

Variabilidade espaço-temporal da evapotranspiração de referência estimada com imagens de satélites na bacia hidrográfica do rio Tibagi, estado do Paraná, Brasil

Spatiotemporal variability of reference evapotranspiration estimated using satellite images in the Tibagi River Basin, Paraná State, Brazil

Jorge Luiz Moretti de Souza*, Denis Pinheiro da Silva**, Daniela Jerszurki***

*Departamento de Solos e Engenharia Agrícola, Universidade Federal do Paraná, jmoretti@ufpr.br

**Departamento de Solos e Engenharia Agrícola, Universidade Federal do Paraná, Silva-denispinheiro263@gmail.com

***NDrip Israel, Center Israel, daniijerszurki@gmail.com

<http://dx.doi.org/10.5380/raega.v62i1.96420>

Resumo

A evapotranspiração de referência (ET_o) é essencial para planejamento e gestão dos recursos hídricos, mas monitorá-la em larga escala com métodos tradicionais é inviável devido ao custo e logística. Uma alternativa é utilizar dados obtidos remotamente para a modelagem da ET_o . Teve-se por objetivo no presente estudo avaliar a variabilidade espacial da ET_o diária na bacia hidrográfica do rio Tibagi (BHRT), estimada com dados remotos em anos com ocorrência de eventos ENOS, e estimar a ET_o no intervalo entre imagens do satélite Landsat com um algoritmo interpolador temporal. A ET_o foi calculada com o modelo Moretti-Jerszurki-Silva (MJS ; $ET_{O_{MJS(\psi_{ar}; Ra)}}$) e dados espacializados de temperatura e umidade relativa do ar, estimados com modelo de regressão linear múltiplo. A variabilidade espacial foi avaliada com imagens das estações de 2013 (Normal), 2015 (El Niño) e 2011 (La Niña). A variabilidade temporal da $ET_{O_{MJS(\psi_{ar}; Ra)}}$ foi testada com interpolação linear entre imagens Landsat 8 de 2013, utilizando o algoritmo "r.series.interp". A $ET_{O_{MJS(\psi_{ar}; Ra)int}}$ interpolada foi comparada com a ET_{OPM} Penman-Monteith, calculada com dados diários de estações meteorológicas. A ET_o espacializada identificou diferenças nas estações do ano nos cenários climáticos analisados, não observadas com a ET_{OPM} . A metodologia para estimar a $ET_{O_{MJS(\psi_{ar}; Ra)}}$ espacializada em grandes áreas obteve precisão aceitável, apesar do processo ser laborioso para coberturas amplas. A ET_o temporal apresentou precisão estatística satisfatória ($RMSE = 0,65 \text{ mm dia}^{-1}$; $r = 0,73$; $MAPE = 5,94\%$; $NSE = -1,2$; $d = 0,04$), embora limitações das imagens e algoritmo interpolador linear dificultassem o acompanhamento das variações diárias da ET_{OPM} .

Palavras-chave:

Mapeamento, Modelagem, Cenários climáticos, Cobertura do solo.

Abstract

The reference evapotranspiration (ET_o) is an essential tool in planning and management of water resources, but large-scale monitoring using traditional methods is impractical due to its cost and logistics. An alternative is to rely on remote data to model ET_o . This study aimed to evaluate the spatial variability of daily ET_o in the Tibagi River Basin (TRB), estimated with remote sensing data during years with ENSO events, and to estimate ET_o between Landsat satellite images using a temporal interpolation algorithm. ET_o was calculated using the Moretti-Jerszurki-Silva model (MJS ; $ET_{O_{MJS}(\psi_{air}; Ra)}$) and spatial data of temperature and relative humidity were estimated with a multiple linear regression model. Spatial variability was assessed using images that represented the seasons in 2013 (Normal), 2015 (El Niño), and 2011 (La Niña). The temporal variability of $ET_{O_{MJS}(\psi_{air}; Ra)}$ was tested with linear interpolation between Landsat 8 images in 2013, using the "r.series.interp" algorithm. The interpolated $ET_{O_{MJS}(\psi_{air}; Ra)_{int}}$ was compared with $ET_{O_{PM}}$ calculated with the Penman-Monteith method using daily climatic data coming from local meteorological stations. The spatialized ET_o identified differences in the seasons under the analyzed climate scenarios, which was not possible with $ET_{O_{PM}}$. The methodology for estimating spatialized $ET_{O_{MJS}(\psi_{air}; Ra)}$ over large areas showed acceptable accuracy, despite being laborious for extensive coverage. Temporal ET_o showed satisfactory statistical accuracy ($RMSE = 0,65 \text{ mm dia}^{-1}$; $r = 0,73$; $MAPE = 5,94\%$; $NSE = -1,2$; $d = 0,04$), although the limitations of the images and the linear interpolation algorithm limited the monitoring of daily $ET_{O_{PM}}$ variations.

Keywords:

Mapping, Modeling, Climate scenarios, Land cover.

I. INTRODUÇÃO

A evapotranspiração de referência (ET_o) é componente fundamental para o planejamento e gestão dos recursos hídricos, principalmente para a realização de balanços hídricos em bacias hidrográficas (ASCE-EWRI, 2005; Allen et al., 2011; Jerszurki et al., 2017). O monitoramento da ET_o em larga escala com os métodos tradicionais (medidas em evapotranspirômetros e lisímetros ou estimadas com modelos físicos ou empíricos) não é viável, devido ao custo, logística, falta de continuidade espacial e necessidade de informações climáticas locais (Rosa et al., 2023). Uma alternativa consiste em utilizar dados obtidos remotamente para modelagem da ET_o (Talsma et al., 2018). Entretanto, poucos trabalhos realizam a validação e utilização do sensoriamento para a estimativa da ET_o . A obtenção da ET_o por meio de sensoriamento remoto poderá contribuir muito com estudos em escala regional a global, fornecendo estimativas especializadas e com baixo custo (Paredes et al., 2021).

Os dados climáticos são medidos em estações meteorológicas, que podem não estar disponíveis em certos locais onde se deseja fazer a estimativa da evapotranspiração (Rosa et al., 2023). A ET_o apresenta grande variabilidade espacial, devido às condições e variações ambientais (ASCE-EWRI, 2005; Paredes et al., 2021). Logo, medidas pontuais da ET_o , determinadas com métodos convencionais podem não representar as medidas

no espaço ao seu redor, limitando a obtenção da variabilidade da *ETo*. No estado do Paraná, o Instituto Nacional de Meteorologia (INMET) tem 25 estações meteorológicas em extensão territorial de 199280 km². Cada estação representa aproximadamente 8000 km² com único valor da *ETo*. Além da importância espacial da *ETo*, estudos considerando o efeito do fenômeno El Niño Oscilação Sul (ENOS) são interessantes, visto que projeções indicam que eventos ENOS tendem a ocorrer com maior frequência e intensidade nos próximos anos (Cavalcante et al., 2015).

Imagens de satélite são uma alternativa interessante para estudos visando realizar a estimativa da *ETo* de uma região de forma espacial e temporal. Constelações modernas de satélites (como Planet, Satellogic, AxelSpace entre outras) têm reduzido as limitações quanto à resolução espacial e temporal, oferecendo imagens frequentes (diárias) e de alta resolução (até 0,5 m). No entanto, ainda há desafios (integração de dados das constelações e limitações espectrais para aplicações específicas) e os custos podem limitar a sua aplicação em pesquisas com análise histórica longa, que visam soluções gratuitas ou de acesso livre (Nagel et al., 2020).

As imagens Landsat são gratuitas, mas possuem resolução espacial de 30 m e o intervalo de tempo de captura entre imagens é de 16 dias, podendo ser um problema para acompanhar o monitoramento diário do crescimento e desenvolvimento de culturas agrícolas, dependendo de pouca ou nenhuma cobertura de nuvens (Gao et al., 2006). O monitoramento diário da *ETo* com alta resolução espacial e temporal é fundamental para compreender a sua dinâmica, fornecendo informações importantes sobre a eficiência hídrica das culturas e umidade do solo, dando subsídio para otimizar o uso da água na irrigação (Cammalleri et al., 2013; Paredes et al., 2021; Rosa et al., 2023).

O sensor Moderate Resolution Imaging Spectroradiometer (MODIS) possui resoluções espacial moderada (250, 500 e 1000 metros) e temporal diária. Ke et al. (2017) consideraram que a resolução espacial do sensor limita muito sua utilização em escala local ou de bacia hidrográfica, para finalidades irrigacionistas ou gestão de recursos hídricos. O ideal seria que mapas contínuos e de alta resolução espacial da *ETo* fossem gerados. No entanto, gratuitamente, os satélites de sensoriamento remoto atualmente disponíveis não conseguem fornecer imagens com alta resolução espacial e temporal em apenas uma plataforma, devido ao equilíbrio que deve existir entre as resoluções (Wang et al., 2019).

Na literatura, encontram-se algoritmos avançados e complexos que foram desenvolvidos para melhorar a resolução espacial do Landsat (Gao et al., 2006; Zhu et al., 2010) e foram utilizados por diversos autores (Yang et al., 2016; Ke et al., 2017). No entanto, acredita-se que algoritmos simplificados possam facilitar o acesso gratuito ao conjunto de dados com alta resolução espacial e temporal, auxiliando o desenvolvimento de

atividades técnicas e estudos científicos. Além disso, nem sempre algoritmos mais complexos resultam em menores erros em relação aos algoritmos mais simples. Desta forma, teve-se por objetivo no presente estudo avaliar a variabilidade espacial da evapotranspiração de referência diária (*ET_o*) na Bacia Hidrográfica do Rio Tibagi (BHRT), estimada com dados remotos em anos com ocorrência de eventos ENOS (El Niño, La Niña e Normalidade climática), bem como estimar a *ET_o* da bacia no intervalo entre imagens do satélite Landsat, utilizando um algoritmo interpolador temporal.

II. MATERIAIS E MÉTODOS

A área de estudo consistiu na Bacia Hidrográfica do Rio Tibagi (BHRT), localizada na porção centro-leste do Estado do Paraná (Figura 1), compreendendo aproximadamente 13% da superfície territorial do Estado (25000 km²), e apresentando os tipos climáticos Cfa e Cfb (Alvares et al., 2013). A BHRT foi escolhida por apresentar características físico climáticas distintas, em relação à posição geográfica. A distinção físico climática foi desejável para avaliar a variabilidade espacial e temporal da *ET_o*.

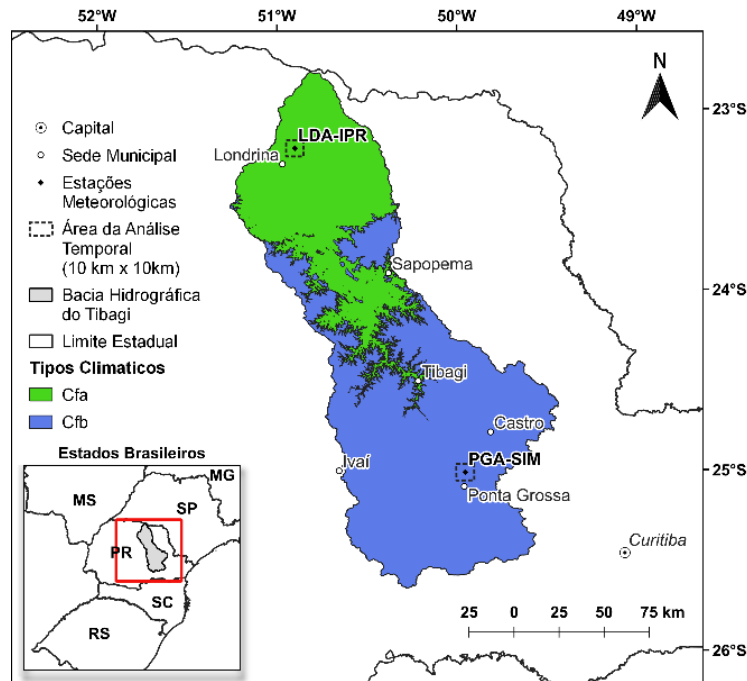


Figura 1 – Localização da Bacia Hidrográfica do Rio Tibagi (BHRT), contendo a distribuição de suas estações meteorológicas, e recorte 10 km x 10 km para a análise temporal (LDA-IPR e PGA-SIM). (Fonte: Os autores)

A *ET_o* foi estimada com o modelo Moretti-Jerszurki-Silva (*MJS*; Jerszurki et al., 2017; Equações 1 a 4), que considera o potencial hídrico atmosférico (ψ_{ar}) e a radiação solar no topo da atmosfera (R_a).

$$ET_{oMJS(\psi_{ar};R_a)} = a + b \cdot Ee_i \quad (1)$$

$$Ee_i = k_{\psi ar} \cdot \frac{Ra_i}{\lambda} \quad (2)$$

$$k_{\psi ar.i} = \left| \frac{\psi_{ar.i} - \psi_{ar.min}}{\psi_{ar.max} - \psi_{ar.min}} \right| \quad (3)$$

$$\psi_{ar.i} = \frac{R \cdot T}{M_v} \cdot \ln\left(\frac{ea}{es}\right) = 0,46191456 \cdot T \cdot \ln(UR) \quad (4)$$

Sendo: $ETOMJS(\psi_{ar}; Ra)$ – evapotranspiração de referência estimada com o modelo Moretti-Jerszurki-Silva (mm dia⁻¹); a – coeficiente linear da equação de regressão obtido da associação “ ψ_{ar} vs. $ETOPM$ ” (mm dia⁻¹); b – coeficiente angular da equação de regressão obtido da associação “ ψ_{ar} vs $ETOPM$ ” (adimensional); Ee_i – evaporação equivalente de água no i -ésimo dia (mm dia⁻¹); $K_{\psi ar.i}$ – coeficiente de proporcionalidade do potencial hídrico atmosférico do i -ésimo dia (adimensional); Ra_i – radiação solar no topo da atmosfera no i -ésimo dia (MJ m⁻² dia⁻¹), estimada conforme ASCE-EWRI (2005); λ – calor latente de vaporização da água (2,45 MJ kg⁻¹); $\psi_{ar.i}$ – potencial hídrico atmosférico no i -ésimo dia (MPa); $\psi_{ar.max}$ – potencial hídrico atmosférico máximo encontrado no período analisado (MPa); $\psi_{ar.min}$ – potencial hídrico atmosférico mínimo encontrado no período analisado (MPa); R – Constante universal dos gases perfeitos (8,314 J mol⁻¹ K⁻¹); T – temperatura média do ar do período considerado (K); M_v – Massa molar da água (18 . 10⁻⁶ m³ mol⁻¹); ea – pressão atual do vapor do período considerado (MPa); es – pressão de saturação de vapor do período considerado (MPa); UR – umidade relativa do ar (adimensional).

Os parâmetros do modelo MJS utilizados ($a = -0,0888$ mm dia⁻¹ e $b = 0,3683$, para $\psi_{ar.min} = 28,5$ MPa e $\psi_{ar.max} = 156,0$ MPa) foram calibrados por Silva (2021) com dados medidos em estações meteorológicas da BHRT, do período entre jan/2014 e dez/2018, utilizando o método dos mínimos quadrados para o ajuste dos coeficientes.

A espacialização da Ra considerou a entrada das variáveis dia Juliano (J ; dias) e latitude local (φ ; radianos). Os valores de J e φ foram espacializados com um módulo de processamento criado no programa QGIS. O ψ_{ar} foi gerado com imagens de temperatura (Te_{SR} ; °C) e umidade relativa (UR_{eSR} ; %) do ar, estimadas com sensoriamento remoto, que serviram de entrada na Equação 4. Com $\psi_{ar.min}$ e $\psi_{ar.max}$ obtidos no período de estudo, estimou-se $k_{\psi ar}$ com a Equação 3. A Ee foi calculada com as imagens geradas de Ra e $k_{\psi ar}$, conforme a Equação 2. Por fim, com a Ee especializada e coeficientes a e b do modelo MJS calibrados, obteve-se a $ETOMJS(\psi_{ar}; Ra)$ distribuída espacialmente (Equação 1).

Na estimativa da $ETOMJS(\psi_{ar}; Ra)$ foi utilizado como entrada a temperatura e umidade relativa do ar, obtida com o modelo linear múltiplo (Equações 5 e 6), estabelecido por Silva (2021):

$$Te_{SR(Wp;Ts)} = a_2 \cdot Wp + a_1 \cdot Ts + a_0 \quad (5)$$

$$UR_{eSR(Wp;Ts)} = a_2 \cdot Wp - a_1 \cdot Ts + a_0 \quad (6)$$

Sendo: $Te_{SR(Wp;Ts)}$ – temperatura do ar estimada com sensoriamento remoto por ajuste linear múltiplo (°C); Wp – coluna total de vapor d’água precipitável estimada com satélite Aqua MODIS, produto MYD05_L2 (cm); Ts – temperatura da superfície do solo estimada da banda 10 do satélite Landsat 8 (°C); $UR_{eSR(Wp;Ts)}$ – umidade relativa do ar estimada com sensoriamento remoto, com ajuste linear múltiplo (%); a_2, a_1, a_0 – coeficientes da equação obtidos no ajuste linear múltiplo para temperatura ($a_2 = 1,75 \text{ °C cm}^{-1}$; $a_1 = 0,52$, $a_0 = 3,25 \text{ °C}$) e umidade relativa ($a_2 = 1,74 \text{ °C cm}^{-1}$; $a_1 = -0,97$, $a_0 = 87,85 \text{ °C}$).

A análise da variabilidade espacial das $ET_{O_{MJS}(\psi_{ar};Ra)}$ na BHRT (pixel da imagem) foram avaliados em imagens representando as estações do verão (04 de janeiro a 18 de fevereiro), outono (03 de abril a 26 de maio), inverno (08 de julho a 21 de agosto) e primavera (08 de outubro a 10 de novembro), em cenários classificados com Índice de El Niño Oceânico (ONI), conforme GGWS (2021). Nas análises, foram considerados os anos: 2013, tendo Normalidade climatológica esperada para a região; 2015, El Niño predominante; e, 2011, La Niña predominante. Os cenários visaram avaliar a variabilidade espacial da ET_o em diferentes situações climáticas ao longo das estações do ano.

As imagens de satélite utilizadas para estimar e analisar a variação da $ET_{O_{MJS}(\psi_{ar};Ra)}$ na BHRT foram agrupadas por cenário climático (Tabela 1), identificando os satélites, órbita/ponto e datas das estações do ano.

Cada cena do satélite Landsat 8 cobre área de 190 km (altura) por 180 km (largura), e a imagem do satélite Aqua, sensor MODIS, cobre área de 2040 km (altura) por 2880 km (largura). Como a BHRT tem 25000 km², foram necessárias quatro cenas Landsat para cobrir toda a bacia e apenas uma imagem Aqua. O mosaico de imagens Landsat 8 e Aqua MODIS foi realizado no software QGIS, para cada estação, em cada um dos cenários avaliados (Normal, El Niño e La Niña), gerando 12 mosaicos da BHRT.

Tabela 1 – Data de obtenção das imagens dos satélites e sensores utilizados para análise da variabilidade espacial da $ET_{O_{MJS}(\psi_{ar};Ra)}$ na Bacia Hidrográfica do Rio Tibagi (BHRT), em três cenários climáticos, para as quatro estações do ano.

----- Satélites orbita/ponto -----		----- Estações do Ano -----			
Aqua – MODIS	Landsat – TIRS	Verão	Outono	Inverno	Primavera
----- Cenário Normal (Ano: 2013) -----					
h13v11	221/77	2013-01-10 ⁽²⁾	2013-05-26 ⁽¹⁾	2013-07-29 ⁽¹⁾	2013-11-10 ⁽²⁾
	221/78	2013-01-10 ⁽²⁾	2013-05-26 ⁽¹⁾	2013-07-29 ⁽¹⁾	2013-11-10 ⁽²⁾
	222/76	2013-02-18 ⁽²⁾	2013-05-01 ⁽¹⁾	2013-08-21 ⁽¹⁾	2013-11-09 ⁽¹⁾
	222/77	2013-02-18 ⁽²⁾	2013-05-01 ⁽¹⁾	2013-08-21 ⁽¹⁾	2013-10-08 ⁽¹⁾
----- Cenário El Niño (Ano: 2015) -----					
h13v11	221/77	2015-01-24 ⁽¹⁾	2015-05-16 ⁽¹⁾	2015-08-04 ⁽¹⁾	2015-10-07 ⁽¹⁾
	221/78	2015-02-09 ⁽¹⁾	2015-05-16 ⁽¹⁾	2015-08-04 ⁽¹⁾	2015-10-07 ⁽¹⁾
	222/76	2015-01-15 ⁽¹⁾	2015-05-07 ⁽¹⁾	2015-08-11 ⁽¹⁾	2015-10-14 ⁽¹⁾
	222/77	2015-01-15 ⁽¹⁾	2015-05-07 ⁽¹⁾	2015-08-11 ⁽¹⁾	2015-10-30 ⁽¹⁾

----- Cenário La Niña (Ano: 2011) -----					
	221/77	2011-01-29 ⁽³⁾	2011-04-19 ⁽³⁾	2011-07-08 ⁽³⁾	2011-11-05 ⁽²⁾
h13v11	221/78	2011-01-29 ⁽³⁾	2011-04-03 ⁽³⁾	2011-07-16 ⁽²⁾	2011-10-28 ⁽³⁾
	222/76	2011-01-04 ⁽³⁾	2011-04-10 ⁽³⁾	2011-07-15 ⁽³⁾	2011-11-04 ⁽³⁾
	222/77	2011-01-04 ⁽³⁾	2011-04-10 ⁽³⁾	2011-07-15 ⁽³⁾	2011-11-04 ⁽³⁾

⁽¹⁾ Imagens obtidas com o satélite Landsat 8; ⁽²⁾ Imagens obtidas com o satélite Landsat 7; ⁽³⁾ Imagens obtidas com o satélite Landsat 5. (Fonte: Os autores)

Para seleção das imagens utilizadas na estimativa da *ETo* considerou-se os seguintes critérios e condições: *i)* A *ETo* espacializada foi estimada considerando as estações do verão (21 de dezembro a 19 de março), outono (20 de março a 20 de junho), inverno (21 de junho a 21 de setembro) e primavera (22 de setembro a 20 de dezembro). A *ETo* espacializada por estação do ano visou atenuar os efeitos dos usos do solo dos efeitos associados aos ENOS, para facilitar comparações; *ii)* Deu-se preferência às imagens coletadas no meio de cada estação do ano (verão, outono, inverno e primavera), com a finalidade de obter o clima típico da estação; *iii)* Priorizou-se condições de céu claro, com até 40% de cobertura de nuvens, nas imagens de satélite Landsat; *iv)* Para a constituição do mosaico das imagens de entrada, para a estimativa da $ETo_{MJS(\psi_{ar}; Ra)}$ espacializada, estabeleceu-se diferença máxima de 30 dias entre as imagens; *v)* Deu-se preferência para as imagens coletadas com os satélites Landsat 5 e 8 e, na ocorrência de intensa cobertura de nuvens, utilizou-se o Landsat 7. As imagens Landsat 7 foram evitadas devido à existência de linhas com ausência de valor de dados nos pixels.

As imagens Landsat 7 foram restauradas no processo de reamostragem com o Método do Vizinho mais Próximo (Boggione; Fonseca, 2004), para corrigir as linhas com dados ausentes, gerando imagens interpoladas com melhor qualidade. Utilizou-se o software QGIS (Meyer; Riechert, 2019) para a correção das imagens, seguindo os procedimentos: *i)* Com o algoritmo “Converter formato” atribuiu-se aos pixels “sem dado” o valor zero na imagem de entrada. O procedimento tem que ser realizado com a imagem composta por apenas uma banda, pois composições de bandas de imagem não são aceitas no algoritmo; *ii)* Posteriormente, no algoritmo “Preenche sem dados”, estimou-se o valor do pixel “sem dado” com a interpolação dos pixels vizinhos. A distância máxima de pesquisa dos pixels vizinhos foi definida em 10 pixels.

A estimativa dos valores temporais de $ETo_{MJS(\psi_{ar}; Ra)}$ entre imagens do satélite Landsat 8 foi feita por interpolação linear, utilizando como entrada imagens contendo menor percentual de nuvens possível do ano de Normalidade climática (2013), considerando a qualidade dos dados de entrada. Foram utilizadas apenas imagens para: orbita/ponto 222/76 (representando o clima Cfa); e, orbita/ponto 221/77 (representando o clima Cfb). A eficácia do algoritmo interpolador temporal “r.series.interp” foi testada em áreas de 10 km x 10 km na parte norte (Clima Cfa) e sul (Clima Cfb) da BHRT (Figura 1). A finalidade da interpolação foi gerar imagens

sintéticas, na periodicidade diária, para um ano de análise (2013), utilizando apenas doze imagens (uma em cada mês).

O algoritmo interpolador “r.series.interp” do provedor Grass7 é uma ferramenta de processamento do software QGIS (Meyer; Riechert, 2019). Para configuração do algoritmo, preencheu-se os campos de informações obrigatórios da seguinte forma: *i*) “Camada(s) raster de entrada”: São as imagens com os valores de $ETO_{MJS(\psi_{ar};Ra)}$ gerada para as datas disponíveis pelos satélites. O nome de cada arquivo foi identificado com a data de imageamento; *ii*) “Posição do ponto para cada mapa de entrada”: Foram fornecidas as datas de obtenção da imagem de satélite, no formato número inteiro (sem separador), em ordem cronológica da imagem mais antiga à mais recente, dispondo o ano-mês-dia; *iii*) “Nome para o mapa raster de saída”: Nome da imagem interpolada de saída, em que cada arquivo foi identificado pela data interpolada de interesse (o nome de cada imagem de saída tem de ser separado por vírgula); *iv*) “Posição do ponto de amostragem para cada mapa de saída”: É a data da imagem interpolada de interesse, no formato de número inteiro (sem separador), em ordem cronológica da imagem mais antiga à mais recente, conforme ano-mês-dia (cada data tem de ser separada por vírgula); *v*) “Método de interpolação linear”: Testou-se o único método suportado atualmente pelo algoritmo do programa “r.series.interp” (linear).

Com os resultados da interpolação foi possível gerar as ETo interpoladas com o modelo Moretti-Jerszurki-Silva ($ETO_{MJS(\psi_{ar};Ra)int}$), para os dias entre imagens Landsat disponíveis ou com cobertura de nuvens acima de 40%.

As imagens de satélite selecionadas para região (órbita/ponto 222/76 e 221/77) foram adquiridas ao longo de 2013, sendo escolhida uma imagem por mês (Tabela 2), com no máximo 30% a 40% de cobertura de nuvens, critério que pode ser indicado no momento da obtenção da imagem. Amostrou-se uma imagem por mês, para que o conjunto de dados de entrada aproximasse da realidade climática da região, bem como permitisse verificar a qualidade dos resultados entre os meses.

Tabela 2 – Sensores e data de obtenção das imagens dos satélites em 2013, utilizadas na análise da variabilidade temporal da $ETO_{MJS(\psi_{ar};Ra)int}$, na Bacia Hidrográfica do Rio Tibagi (BHRT).

Satélites órbita/ponto		Clima	Meses												
Aqua MODIS	Landsat TIRS		Jan.	Fev.	Mar.	Abr.	Maio	Jun.	Jul.	Ago.	Set.	Out.	Nov.	Dez.	
		Dias													
h13v11	221/77	Cfb	10 ⁽¹⁾	11 ⁽¹⁾	31 ⁽¹⁾	16 ⁽¹⁾	26 ⁽²⁾	11 ⁽²⁾	29 ⁽²⁾	30 ⁽²⁾	07 ⁽¹⁾	09 ⁽¹⁾	10 ⁽¹⁾	04 ⁽²⁾	
	222/76	Cfa	01 ⁽¹⁾	18 ⁽¹⁾	22 ⁽¹⁾	23 ⁽¹⁾	01 ⁽²⁾	18 ⁽²⁾	04 ⁽²⁾	21 ⁽²⁾	22 ⁽²⁾	08 ⁽²⁾	09 ⁽²⁾	11 ⁽²⁾	

⁽¹⁾ Imagens obtidas com o satélite Landsat 7; ⁽²⁾ Imagens obtidas com o satélite Landsat 8. (Fonte: Os autores).

A validação da ETo obtida com o método alternativo interpolado (MJS ; $ETO_{MJS(\psi_{ar};Ra)int}$) foi avaliada em associações com a ETo estimada com o método Penman-Monteith ASCE padrão (ET_{OPM} ; ASCE-EWRI, 2005).

Foram feitas estimativas da ET_{OPM} para todos os dias do ano em que houve dados diários disponíveis, para as estações LDA-IPR e PGA-SIM (Tabela 3). As estações foram escolhidas por apresentarem menos pontos divergentes entre as observações com o modelo de Penman-Monteith ASCE e *MJS* (Silva, 2021), e por estarem em condições climáticas distintas.

Tabela 3 – Identificação, localização e caracterização das estações meteorológicas da bacia hidrográfica do rio Tigabi, utilizadas nas análises.

Identificação	Estação	Instituto	Latitude	Longitude	Altitude (m)	Clima
LDA-IPR	Londrina	IAPAR	23°13'12,00" S	51°06'00,00" W	585	Cfa
PGA-SIM	Ponta Grossa	SIMEPAR	25°00'49,32" S	50°09'08,64" W	885	Cfb

(Fonte: Os autores)

O modelo Penman-Monteith ASCE (ASCE-EWRI, 2005) foi calculado utilizando dados diários medidos nas estações meteorológicas (ET_{OPM}), enquanto o modelo alternativo *MJS* (Equação 1) utilizou as variáveis meteorológicas espacializadas (Te_{SR} e UR_{eSR}) como entrada.

As análises estatísticas da validação consistiram na verificação das associações entre: “ ET_{OPM} estimada com dados das estações meteorológicas vs. $ET_{O_{MJS}(\psi_{ar};Ra)_{int}}$ interpolada com o algoritmo `r.series.interp`”. Foram utilizados o Índice de eficiência de Nash-Sutcliffe (*NSE*), Índice de concordância “*d*”, Raiz do erro quadrático médio (*RMSE*), Erro relativo percentual absoluto médio (*MAPE*) e Coeficiente de correlação de Pearson (*r*). O nível de significância do valor de *r* foi verificado com o teste *t* a 99% (**) de significância. Não atendendo o requisito testou-se a 95% (*), e não atendendo ambos critérios o valor de *r* foi considerado não-significativo (*ns*).

III. RESULTADOS E DISCUSSÃO

Variabilidade espacial da $ET_{O_{MJS}(\psi_{ar};Ra)}$ na BHRT

No mosaico de imagens das estações do ano (Figura 2) os limites das cenas que compõem a BHRT foram claramente identificados, principalmente nas imagens do outono de 2013 e 2015, e inverno de 2011. Entretanto, as imagens não foram homogêneas, pois para cobrir toda a bacia em estudo teve-se que utilizar imagens de diferentes dias para representar as *ET_O* da BHRT. As orbitas/pontos 222/76, 222/77 (parte norte da bacia), 221/77 e 221/78 (parte sul da bacia) não passam sobre o mesmo local, no mesmo dia. Por isso, o mosaico da mesma estação do ano foi constituído por datas diferentes (Tabela 1).

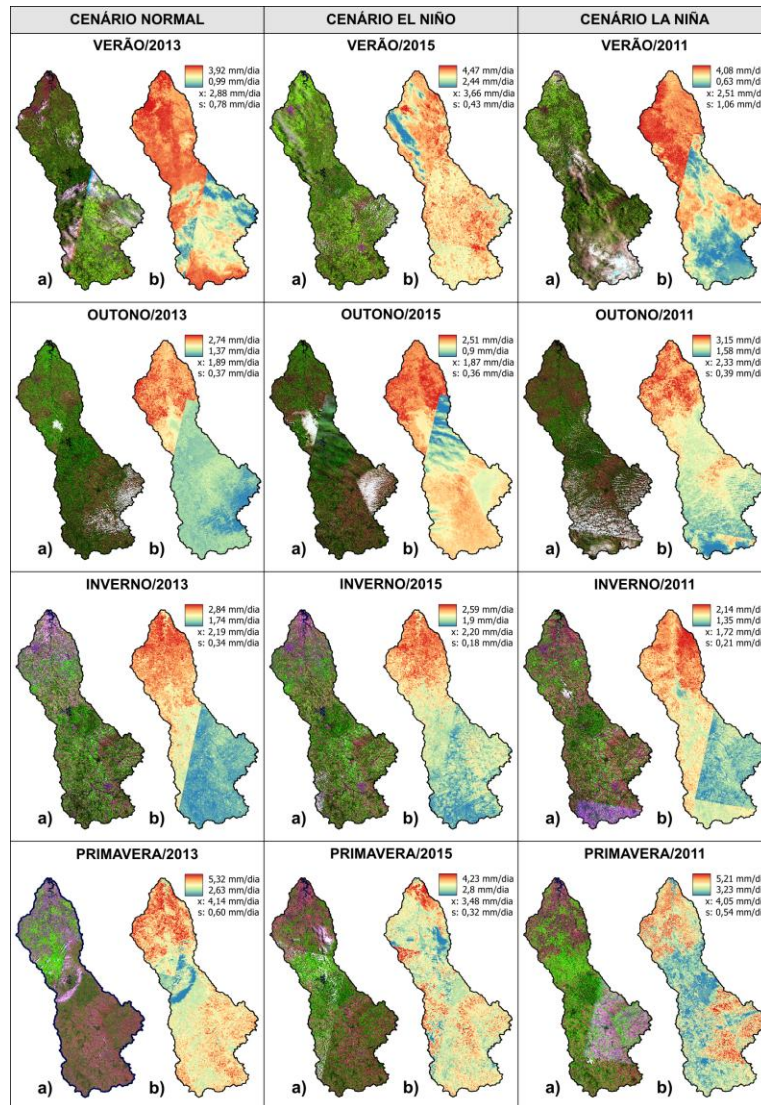


Figura 2 – Variabilidade espacial da $ET_{0MJS(\psi_{ar};R_a)}$ na Bacia Hidrográfica do Rio Tibagi (BHRT), nas estações do ano e cenários normal (ano 2013), El Niño (ano 2015) e La Niña (2011). Sendo: a) Composição colorida falsa cor, para visualização da cobertura de nuvens; e, b) Imagem com valores de $ET_{0MJS(\psi_{ar};R_a)}$ (mm dia⁻¹) estimada com dados de sensoriamento remoto ("x" é a média e "s" o desvio padrão dos valores de $ET_{0MJS(\psi_{ar};R_a)}$ na bacia). (Fonte: Os autores)

A diferença da $ET_{0MJS(\psi_{ar};R_a)}$ média para a BHRT (Figura 2), entre os cenários Normal e El Niño, foi de 0,78 mm dia⁻¹ no verão, 0,02 mm dia⁻¹ no outono, 0,01 mm dia⁻¹ no inverno e 0,66 mm dia⁻¹ na primavera. Entre os cenários Normal e La Niña, a diferença média da $ET_{0MJS(\psi_{ar};R_a)}$ foi de 0,37, 0,44, 0,47, 0,09 mm dia⁻¹ no verão, outono, inverno e primavera, respectivamente. Considerando-se as menores diferenças médias entre os valores de evapotranspiração estimados espacialmente, o cenário Normal no outono e inverno (estações mais frias; Figura 2) foi semelhante ao cenário El Niño. No verão e na primavera (estações mais quentes; Figura 2) o cenário Normal foi semelhante ao La Niña.

A ET_{0PM} média estimada com dados medidos em estações meteorológicas não apresentou diferença na mesma estação do ano para os cenários climáticos (La Niña, Normal e El Niño), mas houve diferença entre os

tipos climáticos Cfa e Cfb analisados (Figura 2). Entretanto, a $ET_{O_{MJS}(\psi_{ar};Ra)}$ espacializada média apresentou diferença na mesma estação do ano, entre os cenários climáticos (Figura 2). O modelo *MJS* apresenta grande sensibilidade em resposta à temperatura do ar e umidade relativa (Jerszurki et al., 2017), variáveis climáticas que controlam o potencial hídrico atmosférico e são utilizadas nos sistemas de classificação climática (Alvares et al., 2013). Nesse sentido, a *ET_O* estimada com o modelo *MJS* tende a apresentar maior variabilidade entre estações do ano e tipos climáticos do que o modelo Penman-Monteith.

A média da $ET_{O_{MJS}(\psi_{ar};Ra)}$ obtida com sensoriamento remoto para a bacia foi calculada considerando todos os valores de evapotranspiração, estimadas nos 27.704.045 pixels (aproximadamente) na BHRT (Figura 2). O intervalo de confiança da média da $ET_{O_{MJS}(\psi_{ar};Ra)}$ é muito estreito e próximo da média verdadeira, devido ao tamanho da amostra.

A diferença nos resultados entre a $ET_{O_{PM}}$ (estimada com dados medidos em estações meteorológicas) e $ET_{O_{MJS}(\psi_{ar};Ra)}$ (estimada com dados remotos) pode estar relacionado à série insuficiente de dados para a estimativa espacial da evapotranspiração com o modelo de Penman-Monteith. Na estimativa da evapotranspiração espacializada a variabilidade espacial e o tamanho da BHRT contribuíram para evidenciar diferenças entre as médias na mesma estação do ano, em diferentes cenários.

A $ET_{O_{PM}}$ estimada para os climas Cfa (estação meteorológica LDA-IPR) e Cfb (estação meteorológica PGA-SIM) não apresentou variação espacial (pois as estações não variaram espacialmente), mas houve variação temporal. Dessa forma, os eventos ENOS (que representaram variação temporal) não influenciaram a variação da $ET_{O_{PM}}$ (medida no local da estação meteorológica) na mesma estação do ano, bem como entre os anos (Figura 2). A utilização de apenas um ano de observação para cada cenário pode ter contribuído para a ausência de variação da $ET_{O_{PM}}$ entre os eventos ENOS, na mesma estação. Meza (2005), avaliando 23 anos de evapotranspiração no Chile Central, obteve diferenças da variável entre as estações do ano, sendo que no outono e inverno a *ET_O* nos períodos de La Niña e Normal foram semelhantes e superiores ao período El Niño. No entanto, na primavera e verão o período Normal foi superior à La Niña e El Niño, que apresentaram valores mais próximos.

Logo, para uma análise mais consistente seria necessário que se aumentasse a série de dados, a fim de constatar maior variação da evapotranspiração, devido aos eventos ENOS. O maior problema para uma análise deste tipo consiste em conseguir obter anos com eventos ENOS bem característicos, contendo imagens de satélite e série de dados meteorológicos sem falhas. Trabalhos de Nagel et al. (2020) (revisão sobre nanosatélites) e Beck et al. (2023) (dados climáticos de alta resolução baseadas em observação e em projeções)

permitem considerar que não será uma limitação realizar análises como as do presente estudo em um futuro próximo, mediante a maior disponibilidade de imagens gratuitas e série de dados de livre acesso mais representativos. Assim, será possível constatar maior variação espacial e temporal da evapotranspiração com maior facilidade.

As maiores diferenças na ET_{OPM} média foram observadas entre os climas Cfa e Cfb, no inverno (0,6 mm dia⁻¹) e primavera (0,6 mm dia⁻¹), bem como maior magnitude da evapotranspiração média dos climas no verão (4,2 mm dia⁻¹) e primavera (4,5 mm dia⁻¹), e menor no outono (2,7 mm dia⁻¹) e inverno (2,8 mm dia⁻¹) (Figura 2). A mesma tendência (diferença e magnitude) da evapotranspiração foi constatada para a $ET_{O_{MJS}(\psi_{ar};Ra)}$ espacializada na BHRT (Figura 2), sendo os maiores valores ao norte da bacia (Cfa) e os menores ao sul (Cfb).

Assim como apresentado na Figura 2, Matzenauer et al. (2008) observaram no Rio Grande do Sul maiores valores de ET_{OPM} (estimado com modelo Penman-Monteith) na primavera, durante os eventos de La Niña e anos Normais, bem como constataram maior ET_{OPM} no inverno somente nos anos Normais. A média da $ET_{O_{MJS}(\psi_{ar};Ra)}$ espacializada de cada cenário (Figura 2) na BHRT ficou em: 2,77 mm dia⁻¹ para o cenário Normal; 2,80 mm dia⁻¹ para El Niño; e 2,65 mm dia⁻¹ para La Niña. Os resultados do presente estudo concordam com Matzenauer et al. (2008).

O tipo de cobertura do solo tem relação direta com a ET_{OPM} , tendo em vista que parte da radiação incidente será refletida pela superfície (albedo). A $ET_{O_{MJS}(\psi_{ar};Ra)}$ não é influenciada diretamente pelo albedo, mas indiretamente sobre a ação da radiação, T e UR , conforme o tipo da superfície. Toda superfície que recebe certa quantidade de radiação tende a aumentar sua temperatura, e consecutivamente a sua emissão, conforme a Lei de Stephan-Boltzmann. O sensor orbital no satélite capta a energia do sol (Radiação Eletromagnética) refletida por uma superfície em determinado comprimento de onda (Meneses; Almeida, 2012). Portanto, objetos claros como solo exposto (tonalidade magenta na Figura 2a) refletem muita energia, e objetos escuros como a vegetação densa (tonalidade verde escuro na Figura 2a) refletem menos energia para o sensor.

Na espacialização da $ET_{O_{MJS}(\psi_{ar};Ra)}$ verificou-se que os maiores valores ocorreram em locais com solo exposto e os menores em área mais vegetadas, indicando que na BHRT a evapotranspiração foi maior quando a temperatura local foi mais alta, o que é consistente. Os resultados obtidos indicaram que a $ET_{O_{MJS}(\psi_{ar};Ra)}$ (estimada com dados remotos) variaram com o uso do solo, e a metodologia de espacialização da evapotranspiração mostrou-se promissora para estimar a demanda da água pela atmosfera, levando em consideração as condições locais, principalmente onde não há informações de estações meteorológicas próximas.

Durante o desenvolvimento metodológico uma das dificuldades foi ter que associar imagens diferentes (Landsat e Aqua) para a execução de alguns módulos de processamento. Para a geração da $Te_{SR(Wp;Ts)}$ e $UR_{eSR(Wp;Ts)}$ o nome dos arquivos das imagens dos satélites precisou ser organizado conforme a data de imageamento, para que os respectivos dados diários de temperatura e umidade relativa do ar fossem inseridos no módulo de processamento de forma mais rápida e ágil. O Landsat disponibiliza os seus arquivos nomeados com a data (ano-mês-dia), mas no Aqua/MODIS a nomeação é feita com o dia juliano.

Assim, para realizar as associações " Wp vs. Ts vs. UR_{mEM} " e " Wp vs. Ts vs. Tm_{EM} ", as variáveis Wp e Ts tiveram que ser organizadas e renomeadas pela sua data de obtenção. A organização dos arquivos permitiu que a geração da temperatura e umidade espacializadas fossem realizadas para várias imagens, com o auxílio do módulo de processamento do QGIS. Porém, o processo de renomeação dos arquivos teve que ser feito imagem a imagem, o que demandou tempo no preparo dos dados.

O script desenvolvido em linguagem Python para transformar o arquivo hdf (Aqua/MODIS) em geotiff (formato aceito no QGIS) permitiu transformar apenas uma a uma das imagens de interesse, e tornou o processo de geração da imagem final de Wp mais demorado. Os módulos de processamento desenvolvidos no QGIS ajudaram muito na velocidade do processamento das imagens. Entretanto, o algoritmo "Calculadora Raster", utilizado em quase todos os módulos, não conseguiu ser utilizado como dado de entrada durante o fluxo de trabalho. Com a ineficiência do algoritmo, a metodologia teve de ser dividida em vários módulos de processamentos até se chegar ao resultado final no cálculo da $ETO_{MJS(\psi_{ar};Ra)}$ espacializada, demandando mais tempo de processamento.

A automatização de várias imagens ao mesmo tempo, com apenas um script para gerar a Wp e modulo para gerar a $ETO_{MJS(\psi_{ar};Ra)}$, seria o ideal para acelerar o processamento. Um procedimento desta forma garantiria maior uso da metodologia estabelecida, o que poderia ser viabilizado programando rotinas em linguagem Python (linguagem em que são desenvolvidos os algoritmos dentro do QGIS).

A principal dificuldade no desenvolvimento e aplicação da metodologia foram as várias etapas a serem realizadas, entre a obtenção das imagens e processamento dos dados de sensoriamento remoto, levando meses para se chegar ao cálculo da $ETO_{MJS(\psi_{ar};Ra)}$ final, em toda a bacia. Além disso, os módulos de processamento passaram por várias etapas de teste até conseguir gerar o produto final esperado. Para difundir o uso da metodologia proposta no presente estudo, uma das alternativas seria a elaboração de um sistema online em conjunto com a plataforma Google Earth Engine, como o algoritmo SSEBop-Br (ANA, 2020), automatizando a obtenção de imagens. Um sistema desse tipo teria acesso às imagens de satélite e dados meteorológicos

diretamente das plataformas de origem, possibilitando a aplicação dos cálculos da metodologia proposta no presente trabalho, mediante os dados obtidos. Outra opção seria o desenvolvimento de um programa (complemento) executável dentro do QGIS, utilizando a linguagem Python.

A falta de correção dos efeitos direcionais e angulares do MODIS podem proporcionar diferenças nas imagens obtidas (Gao et al., 2017), principalmente em imagens acima de 30°. No presente estudo, não foram verificados problemas deste tipo, mas a falta de correção pode ser uma limitação para a aplicação da metodologia utilizada para áreas com maiores latitudes. Neste caso, existem adaptações do algoritmo original STARFM desenvolvido por Gao et al. (2006) (Wang et al., 2014), que ainda possibilitariam correções e a utilização da metodologia proposta e testado no presente estudo. O MODIS também disponibiliza produtos corrigidos por *Bidirectional Reflectance Distribution Function* (BRDF), como o MCD43A1 *Collection 5* (Che et al, 2017), que corrigem as imagens e eliminam os efeitos do amplo campo de varredura do sensor MODIS.

Os modelos remotos desenvolvidos baseando-se no balanço de energia de superfície – Modelo de Mapeamento da Evapotranspiração em Alta Resolução, com Modelo de Calibração Internalizada (Metric; Allen et al., 2007); e Modelo de Balanço de Energia de Superfície Simplificado Operacional (SSEBop; ANA, 2020) –, já possuem uma plataforma que disponibiliza imagens de evapotranspiração prontas, indicando a possibilidade de dinamizar a metodologia proposta no presente trabalho. Silva (2021) verificou a eficiência da estimativa da $ET_{O_{MJS}(\psi_{ar};Ra)}$ com a mesma metodologia proposta. As plataformas para modelos como o METRIC foram desenvolvidas justamente pela dificuldade de se ter à disposição dados meteorológicos de qualidade, calibração específica e pessoal técnico especializado para a aplicação das diversas equações do modelo (Allen et al., 2011).

A vantagem da $ET_{O_{MJS}(\psi_{ar};Ra)}$ especializada consiste em estimá-la para locais contendo poucas informações meteorológicas, como no Norte do Brasil (região amazônica) e outras regiões, em que a quantidade de estações é menor quando comparada ao sul do Brasil. Mesmo na BHRT, tendo diferenças de evapotranspiração em função do uso e da cobertura do solo, houve coerência entre a relação do saldo de radiação (R_n) e $ET_{O_{MJS}(\psi_{ar};Ra)}$. Portanto, utilizar valores estimados espacialmente para determinado local pode ser mais interessante do que usar o valor da ET_{OPM} de uma estação que se encontra a muitos quilômetros de distância da área em estudo. Ou, quando for o caso, possibilitar a determinação da ET_O de grandes áreas, como uma bacia hidrográfica.

A evapotranspiração especializada pode ter uma série de aplicações. Paula et al. (2019) obtiveram estimativas promissoras da evapotranspiração real com o modelo SSEBop, na bacia do rio Preto, Distrito Federal, realizando o manejo de irrigação com pivô central. No presente estudo, avaliou-se apenas a evapotranspiração

de referência espacializada, mas a metodologia também poderá ser usada no ajuste da lâmina de irrigação baseando-se na $ET_{O_{MJS}(\psi_{ar};Ra)}$.

Variabilidade temporal da $ET_{O_{MJS}(\psi_{ar};Ra)}$

As melhores imagens de cada mês (menor cobertura de nuvem possível) do ano de 2013, para os climas Cfa e Cfb, foram obtidas nas datas que constam nas Figura 3, respectivamente. Conforme os critérios estabelecidos para a escolha das imagens que serviram de entrada para a interpolação temporal, doze imagens do clima Cfa (Figura 3.I) foram utilizadas para a estimativa da evapotranspiração de referência diária. No clima Cfb (Figura 3.II) foram excluídas da análise as imagens do mês de fevereiro (11/02/2013) e junho (11/06/2013), devido à cobertura de nuvem de toda a área de estudo no período. Considerou-se que os dados precisavam ser excluídos, pois seriam fonte de erro e imprecisão no resultado final das estimativas. Nos dois climas analisados, observou-se que a $ET_{O_{MJS}(\psi_{ar};Ra)}$ (Figura 3) nos meses do verão e primavera foram maiores do que no outono e inverno na BHRT, o mesmo padrão observado na análise espacial (Figura 2).

Gao et al. (2006) desenvolveram um algoritmo unindo qualidades do satélite Landsat (resolução espacial de 30 metros) e do sensor MODIS (resolução temporal diária) abordo do satélite Aqua/Terra. No algoritmo, que consiste em um modelo de fusão de reflectância adaptativa espacial e temporal (STARFM) aplicado as imagens Landsat e MODIS, é necessário realizar a calibração e correção atmosférica para reflectância de superfície das imagens. O motivo deveu-se às diferenças de processamento dos dados, tempo de aquisição, largura da banda, erros de geolocalização e resolução espacial.

Os autores destacaram os seguintes fatores que dificultaram a fusão das imagens: *i)* A observação não homogênea do MODIS, pois pode incluir tipos mistos de cobertura do solo, considerando a resolução espacial do Landsat; *ii)* A cobertura do solo e erro de geolocalização do pixel pode mudar durante o período de previsão; e, *iii)* A variação fenológica da vegetação e geometria solar alteram a reflectância da imagem, da data de entrada para a data de saída. No entanto, embora o algoritmo melhore a resolução espacial ao combinar dados do Landsat e MODIS, a fusão pode comprometer a resolução espectral, aumentando potenciais erros relacionados às diferenças nas características espectrais dos sensores e ao processamento dos dados, principalmente em áreas heterogêneas (Wang et al., 2014).

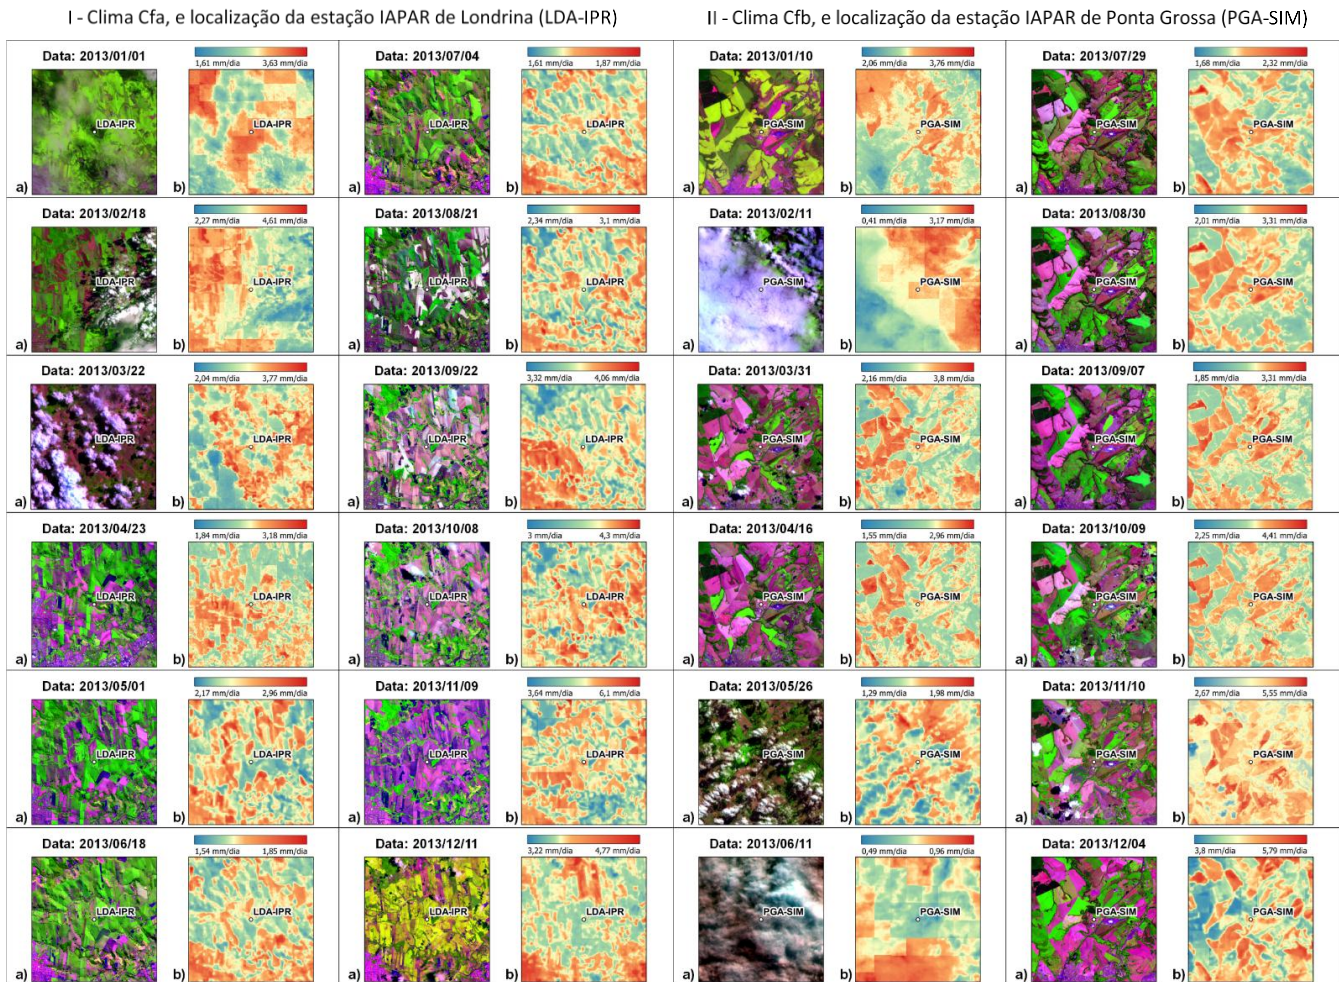


Figura 3 – Melhores imagens do satélite Landsat 7 e 8 no ano de 2013 (cenário Normal), para compor o banco de dados de entrada para a interpolação temporal: I) No clima Cfa, e localização da estação IAPAR de Londrina (LDA-IPR); e, II) clima Cfb, e localização da estação IAPAR de Ponta Grossa (PGA-SIM). Sendo: “a” a Composição colorida falsa cor, para visualização da cobertura de nuvens; e, “b” Imagem com valores de $ETOMS(\psi_{air};Ra)$ ($mm\ dia^{-1}$) estimada com dados de sensoriamento remoto. (Fonte: Os autores).

Os problemas relatados por Gao et al. (2006) e a complexidade de execução do algoritmo STARFM, foram os motivos que levaram à proposição e utilização de um interpolador temporal simplificado no presente trabalho. O algoritmo “r.series.interp” do QGIS tem a vantagem de ser uma ferramenta disponível no SIG, e que pode ser utilizada apenas no satélite de melhor resolução espacial (Landsat) para interpolar o período desejado pelo usuário, sem a necessidade de diversas transformações para chegar ao produto final. Além disso, no levantamento bibliográfico realizado, não foram constatados trabalhos científicos que testassem a eficiência do “r.series.interp”. No entanto, o algoritmo do QGIS disponibiliza apenas o método de interpolação linear, o que limitou a utilização e estimativa da $ETOMS(\psi_{air};Ra)_{int}$ diária, que não conseguiu acompanhar convenientemente a variação da $ETOPM$ (Figura 4).

A metodologia desenvolvida para estimar $ETOMS(\psi_{air};Ra)_{int}$, com dados de sensoriamento remoto e interpolado temporalmente, possibilitou apenas a obtenção de valores médios, comparados à $ETOPM$ (Figura

4.I). Estatisticamente, a consequência disso é que as associações entre “ $ET_{O_{MJS}(\psi_{ar};Ra)_{int}}$ vs. $ET_{O_{PM}}$ ” apresentaram valores razoáveis para os indicadores $RMSE$, $MAPE$ e r , e ruins com NSE e d (Figura 4.II). A falta de sensibilidade nas estimativas da $ET_{O_{MJS}(\psi_{ar};Ra)_{int}}$, conforme os “alinhamentos verticais” que se encontram na Figura 4.II, indicam que a $ET_{O_{MJS}(\psi_{ar};Ra)_{int}}$ não acompanhou a variação precisa da $ET_{O_{PM}}$, o que penalizou os indicadores NSE e d que medem a proximidade dos pontos da associação em relação à linha de 45° (reta 1:1).

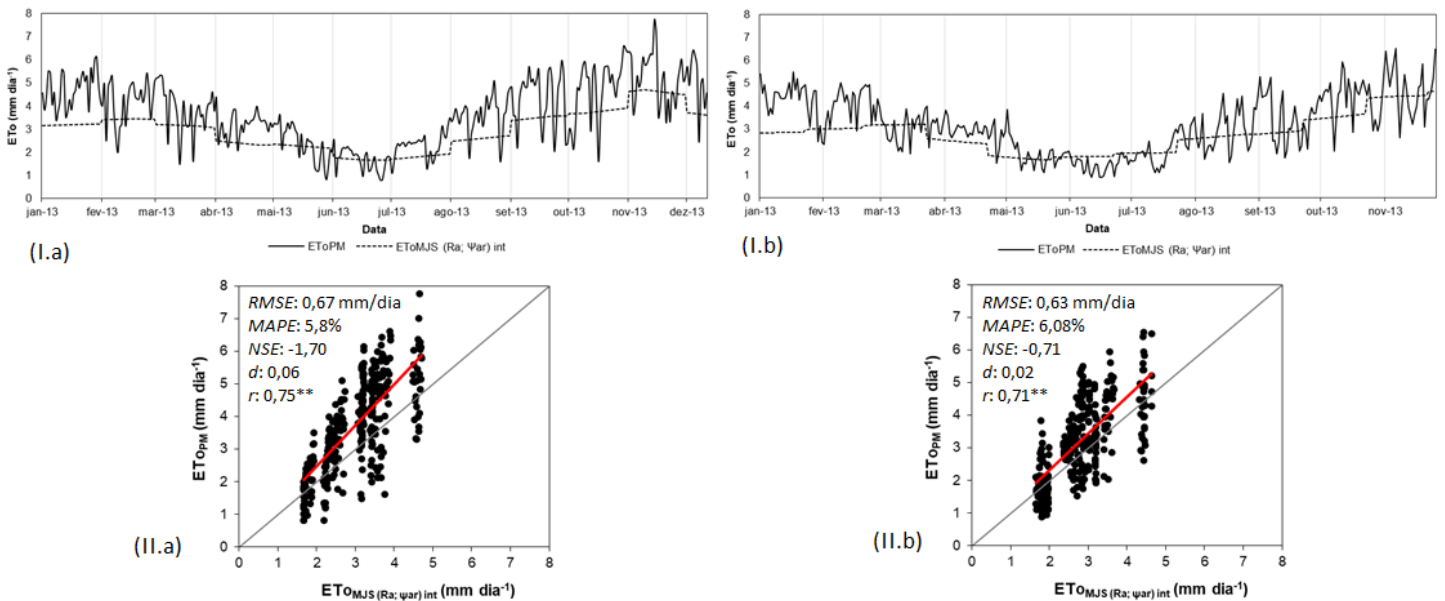


Figura 4 – Evapotranspiração de referência calculadas com os modelos Penman-Monteith ASCE ($ET_{O_{PM}}$; utilizando dados medidos em estações) e Moretti-Jerszurki-Silva ($ET_{O_{MJS}(\psi_{ar};Ra)_{int}}$; utilizando dados obtidos por sensoriamento remoto e interpolado temporalmente): I) Série temporal; e, II) Análise de regressão linear e indicadores estatísticos obtidos entre os respectivos valores “ $ET_{O_{MJS}(\psi_{ar};Ra)_{int}}$ vs. $ET_{O_{PM}}$ ”. Sendo: “a” Estação LDA-IPR, clima Cfa; e “b” Estação PGA-SIM, clima Cfb. (Fonte: Os autores).

No entanto, mesmo com metodologia e modelos perfeitamente adequados para estimar a ET , a obtenção de melhores indicadores NSE e d seria possível somente com a determinação do período mais adequado (antes e após uma cena de alta resolução), para fusionar dados do MODIS. No presente trabalho, as imagens sintéticas na periodicidade diária para 2013 utilizaram apenas doze imagens (uma em cada mês).

A literatura é bem diversa quanto à escala temporal mais adequada das imagens. Walker et al. (2012), com o algoritmo STARFM, avaliando a fusão de dados Landsat-MODIS para fenologia de florestas utilizaram dados de reflectância MODIS diária, oito e dezesseis dias. Os autores verificaram bom desempenho para a composição de oito dias, mas destacaram que seu uso pode ser inadequado para mudanças fenológicas em escalas de tempo mais curtas. Gao et al. (2017) avaliando o desenvolvimento de culturas no campo por meio da fusão de imagens com o algoritmo STARFM, consideraram que é difícil obter dois pares claros de imagens Landsat-MODIS com condições de superfície razoavelmente semelhantes à data-alvo de previsão. Para a opção de um único par, as opções automáticas no sistema incluem: i) Escolher o par de imagens com a data mais

próxima da data de previsão; ou, *ii*) Usar o par de imagens que apresenta a maior correlação espacial com a imagem MODIS na data de previsão.

Uma das vantagens do software QGIS consiste na possibilidade de criar rotinas em linguagem de programação Python (Rogers; Staub, 2013). Assim, com o conhecimento adequado em programação é possível reproduzir o algoritmo com outros métodos de interpolação mais robustos que o linear. A utilização do Python é muito útil para automatização de rotinas, principalmente as voltadas para utilização/geração de dados especializados.

Validação das estimativas da $ET_{O_{MJS}(\psi_{ar}; Ra)_{int}}$

O monitoramento contínuo de alta resolução espacial e temporal da evapotranspiração é essencial para melhorar a gestão de recursos hídricos, principalmente o manejo de irrigação. No entanto, os satélites disponíveis atualmente não possuem mecanismos para integrar altas resoluções espaciais e temporais em um único sensor (Wang et al., 2019). Devido às limitações, muitas fusões espaciais e temporais têm sido desenvolvidas, visando extrair as melhores informações de cada sensor.

Na literatura, inúmeros estudos demonstraram como a alta resolução espacial e a frequência de aquisição de imagens obtidos com nanosatélites e CubeSats melhoraram o manejo e a sustentabilidade agrícola (Nagel et al., 2020). No entanto, trabalhos comparando dados de alta resolução de satélites (como PlanetScope) com os de resoluções mais amplas (Landsat-8 e Sentinel-2) ainda são frequentes (Shimizo et al., 2020; Amankulova et al., 2023; Ibrahim; Balzter, 2024). Apesar da menor resolução dos satélites de constelações maiores, a integração de dados pode melhorar a precisão das estimativas ao corrigir vieses em variáveis como temperatura de superfície e fracionamento da vegetação. Nagel et al. (2020) consideraram que os custos das imagens dos nanosatélites e CubeSats (PlanetScope e Doves) limitam seu uso, especialmente em pesquisas de longa duração. Os autores acrescentaram que devido à melhor qualidade dos sensores, os dados de código aberto fornecidos por satélites de agências nacionais ainda continuarão populares.

Os satélites Landsat e MODIS são as plataformas mais utilizadas para a fusão de dados. Os principais motivos são: O Landsat possui resolução espacial moderadamente alta e o MODIS resolução temporal diária (Yang et al., 2016; Januar et al., 2020); e, As imagens são gratuitas e o acervo disponibilizado é grande o suficiente para estudos temporais. A facilidade de acesso às imagens Landsat e MODIS possibilita que os órgãos públicos melhorem, com custo baixo, o gerenciamento dos recursos hídricos em grandes áreas, como bacias hidrográficas.

A utilização dos dados MODIS para estimativa da ET_o diária vem sendo estudada a alguns anos. Paredes et al. (2021) estimando a ET_o diária com dados remotos do satélite geostacionário Meteosat de segunda geração (disponível para países europeus), conseguiram resultados excelentes ($r > 0,98$ e $RMSE = 0,13 \text{ mm dia}^{-1}$). A limitação dos dados de evapotranspiração espacializados com o sensor MODIS e satélite Meteosat está na resolução espacial, em torno de 1 km e 4 km, respectivamente. A baixa resolução espacial limita a utilização da evapotranspiração em escala local. Melhores resoluções podem fornecer informações detalhadas sobre o uso da água em culturas e estado da umidade do solo, permitindo a otimização da eficiência de irrigação em pequenas propriedades (Ke et al., 2017).

Muitos estudos estão sendo desenvolvidos tentando a união de dados MODIS e Landsat (Cammalleri et al., 2014; Li et al., 2017; Yi et al., 2018), com a finalidade de estimar diariamente imagens de ET_o com 30 m de resolução. Entretanto, em sua maioria, os trabalhos desenvolvidos possuem certa dificuldade para reprodução da metodologia. Diante da complexidade encontrada nas metodologias existentes, o presente trabalho propôs testar a qualidade do algoritmo de interpolação temporal do software QGIS, que utilizou apenas as imagens Landsat para realizar a estimativa temporal.

A variação temporal da ET_{OPM} para os tipos climáticos Cfa e Cfb foi maior que a estimativa da $ET_{O_{MJS}(\psi_{ar};Ra)_{int}}$ (Figura 4.1 “a” e “b”), utilizando o interpolador temporal testado no presente estudo. A evapotranspiração estimada com o método Penman-Monteith (ET_{OPM}) tem a vantagem de combinar de forma não linear as principais variáveis (temperatura, umidade relativa, radiação e velocidade do vento) que atuam no processo, além de ter como base a entrada de variáveis medidas todos os dias. Por outro lado, considera-se que a estimativa temporal da $ET_{O_{MJS}(\psi_{ar};Ra)_{int}}$ com apenas 12 e 10 imagens para os climas Cfa e Cfb, respectivamente, é uma amostra relativamente pequena para alimentar o interpolador temporal para gerar valores diários de evapotranspiração ao longo do ano.

Cabe ressaltar, que a função interpoladora do algoritmo “r.series.interp” é linear (a única disponível), o que explica a existência de linearidade entre um mês e outro (Figura 4.1 “a” e “b”). Logo, mesmo antes de realizar as análises já se esperava que o algoritmo não fosse capaz de representar a variabilidade da ET_{OPM} , devido à simplicidade da interpolação. Contudo, estas ferramentas têm rápido desenvolvimento, e se o algoritmo disponibilizar interpoladores mais robustos (polinomial), os desempenhos nas estimativas poderão ser sensivelmente melhorados, visto que a tendência temporal da ET_{OPM} possui forma senoidal.

Mesmo utilizando um interpolador linear, a tendência da evapotranspiração interpolada ($ET_{O_{MJS}(\psi_{ar};Ra)_{int}}$) foi semelhante a ET_{OPM} (Figura 4.1 “a” e “b”), o que indicou resultado extremamente interessante para ser

utilizado em atividades voltadas ao planejamento de grandes áreas, contendo poucos dados meteorológicos disponíveis. Além disso, com a tendência do avanço tecnológico, em um futuro próximo será possível a obtenção de imagens de satélites com alta resolução temporal e espacial, em apenas uma plataforma, apresentando detalhes com menor tempo de revisita para o mesmo ponto de referência. Um menor período entre imagens de satélite permitiria melhorar as estimativas da $ETO_{MJS(\psi_{ar};Ra)_{int}}$, acompanhando melhor a tendência e variabilidade da ETO_{PM} . Bem como, maior detalhamento possibilitaria estudos em escala local e de bacia, com maior precisão em análise espacial da $ETO_{MJS(\psi_{ar};Ra)_{int}}$.

Li et al. (2017), utilizando o algoritmo STARFM, fez a fusão dos dados do sensor MODIS (resolução temporal diária) e do Satélite ASTER (resolução espacial 90 metros) para obter dados remotos diários. As informações serviram de entrada para realizar a estimativa ETo espacializada (com modelo Surface Energy Balance System – SEBS), que comparada à ETo medida em equipamentos locais obtiveram estimativas temporais com $RMSE = 0,88 \text{ mm dia}^{-1}$. Yi et al. (2018) com a mesma metodologia, obtiveram $RMSE = 0,80 \text{ mm dia}^{-1}$ e $MAPE = 13,40\%$. Cammalleri et al. (2014) utilizando o mesmo algoritmo com dados MODIS e Landsat obtiveram $RMSE = 1,32 \text{ mm dia}^{-1}$ e $MAPE = 24,95\%$.

Comparando com a literatura, os resultados encontrados no presente trabalho (Figura 4.II “a” e “b”) com os indicadores r , $RMSE$ e $MAPE$ apresentaram melhor desempenho. Entretanto, NSE e d indicaram pior desempenho na estimativa temporal. Desta forma, considera-se que a $ETO_{MJS(\psi_{ar};Ra)_{int}}$ pode ser estimada apenas com precisão aceitável. Os valores $ETO_{MJS(\psi_{ar};Ra)_{int}}$ acompanharam em média a tendência ETO_{PM} , mas a distância ou amplitude de valores pontuais pode se apresentar bem discrepante (Figura 4).

IV. CONCLUSÕES

A evapotranspiração espacializada permitiu identificar diferenças na mesma estação do ano nos cenários climáticos analisados.

A metodologia desenvolvida para estimar a $ETO_{MJS(\psi_{ar};Ra)}$ espacializada em grandes áreas tem precisão estatística aceitável, mas o processo para constituir o mosaico final para área de grande cobertura, como na BHRT, ainda se mostrou laborioso. A estimativa temporal da evapotranspiração tem precisão estatística satisfatória ($RMSE = 0,65 \text{ mm dia}^{-1}$; $r = 0,73$; $MAPE = 5,94\%$; $NSE = -1,2$; $d = 0,04$). O número de imagens viáveis e o algoritmo interpolador linear limitou o acompanhamento das variações da ETO_{PM} diária ao longo do tempo.

V. REFERÊNCIAS

- ALLEN, R. G.; TASUMI, M.; TREZZA, R. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration METRIC – Model. *Journal of Irrigation and Drainage Engineering, Asce*, v. 133, n. 4, p. 380-394, 2007.
- ALLEN, R.; IRMAK, A.; TREZZA, R.; HENDRICKX, J. M. H.; BASTIAANSEN, W.; KJAERGAARD, J. Satellite-based ET estimation in agriculture using SEBAL and METRIC. *Hydrological Processes*, v. 25, n. 26, p. 4011-4027, 2011. Wiley. <http://dx.doi.org/10.1002/hyp.8408>.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, v. 22, n. 6, p. 711-728, 2013. Schweizerbart. <http://dx.doi.org/10.1127/0941-2948/2013/0507>.
- AMANKULOVA, K.; FARMONOV, N.; AKRAMOVA, P.; TURSUNOV, I.; MUCSI, L. Comparison of PlanetScope, Sentinel-2, and landsat 8 data in soybean yield estimation within-field variability with random forest regression. *Heliyon*, v. 9, e17432, 2023. <https://doi.org/10.1016/j.heliyon.2023.e17432>.
- ANA (Agência Nacional de Águas). Estimativas de evapotranspiração real por sensoriamento remoto no Brasil. 4. ed. Brasília: Ana, 2020. 23 p.
- ASCE-EWRI (New York). American Society of Civil Engineers. The ASCE Standardized Reference Evapotranspiration Equation. New York: American Society of Civil Engineers, 2005. 70 p. Task Committee Report.
- BECK, H. E.; McVICAR, T. R.; VERGOPLAN, N.; BERG, A.; LUTSKO, N. J.; DUFOUR, A.; ZENG, Z.; JIANG, X.; VAN DIJK, A. I. J. M.; MIRALLES, D. G. High-resolution (1 km) Köppen-Geiger maps for 1901–2099 based on constrained CMIP6 projections. *Scientific Data*, v. 10, n. 724, 2023. <https://doi.org/10.1038/s41597-023-02549-6>
- BOGGIONE, G. A.; FONSECA, L. M. G. Restoration of Landsat-7 Images. National Institute For Space Research, São José dos Campos, 2004. Disponível em: <<http://mtc-m12.sid.inpe.br/rep/sid.inpe.br/jeferson/2004/01.13.13.12>>.
- CAMMALLERI, C.; ANDERSON, M. C.; GAO, F.; HAIN, C. R.; KUSTAS, W. P. A data fusion approach for mapping daily evapotranspiration at field scale. *Water Resources Research*, v. 49, n. 8, p. 4672-4686, 2013. American Geophysical Union (AGU). <http://dx.doi.org/10.1002/wrcr.20349>.
- CAMMALLERI, C.; ANDERSON, M. C.; GAO, F.; HAIN, C. R.; KUSTAS, W. P. Mapping daily evapotranspiration at field scales over rainfed and irrigated agricultural areas using remote sensing data fusion. *Agricultural and Forest Meteorology*, v. 186, p. 1-11, 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.agrformet.2013.11.001>.
- CAVALCANTI, I. F. A.; CARRIL, A. F.; PENALBA, O. C.; GRIMM, A. M.; MENÉNDEZ, C. G.; SANCHEZ, E.; CHERCHI, A.; SÖRENSON, A.; ROBLEDO, F.; RIVERA, J. Precipitation extremes over La Plata Basin – Review and new results from observations and climate simulations. *Journal of Hydrology*, v. 523, p. 211-230, 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.jhydrol.2015.01.028>.
- CHE, X.; FENG, M.; SEXTON, J. O.; CHANNAN, S.; YANG, Y.; SUN, Q. Assessment of MODIS BRDF/Albedo Model Parameters (MCD43A1 Collection 6) for Directional Reflectance Retrieval. *Remote Sensing*, v. 9, n. 1123, 2017. <https://doi.org/10.3390/rs9111123>
-

GAO, F.; ANDERSON, M.; ZHANG, X.; YANG, Z.; ALFIERI, J. G.; KUSTAS, W. P.; MUELLER, R.; JOHNSON, D. M.; PRUEGER, J. H. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery. *Remote Sensing of Environment*, v. 188, p. 9–25, 2017. <http://dx.doi.org/10.1016/j.rse.2016.11.004>.

GAO, F.; MASEK, J.; SCHWALLER, M.; HALL, F. On the blending of the Landsat and MODIS surface reflectance: predicting daily landsat surface reflectance. *Transactions on Geoscience and Remote Sensing*, [S.L.], v. 44, n. 8, p. 2207-2218, 2006. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tgrs.2006.872081>.

GGWS (Golden Gate Weather Services). El Niño and La Niña Years and Intensities. 2021. Disponível em: <https://ggweather.com/enso/oni.htm>. Acesso em: 22 maio 2021.

IBRAHIM, S.; BALZTER, H. Evaluating flood damage to paddy rice fields using PlanetScope and Sentinel-1 data in north-western Nigeria: Towards potential climate adaptation strategies. *Remote Sensing*, v. 16, n. 3657, 2024. <https://doi.org/10.3390/rs16193657>

JANUAR, T. W.; LIN, T.; HUANG, C.; CHANG, K. Modifying an Image Fusion Approach for High Spatiotemporal LST Retrieval in Surface Dryness and Evapotranspiration Estimations. *Remote Sensing*, v. 12, n. 3, p. 498, 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12030498>.

JERSZURKI, D.; SOUZA, J. L. M.; SILVA, L. C. R. Expanding the geography of evapotranspiration: an improved method to quantify land-to-air water fluxes in tropical and subtropical regions. *PLOS ONE*, v. 12, n. 6, p. 1-20, 2017. Public Library of Science (PLOS). <http://dx.doi.org/10.1371/journal.pone.0180055>.

KE, Y.; IM, J.; PARK, S.; GONG, H. Spatiotemporal downscaling approaches for monitoring 8-day 30 m actual evapotranspiration. *Isprs Journal of Photogrammetry and Remote Sensing*, v. 126, p. 79-93, 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.isprsjprs.2017.02.006>.

LI, Y.; HUANG, C.; HOU, J.; GU, J.; ZHU, G.; LI, X. Mapping daily evapotranspiration based on spatiotemporal fusion of ASTER and MODIS images over irrigated agricultural areas in the Heihe River Basin, Northwest China. *Agricultural and Forest Meteorology*, v. 244-245, p. 82-97, 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.agrformet.2017.05.023>.

MATZENAUER, R.; BERLATO, M. A.; SAMPAIO, M. R.; TRINDADE, J. K. Efeitos do fenômeno Enos sobre a evapotranspiração de referência na região do Planalto Médio do Rio Grande do Sul, Brasil. *Pesq. Agrop. Gaúcha*, v. 14, n. 1, p. 67-70, 2008.

MENESES, P. R.; ALMEIDA, T. Introdução ao processamento de imagens de sensoriamento remoto. Bahia: Cnpq, 2012. 276 p.

MEYER, D.; RIECHERT, M. Open source QGIS toolkit for the Advanced Research WRF modelling system. *Environmental Modelling & Software*, v. 112, p. 166-178, 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.envsoft.2018.10.018>.

MEZA, F. J. Variability of reference evapotranspiration and water demands. Association to ENSO in the Maipo river basin, Chile. *Global and Planetary Change*, v. 47, n. 2-4, p. 212-220, 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.gloplacha.2004.10.013>.

NAGEL, G. W.; NOVO, E. M. L. M.; KAMPEL, M. Nanosatellites applied to optical Earth observation: a review. *Ambiente e Água*, v. 15, n. 3, e2513, 2020. <https://doi.org/10.4136/ambi-agua.2513>

PAREDES, P.; TRIGO, I.; BRUIN, H.; SIMÕES, N.; PEREIRA, L. S. Daily grass reference evapotranspiration with Meteosat Second Generation shortwave radiation and reference ET products. *Agricultural Water Management*, v. 248, p. 106543, 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.agwat.2020.106543>.

PAULA, A. C. P.; SILVA, C. L.; RODRIGUES, L. N.; SCHERER-WARREN, M. Performance of the SSEBop model in the estimation of the actual evapotranspiration of soybean and bean crops. *Pesquisa Agropecuária Brasileira*, v. 54, p. 1-11, 2019. FapUNIFESP (SCIELO). <http://dx.doi.org/10.1590/s1678-3921.pab2019.v54.00739>.

ROGERS, S. R.; STAUB, B. Standard use of Geographic Information System (GIS) techniques in honey bee research. *Journal of Apicultural Research*, v. 52, n. 4, p. 1-48, 2013. Informa UK Limited. <http://dx.doi.org/10.3896/ibra.1.52.4.08>.

ROSA, S. L. K.; SOUZA, J. L. M.; SANTOS, A. A. Data from NASA Power and surface weather stations under different climates on reference evapotranspiration estimation. *Pesquisa Agropecuária Brasileira*, v. 58; e03261, 2023. <https://doi.org/10.1590/s1678-3921.pab2023.v58.03261>.

SHIMIZO, K.; OTA, T.; MIZOUE, N.; SAITO, H. Comparison of multi-temporal PlanetScope data with Landsat 8 and Sentinel-2 data for estimating airborne LiDAR derived canopy height in temperate forests. *Remote Sensing*, v. 12, n. 1876, 2020. <https://doi.org/10.3390/rs12111876>.

SILVA, D. P. Associação espaço-temporal de variáveis meteorológicas com técnicas de sensoriamento remoto para estimativa da evapotranspiração. Curitiba, 2021. 173p. Dissertação (Mestrado em Agronomia, área de concentração Ciência do Solo) – Setor de Ciências Agrárias, Universidade Federal do Paraná. Disponível em: <https://acervodigital.ufpr.br/handle/1884/74849> Acesso em: 02 agosto 2024.

TALSMA, C. J.; GOOD, S. P.; JIMENEZ, C.; MARTENS, B.; FISHER, J. B.; MIRALLES, D. G.; MCCABE, M. F.; PURDY, A. J. Partitioning of evapotranspiration in remote sensing-based models. *Agricultural and Forest Meteorology*, v. 260-261, p. 131-143, 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.agrformet.2018.05.010>.

WALKER, J. J.; BEURS, K. M.; WYNNE, R. H.; GAO, F. Evaluation of Landsat and MODIS data fusion products for analysis of dryland forest phenology. *Remote Sensing of Environment*, v. 117, p. 381-393, 2012.

WANG, P.; GAO, F.; MASEK, J. G. Operational data fusion framework for building frequent Landsat-like imagery. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, n. 11, 2014. <http://dx.doi.org/10.1109/TGRS.2014.2311445>.

WANG, T.; TANG, R.; LI, Z.; JIANG, Y.; LIU, M.; NIU, L. An Improved Spatio-Temporal Adaptive Data Fusion Algorithm for Evapotranspiration Mapping. *Remote Sensing*, v. 11, n. 7, p. 761, 2019. MDPI AG. <http://dx.doi.org/10.3390/rs11070761>.

YANG, G.; WENG, Q.; PU, R.; GAO, F.; SUN, C.; LI, H.; ZHAO, C. Evaluation of ASTER-Like Daily Land Surface Temperature by Fusing ASTER and MODIS Data during the HiWATER-MUSOEXE. *Remote Sensing*, v. 8, n. 1, p. 75, 2016. MDPI AG. <http://dx.doi.org/10.3390/rs8010075>.

YI, Z.; ZHAO, H.; JIANG, Y. Continuous Daily Evapotranspiration Estimation at the Field-Scale over Heterogeneous Agricultural Areas by Fusing ASTER and MODIS Data. *Remote Sensing*, v. 10, n. 11, p. 1694, 2018. MDPI AG. <http://dx.doi.org/10.3390/rs10111694>.

ZHU, X.; CHEN, J.; GAO, F.; CHEN, X.; MASEK, J. G. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. *Remote Sensing of Environment*, v. 114, n. 11, p. 2610-2623, 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2010.05.032>.