CRUZ-BUENAGA, F. V. A.; ESPIG, S. A.; CASTRO, T. L. C.; SANTOS, M. A. Environmental impacts of a reduced flow stretch on hydropower plants. **Braz. J. Biol.**, v. 79, n. 3, p. 470-487, 2019.

SPENCER, S.A.; SILINS, U.; ANDERSON, A. E. Precipitation-runoff and storage dynamics in watersheds underlain by till and permeable bedrock in Alberta's Rocky Mountains. **Water Resources Research**, v.12, 2019.

TOSTES, J.O.; LYRA, G.B.; OLIVEIRA- JÚNIOR, J.F.; FRANCELINO, M.R. Assessment of gridded precipitation and air temperature products for the State of Acre, southwestern Amazonia, Brazil. **Environ. Earth Sci.** v.76, n.153, 2017.

TRENBERTH, K.E., Changes in precipitation with climate change. **Clim. Res.** v.47, p.123–138, 2011.

TUNDISI, J. G. Water resources in the future: problems and solutions. **Estudos avançados**, v.22, n.63, p.7-16, 2008.

VALERIANO, T. T. B.; ROLIM, G. S.; BISPO, R. C.; MORAES, J. R. S. C.; APARECIDO, L. E. O. Evaluation of air temperature and rainfall from ECMWF and NASA gridded data for southeastern Brazil. **Theoretical and Applied Climatology**, 2018.

VENZON, P. T.; PINHEIRO, A.; KAUFMANN, V. Hydrological simulation uncertainties in small basins through the SWAT model. **Revista Brasileira de Recursos Hídricos**, v.23, 2018.

VERDIN, A.; RAJAGOPALAN, B.; KLEIBER, W.; FUNK, C. A Bayesian kriging approach for blending satellite and ground precipitation observations, **Water Resources Research**, v.51, ed.2, p.908-921, 2015.

VIANNA, L. F. N.; PERIN, E. B.; RICCE, W. S.; MASSIGNAN, A. M.; PANDOLFO, C. Bancos de Dados Meteorológicos: Análise dos Metadados das Estações Meteorológicas no Estado de Santa Catarina, Brasil. **Revista Brasileira de Meteorologia**, v.32, n.1, p.53-64, 2017.

WAGNER, P. D.; FIENER, P.; WILKEN, F.; KUMAR, S.; SCHNEIDER, K. Comparison and evaluation of spatial interpolation schemes for daily rainfall in data scarce regions. **Journal of Hydrology**, v. 465, p. 388-400, 2012.

WANG, S.; HUANG, G. H.; LIN, Q. G.; LI, Z.; ZHANG, H.; FAN, Y. R. Comparison of interpolation methods for estimating spatial distribution of precipitation in Ontario, Canada. **International Journal of Climatology**, v. 34, p.3745-3751, 2014.

WANG, S.; LIANG, X.; NAN, Z. How much improvement can precipitation data fusion achieve with a Multiscale Kalman Smoother-based framework? **Water Resour. Res.** v.47, 2011.

WILLMOTT, C. J. On the validation of models. **Physical Geography**, v.2, p.184-194, 1981.

WÜEST, M.; FREI, C.; ALTENHOFF, A.; HAGEN, M.; LITSCHI, M.; SCHAR, C. A gridded hourly precipitation dataset for Switzerland using rain-gauge analysis and radar-based disaggregation. **International Journal of Climatology**, v. 30, p.1764-1775, 2010.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R. An update of Xavier, King and Scanlon (2016) daily precipitation gridded data set for the Brazil. In: Anais do Simpósio Brasileiro de Sensoriamento Remoto, 2016. **Anais eletrônicos...** Campinas, Galoá, 2016. Disponível em: <<https://proceedings.science/sbsr/papers/an-update-of-xavier-king-and-scanlon--2016--daily-precipitation-gridded-data-set-for-the-brazil>> Acesso em: 08 out. 2020.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**, v.36, n.6, p.2644-2659, 2015.

- XU, W.; ZOU, Y.; ZHANG, G.; LINDERMAN, M. A comparison among spatial interpolation techniques for daily rainfall data in Sichuan Province, China. **International Journal of Climatology**, v.35, p.2898-2907, 2015.
- YAMAMOTO, J.K. Correcting the Smoothing Effect of Ordinary Kriging Estimates. **Mathematical Geology**, v.37, p.69-94, 2005.
- YANG, S.; JONES, P.D.; JIANG, H.; ZHOU, Z. Development of a near-real-time global in situ daily precipitation dataset for 0000–0000 UTC. **International Journal of Climatology**, v.40, p.2795-2810, 2019.
- YANTO; LIVNEH, B.; RAJAGOPALAN, B. Development of a gridded meteorological dataset over Java island, Indonesia 1985–2014. **Scientific Data**, v. 4, 2017.
- YEGGINA, S.; TEEGAVARAPU, R.S.V.; MUDDU, S. A conceptually superior variant of Shepard's method with modified neighbourhood selection for precipitation interpolation. **Int. J. Climatol.** v.39, p.4627–4647, 2019.
- YIN, L.H.; TING, N.Y.; SHAN, F.P.; SHIMIZU, K.; LATEH, H. Estimation of precipitation data by using deterministic interpolation methods: A case study in Penang Island. **AIP Conf. Proc.** 2019.
- YOUNG-SIK, M.; WON-HO, N.; MIN-GI, J.; TAEGON, K.; EUN-MI, H. Application of meteorological drought index in the Korean Peninsula using satellite-based Climate Hazards Group InfraRed Precipitation with Station (CHIRPS). **J. Korean Soc. Agric. Eng.** v.61, 2019.
- YU, J.; SHEN, Y.; PAN, Y. Comparative assessment between the daily merged precipitation dataset over China and the world's popular counterparts. **Acta Meteorologica Sinica**, v.73, p. 394–410, 2015.
- YUAN, F.; ZHANG, L.; SOE, K.; REN, L.; ZHAO, C.; ZHU, Y.; JIANG, S.; LIU, Y. Applications of TRMM- and GPM-Era Multiple-Satellite Precipitation Products for Flood Simulations at Sub-Daily Scales in a Sparsely Gauged Watershed in Myanmar. **Remote Sens.** v,11, n.140, 2019.
- ZHANG, X., JIANG, H., JIN, J., XU, X., ZHANG, Q. Analysis of acid rain patterns in northeastern China using a decision tree method. **Atmospheric Environment**, v.46, p.590-596, 2012.
- ZHAO, H.; HUANG, W.; XIE, T.; WU, X.; XIE, Y.; FENG, S.; CHEN, F. Optimization and evaluation of a monthly air temperature and precipitation gridded dataset with a 0.025° spatial resolution in China during 1951–2011. **Theoretical and Applied Climatology**, 2019.
- ZHU, W.; JIA, S.; LV, A. A Universal T_s -VI Triangle Method for the Continuous Retrieval of Evaporative Fraction from MODIS Products. **Journal of Geophysical Research: Atmospheres**, v. 122, ed.19, p.206-227, 2017.
- ZHU, X. Land cover classification using moderate resolution satellite imagery and random forests with post-hoc smoothing. **Journal of Spatial Science**, v.58, 2013.

CAPÍTULO II

Random Forest para a espacialização de evapotranspiração potencial diária: estudo de caso de bacias hidrográficas na Mata Atlântica

RESUMO: A importância de dados diários de Evapotranspiração Potencial (EP) tem aumentado nos últimos anos, devido à sua importância no planejamento e tomada de decisão com relação a agricultura irrigada, produção de água e recomposição florestal. Nesse sentido, frente à escassez destas informações medidas *in loco*, o estudo de métodos de interpolação capazes de representar a ET_0 torna-se importante. Por isso, o objetivo deste trabalho baseou-se em avaliar a adequação do método *Random Forest* (RF) na espacialização da ET_0 nas bacias hidrográficas da região Central Sul do Espírito Santo-BR, situadas dentro do bioma Mata Atlântica. A partir deste estudo constatou-se que o método RF é o mais indicado para espacialização de ET_0 . Além disso, as espacializações realizadas por este método foram transformadas em bases de dados em formato de grade (*grid*) e disponibilizada *on-line*. Ademais a base de dados RF também foi comparada a outras bases de dados em *grid* de ET_0 prontas, onde foi concluído-se que, a base de dados RF também apresentou desempenho superior as demais bases de dados para comparação.

Palavras-chave: Random Forest, Evapotranspiração, IDW, ADW.

Random Forest for the spatialization of potential daily evapotranspiration: a case study of hydrographic basins in the Atlantic Forest

ABSTRACT: Daily data on Potential Evapotranspiration (EP) has your demand increased in recent years due to its importance in planning and decision making about irrigated agriculture, water production, and forest restoration. In this sense, given the scarcity of this information measured on the spot, the study of interpolation methods capable of representing ET_0 becomes important. Therefore, this work objective was based on evaluating the adequacy of the Random Forest (RF) method in the spatialization of ET_0 in the hydrographic basins of the South of Espírito Santo-BR, located within the Atlantic Forest biome. From this study, it was found that the RF method is the most suitable for ET_0 spatialization. Also, the spatialization performed by this method was transformed into databases in a grid format and made available online. The RF database was also compared to other ready-made ET_0 grid databases, where it was concluded that the RF database also performed better than the other databases for comparison.

Keywords: Random Forest, Evapotranspiration, IDW, ADW.

1. INTRODUÇÃO

A evapotranspiração potencial referência (ET_0) é uma variável meteorológica frequentemente utilizada, devido à sua sensibilidade às mudanças climáticas e, por ser

considerada o melhor indicador de alterações nos cursos de água, ciclagem de umidade e fluxos de calor latentes na atmosfera (Wang et al., 2017; Xing et al., 2016; Zhang et al., 2016). O conhecimento do comportamento espacial da ET_0 , principalmente em termos diários, tem grande importância para o estabelecimento do balanço hídrico de bacias hidrográficas, para o dimensionamento de projetos e gerenciamento de sistemas de irrigação, para a previsão do rendimento das culturas, e para o planejamento e gerenciamento dos recursos hídricos, em atividades como a gestão de riscos, e a previsão de inundações ou secas (Kisi, 2016; Krajewski et al., 2017).

Todavia, no que tange à disponibilidade de dados de ET_0 diária no Brasil, há escassez de informações, as quais são provenientes de poucas estações meteorológicas e em séries com curto período histórico, além de haver um número considerável de dados falhos (Oliveira et al., 2015; Silva et al., 2018). Os dados diários mais consistentes disponíveis são originários de estações do Instituto Nacional de Meteorologia (INMET) (Lima et al., 2018); porém, é preocupante o fato de que diversas regiões do país, como as bacias hidrográficas localizadas na Mata Atlântica, careçam de informações diárias de ET_0 a fim de auxiliar no manejo da agricultura irrigada, na produção de água, e na recomposição florestal (Honda & Durigan, 2017; Menezes et al., 2011; Wu et al., 2019) deste Bioma.

Uma das alternativas à falta das informações medidas em estações de superfície é a utilização de bases de dados de ET_0 disponíveis em formato *grid* (Braum, 2020; Xavier et al., 2016), todavia isto requer que estes produtos possuam série histórica compatível com a demanda, além de contemplarem a área de estudo.

Outra alternativa potencial consiste na espacialização da ET_0 diária por meio de interpolação espacial. Todavia, devido ao fato de que a performance dos interpoladores espaciais não ser sempre semelhante, variando dentro de uma mesma região (Castro et al., 2010; Hodam et al., 2017), ou com comportamento diferente em diferentes bacias, há necessidade de

mais estudos sobre a definição do melhor interpolador espacial de ET_0 antes de sua aplicação para uma área de interesse. Além disso, segundo Strong et al (2017), a ET_0 não é um fenômeno trivial em terrenos complexos, o que significa que métodos de interpolação espaciais simplificados podem não ser tão eficientes na espacialização deste elemento (Silva Júnior et al., 2019), reforçando a importância de estudos que avaliam diferentes métodos de interpolação (Ravazzani et al., 2020; Tomas-Burguera et al., 2017). Isto porque a ET_0 é sensível à variação dos elementos climáticos, em especial, à temperatura do ar (Feng et al., 2017), a qual, por sua vez, está sujeita aos efeitos topográficos (altitude, orientação das encostas e azimute solar). Desta forma, é possível inferir que a topografia tem uma grande influência na ET_0 (Ma et al., 2019; Peng et al., 2020; Sun et al., 2020), e que sua influência na interpolação espacial desta variável deve ser considerada.

Segundo Hengl et al. (2018), devido ao *Random Forest* (RF) ser um método baseado em dados, o mesmo requer apenas uma entrada limitada do usuário, permitindo o uso simultâneo de mais que uma variável auxiliar para geração de suas previsões. Desta forma, é possível o uso de diversos elementos topográficos, os quais possuem grande influência na estimativa de ET_0 , possuindo potencial de gerar bons resultados na espacialização da evapotranspiração. Nesse sentido, métodos de aprendizagem máquina, como o RF, têm ganhado destaque na interpolação espacial de variáveis climáticas, como a ET_0 (Feng et al., 2017; Wang et al., 2019; Wu et al., 2020). O algoritmo RF consiste em um método de aprendizado de máquina capaz de executar procedimentos de classificação e regressão (Biau & Scornet, 2016). Sendo um método estatístico baseado em dados, sua formulação matemática é bastante simples, pois sua ênfase é colocada no treinamento iterativo do algoritmo, usando técnicas como ensacamento, até que um "Bom Aprendiz" seja produzido (Hengl et al., 2018). Uma característica inerente ao método de aprendizagem máquina é sua capacidade de resolver interações complexas entre variáveis preditoras, mesmo quando apresentam alta colinearidade (Brokamp et al., 2017).

Desta forma, o objetivo do presente trabalho consistiu em avaliar a aplicabilidade do método RF para espacializar a ET_0 diária em bacias hidrográficas do Sul do estado do Espírito Santo, localizadas no bioma Mata Atlântica. Como objetivos específicos deste trabalho, estabelecerem-se a criação de uma base de dados diária em formato *grid* e sua posterior comparação com outras duas bases de dados de ET_0 , disponibilizadas por Braum (2020) e Xavier et al. (2015).

2. METODOLOGIA

2.1. ÁREA EM ESTUDO

A área em estudo consistiu em bacias hidrográficas do Sul do estado do Espírito Santo: Benevente; Guarapari; Itabapoana; Itapemirim; Jucu; Rio Novo e Santa Maria da Vitória. Estas bacias possuem área de drenagem de 14.604 km² (AGERH, 2019), cerca de 31,70% da superfície do Espírito Santo, localizando-se entre os paralelos 39°41'17" e 41°52'47" S e entre os meridianos 17°53'30" e 21°18'06" W, conforme apresenta a Figura 1. Estas bacias estão totalmente inseridas dentro do Bioma Mata Atlântica, o qual possui a maior diversidade de árvores do mundo por unidade de área (MMA, 2010). O bioma Mata Atlântica está distribuído ao longo de quase toda a faixa continental Atlântica leste do Brasil. Originalmente, mais de 1,3 milhões de km² em 17 estados do território brasileiro era cobertos por florestas, porém, atualmente, restam cerca de 29% de sua cobertura original, devido ao desmatamento e queimadas (Jesus et al., 2020; MMA, 2018).

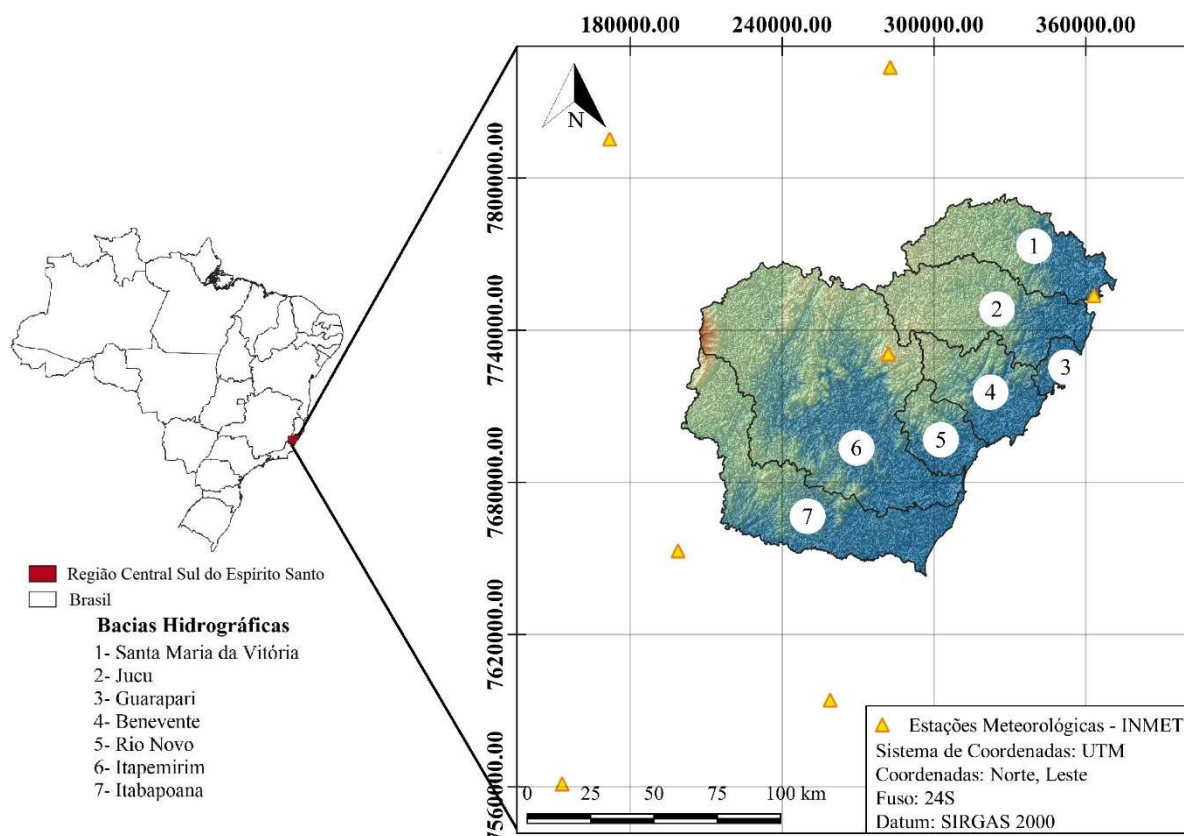


Figura 10 – Estações meteorológicas do INMET nas áreas em estudo do Sul do Espírito Santo.

Nestas bacias observa-se uma variabilidade climática expressiva, a qual se deve à presença de suas duas distintas regiões naturais: o litoral, que se estende na direção norte-sul; e o planalto (Regoto et al., 2018), situado a oeste, após o litoral. Segundo Alvares et al. (2013). A classificação climática de Köppen-Geiger é Aw e ocorre em toda a região costeira, contornando os vales e planaltos em altitudes inferiores a 450 m, porque acima dessa elevação a temperatura média anual é inferior a 18°C (Alvares et al., 2013).

2.2. DADOS UTILIZADOS

Os dados utilizados como base para interpolação espacial foram da evapotranspiração de referência (ET_0) diária, pertinentes a 11 estações meteorológicas (Figura 10 e Tabela 3).

Tabela 3. Estações meteorológicas do INMET (convencionais), cujas bases de dados meteorológicos diários foram utilizadas no presente estudo.

Código OMM	Nome	Longitude (°)	Latitude (°)	Altitude (m)
83592	Caratinga -MG	-42,13	-19,73	609,7
83595	Aimorés -MG	-41,07	-19,49	82,7
83639	Caparaó -MG	-41,09	-20,51	843,2
83642	Viçosa- MG	-42,86	-20,76	712,2
83648	Vitoria- ES	-40,31	-20,31	36,2
83695	Itaperuna- RJ	-41,90	-21,20	123,6
83698	Campos- RJ	-41,33	-21,74	11,2
83037	Coronel Pacheco- MG	-43,26	-21,55	435,0
83498	Caravelas -BA	-39,25	-17,73	2,9
83550	São Mateus -ES	-39,85	-18,70	25,0
83718	Cordeiro -RJ	-42,36	-22,02	505,9

Os valores de ET_0 foram calculados a partir das variáveis meteorológicas disponíveis no Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) medidos nas estações meteorológicas do INMET (INMET, 2020), por intermédio da equação 12 (Allen et al., 1998).

$$ET_0 = \frac{0,408\Delta(R_n - G) + \gamma \frac{900}{T + 272} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34u_2)} \quad (12)$$

em que, ET_0 é a evapotranspiração de referência, mm dia^{-1} ; R_n é o saldo de radiação à superfície da cultura, $\text{MJ m}^{-2} \text{dia}^{-1}$; G é a densidade do fluxo de calor do solo, $\text{MJ m}^{-2} \text{dia}^{-1}$; T é a temperatura do ar a 2 m de altura, $^{\circ}\text{C}$; u_2 é a velocidade de vento a 2 m de altura, m s^{-1} ; e_s é a pressão de vapor de saturação, kPa; e_a é a pressão parcial de vapor, kPa; Δ é a declividade da curva de pressão de vapor de saturação, $\text{kPa } ^{\circ}\text{C}^{-1}$; e γ é o coeficiente psicrométrico, $\text{kPa } ^{\circ}\text{C}^{-1}$.

2.3. AVALIAÇÃO DOS INTERPOLADORES ESPACIAIS

Avaliaram-se diferentes interpoladores espaciais aplicados para a espacialização da ET_0 diária: o Inverso da Distância Ponderada (IDW), a Distância Angular Ponderada (ADW) e Random Forest (RF) (Hengl et al., 2018; Ravazzani et al., 2020; Xavier et al., 2015).

Para a avaliação, utilizou-se a técnica de validação cruzada, a qual, segundo Li et al. (2018), é uma técnica de avaliação de erros de estimativas que consiste na comparação de valores estimados com os observados. A validação cruzada foi aplicada utilizando-se o procedimento *leave one out*, no qual uma estação específica é retirada da base de dados, sendo a interpolação realizada e o valor de ET_0 é então estimado para sua localização. Posteriormente a estação retorna à base de dados e o procedimento é repetido para todas as demais estações disponíveis (Faraco et al., 2008). Este procedimento foi aplicado para cada interpolador em cada dia da série histórica.

Finalmente, a partir dos valores de totais precipitados observados (O_i) e estimados (E_i) por cada interpolador, calcularam-se as estatísticas de desempenho descritas nas equações 13 a 15 (Ceccherini et al., 2015; Machado et al., 2015; Santos et al., 2019; Xavier et al., 2015).

$$d = 1 - \left[\frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - \bar{O}_i| + |O_i - \bar{O}_i|)^2} \right] \quad (13)$$

$$BIAS = \frac{1}{n} \sum_{i=1}^n O_i - E_i \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (E_i - O_i)^2} \quad (15)$$

em que d é o índice de concordância de Willmott, adimensional; BIAS é o desvio sistemático do valor real, mm; RMSE é a raiz do quadrado médio do erro, mm; E_i são os totais de ET_0 diários estimados, mm; O_i são os totais de ET_0 diários observados, mm; \bar{O} é a média dos valores observados, mm; e n indica o número total de dias.

As métricas estatísticas descritas nas equações 13 a 15 foram utilizadas em conjunto para eleger o melhor interpolador de ET_0 diária.

2.3.1. Interpolador espacial Distância Angular Ponderada (ADW)

A ponderação de distância angular (ADW) é uma abordagem comum para interpolação de uma rede irregular de observações meteorológicas em uma grade regular. Uma versão amplamente usada do ADW emprega a distância de decaimento de correlação (CDD) para selecionar estações que devem contribuir para cada estimativa do ponto de grade e definir o componente de distância dos pesos das estações (Hofstra & New, 2009). Esta ponderação das estações vizinhas é calculada usando as distâncias e os ângulos entre as estações vizinhas (O_k) e a estação desconhecida (E_k) (Xavier et al., 2015). O ângulo, a distância e os pesos foram combinados para chegar a um peso de distância angular (W_{Ek}) para estação E_k (New et al., 2000):

$$W_{E_k} = w_k(1 - a_k) \quad (16)$$

Onde o peso a_k é calculado na eq. (5) e está associado a cada estação de apoio para interpolação. Este peso foi determinado pelo isolamento direcional (angular) de cada um dos n_j pontos dos dados selecionados. Onde $\theta_j(k, l)$ é o ângulo formado pelas estações O_l e O_k com o vértice no ponto de interpolação de interesse (E_j), calculado em coordenadas esféricas. O w_l é

o peso da distância nos ponto de dados observados (O_l e O_k). Outro fator associado ao peso da distância é o peso angular (um k , eq. 5) para cada uma das $n_j = 8$ (utilizado neste trabalho) estações seleccionadas para a interpolação:

$$a_k = \frac{\sum_{l=1}^{n_j} w_l (1 - \cos \theta_j(k, l))}{\sum_{l=1}^{n_j} w_l}, l \neq k \quad (17)$$

Ao calcular o peso w_k , utiliza-se a eq. (6). Pode-se notar que o peso decai para valores mais altos de m . Sabendo que m é o expoente para cada variável que será interpolada, o valor de m foi seleccionado durante a validação cruzada, sendo neste trabalho $m=4$, conforme sugere New et al. (2000).

$$w_k = r^m \quad (18)$$

O peso da distância é calculado usando uma função de decaimento de correlação (CDD), em que CDD é derivado empiricamente (New et al., 2000). Onde, x é a distância do ponto em grade de interesse (estação que será estimada) e uma estação meteorológica nas proximidades (dados observados) e, para cada estação calcula-se a correlação (r) em todas as outras estações (Eq. 7).

$$r = e^{-x/CDD} \quad (19)$$

2.3.2. Interpolador espacial Inverso da Distância Ponderada (IDW)

O método IDW consiste na interpolação espacial de um conjunto conhecido de pontos dispersos. Os valores atribuídos aos pontos desconhecidos são calculados a partir da média

ponderada pelo inverso da distância dos valores dos dados dentro de uma região (Mello & Silva, 2013; Mendez et al., 2019). Este método é caracterizado pela magnitude da potência utilizada, que neste estudo variou de 1 a 5, a fim de não penalizar muito a contribuição para a estimativa de pontos distantes (Camera et al., 2014).

No presente estudo, todos os vizinhos foram usados no modelo (Eq. 8):

$$E = \frac{\sum_{i=1}^n (O_i h_i^{-p})}{\sum_{i=1}^n (h_i^{-p})} \quad (20)$$

2.3.3. Interpolador espacial baseado em Random Forest (RF)

As previsões finais do RF são a média das previsões de árvores individuais (Breiman, 2001; Prasad, Iverson & Liaw, 2006; Biau & Scornet, 2016):

$$\hat{\theta}^B(x) = \frac{1}{B} \sum_{b=1}^B t_b^*(x) \quad (21)$$

em que b é a amostra de *bootstrap* individual, B é o número total de árvores e t_b^* é o aprendiz individual, ou seja, a árvore de decisão individual:

$$t_b^*(x) = t(x; z_{b1}^*, \dots, z_{bk}^*) \quad (22)$$

em que z_{bk}^* ($k = 1 \dots K$) é a k enésima amostra de treinamento com pares de valores para a variável alvo (y) e covariáveis (x): $z_{bi}^* = (x_k, y_k)$.

O RF é uma árvore de decisão, uma técnica de aprendizado de máquina. Uma descrição simples seria a divisão de um grupo complexo usando os métodos mais independentes e

variáveis em grupos menores e mais simples, através de métodos condicionais, que podem levar a uma solução mais fácil de ser interpretada (Zhang et al., 2012).

Funciona como uma árvore em que a raiz e cada nó interno são rotulados com uma condição, esta condição é verificada, e caso seja atendida, a árvore de decisão seguirá pelo ramo correspondente, caso contrário, por outro iterativamente, até que a condição seja atendida e a árvore finalizada (Chen et al., 2010). Cada folha representa uma previsão de uma solução para o problema (Zhang et al., 2012). Esta metodologia tenta encontrar uma relação entre variáveis de entrada e saída (Gharaei-Manesh et al., 2016). Ele mapeia as observações de um item para obter conclusões do seu valor alvo (Chen et al., 2010).

Muitas variáveis de entrada que podem contribuir para a previsão são utilizadas, e em cada nó da árvore de decisão, a variável mais importante é então selecionada (Li et al., 2011). Por ser um algoritmo baseado em dados, o RF requer apenas uma entrada limitada do usuário (Hengl et al., 2018). Nesse sentido, foram utilizadas variáveis meteorológicas e topográficas para permitir a decisão da árvore. Isso ocorre porque variáveis climáticas, como temperatura, juntamente com características topográficas, são importantes para a definição da ET (Feng et al., 2018; Yin, 2013).

As variáveis meteorológicas (temperaturas máxima e mínima do ar, e classificação climática de Köppen–Geiger) foram obtidas do *World Clim* (<http://worldclim.org/version2>), um conjunto de camadas climáticas globais em grade, com uma resolução espacial de cerca de 1 km². O Modelo Digital de Elevação (DEM) oriundo da *Shuttle Radar Topography Mission* (SRTM) foi utilizado, obtido pelo *Earth Explorer* (<https://earthexplorer.usgs.gov/>), com uma resolução espacial de 30 m. Utilizaram-se as seguintes informações topográficas obtidas a partir do MDE: altitude, declividade, orientação das encostas, distância até o mar, índice de convergência, índice de robustez do terreno, direção de escoamento, sombreamento analítico e vetor do terreno.

Os cálculos foram realizados no ambiente R, usando o pacote *randomForest*.

2.4. DISPONIBILIDADE DA BASE DE DADOS EM FORMATO GRID

Após a avaliação dos interpoladores espaciais e escolha daquele com melhor desempenho, utilizando os procedimentos estatísticos citados no item 2.3, elaborou-se uma base de dados espacializada de evapotranspiração de referência (ET_0) diária, com resolução espacial de $0,004^\circ$, compreendendo o período entre 1980 e 2018.

2.5. AVALIAÇÃO DE BASES DE DADOS DISPONÍVEIS EM FORMATO *GRID*

Compararam-se bases de dados de precipitação diária em formato grid amplamente utilizadas (Quadro 3) com a base de dados elaborada neste trabalho.

Quadro 3. Bases de dados meteorológicos utilizados para comparação no presente estudo.

Bases de dados de ET_0	Série Histórica	Resolução Espacial	Fonte
BRAUM	2007-2020	$0,005^\circ$	Braum (2020)
XAVIER	1980-2016	$0,25^\circ$	Xavier et al. (2015)

Para tal avaliação calcularam-se as mesmas estatísticas descritas nas equações 14 e 15, além da equação (23) que será descrita a seguir, de acordo com o mesmo método descrito em Schumacher et al. (2020). Este método consistiu na extração dos valores da ET_0 diária diretamente dos grids das bases de dados a partir das coordenadas geográficas referentes às estações meteorológicas.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{E_i - O_i}{O_i} \right| \quad (23)$$

em que, MAPE é o erro percentual absoluto médio, %, adimensional; E_i são os totais de ET_0 diários estimados, mm; O_i são os totais de ET_0 diários observados, mm; \bar{O} é a média dos valores observados, mm; e n indica o número total de dias.

Devido ao período comum entre todas as bases de dados em formato *grid* ser entre os anos (2007-2016), as comparações basearam-se neste período, para que houvesse uma equidade entre as análises, evitando o benefício das bases de dados com uma série histórica maior em detrimento das demais.

3. RESULTADOS

3.1. RESULTADOS DA ESPACIALIZAÇÃO DA ET_0 DIÁRIA

Na Figura 11 apresenta-se o percentual de dias, durante toda a série histórica, em que cada interpolador apresentou melhor desempenho, de acordo com os índices estatísticos “d” e “RMSE”.

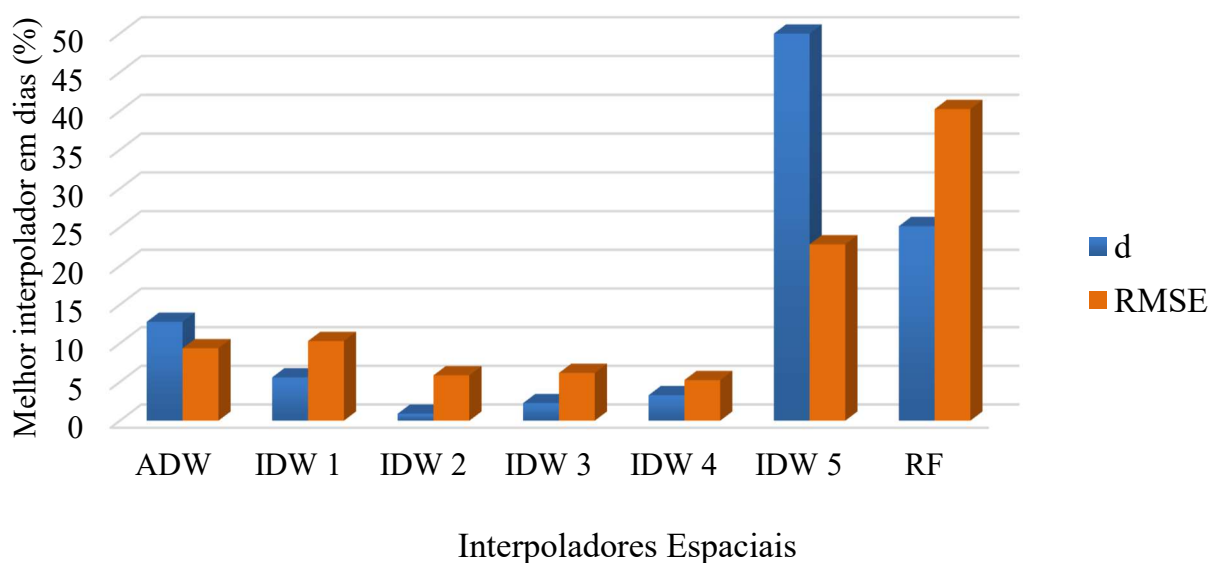


Figura 11 – Percentual dos dias em que cada interpolador apresentou o melhor desempenho para a espacialização do da ET_0 total diária nas bacias hidrográficas do Sul do Espírito Santo, de acordo com os índices “d” e “RMSE”.

Na Tabela 4 são apresentados os resultados médios das estatísticas utilizadas na avaliação dos interpoladores para espacialização da ET_0 diária nas bacias hidrográficas do Sul do Espírito Santo.

Tabela 4. Índices estatísticos utilizados para avaliação do desempenho dos interpoladores usados na espacialização da ET_0 diária nas bacias hidrográficas do Sul do Espírito Santo.

Indicador	ADW	IDW1	IDW2	IDW3	IDW4	IDW5	RF
d (adimensional)	0,78	0,81	0,83	0,84	0,85	0,85	0,81
RMSE (mm)	0,66	0,61	0,60	0,60	0,61	0,62	0,63
BIAS (mm)	-0,02	-0,02	-0,02	-0,03	-0,03	-0,03	-0,03

Nas Figuras 12 e 13 são apresentados os gráficos de dispersão (valores observados vs. valores estimados) de ET_0 , com linha de tendência (regressão linear) e os respectivos valores do coeficiente de determinação (r^2) de todos os interpoladores durante os meses de verão de todos os anos e, durante os meses de inverno de todos os anos, respectivamente.

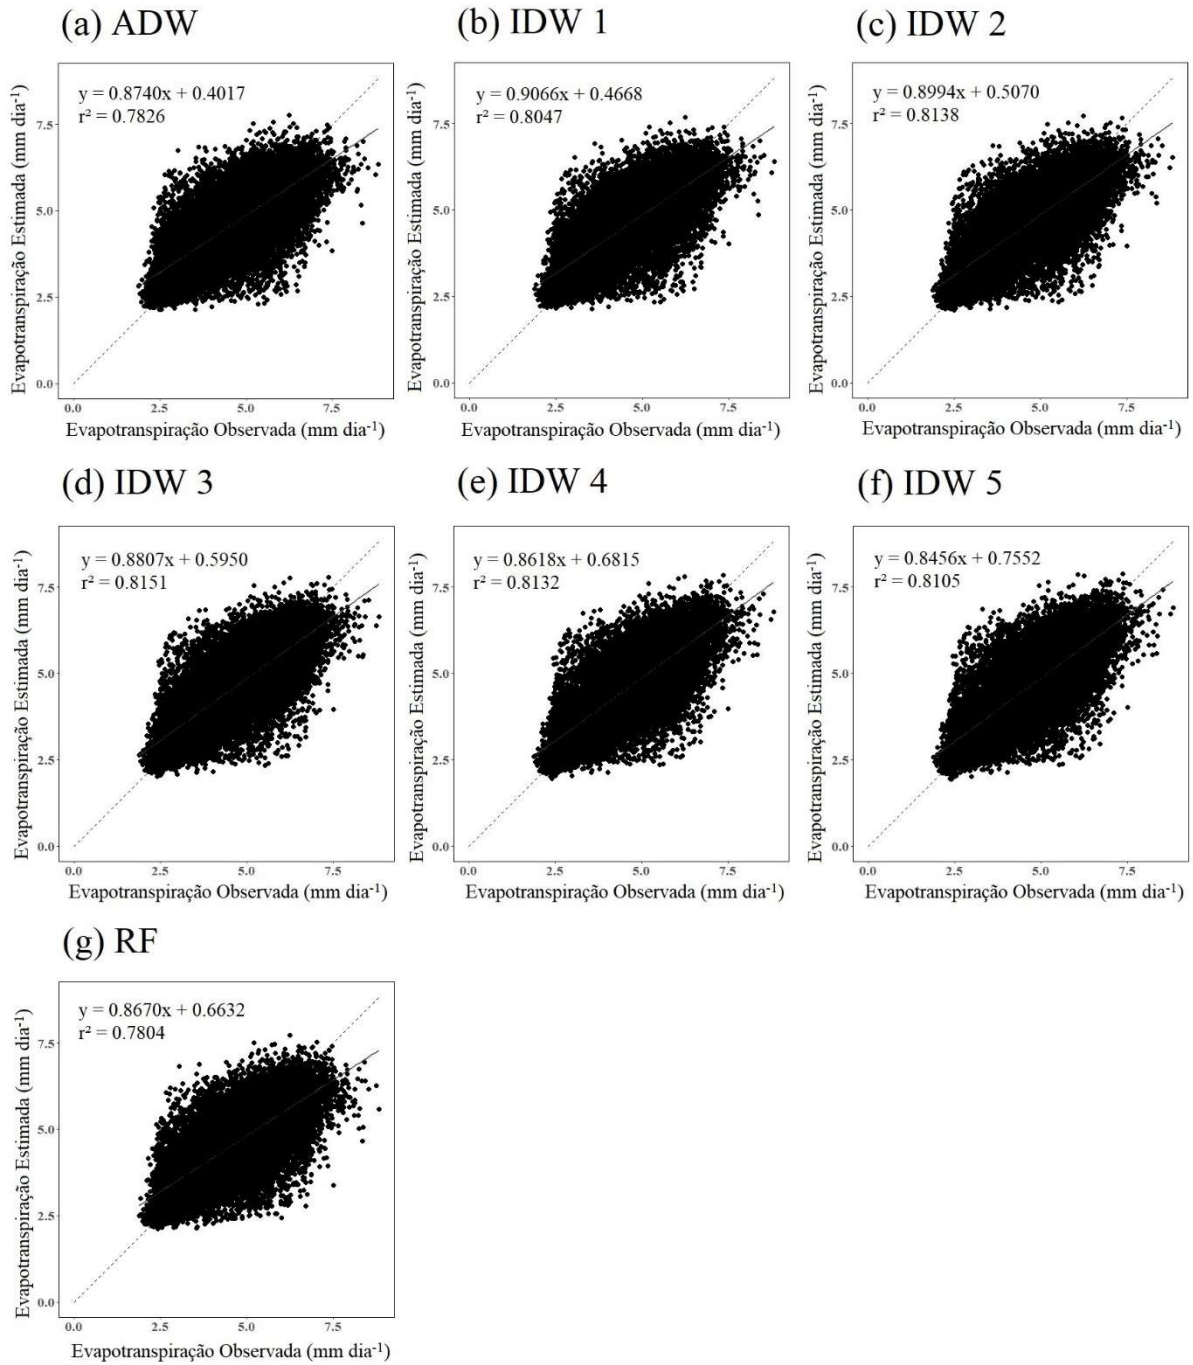


Figura 12 – Gráfico de Dispersão da ET₀ diária observada e interpolada durante o verão de todos os anos da série histórica utilizada, do Sul do Espírito Santo.

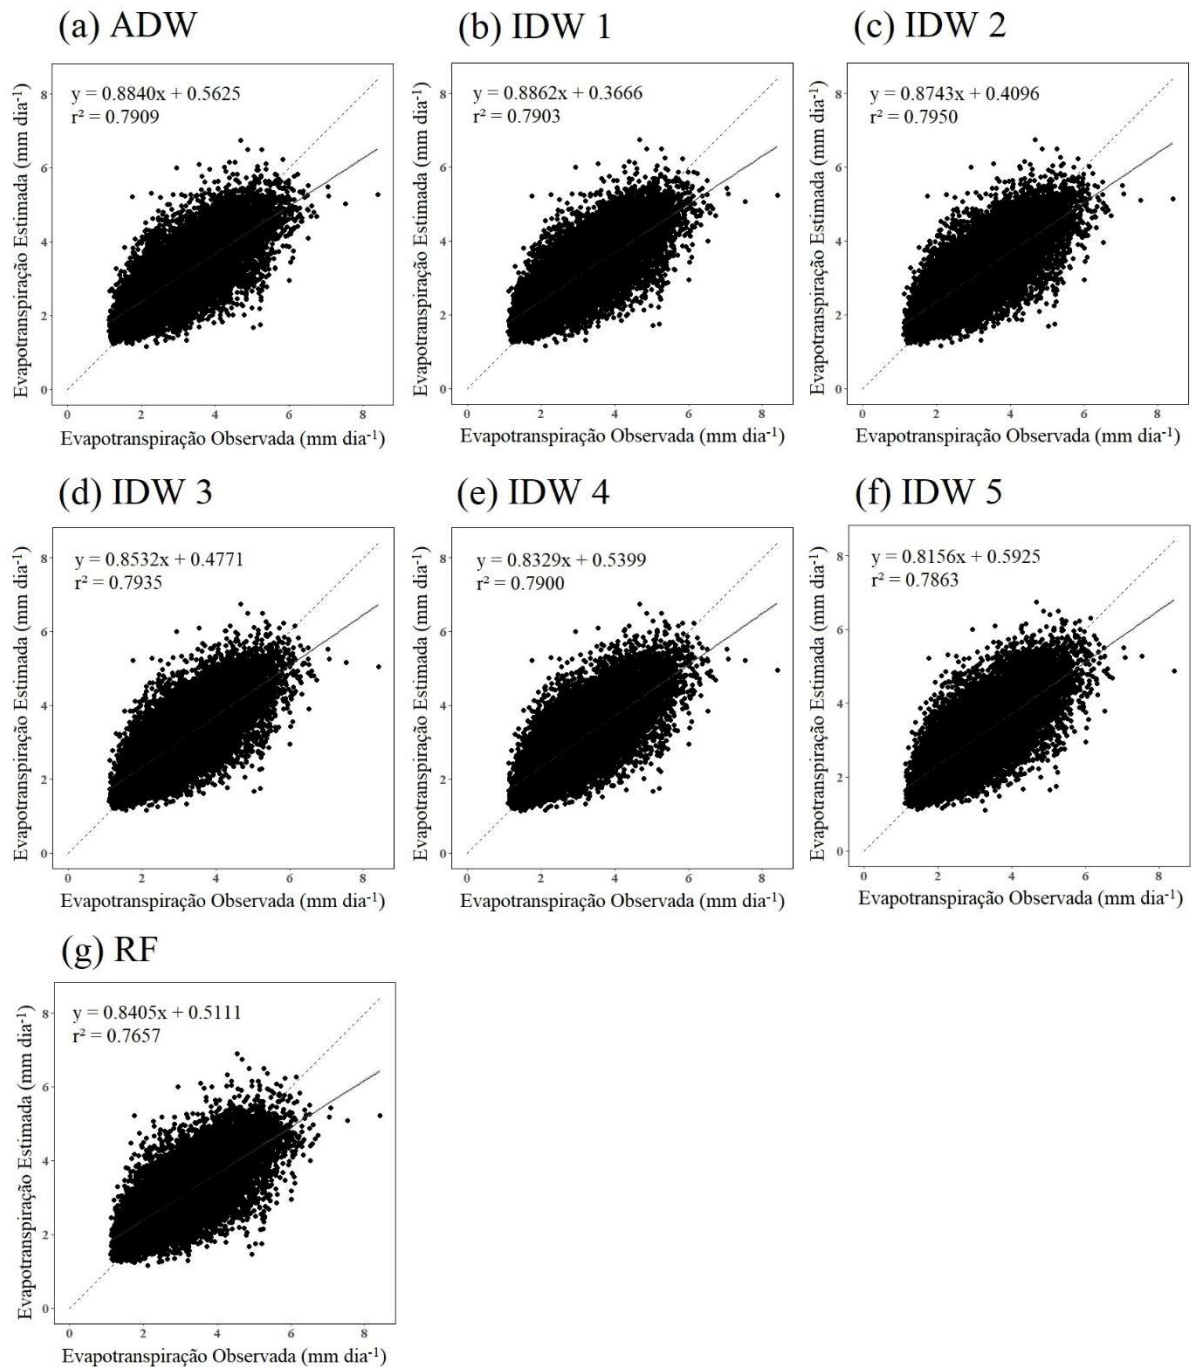



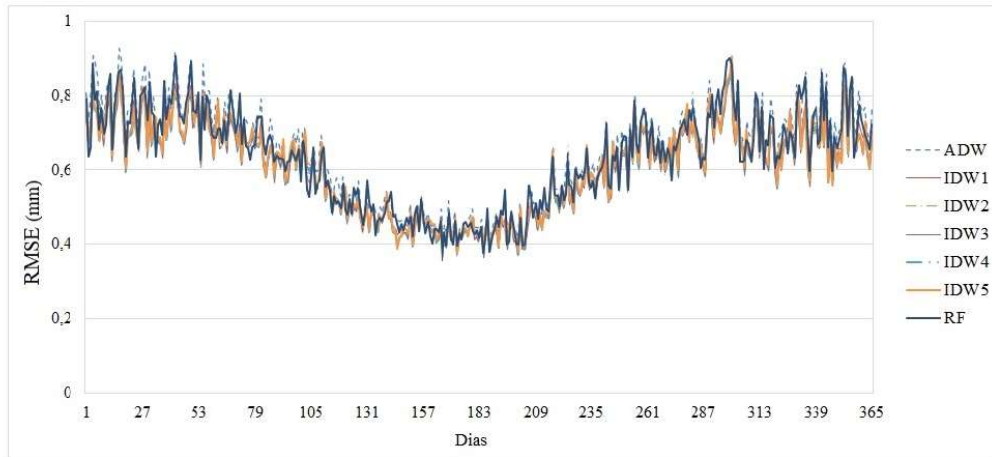
Figura 13 – Gráfico de Dispersão da ET₀ diária observada e interpolada durante o inverno de todos os anos da série histórica utilizada, do Sul do Espírito Santo.

Na Figura 14 apresenta-se a variação dos valores médios das estatísticas de cada dia do ano, no período em estudo.

(a)



(b)



(c)

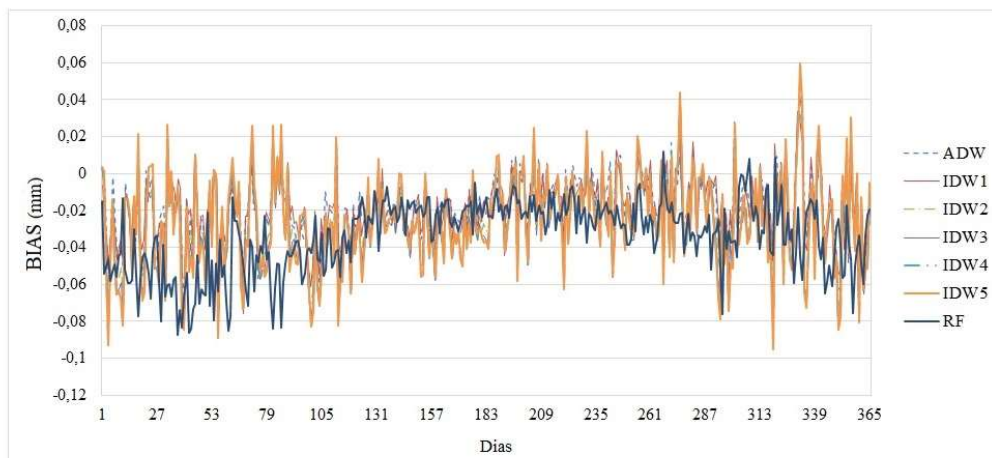


Figura 14 – Resultados estatísticos médios diários da interpolação da ET_0 diária nas bacias hidrográficas do Sul do Espírito Santo: a) “ d ”, b) “RMSE” e c) “BIAS”.

Nas Figuras 15 e 16 são apresentadas as espacializações de ET_0 de todos os interpoladores na área em estudo, para um dia de verão e para um de inverno no ano de 2010, respectivamente. A fim de possibilitar uma análise visual do desempenho dos diversos interpolares na espacialização da ET_0 .

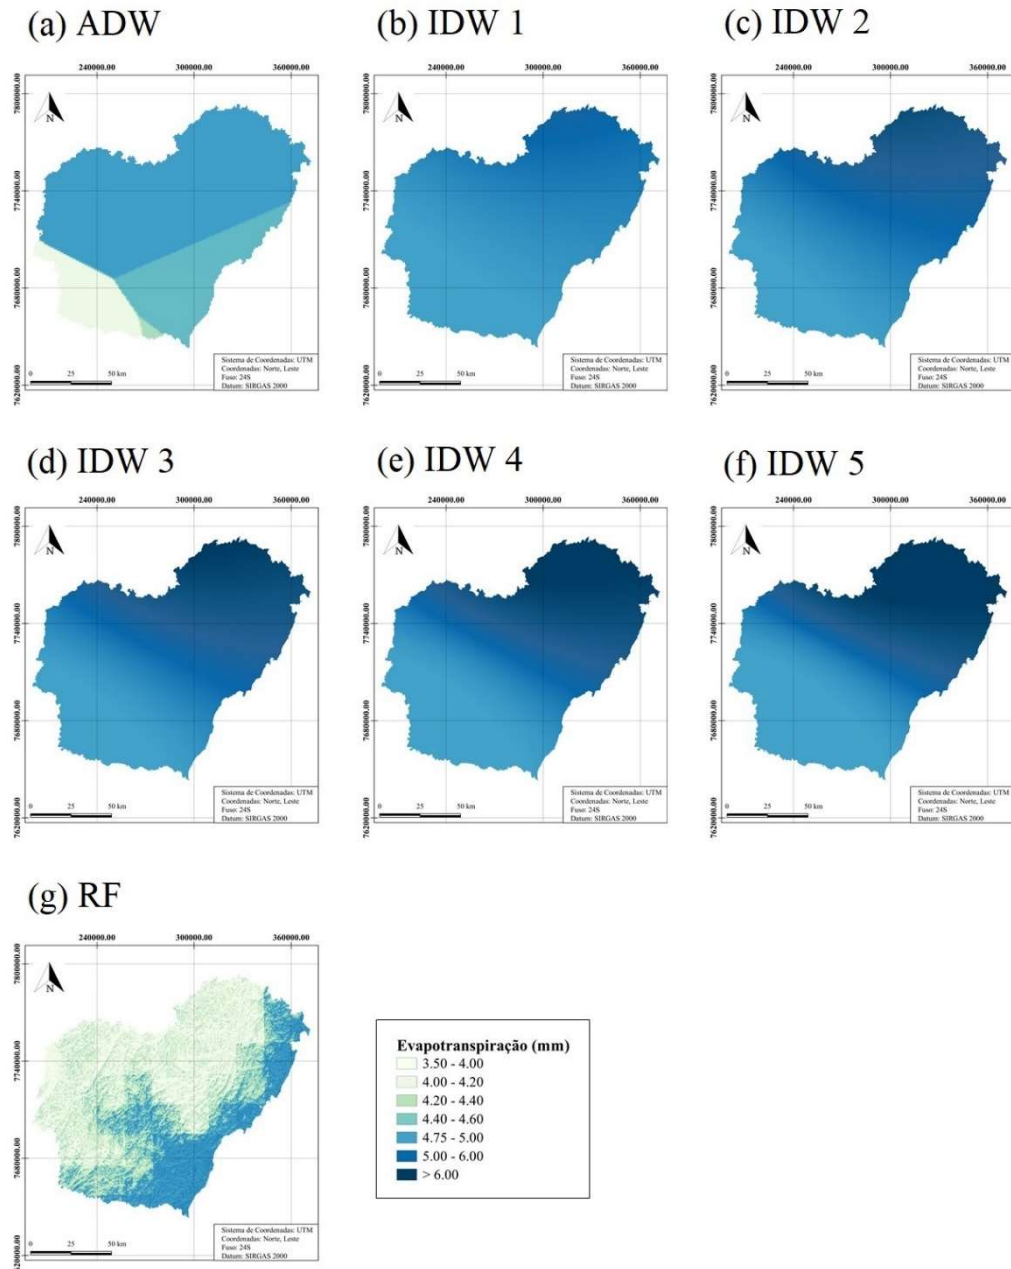


Figura 15 – Espacializações da ET_0 diária do Sul do Espírito Santo em 15/01/2010, pelos métodos de interpolação.

3.2. DOWNLOAD DA BASE DE DADOS DE ET₀ DIÁRIA

A partir da aplicação dos métodos com melhores desempenhos, RF e IDW 5, foi criada e disponibilizada uma base de dados contendo os mapas de ET₀ diária do Sul do Espírito Santo-Brasil, com as especificações técnicas expostas no Quadro 4. As bases de dados de evapotranspiração de referência diária (ET₀) foram disponibilizadas em: <http://dx.doi.org/10.17632/m2tjd73b99.2>.

Quadro 4. Especificações da base de dados de ET₀ diária disponibilizada para as bacias hidrográficas do Sul do Espírito Santo-BR.

Formato	Série histórica	Escala temporal	Resolução Espacial	Datum	SCR (Código EPSG)
GeoTIFF	1980-2018	Diária	0,004°	SIRGAS 2000	31984

3.3. RESULTADOS DA COMPARAÇÃO ENTRE BASES DE DADOS DE ET₀ DIÁRIA

Na Tabela 5 são apresentados os resultados numéricos (*MAPE*, *RMSE* e *BIAS*) da comparação entre bases de dados em formato *grid*. Na Figura 17 apresenta-se as médias anuais dos indicadores estatísticos, para o período em análise (2007-2016), obtidas na comparação das bases de dados em formato *grid* com a base de dados obtida neste trabalho utilizando o interpolador RF.

Tabela 5. Resultados estatísticos da comparação de todas as bases de dados utilizadas no estudo.

Indicador	BRAUM	RF	XAVIER
MAPE (%)	18,99	10,90	15,31
RMSE (mm)	0,55	0,19	0,47
BIAS (mm)	0,35	0,01	0,22

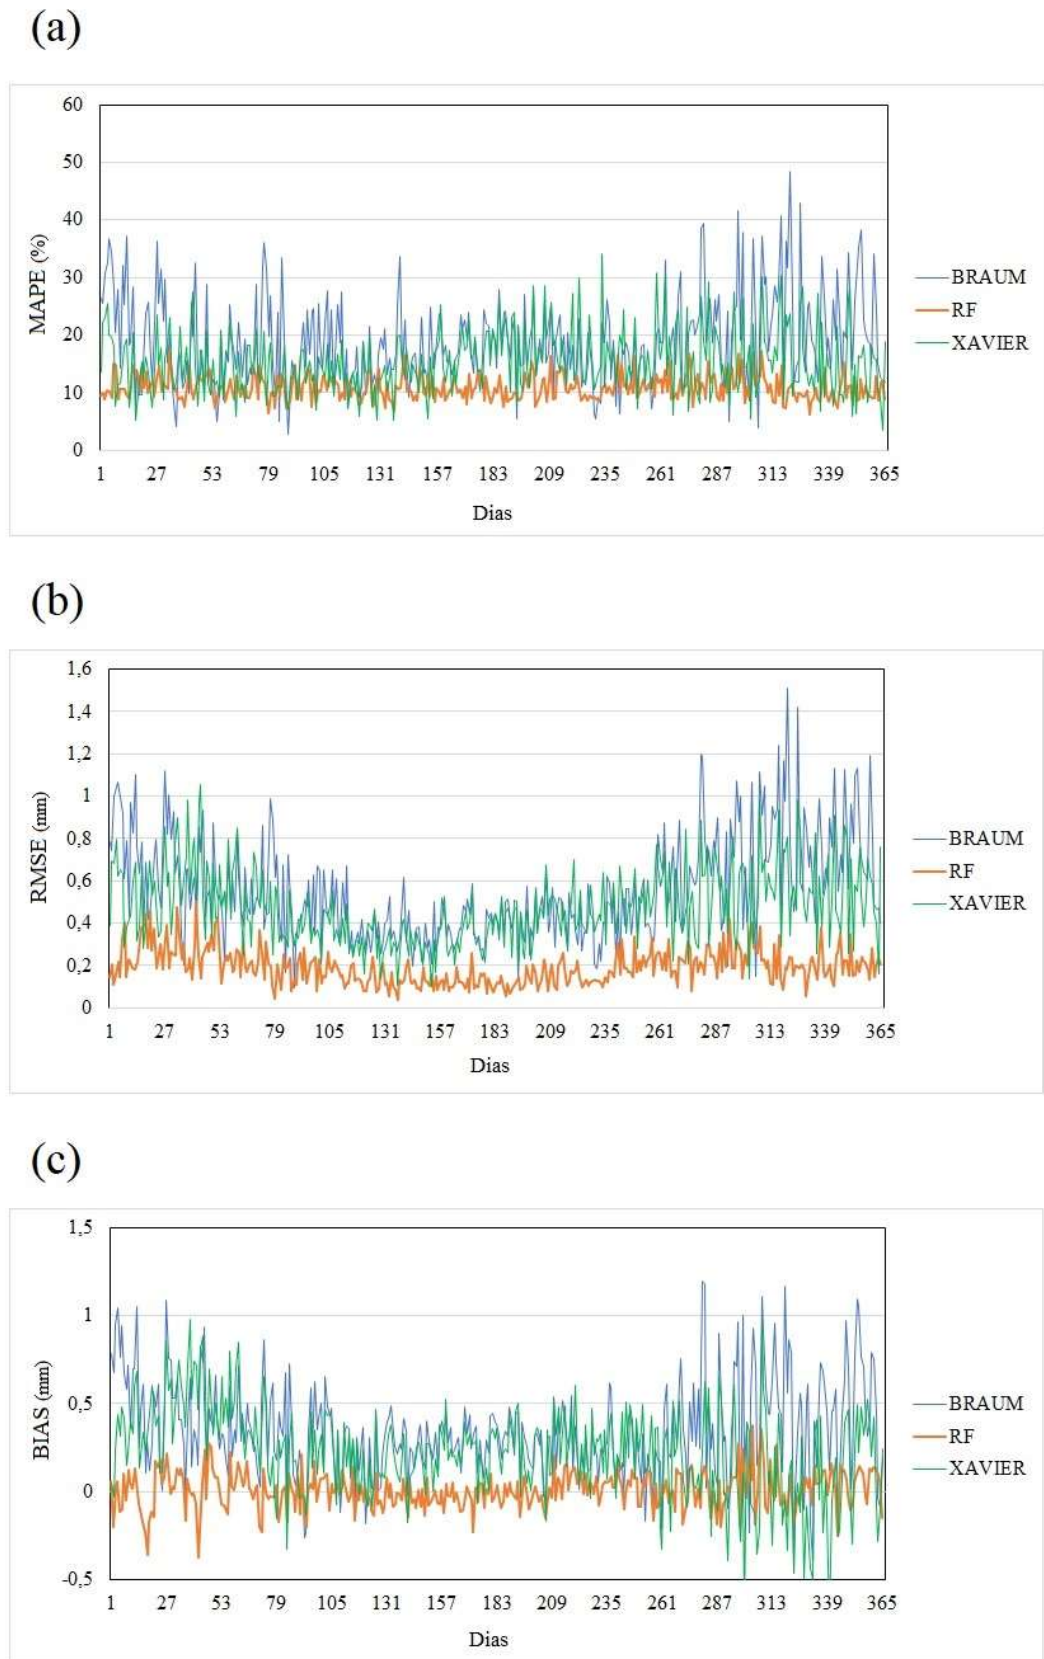


Figura 17 – Resultados estatísticos médios anuais para a interpolação da ET_0 diária nas bacias hidrográficas do Sul do Espírito Santo: a) “MAPE”, b) “RMSE” e c) “BIAS”.

4. DISCUSSÃO

O melhor desempenho dos interpoladores IDW5 e RF na maior parte do período em análise, conforme evidenciado na Figura 11, demonstra a superioridade destes para a espacialização de ET_0 diária na área em estudo. Todavia, apenas a análise da frequência de dias com melhor desempenho, usando os índices d e RMSE, não possibilita distinguir o melhor interpolador, uma vez que esta análise não demonstra a diferença de magnitude entre os métodos. Para isto, é necessário observar os valores numéricos, a fim de obter uma representatividade melhor dos resultados (Cunha et al., 2013; Fernandes et al., 2010; Noia, et al., 2014).

Observando-se os valores médios gerais de “ d ”, RMSE e BIAS pertinentes a cada interpolador (Tabela 4), é possível notar desempenho inferior para o ADW. Dentre as opções de IDW, observa-se que o incremento da potência implica em melhoria do desempenho do interpolador. Todavia, observa-se apenas uma pequena diferença de desempenho entre os interpoladores. Tal fato não é raro na avaliação de métodos de interpolação espacial de ET_0 (Mardikis et al., 2005; Saraiva et al., 2017). Nesse sentido, os interpoladores IDW e RF possuem potencial para criar uma base de dados de ET_0 , em especial devido ao “ d ” superior a 0,80, ao RMSE inferior a $0,65 \text{ mm dia}^{-1}$ e ao BIAS inferior a $0,03 \text{ mm dia}^{-1}$. Todos os resultados são semelhantes aos encontrados em outros trabalhos no território brasileiro, como de Alencar et al. (2015), Pereira et al. (2009) e Souza et al. (2017).

A Figura 14 mostra que o método ADW obteve os piores resultados em comparação com os demais métodos de interpolação. Em contrapartida, também mostra que as opções de IDW e o método RF são semelhantes. A Figura 14a mostra que o valor do índice “ d ” tende a diminuir nos meses de inverno, representando um desempenho inferior dos métodos de interpolação da ET_0 nesta época do ano, conforme também apresentam as Figuras 12 e 13. Na Figura 14b, nota-se que a amplitude dos valores de RMSE diminui à medida que os dias se aproximam do inverno e aumenta nos meses de verão, denotando um comportamento sazonal desta variável; Isto

ocorre devido às menores temperaturas do ar nestes períodos do ano, implicando em menores valores ET_0 (Condon et al., 2020), menores magnitudes de ET_0 , geram menores diferenças matemáticas entre valores estimados e observados, conseqüentemente diminuindo os valores de RMSE. Por fim, a Figura 14c mostra que o BIAS tende a resultar em valores negativos, indicando uma superestimativa da ET_0 , por todos os interpoladores.

Em relação a variação dos valores para as estatísticas d , RMSE e BIAS apresentadas na Figura 14, constatou-se que os valores obtidos neste trabalho não são diferentes daqueles encontrados em trabalhos referentes à estimativa de Evapotranspiração no Brasil. Por exemplo, o índice d normalmente varia na faixa de 0,75 a 0,90 (Araújo et al., 2018; Pereira et al., 2009; Souza & Campelo Júnior, 2017), o RMSE entre 0,40 e 0,90 mm dia⁻¹ (Carvalho et al., 2015; Silva et al, 2018; Tanaka et al., 2016), e o BIAS entre -0,10 a 0,02 mm dia⁻¹ (Alencar et al., 2015; Silva Júnior et al., 2019; Souza et al., 2011).

As Figuras 12 e 13 apresentam os gráficos de dispersão da ET_0 diária, do período de verão e inverno, respectivamente. É possível notar que existe uma elevada correlação em todos os interpoladores espaciais ($>0,75$) (Cunha et al., 2013). Ademais, é possível notar o melhor desempenho dos interpoladores nos meses de verão (a partir coeficiente de determinação), de acordo com a regressão, sendo que tais resultados corroboram com os resultados do índice “ d ” apresentado na Figura 14a. Em contrapartida, o RMSE mostrou-se melhor no verão (Figura 14b), não acompanhando o índice “ d ” e r^2 , contudo, a grandeza do de RMSE está diretamente relacionados à magnitude da variável estimada, nesse sentido, maiores valores de ET_0 no verão, ocasionam maiores valores de RMSE neste mesmo período do ano, porém, apenas os resultados de RMSE não são suficientes para indicar as melhores interpolações, o que reforça a importância de uma análise conjunta dos indicadores estatísticos.

Uma análise conjunta da Tabela 4 e Figuras 12, 13 e 14, permite inferir que, o desempenho dos interpoladores é semelhante, de modo geral, pois tanto de forma numérica quanto gráfica

percebe-se que não há diferenças expressivas; contudo, este tipo de resultado pode ser frequentemente encontrado em trabalhos de estimativa de ET_0 com escala temporal diária, pois a evapotranspiração não apresenta naturalmente grande variabilidade dentro da mesma região climática, beneficiando métodos de interpolação que apresentam dificuldades em representar valores extremos (Mendonça & Dantas, 2010; Silva et al., 2013).

A última das avaliações do desempenho dos interpoladores consiste na análise dos mapas gerados por cada um destes, conforme Figuras 15 e 16. De forma geral, é possível observar que a variação da ET_0 diária é maior na Figura 15 (verão), entre 3 e 6 (mm dia^{-1}), comparativamente à Figura 16 (inverno), onde a variação foi entre 2 e 3 (mm dia^{-1}). Na Figura 15 é possível observar que o ADW é o único método que propicia uma variação brusca na ET_0 , diferentemente dos demais interpoladores. Tal fato deve-se à grande distância entre as estações meteorológicas utilizadas na região em estudo, que implica negativamente no método ADW em realizar suas predições, devido à lógica do método “preferir” o uso apenas de estações correlacionadas com o alvo local (New et al., 2000). Porém, devido à disposição espacial heterogênea das estações na área em estudo, o método fez uso das estações que estavam disponíveis, e não necessariamente as mais correlacionadas, interpolando um ruído ou erro no local de destino, dificultando que o interpolador conseguisse representar uma grade regular de forma suave (Hofstra & New, 2009).

Com base nas Figuras 15 e 16, os métodos baseados no IDW propiciaram a suavização da distribuição espacial da ET_0 na área em estudo. Esta suavização foi menor com as maiores potências, para as quais existe uma redução da influência de estações mais distantes, sendo que os mapas para IDW3 a IDW5 são muito semelhantes. As interpolações utilizando o método IDW têm ganhado destaque nas espacializações de ET_0 (Hodam et al., 2017; Santana et al., 2018; Silva et al., 2013) e outras variáveis meteorológicas (Fuentes et al., 2019; Ibrahim et al., 2019; Yanto et al., 2017). Segundo Li e Heap (2011), a baixa densidade de amostras não afeta

negativamente o desempenho do método IDW. Nesse sentido, conforme exposto neste trabalho, há um baixo número de estações meteorológicas encontradas dentro e próximas à área em estudo e, além disso, sua distribuição espacial é esparsa e heterogênea. Ou seja, não há um número ideal estações para aplicação de interpoladores, como o IDW (Amaral & Justina, 2019). Adicionalmente, a simplicidade do IDW perante outros métodos mais complexos de interpolação espacial, como os geoestatísticos que precisam de ajustes e um número mínimo de observações, pode ter sido a chave para o bom desempenho deste método em relação aos demais (Hodam et al., 2017).

Ainda com relação à espacialização da ET_0 , representada nas Figuras 15 e 16, o RF se destaca por representar as variações da ET_0 em função do relevo. Além disso, este método possui algumas vantagens perante os demais, uma vez que somente ele, entre os que estão sendo avaliados neste trabalho, pode utilizar variáveis auxiliares (Hengl et al., 2018). Este fato implica diretamente na possibilidade do método RF representar fenômenos mais complexos, como a ET_0 . Isto ocorre, pois uma das variáveis utilizadas na estimativa de ET_0 , baseada no método de Penman–Monteith, é a altitude, que também influencia a temperatura, demonstrando uma correlação entre as variáveis auxiliares e as próprias variáveis estimadas (Bardin et al., 2010; Oliveira & Ferreira, 2017). Nesse sentido, devido ao uso de variáveis auxiliares neste trabalho, e ao método não gerar tendência sistemática de superestimação nem subestimação geral dos dados amostrais (Wang et al., 2019; Wu et al., 2019), o método RF proporcionou aos mapas espacializados um maior nível de detalhamento, pois conseguiu representar a discretização da ET_0 de forma semelhante aos mapas gerados por Méndez et al. (2020) e Sekulić et al. (2020), que apresentam este “detalhamento” do RF na espacialização de outras variáveis meteorológicas. Desta forma, o desempenho do método RF é notável para interpolar dados de ET_0 diária, assim como demonstrado em Feng et al. (2017), Silva Júnior et al. (2019), Wang et al. (2019) e Wu et al. (2020).

Analisando somente as métricas estatísticas, com maior ênfase no índice “d”, o método IDW5 demonstrou-se superior aos demais; entretanto, a diferença numérica é pequena em relação a diferença visual apresentada nas Figuras 15 e 16, por isso, o método RF foi eleito o melhor interpolador espacial para a ET_0 diária do Sul do estado do Espírito Santo-BR. Todavia, ambos métodos demonstram um desempenho equivalente e, por isso, a base de dados do IDW 5 também foi disponibilizada em formato grid.

A comparação entre as bases de dados de ET_0 (Tabela 5 e Figura 17) demonstra que a base de dados gerada pelo método RF obteve resultados melhores (numéricos e gráficos) que as demais (Braum, 2020; Xavier et al., 2015). Estes resultados estão relacionados às diferenças nos métodos de obtenção de cada base de dados. A base de dados RF utiliza o método combinado Penman-Monteith/FAO, considerado o mais preciso para estimativa da ET_0 (Alencar et al., 2015; ALLEN et al., 1998). Depois aplica um interpolador espacial que realiza suas predições com variáveis secundárias, as quais têm influência direta na ET_0 , como as variáveis topográficas (Strong et al, 2017).

A Figura 17 apresenta as estatísticas utilizadas para comparação da base de dados em formato *grid* da ET_0 diária (MAPE, RMSE e BIAS), resumidas em dias do ano, de todos os anos do período analisado. Conforme é possível observar a faixa de valores apresentados para RMSE (0,1 a 1,5 mm dia⁻¹) está dentro do esperado para o Brasil, entre 0,1 a 1,8 mm dia⁻¹ (Alencar et al., 2015; Carvalho et al., 2015). Já os valores de BIAS encontrados neste trabalho (entre -0,50 a 1,2 mm dia⁻¹) estão dentro da faixa de -0,55 a 1,23 mm dia⁻¹ (Alencar et al., 2015). As variações de MAPE encontradas neste trabalho (5 a 50%) foram inferiores às encontradas em Aparecido et al. (2020) e Caporusso & Rolim (2015), cujos valores variaram entre 12,0 e 93,9%.

A base de dados de Xavier et al. (2015) também utilizou o método combinado Penman-Monteith/FAO para estimar a ET_0 , porém, fez uso do ADW para realizar a espacialização da ET_0 . Conforme evidenciado no presente trabalho, o método ADW não é o mais adequado para

especializar a ET_0 na área em estudo. Ademais, outra diferença entre os as bases de dados é o tamanho do pixel utilizado, sendo igual a $0,25^\circ$ em Xavier et al. (2015) e de $0,004^\circ$ no RF, denotando uma considerável diferença entre ambos.

O desempenho da base de dados de Braum (2020) foi diferente das demais bases de dados, devido à duas diferenças marcantes. A primeira está na utilização do método de Hargreaves e Samani para estimar a ET_0 , calibrado para o Espírito Santo (Zanetti et al., 2019). A segunda é a utilização do interpolador IDW; contudo, Braum (2020) não interpolou a ET_0 , mas as temperaturas do ar para posteriormente calcular a ET_0 . Nesse contexto, o uso de Hargreaves e Samani, por ser um método mais simples, só é recomendado como alternativa para estimar a ET_0 diante da falta dos dados meteorológicos requeridos pelo modelo Penman-Monteith/FAO (Allen et al., 1998; Lima Junior et al., 2016), sendo que isso explica boa parte das diferenças encontrada nos resultados.

5. CONCLUSÕES

A partir deste estudo foi possível observar que os melhores interpoladores espaciais da ET_0 diária para as bacias hidrográficas presentes do Sul do Espírito Santo foram os métodos e RF e IDW5, respectivamente.

A partir da avaliação dos interpoladores, o método RF foi considerado o melhor, sendo utilizado para gerar uma base de dados de ET_0 diária (1980-2018) com resolução espacial de $0,004^\circ$, que cobre as bacias hidrográficas do Sul do Espírito Santo, situadas no bioma Mata Atlântica. Esta base de dados foi disponibilizada online em um endereço específico.

As melhores base de dados de ET_0 para as bacias hidrográficas do Sul do Espírito Santo-BR, de acordo com a avaliação das estatísticas utilizadas no presente trabalho, no período (2007-2016), foram RF e Xavier et al. (2015), respectivamente.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABNT - Associação Brasileira de Normas Técnicas. **NBR 14166: Rede de Referência Cadastral Municipal - Procedimento**. Rio de Janeiro, 1998. 23 p.
- ADHIKARY, S. K.; MUTTIL, N.; YILMAZ, A. G. Cokriging for enhanced spatial interpolation of rainfall in two Australian catchments. **Hydrological Processes**, v.31, n.12, p.2143-2161, 2017.
- AGERH, Agência Estadual de Recursos Hídricos. **Comitês de Bacias Hidrográficas** Disponível em < <https://agerh.es.gov.br/documentos-dos-comites>>. Acesso em 20 mai. 2020.
- ALENCAR, L. P.; SEDIYAMA, G. C.; MANTOVANI, E. C. Estimativa da evapotranspiração de referência (ET_o padrão FAO), para Minas Gerais, na ausência de alguns dados climáticos. **Engenharia Agrícola**, v. 35, n.1, p. 39-50, 2015.
- ALLEN, R. G.; PEREIRA, D. R.; RAES, D.; SMITH, M. Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements. Rome: **FAO**. ed.1, 1998.
- ALTHOFF, D.; HENRIQUE, S.; DIAS, B., FILGUEIRAS, R.; RODRIGUES, L. N. ET_o-Brazil: A daily gridded reference evapotranspiration dataset for Brazil (2000 – 2018). **Water Resources Research**, 2020.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2014.
- AMARAL, L. R.; JUSTINA, D. D. Spatial Dependence degree and Sampling Neighborhood Influence on Interpolation process for Fertilizer Prescription Maps. **Engenharia Agrícola**, v. 39, p.85–95, 2019.
- AMORIM, R. C. F.; RIBEIRO, A.; LEITE, C. C.; LEAL, B. G.; SILVA, J. B. G. Avaliação do desempenho de dos métodos de espacialização da precipitação pluvial para o estado de Alagoas. **Acta Scientiarum Technology**, v.30, n.1, p.87-91, 2008.
- APARECIDO, L. E. O.; MENESES, K. C.; TORSONI, G. B.; MORAES, J. R. S. C.; MESQUITA, D. Z. Accuracy of Potential Evapotranspiration Models in Different Time Scales. **Revista Brasileira de Meteorologia**, v.35, n.1, p.63-80, 2020.
- ARAÚJO, L. M.; BEZERRA, F. T. C.; BORGES, P. DE F.; PEREIRA, A. R.; MOSCÔSO, J. S. C.; ARAÚJO, L. S. Estimativas da evapotranspiração de referência para o município de Apodi, RN. **Gaia Scientia**, v. 12, n. 3, 2018.
- AVILA, F. B.; DONG, SIYAN.; MENANG, K.P.; RAJCZAK, JAN.; RENOM, M.; DONAT, M.G.; ALEXANDER, L.V. Systematic investigation of gridding-related scaling effects on annual statistics of daily temperature and precipitation maxima: A case study for south-east Australia. **Weather and Climate Extremes**. v.9, p. 6-16, 2015.
- BARDIN, L.; PEDRO JÚNIOR, M. J.; MORAES, J. F. L. Estimativa das temperaturas máximas e mínimas do ar para a região do Circuito das Frutas, SP. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, n.6, p.618-624, 2010.
- BIAU, G.; SCORNET, E. A random forest guided tour. **TEST**, v.25, ed. 2, p.197–227, 2016.
- BLACK, A. J.; OLIVEIRA, J. L. R. HENN, A. Relações entre precipitações intensas de diferentes durações para desagregação da chuva diária em Santa Catarina. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.16, n.4, p.391–398, 2012.
- BRAUM, E. S. **Espacialização da Temperatura do Ar diária considerando a Altitude**. 2020. 67 f. Dissertação (Mestrado em Ciências Florestais) - Centro de Ciências Agrárias e Engenharias, Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2020.

- BROKAMP, C.; JANDAROV, R.; RAO, M. B.; LEMASTERS, G.; RYAN, P. Exposure assessment models for elemental components of particulate matter in an urban environment: A comparison of regression and random forest approaches. **Atmospheric Environment**, v.151, 2017.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, ed. 1, p. 5–32, 2001.
- CAI, X.; WANG, X.; JAIN, P.; FLANNIGAN, M. D. Evaluation of gridded precipitation data and interpolation methods for forest fire danger rating in Alberta, Canada. **Journal of Geophysical Research: Atmospheres**, v. 124, p. 3-17, 2019.
- CAMARGO, A. P.; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, v.5, n.1, p.89-97, 1997.
- CAMERA, C.; BRUGGEMAN, A.; HADJINICOLAOU, P.; PASHIARDIS, S.; LANGE, M. A. Evaluation of interpolation techniques for the creation of gridded daily precipitation ($1 \times 1 \text{ km}^2$); Cyprus, 1980–2010. **Journal of Geophysical Research: Atmospheres**, v.119, ed.2, p.693-712, 2014.
- CAPORUSSO, N. B.; ROLIM, G. S. Modelos de evapotranspiração de referência usando diferentes escalas de tempo na região de Jaboticabal, São Paulo, Brasil. **Acta Scientiarum. Agronomy**, v.37, n.1, p.1-9, 2015.
- CARVALHO, D. F.; ROCHA, H. S.; BONOMO, R.; SOUZA, A. P. Estimativa da evapotranspiração de referência a partir de dados meteorológicos limitados. **Pesquisa Agropecuária Brasileira**, v.50, n.1, p.1-11, 2015.
- CARVALHO, L. G. DE; RIOS, G. F. A.; MIRANDA, W. L.; NETO, P. C. Evapotranspiração de Referência: Uma Abordagem Atual de diferentes Métodos de Estimativa. **Pesquisa Agropecuária Tropical**, v. 41, n. 3, 2011.
- CASTRO, F. S.; PEZZOPANE, J. E.M.; CECÍLIO, R. A.; PEZZOPANE, J. R. M.; XAVIER, A. C. Avaliação do desempenho dos diferentes métodos de interpoladores para parâmetros do balanço hídrico climatológico. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n.8, 2010.
- CECCHERINI, G.; AMEZTOY, I.; HERNÁNDEZ, C.P.R.; MORENO, C.C. High-Resolution Precipitation Datasets in South America and West Africa based on Satellite-Derived Rainfall, Enhanced Vegetation Index and Digital Elevation Model. **Remote Sensing**, v.7, ed. 5, p.6454-6488, 2015.
- CHAVES, H. M. L.; SANTOS, L. B. Ocupação do solo, fragmentação da paisagem e qualidade da água em uma pequena bacia hidrográfica. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, p.922-930, 2009.
- CONDON, L.E.; ATCHLEY, A.L.; MAXWELL, R.M. Evapotranspiration depletes groundwater under warming over the contiguous United States. **Nature Communications**, v.11, 2020.
- CRUZ, P. P. N.; GREEN, T. R.; FIGUEIREDO, R. O.; PEREIRA, A. S.; KIPKA, H.; SAAD, S. Y.; SILVA, J. M.; GOMES, M. A. F. Hydrological modeling of the Ribeirão das Posses - An assessment based on the Agricultural Ecosystem Services (AgES) watershed model. **Revista Ambiente & Água**, v.12, n.3, 2017.
- CUNHA, P. C. R.; NASCIMENTO, J. L.; SILVEIRA, P. M.; ALVES JUNIOR, J. A. Eficiência de métodos para o cálculo de coeficientes do tanque classe A na estimativa da evapotranspiração de referência. **Pesquisa Agropecuária Tropical**, v. 43, n. 2, p. 114-122, 2013.

- FANG, G.; YANG, J.; CHEN, Y.; LI, Z.; JI, H.; MAEYER, P. D. How Hydrologic Processes Differ Spatially in a Large Basin: Multisite and Multiobjective Modeling in the Tarim River Basin. **Journal of Geophysical Research: Atmospheres**, v.123, n.14, p.7098-7113, 2018.
- FENG, T.; SU, T.; JI, F.; ZHI, R.; HAN, Z. Temporal characteristics of actual evapotranspiration over China under global warming. **Journal of Geophysical Research: Atmospheres**, v.123, p.5845–5858, 2018.
- FENG, Y.; CUI, N.; GONG, D.; ZHANG, Q.; ZHAO, L. Evaluation of random forests and generalized regression neural networks for daily reference evapotranspiration modelling. **Agricultural Water Management**, v.193, p.163–173, 2017.
- FERNANDES, A. L. T.; FRAGA JUNIOR, E. F.; TAKAY, B. Y. Avaliação do método Penman-Piche para estimativa de evapotranspiração de referência em Uberaba, MG. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 3, p. 270-276, 2011.
- FRANCO, A. C. L.; BONUMÁ, N. B. Multi-variable SWAT model calibration with remotely sensed evapotranspiration and observed flow. **Revista Brasileira de Recursos Hídricos**, v. 22, ed. 35, 2017.
- FUENTES, I.; PADARIAN, J.; OGTROP, F.; VERVOORT, R.W. Comparison of Surface Water Volume Estimation Methodologies That Couple Surface Reflectance Data and Digital Terrain Models. **Water**, v.11, 2019.
- HARRIS, I.; OSBORN, T.J.; JONES, P.; LISTER, D. Version 4 of the CRU TS monthly high-resolution gridded multivariate climate dataset. **Scientific Data**, v.7, 2020.
- HARTMANN, M.; MOALA, F. A.; MENDONÇA, M. A. Estudo das precipitações máximas anuais em Presidente Prudente. **Revista Brasileira de Meteorologia**, v.26, n. 4, p.561-568, 2011.
- HENGL, T.; NUSSBAUM, M.; WRIGHT, M. N.; HEUVELINK, G. B.M.; GRÄLER, B. Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. **PeerJ**. 2018.
- HODAM, S.; SARKAR, S.; MARAK, A.G.R.; BANDYOPADHYAY, A.; BHADRA, A. Spatial Interpolation of Reference Evapotranspiration in India: Comparison of IDW and Kriging Methods. **Journal of The Institution of Engineers (India): Series A**, v.98, p.511–524, 2017.
- HONDA, E. A., DURIGAN, G. A restauração de ecossistemas e a produção de água. **Hoehnea**, v.44, n.3, p.315–327, 2017.
- HOFSTRA, N.; NEW, M. Spatial variability in correlation decay distance and influence on angular-distance weighting interpolation of daily precipitation over Europe. **International Journal of Climatology**, v.29, p.1872-1880, 2009.
- IBGE, Instituto Brasileiro de Geografia e Estatística. **Espírito Santo**. 2018. Disponível em <<https://cidades.ibge.gov.br/brasil/es>>. Acesso em 20 mai. 2020.
- IBRAHIM, G. R. F.; RASUL, A.; HAMID, A.A.; ALI, Z.F.; DEWANA, A.A. Suitable Site Selection for Rainwater Harvesting and Storage Case Study Using Dohuk Governorate. **Water**, v.11, 2019.
- ISOTTA, F. A.; BEGERT, M.; FREI, C. Long-Term Consistent Monthly Temperature and Precipitation Grid Data Sets for Switzerland Over the Past 150 Years. **Journal of Geophysical Research: Atmospheres**, v.123, 2019.
- JOIA, P. R.; ANUNCIACAO, V. S.; PAIXAO, A. A. Implicações do uso e ocupação do solo para o planejamento e gestão ambiental da Bacia Hidrográfica do Rio Aquidauana, Mato Grosso do Sul. **Interações (Campo Grande)**, v.19, n.2, p.343-358, 2018.

- KISI, O. Modeling reference evapotranspiration using three different heuristic regression approaches. **Agricultural Water Management**, v.169, p.162–172, 2016.
- KRAJEWSKI, W.F.; CEYNAR, D.; DEMIR, I.; GOSKA, R.; KRUGER, A.; LANGEL, C.; MANTILLA, R.; NIEMEIER, J.; QUINTERO, F.; SEO, B-C.; SMALL, F. J.; WEBER, L. J.; YOUNG, N. C. Real-time flood forecasting and information system for the state of Iowa. **Bulletin of the American Meteorological Society**, v.98, p.539–554, 2017.
- LI, J.; HEAP, A. D. A review of comparative studies of spatial interpolation methods in environmental sciences: Performance and impact factors. **Ecological Informatics**, v. 6, n.4, p.228-241, 2011.
- LIMA, C. H. R.; AGHAKOUCHAK, A.; RANDERSON, J. T. Unraveling the role of temperature and rainfall on active fires in the Brazilian Amazon using a nonlinear Poisson model. **Journal of Geophysical Research: Biogeosciences**, v.123, n.1, p.117–128, 2018.
- LIPPER, L.; THORNTON, P.; CAMPBELL, B. M.; BAEDEKER, T.; BRAIMOH, A.; BWALYA, M.; CARON, P.; CATTANEO, A.; GARRITY, D.; HENRY, K.; HOTTLE, R.; JACKSON, L.; JARVIS, A.; KOSSAM, F.; MANN, W.; MCCARTHY, N.; MEYBECK, A.; NEUFELDT, H.; REMINGTON, T.; SEN, P. T.; SESSA, R.; SHULA, R.; TIBU, A.; TORQUEBIAU, E. F. Climate-smart agriculture for food security. **Nature Climate Change**, v.4, p.1068-1072, 2014.
- LIU, W.; WANG, L.; SUN, F.; LI, Z.; WANG, H.; LIU, J.; YANG, T.; ZHOU, J.; QI, J. Snow Hydrology in the Upper Yellow River Basin Under Climate Change: A Land Surface Modeling Perspective. **Journal of Geophysical Research: Atmospheres**, v.123, n.22, p.676-691, 2018.
- MA, Y. J.; LI, X. Y.; LIU, L.; YANG, X. F.; WU, X. C.; WANG, P.; LIN, H.; ZHANG, G. H.; MIAO, C. Y. Evapotranspiration and its dominant controls along an elevation gradient in the Qinghai Lake watershed, northeast Qinghai-Tibet Plateau. **Journal of Hydrology**, v.575, n.135, p.257–268, 2019.
- MACHADO, N. D.; BIUDES, M. S.; ANGELINI, L. P.; MÜTZENBERG, D. M. S.; NASSARDEN, D. C. S.; BILIO, R. S.; SILVA, T. J. A.; NEVES, G. A. R.; ARRUDA, P. H. Z.; NOGUEIRA, J. S. Sazonalidade do Balanço de Energia e Evapotranspiração em Área Arbustiva Alagável no Pantanal Mato-Grossense. **Revista Brasileira de Meteorologia**, v.31, n.1, p.82-91, 2016.
- MACHADO, N. G.; MEIRELLES, T.; DANELICHEN, V. H. M.; QUERINO, C. A. S.; BIUDES, M. S. Estimation of Rainfall by Neural Network Over a Neotropical Region. **Revista Brasileira de Climatologia**, v. 17, p.44-54, 2015.
- MARDIKIS, M.G.; KALIVAS, D.P.; KOLLIAS, V.J. Comparison of Interpolation Methods for the Prediction of Reference Evapotranspiration—An Application in Greece. **Water Resources Management**, v.19, p.251-278, 2005.
- MARENGO, J. A.; NOBRE, C. A.; SELUCHI, M. E.; CUARTAS, A.; ALVES, L. M.; MENDIONDO, E. M.; OBREGÓN, G.; SAMPAIO, G. A seca e a crise hídrica de 2014-2015 em São Paulo. **Revista USP**. n. 106, p. 31-44, 2015.
- MCCABE, G.J.; WOLOCK, D.M. Increasing Northern Hemisphere water deficit. **Climatic change**, v. 132, p. 237-249, 2015.
- MENDEZ, M.; CALVO-VALVERDE, L. A.; MAATHUIS, B.; ALVARADO-GAMBOA, L. F. Generation of Monthly Precipitation Climatologies for Costa Rica Using Irregular Rain-Gauge Observational Networks. **Water**, v. 11, 2019.

- MENDONÇA, E. A.; DANTAS, R. T. Estimativa da evapotranspiração de referência no município de Capim, PB. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, n.2, p.196-202, 2010.
- MÉNDEZ, M.; CALVO-VALVERDE, L. A. Comparison performance of machine learning and geostatistical methods for the interpolation of monthly air temperature over Costa Rica. IOP Conference Series: **Earth and Environmental Science**, v.432, n.1, 2020.
- MENEZES, S. J. M. C.; SEDIYAMA, G. C.; SOARES, V. P.; GLERIANI, J. M.; ANDRADE, R. G. Estimativa dos componentes do balanço de energia e da evapotranspiração em plantios de eucalipto utilizando o algoritmo sebal e imagem landsat 5 - TM. **Revista Árvore**, v.35, n.3, p.649–657, 2011.
- MOREIRA, L. L.; SCHWAMBACK, D.; RIGO, D. Sensitivity analysis of the Soil and Water Assessment Tools (SWAT) model in streamflow modeling in a rural river basin. **Revista Ambiente & Água**, v.13, n.6, 2018.
- NEW, M.; HULME, M.; JONES, P. Representing Twentieth-Century Space–Time Climate Variability. Part II: Development of 1901–96 Monthly Grids of Terrestrial Surface Climate. **Journal of Climate**, v. 13, p. 2217-2238, 2000.
- NOIA, C. P. Z.; PEREIRA, S. B.; ROSA, D. R. Q.; ALMEIDA, R. A. Evapotranspiração de referência estimada pelos métodos Penman–Monteith-FAO (56) e Hargreaves & Samani para o município de Dourados, MS. **Revista Agrarian**, v.7, n.24, p.300-308, 2014.
- OLIVEIRA, D.; FERREIRA, C. Aspectos climáticos da bacia hidrográfica do rio Preto - MG/RJ, Brasil, influência dos fatores geográficos na formação desse clima regional. **Revista de Geografia e Ordenamento do Território**, n. 11, p. 283-307, 2017.
- OLIVEIRA, V. M. R.; DANTAS, G. F.; PALARETTI, L. F.; DALRI, A. B.; SANTOS, M. G.; FISCHER FILHO, J. A. Estimativa de evapotranspiração de referência na região de Rio Paranaíba-MG. **Irriga**, v.20, n.4, p.790-798, 2015.
- PANAHI, D. M.; KALANTARI, Z.; GHAJARNIA, N.; SEIFOLLAHI-AGHMIUNI, S.; DESTOUNI, G. Variability and change in the hydro-climate and water resources of Iran over a recent 30-year period. **Scientific Reports**, v.10, 2020.
- PENG, H.; JIA, Y., ZHAN, C.; & XU, W. Topographic controls on ecosystem evapotranspiration and net primary productivity under climate warming in the Taihang Mountains, China. **Journal of Hydrology**, v.581, 2020.
- PEREIRA, D. R.; YANAGI, S. N. M.; MELLO, C. R.; SILVA, A. M.; SILVA, L. A. Desempenho de métodos de estimativa da evapotranspiração de referência para a região da Serra da Mantiqueira, MG. **Ciência Rural**, v.39, n.9, p.2488-2493, 2009.
- PINHEIRO, A. G.; SOUZA, T. E. M. S.; MONTENEGRO, S. M. G. L.; MONTENEGRO, A. A. A.; GUERRA, S. M. S. Rainfall pattern and erosion potential in the physiographic regions of the state of Pernambuco, Brazil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.22, n.12, p.849-853, 2018.
- PRASAD, A. M.; IVERSON, L. R.; LIAW, A. Newer classification and regression tree techniques: bagging and random forests for ecological prediction. **Ecosystems**, v. 9, ed. 2, p.181–199, 2006.
- RAVAZZANI, G.; CEPPI, A.; DAVOLIO, S. Wind speed interpolation for evapotranspiration assessment in complex topography area. **Bulletin of Atmospheric Science and Technology**, p.13-22, 2020.

- REGOTO, P.; DEREZYNSKI, C.; SILVA, W. L.; SANTOS, R.; CONFALONIERI, U. Tendências de Extremos de Precipitação para o Estado do Espírito Santo. **Anuário do Instituto de Geociências**, v.41, n.1, p.365-381, 2018.
- ROBINSON, T. P.; METTERNICHT, G. Testing the performance of spatial interpolation techniques for mapping soil properties. **Computers and Electronics in Agriculture**, v.50, n.2, p.97-108, 2006.
- ROMERO, H. A. I.; ORTIZ, L. F. Ajuste metodológico al índice de escasez de água propuesto por el ideam en el plan de ordenación y manejo de la cuenca del Río Pamplonita, norte de Santander, Colombia. **Colombia Forestal**, v.11, n.1, p. 165-173, 2008.
- SANCHES, F.O.; VERDUM, Roberto; FISCH, Gilberto. Estudo de tendência de luvas de longo prazo. **Revista Ambiente & Água**, v.8, n.3, p. 214-228, 2013.
- SANTANA, J. S.; SILVA, W. A.; LIMA, E. F.; OLIVEIRA, G. C. Análise Espaço-Temporal Da Evapotranspiração De Referência Para O Estado Do Maranhão. *Revista Brasileira de Agricultura Irrigada*, v.12, n.5, p.2866–2876, 2018.
- SANTOS, L. O. F.; QUERINO, C. S. A.; QUERINO, J. K. A. S.; PEDREIRA, J. A. L.; MOURA, A. R. M.; MACHADO, N. G.; BIUDES, M. S. Validation of rainfall data estimated by GPM satellite on Southern Amazon region. **Revista Ambiente & Água**, v. 14, n.1, 2019.
- SANTOS, P. V. C. J.; CUNHA, A. C. Potencial de vazão ambiental: método participativo para estimar vazão ambiental em rios na Amazônia. **Engenharia Sanitaria e Ambiental**, v.23, n.1, p.137-150, 2018.
- SARAIVA, G. S.; BONOMO, R.; SOUZA, J. M. Avaliação de interpoladores geoestatísticos e determinísticos da evapotranspiração de referência diária para o estado do Espírito Santo. **Revista Agro@ambiente**, v.11, p. 21-30, 2017.
- SCHUMACHER, V.; JUSTINO, F.; FERNÁNDEZ, A.; MESEGUER'RUIZ, O.; SARRICOLEA, P.; COMIN, A.; VENANCIO, L. P.; ALTHOFF, D. Comparison between observations and gridded datasets over complex terrain in the Chilean Andes: precipitation and temperature. **International Journal of Climatology**, v.1, 2020.
- SEKULIĆ, A.; KILIBARDA, M.; HEUVELINK, G. B. M.; NIKOLIĆ, M.; BAJAT, B. Random forest spatial interpolation. **Remote Sensing**, v.12, n.10, p.1–29, 2020.
- SHEPARD, D. S. A two-dimensional interpolation function for irregularly-spaced data. **Proceedings of the 1968 ACM National Conference**, p.517-524, 1968.
- SILVA, G. H.; DIAS, S. H. B.; FERREIRA, L. B.; SANTOS, J. É. O.; CUNHA, F. F. Performance of different methods for reference evapotranspiration estimation in Jaíba, Brazil. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.22, n.2, p.83-89, 2018.
- SILVA, M. G.; ARRAES, F. D. D.; LEDO, E. R. F.; SANTOS, N. T.; SILVA FILHO, J. A. Avaliação da evapotranspiração de referência por Penman-Monteith usando dados climáticos mínimos no sertão do Ceará. **Revista Agro@ambiente**, v.7, n.3, p.284-293, 2013.
- SILVA JÚNIOR, J. C.; MEDEIROS, V.; GARROZI, C.; MONTENEGRO, A.; GONÇALVES, G. E. Random forest techniques for spatial interpolation of evapotranspiration data from Brazilian's Northeast. **Computers and Electronics in Agriculture**, v. 166, 2019.
- SOUZA, A. F.; CAMPELO JÚNIOR, J. H. Desempenho de métodos de estimativa da evapotranspiração de referência para região da Baixada Cuiabana, MT. **Agrometeoros**, v.25, n.2, p.395-403, 2017.
- SOUZA, A. P.; CARVALHO, D. F.; SILVA, L. B. D.; ALMEIDA, F. T.; ROCHA, H. S. Estimativas da evapotranspiração de referência em diferentes condições de nebulosidade. **Pesquisa Agropecuária Brasileira**, v.46, n.3, p.219-228, 2011.

- SUN, J-Y.; SUN, X-Y.; HU, Z-Y.; WANG, G-X. Exploring the influence of environmental factors in partitioning evapotranspiration along an elevation gradient on Mount Gongga, eastern edge of the Qinghai-Tibet Plateau, China. **Journal of Mountain Science**, v.17, n.2, p.384–396, 2020.
- TANAKA, A. A.; SOUZA, A. P.; KLAR, A. E.; SILVA, A.C.; GOMES, A. W. A. Evapotranspiração de referência estimada por modelos simplificados para o Estado do Mato Grosso. **Pesquisa Agropecuária Brasileira**, v.51, n.2, p.91-104, 2016.
- TOMAS-BURGUERA, M.; VICENTE-SERRANO, S. M.; GRIMALT, M., & BEGUERÍA, S. Accuracy of reference evapotranspiration (ETo) estimates under data scarcity scenarios in the Iberian Peninsula. **Agricultural Water Management**, v. 182, p.103–116, 2017.
- TUNDISI, J. G. Water resources in the future: problems and solutions. **Estudos avançados**, v.22, n.63, p.7-16, 2008.
- VALERIANO, T. T. B.; ROLIM, G. S.; BISPO, R. C.; MORAES, J. R. S. C.; APARECIDO, L. E. O. Evaluation of air temperature and rainfall from ECMWF and NASA gridded data for southeastern Brazil. **Theoretical and Applied Climatology**, 2018.
- VERDIN, A.; RAJAGOPALAN, B.; KLEIBER, W.; FUNK, C. A Bayesian kriging approach for blending satellite and ground precipitation observations, **Water Resources Research**, v.51, ed.2, p.908-921, 2015.
- WANG, Z.; XIE, P.; LAI, C.; CHEN, X.; WU, X.; ZENG, Z., LI, J. Spatiotemporal variability of reference evapotranspiration and contributing climatic factors in China during 1961–2013. **Journal of Hydrology**, v.544, p.97–108, 2017.
- WANG, S.; LIAN, J.; PENG, Y.; HU, B.; CHEN, H. Generalized reference evapotranspiration models with limited climatic data based on random forest and gene expression programming in Guangxi, China. **Agricultural Water Management**, v.221, p.220–230, 2019.
- WILLMOTT, C. J. On the validation of models. **Physical Geography**, v.2, p.184-194, 1981.
- WU, L.; PENG, Y.; FAN, J.; WANG, Y. Machine learning models for the estimation of monthly mean daily reference evapotranspiration based on crossstation and synthetic data. **Hydrology Research**, v.50, n.6, p.1730–1750, 2019.
- XAVIER, A. C.; KING, C. W.; SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**. v.36, n.6, p.2644-2659, 2015.
- XING, W.; WANG, W.; SHAO, Q.; YU, Z.; YANG, T.; FU, J. Periodic fluctuation of reference evapotranspiration during the past five decades: Does Evaporation Paradox really exist in China? **Scientific Reports**, v.6, n.1, 2016.
- YANTO; LIVNEH, B.; RAJAGOPALAN, B. Development of a gridded meteorological dataset over Java island, Indonesia 1985–2014. **Scientific Data**, v. 4, 2017.
- YIN, Y.; WU, S.; ZHAO, D. Past and future spatiotemporal changes in evapotranspiration and effectiveness on the Tibetan Plateau, **Journal of Geophysical Research: Atmospheres**, v.118, p.10850–10860, 2013.
- ZANETTI, S. S.; DOHLER, R. E.; CECÍLIO, R. A.; PEZZOPANE, J. E. M.; XAVIER, A. C. Proposal for the use of daily thermal amplitude for the calibration of the Hargreaves-Samani equation. **Journal of Hydrology**, v. 571, p. 193–201, 2019.
- ZHANG, Y.; PEÑA-ARANCIBIA, J. L.; MCVICAR, T. R.; CHIEW, F. H. S.; VAZE, J., LIU, C.; MIRALLES, D. G.; PAN, M. Multi-decadal trends in global terrestrial evapotranspiration and its components. **Scientific Reports**, v.6, 2016.

ZHU, W.; JIA, S.; LV, A. A Universal T_s -VI Triangle Method for the Continuous Retrieval of Evaporative Fraction from MODIS Products. **Journal of Geophysical Research: Atmospheres**, v. 122, ed.19, p.206-227, 2017.

CONCLUSÕES GERAIS

A partir do presente trabalho de dissertação foi possível concluir-se que, para a espacialização da precipitação diária na região centro-sul do Espírito Santo, o melhor método foi o ADW, e para a espacialização da ET_0 diária, o melhor método foi o *Random Forest*. O trabalho resultou em duas bases de dados diários em formato *grid* (1980-2018), cuja resolução espacial para os dados de precipitação foi de $0,01^\circ$ e para ET_0 foi de $0,004^\circ$, disponíveis *on-line*, cada uma em um sítio específico hospedados pelo Mendeley.

Desta forma, com o presente trabalho, procurou-se contribuir para a ciência agrária e ambiental, a partir da disponibilização de uma nova base de dados meteorológicos, que pode ser utilizada no planejamento e tomada de decisão com relação à agricultura irrigada, produção de água, recomposição florestal, dentre outros fins gerais.

REFERÊNCIAS

- ASLAMI, F.; GHORBANI, A.; SOBHANI, B.; ESMALI, A. Comprehensive comparison of daily IMERG and GSMaP satellite precipitation products in Ardabil Province, Iran. **International Journal of Remote Sensing**, v.40, p.3139-3153, 2019.
- ALMEIDA, C.T.; DELGADO, R.C.; OLIVEIRA JUNIOR, J.F.; GOIS, G.; CAVALCANTI, A.S. Avaliação das Estimativas de Precipitação do Produto 3B43-TRMM do Estado do Amazonas. **Floresta e Ambiente**, v.22, 279–286, 2015.
- BIER, A.A.; FERRAZ, S.E.T.; BIER, A.A.; FERRAZ, S.E.T. Comparação de Metodologias de Preenchimento de Falhas em Dados Meteorológicos para Estações no Sul do Brasil. **Revista Brasileira de Meteorologia**, v.32, p.215-226, 2017.
- CASTRO, F. S.; PEZZOPANE, J. E.M.; CECÍLIO, R. A.; PEZZOPANE, J. R. M.; XAVIER, A. C. Avaliação do desempenho dos diferentes métodos de interpoladores para parâmetros do balanço hídrico climatológico. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n.8, 2010.
- CHEN, T.; REN, L.; YUAN, F.; YANG, X.; JIANG, S.; TANG, T.; LIU, Y.; ZHAO, C.; ZHANG, L. Comparison of Spatial Interpolation Schemes for Rainfall Data and Application in Hydrological Modeling. **Water**, v.9, n.342, 2017.
- DARAND, M.; AMANOLLAHI, J.; ZANDKARIMI, S. Evaluation of the performance of TRMM Multi-satellite Precipitation Analysis (TMPA) estimation over Iran. **Atmos. Res.** v.190, p.121-127, 2017.
- FALCK, A.S.; VILA, D.; TOMASELLA, J.; MAGGIONI, V.; DINIZ, F.L.R.; FALCK, A.S.; VILA, D.; TOMASELLA, J.; MAGGIONI, V.; DINIZ, F.L.R. Avaliação de um Modelo Estocástico de Erro Multidimensional Aplicado a Estimativas de Precipitação por Satélite. **Rev. Bras. Meteorol.** v.31, p.52–63, 2016.
- FRANCO, A. C. L.; BONUMÁ, N. B. Multi-variable SWAT model calibration with remotely sensed evapotranspiration and observed flow. **Revista Brasileira de Recursos Hídricos**, v. 22, ed. 35, 2017.
- HE, X.; CHANEY, N.W.; SCHLEISS, M.; SHEFFIELD, J. Spatial downscaling of precipitation using adaptable random forests. **Water Resour. Res.** v.52, p.8217-8237, 2016.
- HOFSTRA, N.; HAYLOCK, M.; NEW, M.; JONES, P.; FREI, C. Comparison of six methods for the interpolation of daily, European climate data. **Journal of Geophysical Research**, v.113, 2008.
- KRAJEWSKI, A.; SIKORSKA-SENONER, A. E.; RANZI, R.; BANASIK, K. Long-Term Changes of Hydrological Variables in a Small Lowland Watershed in Central Poland. **Water**, v.11, n.564, 2019.
- MADSEN, H.; LAWRENCE, D.; LANG, M.; MARTINKOVA, M.; KJELDTSEN, T.R. Review of trend analysis and climate change projections of extreme precipitation and floods in Europe. **J. Hydrol.** p.3634-3650, 2014.
- MAIDMENT, R.I.; GRIMES, D.; BLACK, E.; TARNAVSKY, E.; YOUNG, M.; GREATREX, H.; ALLAN, R.P.; STEIN, T.; NKONDE, E.; SENKUNDA, S.; ALCÁNTARA, E.M.U. A new, long-term daily satellite-based rainfall dataset for operational monitoring in Africa. **Sci. Data.** v.4, 2017.

MMA. Ministério do Meio Ambiente. **Mata Atlântica**. Disponível em: https://www.mma.gov.br/estruturas/202/_arquivos/adequao_ambiental_publicao_web_202.pdf. Acesso em: 10 jun. 2020.

RODY, Y. P.; ALMEIDA, A. Q.; RIBEIRO, A.; SEDIYAMA, G. C.; PEZZOPANE, J. E. M. Delimitação de sítios ambientais homogêneos no Estado do Espírito Santo, com base no relevo, solo e clima. **Ciência Rural**, v.40, n.12, p.2493-2498, 2010.

SCHUMACHER, R. S. The Studies of Precipitation, Flooding, and Rainfall Extremes across Disciplines (SPREAD) Workshop: An Interdisciplinary Research and Education Initiative. **Bull. Am. Meteorol. Soc.** v.97, p.1791-1796, 2016.

SIMPSON, M. J.; HIRSCH, A.; GREMLER, K.; LUPO, A. The importance of choosing precipitation datasets. **Hydrol. Process.** v.31, p.4600-4612, 2017.

TRENBERTH, K.E., Changes in precipitation with climate change. **Clim. Res.** v.47, p.123–138, 2011.

WANG, Z.; XIE, P.; LAI, C.; CHEN, X.; WU, X.; ZENG, Z., LI, J. Spatiotemporal variability of reference evapotranspiration and contributing climatic factors in China during 1961–2013. **Journal of Hydrology**, v.544, p.97–108, 2017.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**, v.36, n.6, p.2644-2659, 2015.

YEGGINA, S.; TEEGAVARAPU, R.S.V.; MUDDU, S. A conceptually superior variant of Shepard's method with modified neighbourhood selection for precipitation interpolation. **International Journal of Climatology**, v.39, p.4627–4647, 2019.

YIN, Y.; WU, S.; ZHAO, D. Past and future spatiotemporal changes in evapotranspiration and effective moisture on the Tibetan Plateau. **Journal of Geophysical Research: Atmospheres**, v.118, p.10850–10860, 2013.

APÊNDICE A

Tabela 6. Estações pluviométricas da ANA e INMET utilizadas no estudo.

Código da estação	Long. (°)	Lat. (°)	Altitude (m)	Período	Código da estação	Long. (°)	Lat. (°)	Altitude (m)	Período
01940000	-40,874	-19,874	165,0	1980-2018	02041000	-41,195	-20,913	76,0	1980-2018
01940001	-40,679	-19,805	149,0	1980-2018	02041001	-41,682	-20,774	576,0	1980-2005
01940002	-40,154	-19,958	5,0	1980-2018	02041002	-41,200	-20,606	107,0	1980-2018
01940003	-40,043	-19,750	5,0	1980-2018	02041003	-41,466	-20,767	127,0	1980-2018
01940005	-40,398	-19,692	50,0	1980-2018	02041005	-41,922	-20,694	747,0	1980-2018
01940006	-40,623	-19,531	40,0	1980-2018	02041008	-41,728	-20,108	458,0	1980-2018
01940007	-40,401	-19,937	50,0	1980-2018	02041010	-41,016	-20,702	580,0	1980-2018
01940009	-40,853	-19,220	135,0	1980-2018	02041011	-41,239	-20,352	600,0	1980-2018
01940010	-40,553	-19,953	180,0	1980-2018	02041013	-41,538	-20,346	615,0	1980-2018
01940012	-40,835	-19,664	70,0	1980-2018	02041014	-41,846	-20,686	772,0	1980-2005
01940013	-40,591	-19,238	170,0	1980-2018	02041015	-41,401	-20,945	450,0	1980-2018
01940021	-40,162	-19,830	58,0	1980-2018	02041016	-41,666	-20,541	794,0	1980-2018
01941008	-41,058	-19,901	250,0	1980-2018	02041017	-41,704	-20,323	920,0	1980-2018
02040003	-40,319	-20,190	70,0	1980-2018	02041018	-41,409	-20,371	580,0	1980-2018
02040004	-40,509	-20,652	6,0	1980-2018	02041019	-41,511	-20,528	380,0	1980-2018
02040005	-40,826	-20,784	25,0	1980-2018	02041020	-41,061	-20,367	1075,0	1980-2018
02040006	-40,953	-20,953	40,0	1980-2018	02041021	-41,348	-20,681	180,0	1980-2018
02040007	-40,743	-20,028	710,0	1980-2018	02041023	-41,121	-20,079	300,0	1980-2018
02040008	-40,975	-20,143	940,0	1980-2018	02041046	-41,850	-20,931	650,0	1980-2018
02040009	-40,656	-20,804	6,0	1980-2018	02041048	-41,961	-20,183	635,0	1984-2018
02040010	-40,528	-20,060	160,0	1980-2018	02041050	-41,417	-20,467	530,0	1980-1998
02040011	-40,484	-20,557	515,0	1980-2018	02041057	-41,524	-20,765	190,0	2003-2012
02040012	-40,682	-20,412	544,0	1980-2018	02041058	-41,101	-20,685	36,0	2004-2012
02040013	-40,943	-20,881	80,0	1980-2009	02042000	-42,024	-20,740	399,0	1980-2018
02040014	-40,479	-20,261	200,0	1980-2018	02140000	-40,835	-21,008	4,0	1980-2018
02040015	-40,783	-20,284	640,0	1980-2016	02141001	-40,850	-21,017	35,0	1980-2018
02040017	-40,883	-20,728	15,0	1980-2018	02141003	-40,983	-21,900	11,0	1980-2018
02040018	-40,607	-20,079	65,0	1980-2018	02141014	-41,463	-21,206	59,0	1980-2018
02040020	-40,949	-20,588	980,0	1980-2018	02141016	-41,652	-21,034	150,0	1980-2018
02040022	-40,364	-20,516	3,0	1980-2018	02141017	-41,241	-21,063	120,0	1980-2018
02040023	-40,934	-20,296	818,0	1980-2018	INMET83550	-39,850	-18,700	25,0	1980-2018
02040035	-40,333	-20,317	9,0	1980-2018	INMET83595	-41,070	-19,490	82,7	1980-2018
02040042	-40,750	-20,633	35,0	1980-1998	INMET83639	-41,090	-20,510	843,2	1980-2018
02040046	-40,571	-20,395	115,0	2003-2012	INMET83648	-40,310	-20,310	36,2	1980-2018
02040047	-40,714	-20,034	675,0	2004-2018	INMET83695	-41,900	-21,200	123,6	1980-2018
02040049	-40,516	-20,102	23,0	2003-2018	INMET83698	-41,330	-21,740	11,2	1980-2018