

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS E SANEAMENTO
AMBIENTAL

FERNANDO BASQUIROTO DE SOUZA

Downscaling de imagens MODIS e LANDSAT para estimativas de evapotranspiração em
alta resolução espacial e temporal

PORTO ALEGRE

2022

FERNANDO BASQUIROTO DE SOUZA

Downscaling de imagens MODIS e LANDSAT para estimativas de evapotranspiração em alta resolução espacial e temporal

Dissertação apresentada ao Programa de Pós-graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul, como requisito parcial à obtenção do grau de mestre.

Orientador: Dr. Anderson Ruhoff

PORTO ALEGRE

2022

CIP - Catalogação na Publicação

Souza, Fernando Basquiroto de
Downscaling de imagens MODIS e LANDSAT para
estimativas de evapotranspiração em alta resolução
espacial e temporal / Fernando Basquiroto de Souza. --
2022.

101 f.

Orientador: Anderson Ruhoff.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Instituto de Pesquisas Hidráulicas,
Programa de Pós-Graduação em Recursos Hídricos e
Saneamento Ambiental, Porto Alegre, BR-RS, 2022.

1. Sensoriamento Remoto. 2. Temperatura de
Superfície. 3. Evapotranspiração. I. Ruhoff, Anderson,
orient. II. Título.

FERNANDO BASQUIROTO DE SOUZA

DOWNSCALING DE IMAGENS MODIS E LANDSAT PARA ESTIMATIVAS DE
EVAPOTRANSPIRAÇÃO EM ALTA RESOLUÇÃO ESPACIAL E TEMPORAL

Dissertação apresentada ao Programa de Pós-graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul, como requisito parcial à obtenção do grau de mestre.

Aprovado em: Porto Alegre, 23 de agosto de 2022.

Prof. Dr. Anderson Ruhoff – IPH / UFRGS
Orientador

Prof. Dr. Marcelo Sacardi Biudes – UFMT
Examinador

Prof. Dr. Ivo Zution Gonçalves – ESALQ/USP
Examinador

Prof. Dr. Walter Collischonn – PPGRHSA/UFRGS
Examinador

Dedicado à Tia Graça (*in memoriam*).

AGRADECIMENTOS

Agradeço minha família. Minha esposa Émilin pelo apoio e suporte durante a elaboração deste trabalho. Ao meus pais, Luiz Rogério e Zeide, que sempre estão presentes e apoiando seus filhos.

Agradeço o prof. Anderson Ruhoff pela orientação e conhecimento compartilhado, bem como pelo desafio proposto na execução desta pesquisa.

Aos colegas Leonardo Laipelt e Rafael Kayser pela ajuda na pesquisa e na programação do Google Earth Engine e aos colegas do grupo de pesquisa.

Aos professores Walter, Marcelo e Ivo pelas contribuições realizadas tanto na qualificação quanto na defesa.

Aos professores do IPH e funcionários, que durante a pandemia, tiveram que se ajustar para dar continuidade às pesquisas, aulas e procedimentos.

Muito obrigado a todos.

“Não entre em pânico”. (Douglas Adams)

RESUMO

A temperatura de superfície é uma variável fundamental para balanços energéticos entre superfície e atmosfera, sendo muito utilizada na hidrologia para a estimativa de evapotranspiração. A natureza pontual de suas medições e o baixo número de estações meteorológicas que a medem faz com que o uso de sensoriamento remoto para obtê-la torne-se mais frequente e abrangente. Mesmo abrangendo grandes áreas, as imagens de sensoriamento remoto termal podem apresentar resoluções espaciais moderadas, quando a disponibilidade de dados é diária (e.g. sensor MODIS) e resoluções espaciais mais detalhadas, mas com resolução temporal de até 16 dias (e.g. Landsat). Essa relação inversa entre resolução espacial e temporal fez com que fossem desenvolvidas técnicas para aproveitar o melhor de cada resolução. Uma dessas técnicas é denominada *downscaling*. Dessa forma, buscou-se a obtenção de imagens de alta resolução espacial e temporal por meio de *downscaling* para estimativas de evapotranspiração, usando o modelo geeSEBAL. Como área de estudo, utilizou-se dados medidos em estações micrometeorológicas instaladas no sul do Brasil. Os resultados do *downscaling* da temperatura, ao compará-los com as imagens termais do Landsat, demonstraram que 84% dos valores MAE e 65% de RMSE ficaram abaixo de 2 K. Grande parte dos valores de R (77%) foram superiores à 0,70. Os valores de viés ficaram em sua grande maioria (84%) entre -2 e 2 K. De modo geral, comparando os resultados de *downscaling* obtidos com as medições de campo, os valores de MAE variaram entre 1,18 e 3,96 K; RMSE entre 1,55 e 4,32 K; com viés variando de -1,07 a 3,96 K. Os valores de R ficaram, em média, bem próximos de 0,90. Ao comparar os resultados de evapotranspiração com aqueles obtidos com imagens Landsat, verificou-se que 61% do MAE e 39% do RMSE apresentaram valores inferiores à 1,5 mm/d. Os valores de R tiveram valores maiores que 0,70 em 84% dos casos. Os vieses tiveram 74% dos resultados entre -1,5 à 1,5 mm/d. Os resultados da comparação da evapotranspiração com as medições de campo demonstraram maior amplitude de erro conforme estação, com valores medianos de MAE de 1,90 mm/d; RMSE de 2,25 mm/d; viés de 0,10 mm/d; e com R de até 0,69. Mesmo com a variabilidade dos resultados, observou-se a viabilidade do *downscaling* da temperatura de superfície e evapotranspiração usando computação em nuvem para o desenvolvimento de séries temporais de alta resolução temporal e espacial usando o modelo geeSEBAL.

Palavras-chave: Sensoriamento Remoto. Fusão de Imagens. Temperatura de Superfície. SEBAL.

ABSTRACT

Land surface temperature (LST) is a key parameter for energy balances between surface and atmosphere. However, its punctual measures and the lack of meteorological sites has provided opportunities to the use of remote sensing to retrieve this variable. In hydrology, evapotranspiration (ET) models has as input land surface temperature. Remote sensing is able to provide data for large areas, however, the retrieved data may have coarse spatial resolution with daily temporal resolution (e.g. MODIS sensor), and finer spatial resolution, but with temporal resolution of 16 days (e.g. Landsat). This trade-off between spatial and temporal resolutions stimulated researchers to develop methods and algorithms that create high spatial and temporal resolution images. One of these methods is called downscaling. Thus, this research aimed to create high temporal and spatial resolution LST and ET images in the south region of Brazil. In the downscaling of LST, the results were validated with thermal images of Landsat images. Most of the values of MAE (84%) and RMSE (65%) were below 2 K. Similar results were verified with the correlation coefficient, wherein 77% of the values were higher than 0.70. Bias values were mostly (84%) between -2 and 2 K. The results of the downscaling were validated with in situ measurements. The accuracy levels can be slightly different between sites and LST retrieval methods. The average values of MAE were between 1,18 e 3,96 K; RMSE values were between 1,55 and 4,32 K; and bias were between -1,07 and 3,96 K. Correlation Coefficients were nearly 0,90. While comparing to evapotranspiration obtained with Landsat images, accuracy results were the following: Values of MAE and RMSE were lower than 1.5 mm/d in 61% and 39% of the times. R values were higher than 0.70 most of the times (i.e. 84%). Bias values ranged from -1.5 to 1.5 mm/d in 74% of the results. The comparison with in situ measurements showed higher errors range depending on the selected site. MAE median value was 1.90 mm/d; median RMSE was 2.25 mm/d; median bias was 0.10 mm/d and R has 0.69 as its maximum value. Despite the variable results obtained, the use of cloud computing to retrieve higher spatial-temporal resolution time series of LST and ET is feasible.

Keywords: Remote Sensing. Image Fusion. Land Surface Temperature. SEBAL.

LISTA DE ILUSTRAÇÕES

Figura 1 - Classificação das faixas do espectro eletromagnético conforme comprimento de onda (λ) e frequência (ν) da radiação eletromagnética.	20
Figura 2 – Variação da exitância espectral em função do comprimento de onda e temperatura (Barra azul representa a faixa do espectro visível; hachura laranja representa a exitância total para a temperatura de 300 K; e linha tracejada verde são os picos de exitância máxima).	22
Figura 3 - Caminhos na atmosfera da radiação solar (esquerda) e térmica (direita). ..	25
Figura 4 - Principais componentes e sua contribuição na evapotranspiração.....	44
Figura 5 - Balanço energético de superfície homogênea. R_n é a radiação líquida; LE é o calor latente; H é o calor sensível; St e P são as energias armazenadas em processos físicos e bioquímicos, respectivamente; e A_{in} e A_{out} são as energias que entram no sistema.	44
Figura 6 - Fluxograma dos procedimentos adotados neste estudo para o desenvolvimento do downscaling de T_s e da estimativa de ET.....	48
Figura 7 - Localização dos sítios de medições de T_s e ET.....	50
Figura 8 – Composição das bandas RGB (Colorida) e SWIR-NIR-G das imagens Landsat no entorno dos sítios SMA (Santa Maria), PAS (Pedras Altas), e PRS (Paraíso do Sul).....	52
Figura 9 – Estações micrometeorológicas nos sítios de Pedras Altas (PAS) (Esquerda) e Paraíso do Sul (PRS) (Direita).	54
Figura 10 – Exemplo de cobertura de nuvens nas imagens Landsat (Topo) e MODIS (Inferior) adquiridas na data 01/01/2019 para o sítio SMA (Santa Maria), em vermelho.	57
Figura 11 - Representação gráfica do procedimento de <i>downscaling</i> de T_s	61
Figura 12 - Fluxograma do geeSEBAL para obtenção de ET por sensoriamento remoto.	62
Figura 13 – Procedimento para seleção de datas com imagens Landsat para a análise de acurácia do <i>downscaling</i> . Data em verde representa data presente em dois pares de data.	63
Figura 14 - Comparação dos dados de campo com os do sensor MODIS (Terra) durante o dia para os três sítios analisados (SMA - Santa Maria; PAS - Pedras Altas; e PRS - Paraíso do Sul) nos intervalos de datas com disponibilidade de dados.....	65

Figura 15 – Histograma da variação das anomalias nas séries temporais de T_s para as medições de campo (SMA - Santa Maria; PAS - Pedras Altas; e PRS - Paraíso do Sul) e respectivo pixel nas imagens MODIS.	67
Figura 16 - Dispersão das anomalias encontradas nos dados MODIS de T_s comparadas com as medições de campo (SMA - Santa Maria; PAS - Pedras Altas; e PRS - Paraíso do Sul).	68
Figura 17 - Comparação das T_s medidas <i>in situ</i> com aquelas obtidas por sensoriamento remoto por meio de diferentes métodos usando as imagens Landsat.	70
Figura 18 – Distribuição dos valores de T_s dos pixels das imagens Landsat e MODIS para três diferentes datas e métodos de obtenção da T_s ao longo da cena Landsat.	73
Figura 19 - Comparação da imagem obtida pelo <i>downscaling</i> de T_s com a respectiva imagem Landsat oriunda de diferentes métodos de obtenção de T_s	76
Figura 20 – Resumo das métricas de acurácia dos resultados do <i>downscaling</i> da T_s , comparando-se com imagens Landsat (SMA1 e SMA2: Santa Maria em diferentes orbitas-ponto; PAS: Pedras Altas; PRS: Paraíso do Sul).	77
Figura 21 – Comparação das imagens de T_s obtidas no sítio PRS (Orbita-ponto 222/081; Data 05/03/2004). A: Landsat de referência; B: MODIS; C: <i>downscaling</i> ; e D: Diferença entre <i>downscaling</i> e imagem Landsat de referência.	78
Figura 22 - Comparação das imagens de T_s no sítio SMA1 (Orbita-ponto 223/080; Data 22/01/2015). A: Landsat de referência; B: MODIS; C: <i>downscaling</i> ; e D: Diferença entre <i>downscaling</i> e Landsat de referência.	79
Figura 23 - Detalhamento das imagens termais (Landsat e <i>Downscaling</i>) com diferentes usos do solo (Sítio SMA1, data 22/01/2015). Coluna A: Google Earth; B: Landsat; C: <i>Downscaling</i> ; D: Diferença (Downscaling menos Landsat).	80
Figura 24 - Comparação das medições <i>in situ</i> de T_s e aquelas obtidas por <i>downscaling</i> com diferentes métodos de obtenção da T_s	83
Figura 25 - Comparação dos resultados de <i>downscaling</i> da ET com a ET obtida da imagem Landsat de referência.	86
Figura 26 - Resumo das métricas de acurácia dos resultados do <i>downscaling</i> da ET, comparando-se com a ET obtida das imagens Landsat de referência.	87
Figura 27 – Comparação de imagens no sítio PRS (Orbita-ponto 222/081, Data 5/3/2004). A: Imagem aérea do Google Earth; B: Imagem de ET oriunda do Landsat	

de referência; C: <i>Downscaling</i> de ET; D: Diferença entre ET de referência e ET <i>downscaling</i>	89
Figura 28 - Comparação de imagens no sítio SMA1 (Orbita-ponto 223/080, Data 22/1/2015). A: Imagem aérea do Google Earth; B: Imagem de ET oriunda do Landsat de referência; C: <i>Downscaling</i> de ET; D: Diferença entre ET de referência e ET <i>downscaling</i>	90
Figura 29 - Detalhamento das imagens de ET (Landsat e <i>Downscaling</i>) com diferentes usos do solo (Sítio SMA1, data 22/01/2015). Coluna A: Google Earth; B: Landsat; C: <i>Downscaling</i> ; D: Diferença (<i>Downscaling</i> menos Landsat).	91
Figura 30 - Comparação dos dados pontuais de ET obtidos por <i>downscaling</i> com cobertura de nuvens inferior à 50% e intervalo de dias entre datas de referência de 60 dias.....	93
Figura 31 - Comparação dos dados pontuais de ET obtidos por <i>downscaling</i> com cobertura de nuvens inferior à 10% e intervalo de dias entre datas de referência de 120 dias.....	95

LISTA DE TABELAS

Tabela 1 - Descrição das características dos sítios analisados.	49
Tabela 2 – Percentual médio do uso do solo no entorno (raio de 500 m) das estações de amostragem SMA (Santa Maria), PAS (Pedras Altas), e PRS (Paraiso do Sul) no seu período de disponibilidade de dados.	51
Tabela 3 – Estimativa das médias anuais das variáveis climatológicas nas estações de amostragem SMA (Santa Maria), PAS (Pedras Altas), e PRS (Paraiso do Sul). .	53
Tabela 4 – Equipamentos utilizados nas medições de campo nos sítios SMA (Santa Maria), PAS (Pedras Altas), e PRS (Paraiso do Sul).	55
Tabela 5 - Descrição dos dados disponíveis no GEE e utilizados no <i>downscaling</i> da T_s	56
Tabela 6 - Datas utilizadas na validação dos dados de campo com dados Landsat 5 e 8.	58
Tabela 7 - Datas utilizadas na comparação entre as imagens Landsat e as imagens MODIS.	58
Tabela 8 - Resultados da acurácia entre os dados de T_s <i>in situ</i> e T_s no respectivo pixel MODIS.	66
Tabela 9 - Resultados da acurácia entre as T_s <i>in situ</i> e T_s das imagens Landsat.	71
Tabela 10 – Valores médios de acurácia entre a T_s das imagens Landsat e MODIS para todos os sítios amostrados.	73
Tabela 11 - Comparação dos pixels de T_s obtidos por <i>downscaling</i> com as medições <i>in situ</i>	83
Tabela 12 - Comparação dos dados de <i>downscaling</i> de ET com as medições <i>in situ</i> utilizando cobertura de nuvens máximo de 50% e intervalo entre as datas de 60 dias.	93
Tabela 13 - Comparação dos dados de <i>downscaling</i> de ET com as medições <i>in situ</i> utilizando cobertura de nuvens máximo de 10% e intervalo entre as datas de 120 dias.	95

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Apresentação do problema de pesquisa.....	14
1.2	Objetivos de pesquisa.....	18
2	REVISÃO BIBLIOGRÁFICA	19
2.1	Sensoriamento Remoto e Espectro Eletromagnético	19
2.2	Conceitos de Radiometria.....	20
2.3	Interação da Radiação com a Atmosfera.....	23
2.4	Sensoriamento Remoto da Temperatura.....	25
2.4.1	Métodos de obtenção de T_s com Emissividade	28
2.4.1.1	Método da Banda Única (<i>single-channel method</i>).....	28
2.4.1.2	Método das Bandas Múltiplas (<i>multiple-channel method</i>)	30
2.4.1.3	Métodos de ângulos múltiplos (<i>multiple angles methods</i>)	31
2.4.2	Métodos de obtenção de T_s sem Emissividade	31
2.4.2.1	Obtenção por Etapas (<i>stepwise retrieval method</i>).....	31
2.4.2.2	Obtenção Simultânea com características da atmosfera.....	32
2.4.2.3	Obtenção Simultânea sem informações atmosféricas.....	33
2.4.3	Validação da T_s	33
2.5	Sensoriamento remoto na Hidrologia.....	34
2.6	Fusão de Imagens (<i>Downscaling</i>).....	36
2.6.1	STARFM.....	37
2.6.2	ESTARFM.....	38
2.6.3	SEVERI_1km	39
2.6.4	SADFAT.....	40
2.6.5	STAIR	40
2.6.6	ST-Cokriging.....	41
2.6.7	TsHARP	42
2.6.8	ALEXI/DisALEXI	42
2.7	Evapotranspiração	43
3	MATERIAIS E MÉTODOS.....	48
3.1	Descrição dos sítios amostrados	48
3.1.1	Medições em campo para das estimativas de T_s e ET	53
3.2	Métodos de Obtenção de T_s	55

3.3	Comparação com dados existentes.....	57
3.4	<i>Downscaling</i> da Temperatura	58
3.5	Séries temporais de ET.....	62
3.6	Análise de Acurácia	63
4	RESULTADOS E DISCUSSÃO	65
4.1	Diferenças entre estimativas de temperatura baseadas em imagens MODIS e Dados de Campo	65
4.2	Diferenças entre estimativas de temperatura baseadas em imagens Landsat e Dados de Campo	70
4.3	Diferenças entre estimativas de temperatura baseadas em imagens Landsat e MODIS	72
4.4	<i>Downscaling</i> da Temperatura	75
4.4.1	<i>Downscaling</i> para datas com imagem Landsat.....	75
4.4.2	Estimativa de Séries Temporais de T_s com <i>Downscaling</i>	82
4.5	<i>Downscaling</i> da ET	85
4.5.1	<i>Downscaling</i> de ET para datas com imagem Landsat.....	85
4.5.2	Estimativa de Séries Temporais de ET com <i>Downscaling</i>	92
5	CONSIDERAÇÕES FINAIS	99
6	REFERÊNCIAS	100

1 INTRODUÇÃO

1.1 Apresentação do problema de pesquisa

A temperatura da superfície terrestre (T_s) é uma variável fundamental para balanços energéticos e hídricos em processos de interação entre superfície e atmosfera (ANDERSON et al., 2011; LI et al., 2013). Esta variável é utilizada em estudos sobre urbanização e ilhas de calor (FASHAE et al., 2020; VENTER et al., 2020; CHEN et al., 2021a), estimativas de evapotranspiração (ET) (ALLEN et al., 2007; ANDERSON et al., 2011; ALLAM et al., 2021) e de umidade do solo (LEI et al., 2020), mudanças climáticas (JIN et al., 2005), monitoramento de secas (KARNIELI et al., 2010) e culturas agrícolas (LI et al., 2017), estresse térmico (LAFORTEZZA et al., 2009) e propagação de vetores (RUIZ et al., 2010; LIU E WENG, 2012). Em função da sua relevância, é considerada como variável climática essencial e de alta prioridade pelo Sistema de Observação do Clima Global (*Global Climate Observing System*) (GUILLEVIC et al., 2018) e Programa Internacional da Geosfera e Biosfera (*International Geosphere and Biosphere Program - IGBP*) (LI et al., 2013).

A aquisição de forma pontual da T_s não representa de forma adequada esta variável no espaço em função de sua pequena área de abrangência (WENG, 2009), assim como exige tempo e esforços para instalação e manutenção dos equipamentos (LONG et al., 2020; PATTERSON et al., 2022). Além disso, o monitoramento usando uma rede densa de estações micrometeorológicas requer amplo aporte de recursos financeiros e equipe técnica capacitada. Isso também é um problema para outros parâmetros na hidrologia, como a ET, onde a sua interpolação em redes pouco densas prejudica a sua acurácia (CHEN E KUSTAS, 2019) em função da heterogeneidade natural da superfície e complexidade dos processos hidrológicos (LONG et al., 2011). Assim, técnicas de sensoriamento remoto são utilizadas para a obtenção de T_s de forma a abranger áreas mais extensas (BINDHU et al., 2013; LIOU E KAR, 2014).

O sensoriamento remoto tem se demonstrado bastante útil na aquisição de dados termais por meio das bandas do infravermelho termal, apresentando observações consistentes e acuradas em diferentes escalas (GILLESPIE, 2014; CHEN et al., 2021a). Diferentes sensores podem ser utilizados para adquirir informações termais, e.g. GOES, MODIS (Terra), TIRS (Landsat 8) e NOAA-AVHRR (KUENZER E DECH, 2013).

As imagens obtidas pelos sensores apresentam características e propriedades distintas. Exemplo disso é a resolução espacial e temporal do LANDSAT e MODIS, onde o primeiro tem 30 a 120 m e 16 dias de resolução espacial e temporal, respectivamente, e o segundo tem 250 a 1.000 m de resolução espacial e resolução temporal diária (WENG et al, 2014; LUO et al., 2018; XIE et al., 2018). Tais diferenças podem trazer limitações, como na aplicação em pequenas áreas ou monitoramento contínuo, do uso das imagens termais em estudos de balanço energético terrestre (ANDERSON et al., 2021) e na agricultura de precisão (KHANAL et al, 2017). As diferenças são originadas tanto por razões econômicas, quanto técnicas. Ainda há a limitação teórica da resolução espacial na obtenção de imagens em função da altitude, velocidade e capacidade de processamento dos satélites (LIU, 2006), podendo ainda haver outros fatores envolvidos, tal como a quantidade de energia que o sensor recebe (SCHOTT, 2007). A resolução espacial pode ser obtida pela multiplicação entre o campo de visada instantâneo (IFOV) e a altitude (JENSEN, 2014, pg. 16). Esses aspectos acabam criando relações inversas entre alguns parâmetros dos satélites, como por exemplo, a relação entre a resolução espacial e temporal, onde imagens com alta resolução espacial apresentam baixa resolução temporal, e vice-versa (WENG et al., 2014; LUO et al., 2020).

Para contornar tais limitações dos sistemas sensores, técnicas de fusão de imagens, como *downscaling*, vem sendo desenvolvidas para aproveitar o melhor de cada uma das resoluções (BAI et al., 2020; CHEN et al., 2021b). O *downscaling* é comumente utilizado para melhoramento da resolução espacial da T_s (BARTKOWIAK et al., 2019). Muitas das técnicas iniciais de fusão de imagens basearam-se na relação estatística entre NDVI (*Normalized Difference Vegetation Index*) e T_s , sendo ainda adotadas com diferentes abordagens, como a adoção de outras variáveis (e.g. fração da cobertura vegetal e modelo digital do terreno) e uso de inteligência artificial (BINDHU et al., 2013; BARTKOWIAK et al., 2019). Cabe comentar que métodos baseados no uso de inteligência artificial (e.g. aprendizado de máquina) sofrem de problemas de sobreajuste (*overfitting*), as estruturas de covariância não são representadas explicitamente e não há estimativa da incerteza dos resultados obtidos (YANG et al, 2021).

Outros métodos e algoritmos de *downscaling* espacial e temporal também já foram propostos por diferentes autores, destacando os algoritmos STARFM (GAO et al., 2006) e sua versão melhorada ESTARFM (ZHU et al., 2010), SADFAT (WENG et

al., 2014), STAIR (LUO et al., 2018; LUO et al., 2020) e ELRFM (BAI et al., 2020). Há também outros procedimentos de *downscaling*, tal como o apresentado por Amazirh et al. (2019), que propuseram o uso de dados de radar (Sentinel 1) para obter melhores resultados de *downscaling* espacial de T_s , abrangendo também indicadores de umidade do solo no processo. Já Bartkowiak et al. (2019) fazem uso de propriedades como elevação do terreno e NDVI como propriedades auxiliares para o *downscaling*. Lee e Singh (2018) apresentam diferentes métodos estatísticos de *downscaling* para análise de cenários futuros de mudanças climáticas com modelos climáticos globais e regionais. Por fim, os algoritmos desenvolvidos podem ser classificados em métodos baseados em aprendizado de máquina, métodos de modelo linear de mistura espectral e métodos baseados no STARFM ou suas derivações (BAI et al., 2020). Comparações entre os métodos são pouco observadas na literatura, sendo comumente encontrado comparações com STARFM.

Dos algoritmos desenvolvidos, observa-se que os mais utilizados estão focados na reflectância de superfície (e.g. STARFM e ESTARFM), embora também possam ser aplicados para T_s (LONG et al., 2020). Além disso, os métodos desenvolvidos podem apresentar limitações como a disponibilidade de imagens devido a presença de nuvens ou erros na obtenção da imagem (e.g. Landsat 7), valores de pixels não registrados nas imagens de referência, heterogeneidade da área/pixel, processamento limitado devido ao poder computacional disponibilizado e alta complexidade (ZHU et al., 2010; LUO et al., 2018; BAI et al., 2020). Cabe comentar que métodos mais complexos, como aprendizagem profunda (do inglês *deep learning*), também são sensíveis ao processo de treinamento e de ajuste, sendo que a performance pode variar conforme heterogeneidade espacial e dinâmica temporal (CHEN et al, 2021b).

As técnicas de *downscaling* são desenvolvidas em função das necessidades que diferentes campos apresentam. O seu uso na agricultura para estimativa da produção, monitoramento contínuo e rápido de secas, temperatura do solo e ET são alguns exemplos (ZHU et al., 2021). A T_s é um dado fundamental para tais campos, especialmente para a estimativa de ET, visto que a T_s é utilizada no cálculo da radiação líquida, calor sensível conduzido ao solo e calor sensível conduzido para atmosfera, bem como na obtenção do saldo de energia das interações entre atmosfera e superfície (ALLEN et al., 2007; BINDHU et al., 2013; LIOU E KAR, 2014).

O detalhamento, tanto espacial quanto temporal, da ET por meio do *downscaling* da T_s visa melhorar o acompanhamento desta variável, visto que a perda por ET no ciclo hidrológico terrestre é significativa e sua negligência pode trazer problemas nas estimativas e previsões realizadas nas modelagens (FISHER et al., 2017). A obtenção da ET pode ser feita por meio do sensoriamento remoto, apresentando boa relação custo-benefício, ampla cobertura, repetibilidade e acurácia considerável (CABALLERO et al., 2022). Ela pode ser estimada com o uso de modelos como *Surface Energy Balance Algorithm for Land* - SEBAL (BASTIAANSEN et al., 1998) e *Mapping EvapoTranspiration at High Resolution using Internalized Calibration* - METRIC (ALLEN et al., 2007). Nestes modelos, a ET é considerada como residual do balanço energético da superfície (LIOU E KAR, 2014). Salieta-se ainda que a validação desses modelos ocorre em diferentes países e condições climáticas, como Brasil (LAIPILT et al., 2021); Chile (MOLETTA-LOBOS et al., 2020); EUA (ANDERSON et al., 2021); Alemanha, Itália, China, Bélgica e Líbano (ALLAM et al., 2021).

Tais modelos envolvem uma grande quantidade de dados, o que pode tornar análises de series temporais inviáveis em escalas regionais, tanto pelo poder computacional de processamento quanto pela disponibilidade de acesso desses dados (ALLAM et al., 2021; CHEN et al., 2021c). Por exemplo, Yang et al (2021) comentam que seu método, quando comparado com algoritmos como STARFM e FSDAF, requer maior esforço computacional. Uma forma de contornar tal problema é a utilização de plataformas de computação em nuvem, tal como o Google Earth Engine (GEE), que com seu amplo acervo de dados permite a realização de diversos cálculos e análises em poucos segundos (GORELICK et al., 2017).

Nesse contexto, buscou-se validar a hipótese de que estimativas de ET em alta resolução espacial e temporal fusionando imagens MODIS e Landsat são viáveis usando ambiente de computação em nuvem.

1.2 Objetivos de pesquisa

O objetivo principal deste trabalho foi desenvolver séries temporais de T_s e de ET de alta resolução temporal e espacial utilizando metodologia de *downscaling* baseada em computação na nuvem.

Como objetivos específicos, buscou-se:

- Realizar comparação entre as medições de temperatura de superfície *in situ* com os valores obtidos a partir de estimativas usando imagens LANDSAT (métodos JM&S, GS e ERM) e MODIS (produto MODIS/006/MOD11A1);
- Aplicar método de *downscaling* para obtenção de imagens de T_s com alta resolução temporal e espacial;
- Avaliar acurácia das séries temporais de T_s obtidas por *downscaling* com os dados *in situ*;
- Analisar a acurácia das estimativas de ET por sensoriamento remoto utilizando dados de T_s por *downscaling*.


2 REVISÃO BIBLIOGRÁFICA

2.1 Sensoriamento Remoto e Espectro Eletromagnético

A obtenção de informações e dados sobre objetos por meio de instrumentos, sendo que estes instrumentos não se encontram em contato físico com o objeto em análise, é chamada de sensoriamento remoto. Embora essa definição seja bastante abrangente, usualmente ela é direcionada para a observação da Terra, onde sensores captam informações por meio da quantidade de energia que estes recebem (NJOKU, 2014). Essa definição é comumente encontrada de forma similar em outras literaturas, tais como Liu (2006), Schowengerdt (2006), Schott (2007) e Jensen (2014). A definição de sensoriamento remoto pode ainda ser combinada com a de fotogrametria, conforme relata Jensen (2014), sendo essa definição adotada pela Sociedade Americana de Fotogrametria e Sensoriamento Remoto, a qual comenta que ambos são a arte, ciência e tecnologia para aquisição de informações de objetos físicos e do ambiente por meio de imagens e representações digitais de padrões de energia oriundos de sistemas sensores remotos. O mesmo autor também discute a extensão do termo sensoriamento remoto, citando definições simples ou mais específicas, que abrangem as faixas do espectro eletromagnético e as plataformas de aquisição de dados.

Espectro eletromagnético é a denominação dada ao intervalo que abrange todos os tipos de radiação eletromagnética, sendo que a faixa visível e infravermelho próximo são comumente usadas na observação terrestre (SCHOTT, 2007). A radiação eletromagnética é a forma pelo qual a informação (seja ela frequência, intensidade ou polarização da onda) propaga-se do objeto até o sensor, na velocidade da luz (LIU, 2006). A energia registrada pelos sensores, restringindo-se ao sensoriamento remoto passivo (i.e. 0,4 – 15 μm), pode ser oriunda de duas fontes: Sol e Temperatura de outros objetos. A energia oriunda da primeira fonte pode apresentar diferentes caminhos ao interagir com a atmosfera terrestre até chegar no sensor. Já no segundo caso, qualquer objeto com temperatura superior ao zero absoluto (i.e. 0 K) emite energia, logo, tais objetos terrestres emitem radiação com comprimento médio de onda de 10 μm (Infravermelho termal) (SCHOTT, 2007). A Figura 1 apresenta as faixas do espectro eletromagnético com relação às diferentes ordens de grandeza para comprimento de onda (λ) e frequência (ν).

Figura 1 - Classificação das faixas do espectro eletromagnético conforme comprimento de onda (λ) e frequência (ν) da radiação eletromagnética.



Fonte: Modificado de Abel (2012) e Liu (2006).

2.2 Conceitos de Radiometria

Para a compreensão dos processos relacionados ao sensoriamento remoto, é importante definir os conceitos relacionados à radiometria, conforme dispõe Schott (2007) e Kuenzer e Dech (2013). Inicialmente, a relação entre o comprimento de onda (λ), que representa a distância entre duas fases de uma onda (e.g. crista a crista ou pico a pico); a frequência (ν), que é o número de ondas que passam por um ponto fixo em um segundo; e a velocidade da luz (c) é dada pela seguinte equação:

$$c = \lambda\nu \quad (\text{Equação 1})$$

Esse modelo considera a energia transmitida como ondas, porém, é possível expressá-la como partículas de energia (i.e., fótons), resultando na equação abaixo,

$$q = h\nu = h\frac{c}{\lambda} \quad (\text{Equação 2})$$

onde q é a quantidade de energia em Joules, h é a constante de Planck ($6,6256 \times 10^{-34}$ J.s). Por meio desta equação, observa-se que quanto maior for o comprimento de onda, menor será sua energia, e vice-versa. Somando-se as energias de cada frequência e quantidade de fótons, o resultado é a Energia Total (Q).

Desses conceitos, obtêm-se a definição de Fluxo Radiante (Φ). Ele é a quantidade de energia que passa ou propaga por um local, sendo dada pela primeira derivada da quantidade de energia (Energia Total – Q) pelo tempo, expressando seus valores em Watts. Mesmo assim, esse conceito ainda não abrange a interação com uma superfície, sendo necessário o conceito de Irradiância, a qual é a taxa de fluxo radiante que chega em uma superfície, sendo expressa em watts por metro quadrado

(W/m²). Salienta-se que este conceito é similar ao de exitância (quantidade de fluxo de energia que sai de uma superfície).

O conceito de irradiância ainda não é completo, pois não demonstra qual a direção do fluxo de energia. Dessa forma, foi criado a Intensidade Radiante, a qual é a derivada da irradiância em função do ângulo sólido (normalmente representado por um cone que abrange a superfície que interagiu com a energia). A unidade da Intensidade Radiante é watts por esterradiano (W/sr).

E por fim, apresenta-se o conceito de Radiância, que coloca a intensidade radiante em um local definido no espaço, sendo expresso em W/m².sr. Este conceito é o mais utilizado para a propagação radiométrica, pois ele é independente de considerações geométricas e somente fatores relacionados ao meio precisam ser considerados (e.g. absorção e espalhamento). Além disso, cabe salientar que cada fluxo de energia citado irá variar conforme o comprimento de onda.

Outro conceito fundamental é o de corpo negro. Corpo negro é uma superfície ou material idealizado na qual todo fluxo eletromagnético incidente é absorvido ou que emite toda energia termal possível (SCHOTT, 2007; GILLESPIE, 2014). Deste conceito é formulada a Lei de Planck, a qual relaciona a exitância espectral de uma superfície (M_λ) com fatores como comprimento de onda e temperatura (T). A equação da Lei de Planck é expressa a seguir.

$$M_\lambda = \frac{2\pi hc^2}{\lambda^5} \left(\frac{1}{e^{\frac{hc}{\lambda kT}} - 1} \right) \quad (\text{Equação 3})$$

onde k é a constante de Boltzmann (1,38 x 10⁻²³ j/K) e h é a constante de Planck.

Da Lei de Planck, a representação gráfica do comprimento de onda no eixo x e a exitância espectral no eixo y, com diferentes valores de temperatura, resulta em um conjunto de curvas de corpos negros que demonstra que, conforme há um aumento da temperatura, há deslocamento do pico predominante de emissão para comprimentos de ondas menores. A Figura 2 apresenta essa relação, bem como outras leis (Lei de Stefan-Boltzmann e Deslocamento de Wien) que serão comentadas a seguir.

A Lei de Stefan-Boltzmann demonstra que é possível obter a exitância total (M) de um corpo negro ao integramos a Lei de Planck para todos os comprimentos de onda, o que resulta na seguinte equação:

$$M = \sigma T^4 \quad (\text{Equação 4})$$

onde σ é a constante de Stefan-Boltzmann ($5,67 \times 10^{-8} \text{ W/m}^2\text{K}^4$). Na Figura 2, ela é apresentada como uma hachura laranja sob a curva de temperatura de 300 K.


A Lei do Deslocamento de Wien, também obtida a partir da Lei de Planck, obtém o comprimento de onda para determinada temperatura onde a exitância é máxima, conforme expressa a equação seguinte.

$$\lambda_{max} = A/T \quad (\text{Equação 5})$$

onde A é a constante de deslocamento de Wien ($2.898 \mu\text{m}\cdot\text{K}$). Na Figura 2, ela é apresentada como uma linha tracejada verde ao longo dos picos das curvas.

Considerando as temperaturas observadas na superfície terrestre (i.e. 250 K à 330 K) e a Lei do Deslocamento de Wien, obtêm-se comprimentos de onda na faixa de 8 e 13 μm , o qual coincide com a janela atmosférica para a radiação do infravermelho termal (LI et al., 2013).

Figura 2 – Variação da exitância espectral em função do comprimento de onda e temperatura (Barra azul representa a faixa do espectro visível; hachura laranja representa a exitância total para a temperatura de 300 K; e linha tracejada verde são os picos de exitância máxima).



Fonte: Kuenzer e Dech (2013, pg. 6).

Muitas dessas leis foram desenvolvidas para corpos negros. Entretanto, corpos negros não existem na realidade, sendo necessário introduzir o conceito de emissividade (ϵ), a qual é a razão entre a emitância espectral de um corpo natural na temperatura T pela emitância espectral de um corpo negro na mesma temperatura (LI et al., 2013). A emissividade representa o quão bem um corpo natural radia energia em relação ao corpo negro, logo, ela varia entre 0 e 1 (ARTIS E CARNAHAN, 1982; SCHOTT, 2007; GILLESPIE, 2014).

A emissividade é uma propriedade que está relacionada ao tipo de material, assim como propriedades como transmissividade, refletância e absorvidade, as quais são conceituadas a seguir:

- Transmissividade (τ): Razão entre emitância no lado oposto do material e a irradiância na parte frontal;
- Refletância (r): Razão entre a emitância na parte frontal do material e a irradiância na parte frontal;
- Absorvidade (α): Razão entre a quantidade de energia convertida para outras formas de energia e a irradiância na parte frontal do material.

De forma a garantir a conservação de energia, a soma dessas razões deve ser igual à 1. Além disso, conforme a Lei de Kirchoff, a emissividade deve ser igual à absorvidade para corpos em equilíbrio termodinâmico (i.e. toda energia absorvida é posteriormente emitida) (KUENZER E DECH, 2013).

2.3 Interação da Radiação com a Atmosfera

Considerando a quantidade total de radiação solar que chega no topo da atmosfera (i.e., irradiância solar), essa energia poderá seguir diferentes caminhos. Inicialmente, ela poderá atravessar a atmosfera, ser refletida pela superfície e ser capturada pelo sensor remoto. A atmosfera poderá interferir de forma que ela espalhe essa radiação, tanto antes quanto depois da reflexão pela superfície. Nas situações onde não há contato com a superfície, esta radiação é denominada radiação *upwelling*. Objetos também podem contribuir para a reflexão junto com a superfície (SCHOTT, 2007).


A interação com a atmosfera resulta em dois fenômenos, absorção e espalhamento. A absorção ocorre pela remoção de energia das ondas eletromagnéticas pela sua conversão em outra forma de energia, sendo esta,

geralmente, energia térmica. O espalhamento é a mudança na direção e distribuição espectral do raio de energia que adentra a atmosfera terrestre. Este tipo de interação pode ainda ser dividido conforme o tamanho da molécula que ocorreu a interação, a citar: Espalhamento Rayleigh (partículas menores que o comprimento de onda); Espalhamento Mie (partículas com tamanho similar ao comprimento de onda); e Espalhamento Não-Seletivo (partículas maiores que o comprimento de onda) (SCHOTT, 2007).

Com relação à energia térmica, os caminhos percorridos pela radiação são similares aos já citados, sendo seu ponto de origem a superfície ou os objetos que as emitiram. A atmosfera também contribui com as emissões de radiação térmica, podendo interagir com objetos na superfície ou não. Quando há esta interação, ela é denominada radiação *downwelling*.

A Figura 3 resume os caminhos aqui citados, sendo A a radiação oriunda do Sol que interage com a superfície e retorna diretamente para o sensor; B é similar ao A, porém a radiação é espalhada pela atmosfera antes de tocar o solo; C é a radiação espalhada pela atmosfera e que não interage com a superfície e vai direto para o sensor (i.e. radiação *upwelling*); G é a radiação que interage com objetos na superfície; I é a radiação refletida por objetos do entorno e depois espalhada em direção ao sensor; J é a radiação que atingiu a superfície e foi espalhada novamente de volta para ela e posteriormente encaminhada ao sensor. No caso da radiação térmica, D é a radiação emitida diretamente pela superfície; E é a radiação emitida pela atmosfera que interage com a superfície e em seguida vai em direção ao sensor (i.e. radiação *downwelling*); F é a radiação emitida pela atmosfera diretamente para o sensor; e H é a radiação emitida por objetos que interage com a superfície e vai em direção ao sensor.

Figura 3 - Caminhos na atmosfera da radiação solar (esquerda) e térmica (direita).



Fonte: Schott (2007).

2.4 Sensoriamento Remoto da Temperatura

A T_s pode ser definida como a temperatura média de um elemento com a superfície exata da Terra, calculada a partir da radiância. Esta medição não é a temperatura propriamente dita, mas sim, a radiação térmica emitida pela superfície. Mesmo assim, é por meio desta medida que é possível calcular a T_s por meio da inversão da Lei de Planck e outras equações que dela derivam (GILLESPIE, 2014). A definição de T_s pode variar conforme a aplicação, podendo também ser chamada de temperatura radiométrica (ou *skin temperature*). Esta temperatura corresponde à radiação emitida na profundidade que a onda penetra, a qual são alguns poucos milímetros para o infravermelho térmico. A T_s ainda difere fisicamente de outras formas de medição de temperatura, como àquelas medidas por meio de termômetros, podendo ser equivalentes para superfícies homogêneas e isotermias (LI et al., 2013).

A T_s é um parâmetro chave para o cálculo do balanço energético entre a superfície e a atmosfera, sendo um fator que interfere no clima global e nas mudanças ambientais (WANG E LIANG, 2009). Ela atua como força motriz na troca de radiação de ondas longas e fluxos turbulentos de calor na interface entre atmosfera e superfície,

sendo utilizada em diferentes estudos. Ela ainda é definida como um parâmetro de alta prioridade no Programa Internacional da Geosfera e Biosfera (*International Geosphere and Biosphere Program* - IGBP) (LI et al., 2013) e reconhecida como variável climática essencial pelo Sistema de Observação do Clima Global (*Global Climate Observing System*) (GUILLEVIC et al., 2018). Além da importância ambiental, a T_s é um parâmetro que está relacionado à saúde pública, por estar vinculada aos fenômenos de ondas de calor e propagação de vetores de doenças (WENG et al., 2014). Na agricultura de precisão, sua importância se deve à rápida resposta que este parâmetro tem às variações das condições das culturas e do solo (KHANAL et al., 2017).

No sensoriamento remoto, a faixa do espectro eletromagnético considerado para as medições de temperatura é o infravermelho termal, na qual o intervalo de 1,4 a 14 μm é o mais significativo para a superfície terrestre (GILLESPIE, 2014). Na faixa entre 8 e 14 μm , há o predomínio da emissão de radiação térmica pela superfície, sendo muito menor os valores de reflectância. Na faixa do infravermelho intermediário (3 a 5 μm), tanto a emissão de energia pela superfície quanto a reflectância apresentam ordem de grandeza semelhantes, podendo ocorrer 'contaminação' da radiação termal (SCHOTT, 2007; KUENZER E DECH, 2013).

O cálculo da T_s a partir dos dados de sensoriamento remoto pode apresentar dificuldades. Fatores que podem dificultar o seu cálculo são absorção, emissão e espalhamento atmosférico (efeitos atmosféricos), heterogeneidade da superfície (que interferem em propriedades da superfície como emissividade) (LI et al., 2013; GILLESPIE, 2014), ângulo de visualização, altitude e tempo de aquisição (KHANAL et al., 2017). Li et al. (2013) e Parastatidis et al. (2017) também comentam sobre as dificuldades da validação destes dados. Estes fatores podem ainda mudar ao longo do tempo, onde a T_s pode ter contribuições diferenciadas conforme as estações (especialmente no verão) e uso do solo (CHEN et al., 2021a). Cabe comentar ainda que os efeitos atmosféricos citados variam ao longo do espectro eletromagnético, havendo três janelas atmosféricas onde há maior transmissividade da radiação termal, sendo eles denominados infravermelho de ondas curtas, infravermelho intermediário e infravermelho de ondas longas (GILLESPIE, 2014).

Outros fatores também devem ser levados em conta na avaliação do balanço energético para obtenção da T_s , tais como a radiação termal que nunca interage com a superfície (i.e. radiação *upwelling*) e a radiação *downwelling* (GILLESPIE, 2014).

A integração desses fatores pode ser realizada na Equação de Transferência Radiativa (do inglês *Radiative Transfer Equation* - RTE) na região do infravermelho termal, a qual é dada pela seguinte equação, conforme Sobrinho et al. (2004):

$$L_{sensor} = [\varepsilon B(T_s) + (1 + \varepsilon)L_{atm}^{\downarrow}] \tau + L_{atm}^{\uparrow} \quad (\text{Equação 6})$$

onde L_{sensor} é a radiância medida pelo sensor, ε é a emissividade da superfície, $B(T_s)$ é a radiância dada pela equação da Lei de Planck e T_s é a temperatura de superfície, L_{atm}^{\downarrow} é a radiância atmosférica *downwelling*, τ é a transmissividade da atmosfera, e L_{atm}^{\uparrow} é a radiância atmosférica *upwelling*.

O uso desta equação apresenta como desvantagem a necessidade de radiossondagens para a estimativa dos parâmetros τ , L_{atm}^{\downarrow} e L_{atm}^{\uparrow} (JIMENEZ-MUNOZ et al., 2009). Dessa forma, diversos algoritmos e métodos vem sendo propostos para tratar a RTE e obter a T_s , os quais podem ser separados em métodos de banda única (*single-channel*), bandas múltiplas (*multi-channel*) e ângulos múltiplos (*multiple angles*), nos casos em que a emissividade seja conhecida (LI et al., 2013). Destaca-se que para os dois últimos métodos, são necessárias duas bandas termiais (JIMÉNEZ-MUÑOZ E SOBRINHO, 2003). Caso a emissividade seja desconhecida, temos três categorias de métodos, conforme Li et al. (2013), os quais são: Obtenção por Etapas (*Stepwise Retrieval Method*), Obtenção Simultânea de T_s e emissividade com características da atmosfera, e Obtenção Simultânea sem informações atmosféricas. Os mesmos autores ainda ressaltam que devido as restrições de cada método, tais como número de bandas necessárias e conhecimento da emissividade e condições atmosféricas, comparações entre métodos não são realizadas com frequência.

2.4.1 Métodos de obtenção de T_s com Emissividade

2.4.1.1 Método da Banda Única (*single-channel method*)

O cálculo da T_s por este método é realizado a partir da radiância medida pelo sensor em apenas uma banda, sendo então realizado as devidas correções atmosféricas usando modelos de transferência radiativa (e.g. MODTRAN e 4A/OP) e perfis atmosféricos. Após esse procedimento, a T_s é obtida pela inversão da RTE. Alguns fatores podem resultar em erros na obtenção da T_s por meio deste método, sendo eles: Acurácia do modelo usado, caracterização incompleta do perfil atmosférico, incertezas na emissividade, uso de radiossondagens distantes da área de estudo ou distantes do tempo de passagem do satélite (LI et al., 2013). Cabe comentar que erros na emissividade podem chegar até 1 K para usos do solo convencionais (KUENZER E DECH, 2013).

Para este método, um dos principais problemas é a disponibilidade de dados de radiossondagens. Desta forma, vários métodos têm sido propostos considerando alternativas a estes dados, tais como somente o uso do conteúdo de água na atmosfera e temperatura do ar nas proximidades da superfície (JIMENEZ-MUNOZ et al., 2009; LI et al., 2013).

Um desses métodos é o proposto por Jiménez-Muñoz e Sobrinho (2003), aplicável ao Landsat Thematic Mapper 5, o qual correlaciona a T_s com parâmetros como emissividade (ϵ), radiância no sensor (L_{sensor}), temperatura de brilho no sensor (T_{sensor}), comprimento de onda efetivo (λ) e o conteúdo total de vapor d'água na atmosfera (w). As equações seguintes apresentam essas relações:

$$T_s = \gamma[\epsilon^{-1}(\psi_1 L_{sensor} + \psi_2) + \psi_3] + \delta \quad (\text{Equação 7})$$

$$\gamma = \left\{ \frac{c_2 L_{sensor}}{T_{sensor}^2} \left[\frac{\lambda^4}{c_1} L_{sensor} + \lambda^{-1} \right] \right\}^{-1} \quad (\text{Equação 8})$$

$$\delta = -\gamma L_{sensor} + T_{sensor} \quad (\text{Equação 9})$$

$$\psi_1 = 0,14714w^2 - 0,15583w + 1,1234 \quad (\text{Equação 10})$$

$$\psi_2 = -1,1836w^2 - 0,37607w - 0,52894 \quad (\text{Equação 11})$$

$$\psi_3 = -0,04554w^2 - 1,8719w - 0,39071 \quad (\text{Equação 12})$$

salienta-se que as constantes C_1 e C_2 são iguais à $1,19104 \times 10^{-8} \text{ W} \cdot \mu\text{m} \cdot \text{m}^{-2} \cdot \text{sr}^{-1}$ e $14387,7 \mu\text{m} \cdot \text{K}$, respectivamente e ψ são coeficientes atmosféricos.

Uma revisão deste método foi realizada por Jimenez-Munoz et al. (2009) e Jimenez-Munoz et al. (2014) para abranger também as imagens do Landsat 4, 7 e 8, bem como atualizar as relações do Landsat 5 e 8 e introduzir novos coeficientes atmosféricos com base em diferentes bancos de dados de sondagens atmosféricas (e.g. SAFREE, TIGR1, TIGR2, TIGR3 e GAPRI). Mais recentemente, Parastatidis et al. (2017) desenvolveram os métodos anteriormente citados na plataforma do GEE, possibilitando a obtenção de valores T_s para todo o catálogo disponível na plataforma.

Outro método é apresentado por Artis e Carnahan (1982), os quais por meio da Lei de Planck, demonstram equação para obtenção da temperatura a partir da temperatura de brilho (T_B), comprimento de onda emitido (λ) e emissividade (ϵ), sendo a mesma apresentada a seguir:

$$T_s = \frac{T_B}{1 + (\lambda T_B / \alpha) \ln \epsilon} \quad (\text{Equação 13})$$

onde α é igual à $1,438 \times 10^{-2} \text{ mK}$, resultado da relação entre as constantes de Planck (h), Boltzmann (K) e velocidade da luz (c). Tal equação também é encontrada nos trabalhos de Allen et al. (2007), Ndossi e Avdan (2016) e Chen et al. (2021).

Ermida et al. (2020) implementaram o algoritmo de obtenção de T_s da CM-SAF (*Climate Monitoring Satellite Application Facility*) no GEE. O método pode ser classificado como de janela única estatístico (*Statistical Mono-Window – SMW*) e é aplicável às series Landsat 4, 5, 7 e 8. A base do método utilizado pelos autores é a relação empírica entre temperatura de brilho no topo da atmosfera e a T_s , fazendo uso de uma regressão linear. A equação seguinte demonstra essa relação.

$$T_s = A \frac{T_b}{\epsilon} + B \frac{1}{\epsilon} + C \quad (\text{Equação 14})$$

onde A , B e C são coeficientes definidos pela regressão linear de simulações de transferência de radiação em diferentes classes de vapor d'água, sendo T_b a temperatura de brilho e ϵ a emissividade.

2.4.1.2 Método das Bandas Múltiplas (*multiple-channel method*)

Diferente do método da banda único, os métodos das bandas múltiplos não precisam de informações sobre o perfil atmosférico (i.e. radiossondagens), sendo utilizado dados de duas bandas adjacentes. Além disso, também são utilizados parâmetros como a diferença entre a T_s e a temperatura do ar, coluna total de vapor d'água e ângulo zenital de visada. Estes métodos são chamados de Janela Dividida (*split-window*), podendo ser divididos em lineares, não-lineares e combinação de ambos (LI et al. 2013).

Os métodos de janela dividida lineares expressam a T_s por meio de uma combinação linear entre as duas temperaturas de brilho medidas pelas duas bandas de infravermelho (T_i e T_j), sendo, de modo geral, representada pela equação abaixo:

$$T_s = a_0 + a_1 T_i + a_2 (T_i - T_j) \quad (\text{Equação 15})$$

onde a_k ($k = 0, 1$ e 2) são coeficientes que dependem da função da resposta espectral e emissividade das bandas em uso, do conteúdo de vapor d'água na atmosfera e do ângulo de visada zenital, onde sua obtenção varia conforme o algoritmo (LI et al., 2013).

A obtenção da T_s pelo sensor MODIS é realizada por um algoritmo do tipo janela dividida, sendo denominado janela dividida generalizada (*Generalized Split-Window – GSW*). Este algoritmo usa as bandas termais 31 (i) e 32 (j) para o cálculo da T_s por meio da seguinte equação:

$$T_s = b_0 + \left(b_1 + b_2 \frac{1-\varepsilon}{\varepsilon} + b_3 \frac{\Delta\varepsilon}{\varepsilon^2} \right) \frac{T_i - T_j}{2} + \left(b_4 + b_5 \frac{1-\varepsilon}{\varepsilon} + b_6 \frac{\Delta\varepsilon}{\varepsilon^2} \right) \frac{T_i - T_j}{2} \quad (\text{Equação 16})$$

onde os coeficientes b são definidos considerando o ângulo de visada zenital, emissividade, conteúdo de vapor d'água na atmosfera e temperatura superficial do ar (LI et al., 2013; GUILLEVIC et al., 2018).

O método anterior (janela dividida linear) acaba introduzindo alguns erros por causa da linearização da RTE, bem como por causa de algumas aproximações usadas. Diante disso, surgiram métodos janela dividida não lineares. As equações seguem o modelo similar à linear, sendo adicionado um termo elevado ao quadrado, conforme equação seguinte:

$$T_s = c_0 + c_1 T_i + c_2 (T_i - T_j) + c_3 (T_i - T_j)^2 \quad (\text{Equação 17})$$

onde os valores dos coeficientes c são obtidos por meio de regressões em dados simulados em um conjunto de parâmetros atmosféricos e superficiais (LI et al. 2013).

Nas situações onde há mais de duas bandas que podem ser consideradas, é possível mesclar o uso de algoritmos lineares e não lineares (LI et al., 2013).

2.4.1.3 Métodos de ângulos múltiplos (*multiple angles methods*)

O método dos ângulos múltiplos segue os mesmos preceitos do método janela dividida, sendo a T_s obtida por meio de duas medições com ângulos diferentes, onde a diferença entre a absorção atmosférica ocorre devido aos diferentes comprimentos de trajetos percorridos pela radiação. Mesmo que apresentem bons resultados, o método dos ângulos múltiplos apresenta limitações como a dependência angular da emissividade e T_s e aplicação restrita a áreas homogêneas (LI et al., 2013).

2.4.2 Métodos de obtenção de T_s sem Emissividade

A emissividade é um parâmetro fundamental para a obtenção da T_s , visto que incertezas na ordem de 1% podem acarretar erros de mais de 1 K na T_s (PARASTATIDIS et al., 2017). Ela pode variar em função da vegetação, umidade da superfície, rugosidade e ângulo de visada, tornando-se uma variável de difícil aquisição. Assim, foram desenvolvidos métodos para a estimativa da T_s quando a emissividade é desconhecida (LI et al., 2013). Alguns destes métodos são: método dos limites de NDVI (*NDVI Thresholds*), Separação Temperatura/Emissividade, e Razão entre Radiância Termal SWIR (JIMÉNEZ-MUÑOZ E SOBRINHO, 2003; SOBRINHO et al., 2004).

2.4.2.1 Obtenção por Etapas (*stepwise retrieval method*)

Este método é constituído por duas etapas, inicialmente a emissividade é definida empiricamente a partir de medições do visível e infravermelho próximo, ou ainda estimadas de radiâncias do infravermelho intermediário e termal a nível do solo. Em seguida, utiliza-se um dos métodos já apresentados (banda única, janela dividida

ou múltiplos ângulos) para a obtenção da temperatura. A primeira etapa deste procedimento (i.e. definição da emissividade) pode ser realizada de diferentes formas, tais como o método da emissividade baseado na classificação, emissividade baseado no NDVI (ou limite de NDVI) e índices espectrais independentes da temperatura (LI et al., 2013).

O primeiro método citado assume que as emissividades em usos do solo classificados por sensoriamento remoto são similares nas mesmas classes, sendo que a emissividade pode ser obtida numa tabela de valores pré-definidos. Neste método, erros podem estar associados à umidade do solo, ao ciclo anual biofísico da vegetação e a outras condições de uso e cobertura da terra. Já o método baseado no NDVI assume uma relação estatística entre o NDVI e a emissividade obtida nas bandas do infravermelho termal. Por utilizar o NDVI, este método tem como desvantagem o tratamento diferenciado para superfícies com rochas expostas, neve e corpos d'água. Por fim, há o método baseado em índices espectrais independentes da temperatura. Neste método, assume-se que os índices espectrais nas faixas do infravermelho intermediário (MIR) e termal (TIR) durante o dia (sem a contribuição da iluminação solar) são os mesmos durante a noite, de forma a possibilitar a extração de dados de reflectância bidirecional no canal MIR. Dessa forma, obtém-se a emissividade na faixa do TIR, possibilitando assim o cálculo da T_s pelos métodos já comentados (LI et al., 2013).

2.4.2.2 Obtenção Simultânea com características da atmosfera

Visto que a acurácia da T_s depende da acurácia da emissividade, diferentes métodos foram propostos para a obtenção destas variáveis de forma conjunta, podendo estes serem agrupados em métodos multitemporais e multiespectrais. O primeiro grupo de métodos assume que a emissividade não varia ao longo do tempo, possibilitando o cálculo da T_s , enquanto o segundo grupo baseia-se no comportamento intrínseco da emissividade (LI et al., 2013).

Dentro dos métodos multitemporais, temos o método baseado em duas temperaturas, cujo intuito é a redução do número de variáveis desconhecidas por meio de um maior número de medições; e o método operacional dia/noite físico, que combina o uso de medições diárias e noturnas de emissividade e T_s de pares de dados MIR e TIR (LI et al., 2013).

Já para os métodos multiespectrais, temos os seguintes métodos: Emissividade de corpo cinza, o qual assume que o espectro é plano para comprimentos de ondas superiores à 10 μm (para reduzir o número de incógnitas); Separação temperatura/emissividade, o qual baseia-se na relação entre contraste espectral e a emissividade mínima; Separação temperatura/emissividade iterativa e espectralmente suave, onde a T_s e a emissividade são obtidas nos pontos onde sua suavização seja maximizada; e Separação temperatura/emissividade com emissividade linear limitada, o qual assume que o espectro da emissividade possa ser dividido em segmentos e que em cada segmento ela está linearmente correlacionada com o comprimento de onda (LI et al., 2013).

2.4.2.3 Obtenção Simultânea sem informações atmosféricas

Há situações que a obtenção de dados atmosféricos para os cálculos da emissividade e a T_s não é possível, sendo necessário obtê-los simultaneamente aos cálculos. Métodos que utilizam essa abordagem são Redes Neurais Artificiais e Obtenção Física em Duas Etapas. Redes Neurais Artificiais desenvolvem-se bem ao lidar com padrões complexos das relações existentes as variáveis biofísicas atmosféricas e superficiais, possibilitando obtê-las simultaneamente. Entretanto, este método requer um bom conjunto de dados para treinamento. Já a obtenção física em duas etapas utiliza os dados de radiância de topo da atmosfera (TOA) para obtenção dos dados de superfície e atmosfera (LI et al., 2013).

2.4.3 Validação da T_s

A validação é o processo de avaliação das incertezas existentes nos parâmetros de saída de diferentes sistemas, tais como sensores remotos. Este é um processo essencial, visto que possibilita o melhoramento dos produtos gerados por sensoriamento remoto (WANG E LIANG, 2009). Mesmo sendo um procedimento de grande importância, o número de estudos de validação não acompanha a mesma tendência de aumento dos estudos de métodos para obtenção da T_s . Isso ocorre principalmente em função das dificuldades de comparação da T_s medida em campo com aquelas medidas por satélites e pela alta variação espacial da T_s (LI et al., 2013).

Usualmente, três métodos podem ser utilizados para a validação de dados T_s , aqueles baseados na temperatura, na radiância e validação cruzada. O primeiro método compara medições de temperatura em campo (*in situ*) com as medições de T_s de sensoriamento remoto no momento da passagem do satélite. Diferenças entre as escalas das medições (quilômetros para os satélites e metros a centímetros para as *in situ*) e a variação do uso do solo são algumas dificuldades encontradas neste método de validação. Mesmo com tais desvantagens, o método baseado na temperatura produz uma avaliação direta do valor de T_s obtido e do algoritmo utilizado (LI et al., 2013).

O método baseado na radiância requer o uso de espectros de emissividade e perfis atmosféricos da área de validação durante a passagem do satélite. Tais parâmetros são utilizados como dados de entrada em um modelo de transferência radiativa para simular a radiação topo da atmosfera, onde por meio da diferença e a radiação medida por satélite, obtêm-se a T_s inicial, que é posteriormente ajustada para coincidir com a medida pelo sensor. Neste caso, a T_s inicial é a incerteza do modelo. Já o método de validação cruzada realizada a comparação da T_s obtida por sensores remotos com dados de outros sensores que já apresentam T_s validadas e bem documentadas (LI et al., 2013).

2.5 Sensoriamento remoto na Hidrologia

A necessidade de análises globais dentro da hidrologia não é atual (EAGLESON, 1986; SIVAPALAN E BLÖSCHL, 2017). Neste sentido, o sensoriamento remoto vem avançando significativamente nos últimos anos com novas tecnologias e técnicas, possibilitando a disponibilidade de informações para diferentes usuários para a gestão de recursos naturais (LIANG E WANG, 2019). O crescimento atual do sensoriamento remoto é uma oportunidade tecnológica para a hidrologia (SIVAPALAN E BLÖSCHL, 2017). O trabalho desenvolvido por Moreira et al. (2019) é um exemplo, no qual os autores avaliaram o potencial do uso de sensoriamento remoto para realizar um balanço hídrico na América do Sul. Os autores utilizaram dados de diferentes missões e sensores, tais como *Tropical Rainfall Measuring Mission* (TRMM), *The Multi-Source Weighted-Ensemble Precipitation* (MSWEP), *MODIS Global Evapotranspiration Project* (MOD16), *Global Land Surface Evaporation: The Amsterdam Methodology* (GLEAM) e *Gravity Recovery and Climate Experiment* (GRACE). Outro exemplo pode

ser visto no trabalho de Caballero et al. (2022), onde em sua revisão sistêmica dos impactos da mudança do uso e cobertura do solo nas interações entre superfície e atmosfera no Brasil, 31 dos 61 trabalhos analisados usaram, de forma direta ou indireta, sensoriamento remoto.

Além do avanço relacionado aos tipos de dados, temos também desenvolvimentos no processamento e disponibilidade desses dados, que tem aumentado significativamente nas últimas décadas (ATKINSON, 2013; BAI et al., 2020). Tais avanços são fundamentais pois o processamento de imagens de satélite em computadores convencionais requer que as imagens sejam baixadas e processadas para posteriormente serem analisadas. Nas situações em que há várias imagens para serem usadas, isso pode tornar-se inviável, tanto no sentido de tempo quanto de processamento computacional. Diante desse aumento significativo da quantidade de dados espaciais, fazendo com que alguns autores cunhem o termo *big geodata*, são necessárias novas estratégias ou plataformas para o seu processamento (PARASTATIDIS et al., 2017).

Desta forma, surge o Google Earth Engine (GEE), o qual é uma plataforma de computação em nuvem que facilita o acesso à recursos computacionais de alta performance, possibilitando processar grandes quantidades de dados espaciais em pouco tempo. A plataforma permite a realização de análises espaciais de um extenso banco de dados (e.g. Landsat, Sentinel e MODIS), de forma rápida em função do processamento ser realizado nos servidores da Google (*server-side*). Nas situações que o usuário precisar baixar os dados, a plataforma permite a realização do download das imagens para processamento em outras ferramentas off-line (*client-side*) (GORELICK et al., 2017).

Um exemplo do uso da plataforma GEE na hidrologia é o trabalho de Pekel et al. (2016), os quais mapearam áreas cobertas por corpos d'água entre os anos de 1984 e 2015 em escala global. Outro exemplo é o desenvolvimento de algoritmos para o mapeamento de áreas alagáveis e a implementação de modelos para estimativa de evapotranspiração, tais como nos trabalhos de Coltin et al. (2016) e Laipelt et al. (2021), respectivamente. Os trabalhos de Parastatidis et al. (2017) e Ermida et al. (2020) também fazem uso dessa plataforma para obtenção da T_s .

2.6 Fusão de Imagens (*Downscaling*)

O procedimento de unir informações de diferentes fontes para melhorar nossa interpretação das imagens é chamado de fusão de imagens (SCHOTT, 2007). Assim como a fusão de imagens, o *downscaling* segue o mesmo princípio, onde o termo pode ser definido como um aumento da resolução espacial da imagem. Além disso, cabe comentar sobre a necessidade da modificação da escala dos dados (tanto aumentando ou reduzindo ela) para adequar e comparar diferentes bancos de dados com resoluções distintas (ATKINSON, 2013).

Entretanto, mesmo com os avanços vistos na área de sensoriamento remoto, ainda há uma relação inversa entre resolução espacial e temporal em função de restrições financeiras e tecnológicas (ZHU et al., 2010; ATKINSON, 2013). Isso pode ser visto na análise de bancos de dados espaciais ambientais realizada por Patterson et al. (2022), os quais demonstram que problemas como consistência temporal e resolução espacial são normalmente encontrados. Um exemplo típico deste problema é a resolução espacial relativamente alta (30 m) e baixa resolução temporal (16 dias) do LANDSAT e a resolução espacial moderada (250 a 1.000 m) e resolução temporal diária do MODIS (WENG et al., 2014; LUO et al., 2018; XIE et al., 2018). Alguns satélites comerciais podem apresentar frequências diárias com alta resolução espacial por meio de constelações de nanosatélites (*CubeSats*), entretanto, desvantagens como custos para aquisição, disponibilidade somente da banda do visível, pouco rigor científico nas correções atmosféricas e calibrações radiométricas tornam seu uso menos frequente no meio acadêmico (LUO et al., 2018; LIANG E WANG, 2019; BAI et al., 2020).

Além da limitação em relação as resoluções temporais, outro problema na aquisição de imagens é a presença de nuvens (GAO et al., 2006; WEISS et al., 2014; ZHANG et al., 2021) e falhas no escaneamento dos sensores (e.g. Landsat 7) (LUO et al., 2018), que acabam limitando suas aplicações. Dessa forma, o desenvolvimento de métodos de fusão de imagens para buscar melhores resoluções temporais e espaciais torna-se essencial para pesquisas de abrangência global, gerenciamento de recursos ambientais e de mudanças no uso do solo (XIE et al. 2018; CHEN et al., 2021b). Técnicas tradicionais de fusão de imagens usualmente unem bandas de baixa resolução espacial com as de alta resolução espacial (e.g. banda pancromática) para obter novas imagens (SCHOTT, 2007), porém, para o melhoramento da resolução

temporal, tais técnicas não são apropriadas (ZHU et al., 2010). Cabe salientar que diferentes termos podem ser utilizados para descrever os métodos de fusão de imagens, tais como *image merging*, *spatial/thermal sharpening*, *disaggregation* e *downscaling* (WENG et al., 2014; LIANG E WANG, 2019). Na literatura levantada por Zhang et al. (2013), outros termos ainda são apresentados, correlacionando-os com suas disciplinas de origem.

As técnicas de fusão de imagens podem ser resumidas em duas categorias, técnicas de fusão espacial e técnicas de fusão temporal (WENG et al., 2014). Outras classificações podem surgir conforme campo de aplicação, como para modelos de mudanças climáticas, onde há a classificação entre técnicas estatísticas e técnicas dinâmicas (LEE E SINGH, 2018; XU E WANG, 2019). Para imagens de T_s , distinções como técnicas estatísticas, baseadas em fusão e híbridas existem (DONG et al, 2020). Para as técnicas de fusão temporal, o uso mais frequente das imagens LANDSAT junto às imagens MODIS (TERRA) é feito devido ao fato de seus satélites orbitarem em formação e com diferença de meia hora entre suas passagens (GAO et al., 2006; SCHOTT, 2007). Além disso, os instrumentos MODIS apresentam vantagens como cobertura global, alta resolução radiométrica e boa calibração das bandas termais (XIONG et al., 2008). Diante do exposto, diversos autores exploram tais propriedades das imagens dos sensores, desenvolvendo assim algoritmos para *downscaling* temporal e espacial. Nos tópicos seguintes são comentados alguns exemplos destes algoritmos, sendo que diferentes métodos de *downscaling* da T_s podem ser encontrados em Zhang et al. (2013).

2.6.1 STARFM

Gao et al. (2006) desenvolveram o algoritmo STARFM (*Spatial and Temporal Adaptive Reflectance Fusion Model*) para criar dados de reflectância 'sintéticos' diários por meio do uso de imagens LANDSAT 7 e MODIS. O STARFM baseia-se na diferença existente entre duas imagens da mesma data de diferentes sensores, porém com resoluções espaciais diferentes, que ao serem comparadas com outras duas de data distinta, possibilita o desenvolvimento da equação seguinte:

$$L(t_0) = M(t_0) + L(t_k) - M(t_k) \quad (\text{Equação 18})$$

Onde L e M representam o pixel da imagem Landsat e MODIS, respectivamente, e t_0 e t_k duas datas distintas. Desta forma, podemos estimar o valor do pixel L no tempo t_0 a partir da diferença entre L e M no tempo t_k , somando essa diferença ao pixel M no tempo t_0 .

Entretanto, tal relação é para uma situação ideal, onde os pixels são homogêneos. Para poder adequar a relação para pixels heterogêneos, Gao et al. (2006) propuseram um peso que percorre a imagem como uma janela móvel, de forma a definir como utilizar informações dos pixels vizinhos. Este peso faz uso de informações como a diferença absoluta entre a imagem Landsat e MODIS, diferença temporal entre as imagens MODIS e a distância do pixel dentro da janela móvel em relação ao pixel central. Os autores ainda apresentam o conceito de pixels espectralmente similares, os quais podem ser identificados por meio de classificação não supervisionada ou por meio de um limite, obtido, por exemplo, a partir do desvio padrão e pelo número de usos do solo.

Resultados do STARFM demonstraram que este é capaz de capturar mudanças fenológicas na vegetação, embora a acurácia dependa do tamanho e características de uso e cobertura da terra (GAO et al., 2006).

2.6.2 ESTARFM

Mesmo apresentando bons resultados, o algoritmo STARFM tem limitações, tal como a necessidade de pixels homogêneos para prever com acurácia a reflectância, de forma que os autores Zhu et al. (2010) desenvolveram o método ESTARFM (*Enhanced Spatial and Temporal Adaptive Reflectance Fusion Model*) para contornar esse problema.

A solução proposta por Zhu et al. (2010) envolve o uso da tendência linear entre a reflectância em dois pontos no tempo e o modelo linear de mistura espectral. Os autores comentam que, para um pixel homogêneo com resolução espacial ruim, a relação entre esse pixel e os pixels de uma imagem com boa resolução espacial pode ser estabelecida por meio da seguinte relação linear:

$$L(t_0) = a \times M(t_0) + b \quad (\text{Equação 19})$$

onde a e b são coeficientes lineares para a calibração relativa entre as imagens de diferentes resoluções espaciais. Considerando a mesma equação para uma nova data, podemos juntar ela com a equação já apresentada e teremos:

$$L(t_k) = L(t_0) + a \times (M(t_k) - M(t_0)) \quad (\text{Equação 20})$$

Em outras palavras, a equação proposta por Zhu et al. (2010) obtém a reflectância de uma imagem Landsat de uma data a partir da reflectância de outra data, somada à diferença entre as imagens MODIS e multiplicada por um coeficiente linear que engloba o viés relacionado aos erros entre as imagens (tais como diferença entre os sensores, comprimento das bandas e respostas espectrais).

Para os casos de pixels heterogêneos, o coeficiente a é substituído por uma variável que representa a taxa de mudança de reflectância para um determinada membro de referência (*endmember*). Cabe salientar que pixels heterogêneos têm seus valores definidos proporcionalmente em função dos tipos de usos de solo presentes (ZHU et al., 2010).

Da mesma forma que Gao et al. (2006), Zhu et al. (2010) implementam uma janela móvel para buscar pixels semelhantes e atribuir um peso aos pixels analisados. Além disso, Zhu et al. (2010) também apresentam um peso temporal, onde a imagem com data mais próxima tem um peso maior, sendo tal relação representada pela diferença entre as reflectâncias da imagem MODIS. Salienta-se que o ESTARFM, assim como o STARFM, não consegue prever mudanças que não forem registradas em alguma das imagens do Landsat (ZHU et al., 2010; WENG et al., 2014).

2.6.3 SEVERI_1km

Com o intuito de analisar a variação diurna da T_s em áreas urbanas, Zaksek e Ostir (2012) propuseram o *downscaling* das imagens do sensor SEVERI, que está abordo do satélite geoestacionário MSG. O uso do SEVERI possibilita a obtenção de imagens de T_s com frequência de até 5 minutos, porém, com resolução espacial de 3,1 km. O método proposto pelos autores para o *downscaling* dessas imagens faz uso de dados auxiliares oriundos do MODIS (e.g. NDVI, EVI e albedo) por meio de análise

de componentes principais. Os principais componentes são utilizados para criar equações de regressão por meio de uma janela móvel, possibilitando assim a estimativa da T_s numa escala espacial de 1 km com alta frequência. Comparando os resultados com as imagens de T_s do MODIS, foram obtidos valores de RMSE de 2,5 K e coeficiente de correlação de 0,97.

2.6.4 SADFAT

Weng et al. (2014) desenvolveram algoritmo de fusão de imagens termais, denominado SADFAT, para estimar a T_s diária com resolução espacial de 120 m usando imagens Landsat e MODIS. Os princípios teóricos do SADFAT são similares aos algoritmos já apresentados, i.e. STARFM e ESTARFM, sendo que os autores utilizaram a Lei de Planck para trabalhar na fusão de imagens usando dados de radiância e modelarem a variação sazonal da T_s por meio do ciclo anual da temperatura (que acaba se traduzindo no coeficiente de conversão) (WENG et al., 2014).

Mesmo avançando em vários pontos no desenvolvimento do SADFAT, Weng et al. (2014) apontam como limitações do método a incapacidade de prever mudanças de temperaturas que não forem registradas nos pares Landsat e MODIS usados, e de estabelecer condições atmosféricas e superficiais locais que possam interferir na temperatura.

2.6.5 STAIR

Luo et al. (2018) desenvolveram o método de fusão para reflectância de superfície denominado STAIR (*SaTellite dAta IntegRation*) com o intuito de contornar os problemas encontrados por métodos já citados, tais como presença de nuvens e pixels ausentes devido a falhas no escaneador. A premissa do STAIR é a utilização de uma série temporal dos pares de imagens Landsat-MODIS, possibilitando assim, suprir a demanda dos pixels ausentes ou contaminados por nuvens por meio de uma regressão linear seguida de uma correção a partir de um conjunto de pixels vizinhos e de diferentes usos do solo (LUO et al., 2018).

Para a realização do *downscaling*, os autores consideram que a relação entre os pixels homogêneos do Landsat (L) e do MODIS (M) pode ser modelada pela seguinte equação:

$$L_{(x,y,t_0)} = M_{(x,y,t_0)} + \epsilon_{(x,y,t_0)} \quad (\text{Equação 21})$$

onde ϵ representa a diferença entre as imagens Landsat e MODIS em função de erros de medição, ângulos solar e de visada, ruído ou vieses sistemáticos.

Fazendo uso da série temporal e isolando a variável ϵ , é realizado uma nova regressão linear, obtendo-se uma função para a diferença entre as imagens de entrada. Dessa forma, é possível prever a reflectância em uma data em que a imagem Landsat não esteja disponível. A equação seguinte demonstra essa relação:

$$I_{(x,y,t_p)} = M_{(x,y,t_p)} + \Delta_{(x,y,t_p)} \quad (\text{Equação 22})$$

onde Δ representa a diferença estimada na data t_p e I representa a imagem obtida por *downscaling*.

Luo et al. (2018) observam que, como a série temporal tem a mesma resolução espacial das imagens Landsat, tal resolução é transferida para as imagens obtidas pelo método proposto. Além disso, uma das vantagens do método proposto por Luo et al. (2018) é a possibilidade de integrar mais de duas imagens de diferentes satélites, sendo demonstrado esse avanço em Luo et al. (2020), onde é apresentado o STAIR 2.0, o qual, após integrar imagens MODIS e Landsat, os autores unem ao processo imagens Sentinel 2.

2.6.6 ST-Cokriging

Considerando que os métodos baseados no algoritmo do STARFM apresentam limitações como requerimento de classificação e reamostragem e o uso de combinações lineares entre as diferenças espectrais, Yang et al. (2021) propuseram o ST-Cokriging. Além disso, os autores comentam ainda que métodos baseados em aprendizado de máquina têm problemas como sobreajuste (*overfitting*), estruturas espaciais e temporais da covariância não são explicitamente representadas e não há o fornecimento da incerteza das estimativas. Dessa forma, é proposto o método ST-

Cokriging, o qual amplia as técnicas tradicionais de cokrigagem do domínio espacial para um domínio espaço-temporal.

O ST-Cokriging foi testado usando imagens MODIS e Landsat para uma área localizada nos EUA. Ele apresentou resultados razoavelmente melhores que aqueles do STARFM e FSDAF, incluindo ainda a incerteza dos resultados obtidos e o preenchimento de pixels cobertos por nuvens. O método foi aplicado usando linguagem Python em um ambiente ArcGIS, sendo computacionalmente mais exigente, quando comparado com os métodos já citados (YANG et al., 2021).

2.6.7 TsHARP

O TsHARP foi desenvolvido considerando a relação existente entre as variáveis NDVI e T_s , especificamente a relação entre fração de cobertura vegetal. A partir dessa relação, é possível realizar o *downscaling* da T_s , visto que grande parte das imagens de reflectância de superfície obtidas por satélites apresentam melhor resolução espacial que aquelas de T_s . Embora não seja possível utilizar para corpos d'água (visto que estes prejudicam a relação NDVI x T_s), tal relação não se restringe somente aos satélites MODIS e Landsat, podendo ser aplicada também para o GOES (AGAM et al., 2007).

Ao realizar o *downscaling* por meio desta técnica com foco em diferentes resoluções espaciais, Agam et al. (2007) observaram que, conforme há o aprimoramento da resolução espacial (maior nível de detalhamento), há uma tendência de aumento dos erros. Mesmo assim, os autores observaram erros entre 1,6 e 2,4 °C ao obter imagens de T_s de 30 m.

2.6.8 ALEXI/DisALEXI

Anderson et al. (1997) desenvolveram modelo de duas fontes (solo e vegetação) para estimar o balanço energético da superfície terrestre. O modelo faz uso da relação entre a temperatura radiométrica da superfície e o fluxo de calor sensível. A partir do modelo mencionado, é possível obter estimativas de ET por meio de sensoriamento remoto (ANDERSON et al., 2011). Entretanto, tal modelo, denominado ALEXI (*Atmosphere-Land Exchange Inverse model*) fica limitado à resolução espacial dos satélites usados. Neste sentido, foi desenvolvido o algoritmo DisALEXI para obtenção

estimativas de T_s por meio do *downscale* de imagens GOES com dados do Landsat, ASTER e MODIS. Esse processo é realizado utilizando a relação inversa entre T_s e NDVI (ANDERSON et al., 2004). Tanto o ALEXI quanto o DisALEXI vem sendo constantemente pesquisados, sendo comparados com algoritmos como STARFM (ANDERSON et al., 2011) ou testado com outras fontes de dados, como ECOSTRESS (ANDERSON et al., 2021).


2.7 Evapotranspiração

A ET é a passagem da água em estado líquido para o estado gasoso, a partir do recebimento de energia (calor latente, LE), abrangendo a evaporação em corpos d'água abertos e na superfície terrestre, onde inclui a evaporação da água do solo e da água interceptada pela vegetação e a transpiração das plantas (DAVIE, 2008). A Figura 4 apresenta os principais componentes da evapotranspiração. Normalmente, a conversão do estado líquido para o gasoso da água acarreta na absorção de energia, o que resulta na redução de temperatura da superfície, pois a radiação líquida (R_n) que atinge a superfície terrestre é utilizada para o processo da ET, limitando a energia disponível para o aquecimento da atmosfera, ou seja, limita o calor sensível (H). Em áreas alagadas ou cultivos agrícolas irrigados, aproximadamente 70% da R_n é utilizada na forma de LE (ZHANG et al, 2016). A Figura 5 mostra esquema do balanço de energia em uma superfície uniforme.

Na hidrologia, é um processo que remove grandes quantidades de água do solo e das plantas, representando 2/3 da quantidade de água precipitada global sobre os continentes (ALLEN et al., 2007; FISHER et al., 2017). Dessa forma, sua quantificação torna-se essencial para a realização, de forma mais acurada, da gestão de recursos hídricos, projetos de irrigação, balanços hídricos, monitoramentos de secas (ALLEN et al., 2007; LIOU E KAR, 2014); previsão climática, balanços energéticos (ZHANG et al., 2016), agricultura de precisão (MAHOUR et al., 2017) e estudos sobre o uso água subterrânea e a regulação do uso de água (JAAFAR et al, 2022). Normalmente, as estimativas de ET são realizadas por meio de lisímetros, *eddy covariance* ou razão de Bowen em estações micrometeorológicas (LONG et al., 2011). Entretanto, tais medições são acuradas para áreas locais, apresentando alto custo e demanda técnica. Há ainda métodos de estimativas de ET utilizando dados climáticos através de estações meteorológicas, entretanto para obtenção de ET em escalas maiores, é


necessário interpolar espacialmente dados de uma rede de estações pouco densa para uma escala regional, sendo a acurácia prejudicada, principalmente quando tem-se uma alta heterogeneidade no uso do solo (CHEN E KUSTAS, 2019).

Figura 4 - Principais componentes e sua contribuição na evapotranspiração.



Fonte: Adaptado de Miralles et al. (2020).

Figura 5 - Balanço energético de superfície homogênea. R_n é a radiação líquida; LE é o calor latente; H é o calor sensível; S_t e P são as energias armazenadas em processos físicos e bioquímicos, respectivamente; e A_{in} e A_{out} são as energias que entram no sistema.



Fonte: Adaptado de Shuttleworth (2012).

Dessa forma, a obtenção de estimativas de ET por sensoriamento remoto visa suprir essa demanda de dados, em função da natureza pontual de suas medições *in situ* (LIOU E KAR, 2014). Informações das bandas visíveis, infravermelho próximo e infravermelho termal podem ser utilizadas para obter variáveis da superfície e atmosfera (e.g. T_s e NDVI) (LONG et al., 2011). Nesse sentido, os modelos podem ser divididos naqueles baseados em índices vegetacionais (e.g. MOD16, GLEAM e PT-JPL) e baseados na T_s (e.g. SEBAL, METRIC e ALEXI) (LAIPILT et al., 2021). Em relação aos métodos baseados em T_s , técnicas de balanço de energia são utilizadas para o cálculo da ET a partir de dados de satélite (ALLEN et al., 2007). O cálculo é realizado pela equação apresentada a seguir, onde a energia consumida pela ET é representada pelo residual do balanço energético (ALLEN et al., 2007; LIOU E KAR, 2014).

$$LE = R_n - G - H \quad (\text{Equação 23})$$

onde LE é o calor latente consumido pela ET, R_n é a radiação líquida, G é o calor sensível perdido para solo, e H é o calor sensível perdido para a atmosfera, sendo estes parâmetros normalmente expressos em W/m^2 (BASTIAANSEN et al., 1998; ALLEN et al., 2007). R_n e G são calculados usando variáveis como albedo, T_s , emissividade, NDVI, temperatura do ar e pressão de vapor (LONG et al., 2011).

A base do SEBAL é o balanço energético instantâneo da superfície (Equação 24), onde o residual deste (i.e. calor latente) é utilizado para calcular a fração evaporativa (Equação 25) e posteriormente estimar a ET diária (Equação 26) (conforme Laipelt et al., 2021).

$$LE = R_n - H - G \quad (\text{Equação 24})$$

$$\Lambda = LE / (R_n - G) \quad (\text{Equação 25})$$

$$ET_{24h} = \Lambda R_{n24h} / \lambda \quad (\text{Equação 26})$$

Nas equações apresentadas, LE é o calor latente; H é o calor sensível; R_n é a radiação líquida; G é o fluxo de calor para o solo; Λ é a fração evaporativa; λ é o calor latente de vaporização da água; R_{n24h} é a radiação líquida diária; e ET_{24h} é a

evapotranspiração diária. Os valores de R_n e G são obtidos pelas seguintes equações.

$$R_n = (1 - \alpha)R_s \downarrow + R_l \downarrow - R_l \uparrow - (1 - \varepsilon_0)R_l \downarrow \quad (\text{Equação 27})$$

$$\frac{G}{R_n} = \alpha(T_s - 273,15)(0,0038\alpha + 0,0074\alpha^2)(1 - 0,98NDVI^4) \quad (\text{Equação 28})$$

Nestas equações, α é o albedo da superfície; $R_s \downarrow$ é a radiação de ondas curtas de entrada; $R_l \downarrow$ é a radiação de ondas longas de entrada; $R_l \uparrow$ é a radiação de ondas longas de saída; ε_0 é a emissividade termal da superfície. T_s é a temperatura de superfície e é calculada pela seguinte equação.

$$T_s = \frac{K_2}{\ln \left[\left(\frac{\varepsilon_{nb} K_1}{L_t} \right) + 1 \right]} \quad (\text{Equação 29})$$

K_1 e K_2 são constantes obtidas das propriedades das imagens Landsat; ε_{nb} é a emissividade banda estreita (*narrow band*); L_t é a radiância termal corrigida da superfície. A T_s também é corrigida em função do relevo, fazendo uso de dados do SRTM (*Shuttle Radar Topography Mission*), conforme equação 30.

$$T_{scorr} = T_{sdem} + \frac{[G_{sc} * d_r * \tau_{sw} (\cos \theta_{decliv} - \cos \theta_{plano})]}{\rho * 1004 * 0,05} \quad (\text{Equação 30})$$

Nesta equação, G_{sc} é a constante solar; d_r é a distância relativa inversa entre a Terra e o Sol; τ_{sw} é a transmissividade da atmosfera; θ_{decliv} é o ângulo solar incidente para a declividade do terreno; e θ_{plano} é o ângulo solar incidente para um terreno plano e ρ é a densidade do ar.

A estimativa de H é realizada por meio de um processo iterativo, visto que H e a resistência aerodinâmica para transporte turbulento de calor (r_{ah}) são desconhecidos. Tal processo é realizado pela equação 31, selecionando-se pixels frios e quentes (pixels âncoras), sendo assumido uma relação linear entre T_s e dT (Equação 32).

$$H = \rho a * c_p * dT / r_{ah} \quad (\text{Equação 31})$$

$$dT = a + bT_s \quad (\text{Equação 32})$$

Aqui, C_p é a capacidade específica de calor; r_{ah} é a resistência aerodinâmica para transporte turbulento de calor nas superfícies de nas altitudes z_1 e z_2 , e dT é o gradiente de temperatura.

Por fim, r_{ah} é calculado pela equação 33. E o valor da velocidade de fricção (u) é calculado pela equação demonstrada logo em seguida. Nelas, k é a constante de von Karman; u_{200} é a velocidade do vento na altitude 200 m; e z_{om} é a rugosidade da superfície.

$$r_{ah} = \frac{\ln \frac{z_1}{z_2}}{u * k} \quad (\text{Equação 33})$$

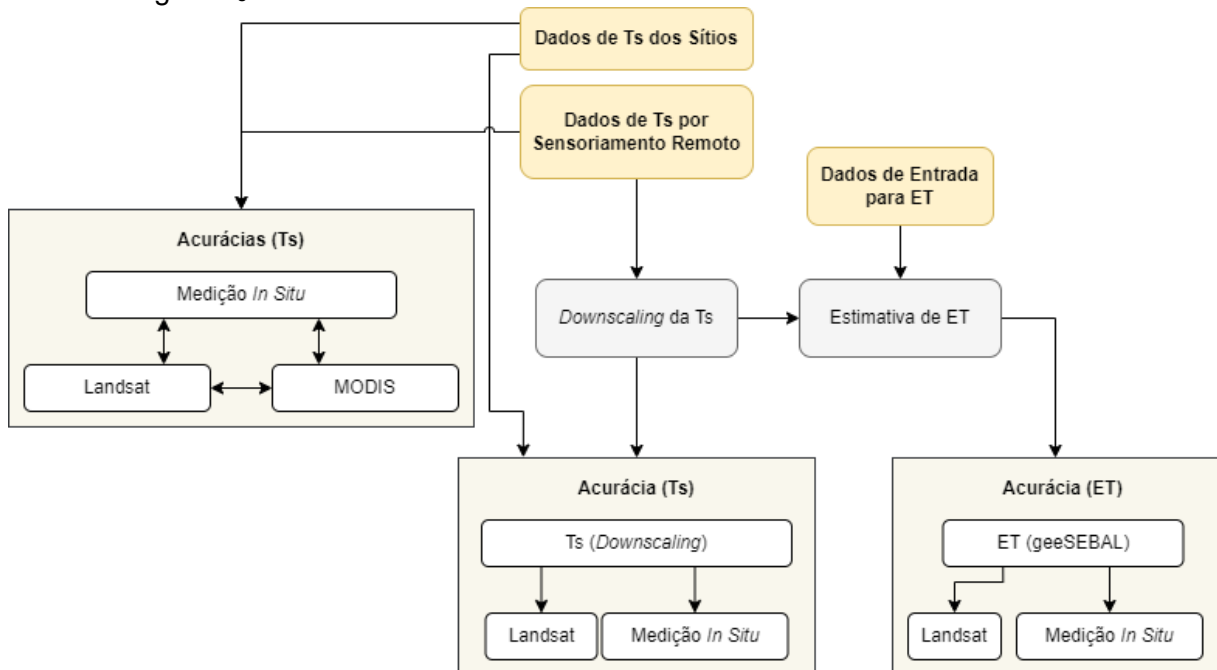
$$u = \frac{u_{200} k}{\ln \left(\frac{200}{z_{om}} \right)} \quad (\text{Equação 34})$$

Modelos como o SEBAL foram desenvolvidos para simular os fluxos de energia entre superfície e atmosfera incorporando dados de sensoriamento remoto e poucos dados *in situ* (BASTIAANSSEN et al., 1998a, 1998b apud LONG et al., 2011). Além disso, o modelo SEBAL assume uma relação linear entre a diferença da temperatura do ar próxima à superfície e a T_s (TANG et al., 2013). O modelo é muito utilizado na estimativa de consumo de água da vegetação natural e culturas agrícolas, escassez de água em bacias hidrográficas, monitoramento de áreas irrigadas e assistência na gestão de recursos hídricos (ALLEN et al., 2007; BASTIAANSSEN et al., 2005 apud LONG et al., 2011).

3 MATERIAIS E MÉTODOS

O *downscaling* das imagens MODIS e Landsat de T_s foi realizado em 4 orbitas-ponto Landsat (5 e 8)¹, onde há medições *in situ* de T_s e ET em 3 sítios. Os resultados foram comparados com as próprias imagens Landsat e com as medições *in situ*. Além disso, comparações entre as T_s das imagens MODIS, Landsat e as medições de temperatura *in situ* também foram realizadas para conhecer o viés existente entre tais dados. Por fim, com os dados obtidos por meio do *downscaling*, estes foram utilizados no geeSEBAL para obter estimativas de alta resolução espacial e temporal, sendo posteriormente avaliado sua acurácia comparando os resultados com as medições *in situ* e as imagens Landsat. O detalhamento destes tópicos é apresentado nos itens a seguir, sendo apresentado um resumo gráfico na Figura 6.

Figura 6 - Fluxograma dos procedimentos adotados neste estudo para o desenvolvimento do *downscaling* de T_s e da estimativa de ET.



3.1 Descrição dos sítios amostrados

Os sítios amostrados estão localizados no estado do Rio Grande do Sul (Brasil) e fazem parte da rede de estações micrometeorológicas SULFLUX (Rede Sul

¹ Imagens Landsat 7 não foram consideradas devido ao erro de escaneamento (Scan Line Error).

Brasileira de Fluxos Superficiais e Mudanças Climáticas). O sítio SMA está localizado no município de Santa Maria. Visto que o sítio SMA abrange duas orbitas-ponto do Landsat, este será denominado como SMA1 para a órbita/ponto 223/80 e SMA2 para a órbita/ponto 223/81 nas situações onde for necessário diferenciar a cena. O sítio PAS mensura a temperatura em superfície, da mesma forma que o sítio SMA, porém no município de Pedras Altas. Já o sítio PRS, localizado no município de Paraíso do Sul. Um resumo das características dos locais amostrados é apresentado na Tabela 1, sendo disposto na Figura 7 suas localizações.

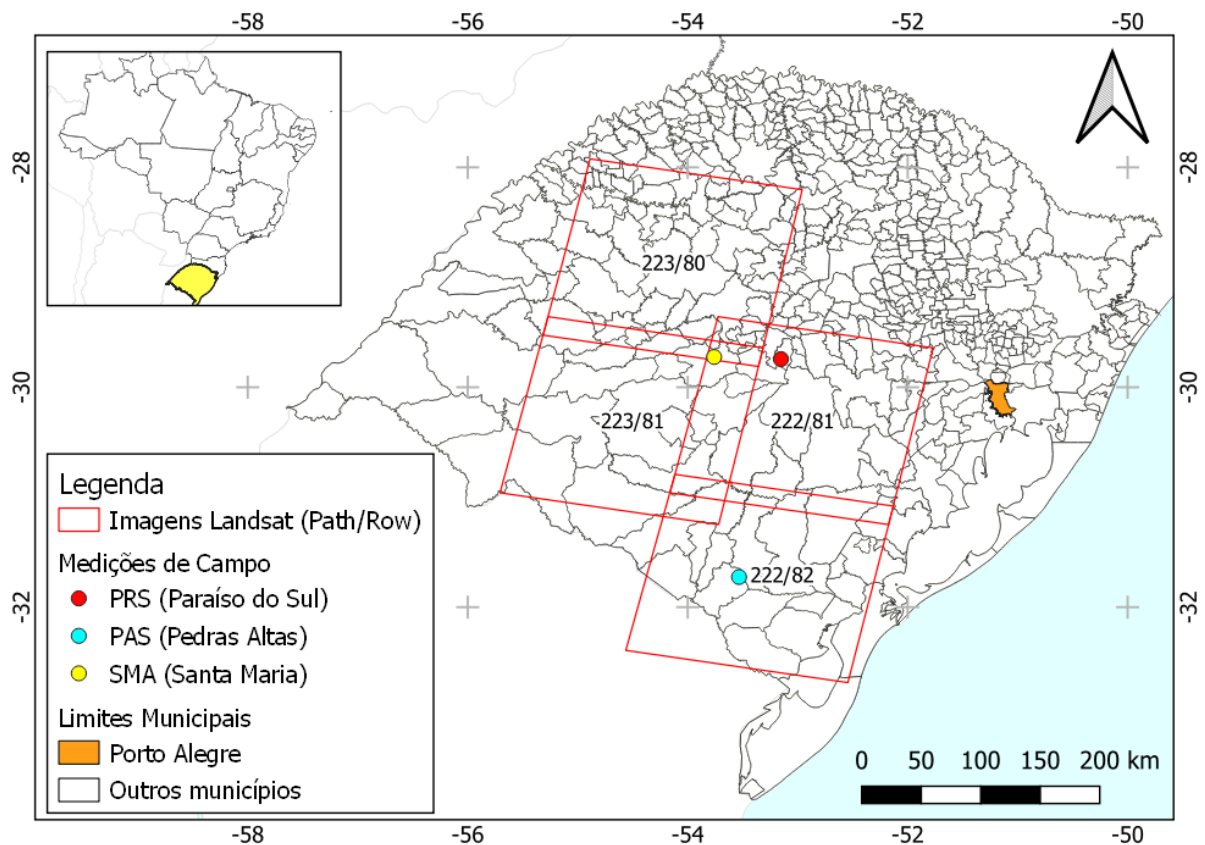
Tabela 1 - Descrição das características dos sítios analisados.

Parâmetro	SMA	PAS	PRS
Município	Santa Maria	Pedras Altas	Paraíso do Sul
Coordenadas ¹	-53,76 E / -29,72 S	-53,53 E / -31,72 S	-53,15 E / -29,74 S
Elevação ^{2,3}	88 m	395 m	108 m
Uso do Solo ⁴	Formação Campestre	Formação Campestre	Lavouras Temporárias
Tipo de Solo	Planossolo Háplico Eutrófico ² ; Argissolo Vermelho ⁵	Neossolos e Cambissolos ² ; Argissolo Vermelho-Amarelo ⁵	Planossolo Háplico ⁵
Direção Principal do Vento ^{2,3}	Leste	Sudeste	Sudeste
Orbita/Ponto ⁶	223/80 e 223/81	222/82	222/81

¹ Coordenada geográfica WGS84 (EPSG: 4326); ² Conforme Rubert et al. (2018); ³ Conforme Souza et al. (2019); ⁴ Conforme Projeto MapBiomias (2021); ⁵ Conforme Projeto RADAMBRASIL (2018); ⁶ Path e row da imagem Landsat disponível.

O sítio SMA apresenta solo profundo com alta capacidade de retenção de água, enquanto PAS tem um solo raso, arenoso e pedregoso (presença de fragmentos de rochas), com baixa retenção de água (RUBERT et al., 2018). No sítio PRS, os solos são utilizados para cultivo de arroz por inundação (SOUZA et al., 2019).

Figura 7 - Localização dos sítios de medições de T_s e ET.



A descrição do uso do solo do entorno (raio de 500m) dos sítios analisados foi realizada para avaliar a heterogeneidade local (Tabela 2). Esta análise visa subsidiar a comparação dos dados de campo com aqueles obtidos com os das imagens de satélite. As coberturas vegetais e usos dos solos obtidas são descritas a seguir, conforme Souza et al. (2020):

- Formação Florestal: Predomínio de espécies arbóreas com dossel contínuo e com maior densidade;
- Formação Campestre: Predomínio de um estrato herbáceo, incluindo porções com espécies arbustivas e herbáceas;
- Infraestrutura Urbana: Áreas urbanas propriamente ditas;
- Soja: Áreas utilizadas para o plantio de soja;
- Outras Lavouras Temporárias: Áreas utilizadas para diferentes tipos de lavouras temporárias;
- Pastagem: Pastagens naturais ou artificiais utilizadas para atividades agropecuárias;

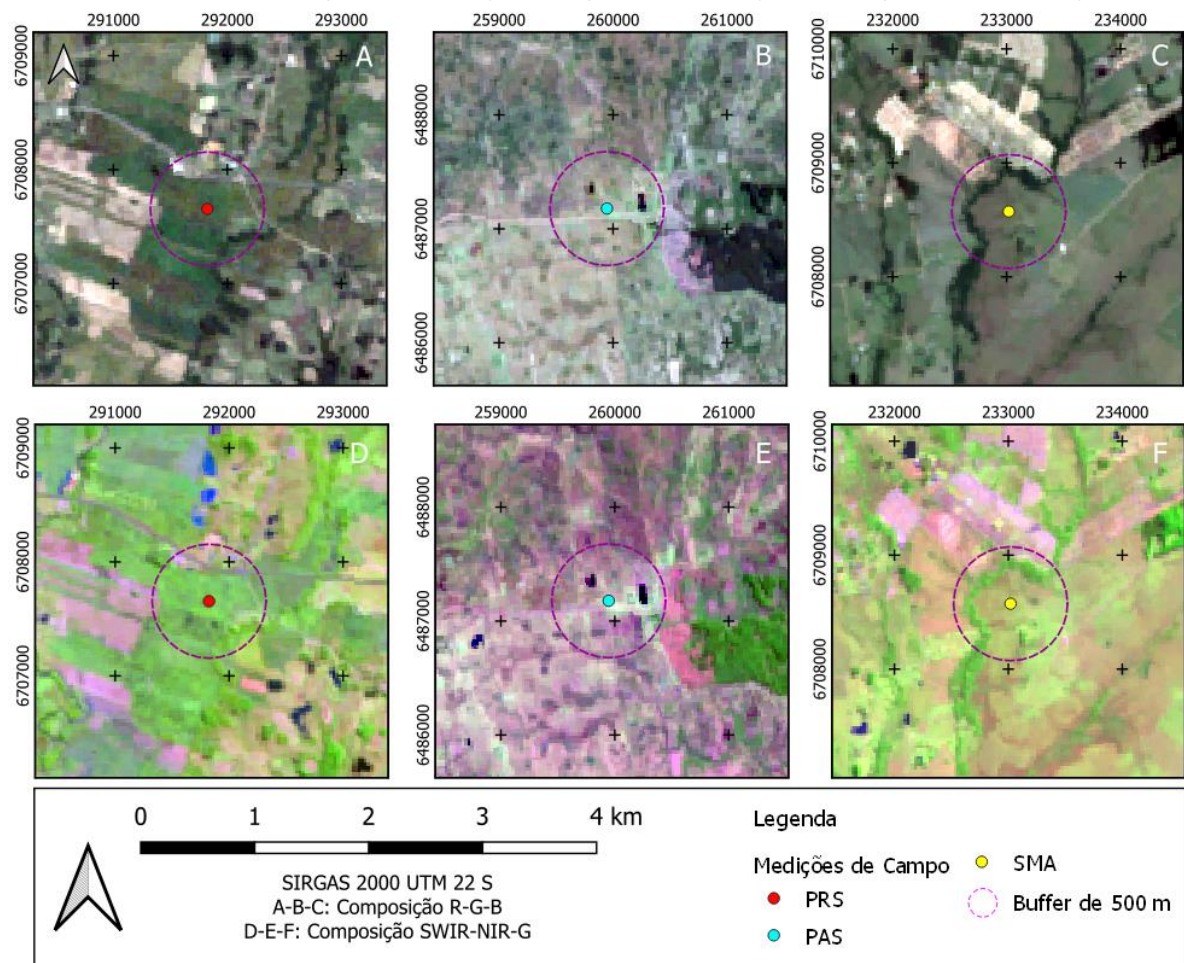
- Mosaico de Agricultura e Pastagem: Locais onde não foi possível distinguir pastagem de agricultura;
- Outras Áreas não Vegetadas: Áreas urbanas, de mineração ou solos expostos não classificados como pastagem ou formação campestre;
- Floresta Plantada: Espécies arbóreas plantadas para uso comercial.

Tal descrição foi obtida por meio das imagens classificadas do Projeto MapBiomas. Maiores detalhes sobre a metodologia do Projeto MapBiomas podem ser vistos em Souza et al. (2020). A Figura 8 apresenta as imagens Landsat 5 e 8 (composições médias para os intervalos disponíveis de datas) para ilustrar tais usos.

Tabela 2 – Percentual médio do uso do solo no entorno (raio de 500 m) das estações de amostragem SMA (Santa Maria), PAS (Pedras Altas), e PRS (Paraiso do Sul) no seu período de disponibilidade de dados.

Uso do Solo	Área média (%)		
	SMA	PAS	PRS
Formação Florestal	16,94	1,03	3,08
Formação Campestre	49,31	98,20	-
Infraestrutura Urbana	4,54	-	-
Soja	11,83	-	0,03
Outras Lavouras Temporárias	17,83	0,46	71,54
Pastagem	-	-	6,28
Mosaico de Agricultura e Pastagem	-	-	15,90
Outras Áreas Não Vegetadas	-	-	3,17
Floresta Plantada	-	0,32	-

Figura 8 – Composição das bandas RGB (Colorida) e SWIR-NIR-G das imagens Landsat no entorno dos sítios SMA (Santa Maria), PAS (Pedras Altas), e PRS (Paraíso do Sul).



De modo geral, as áreas no entorno das estações apresentaram pouca variação ao longo dos anos. Entretanto, cabe salientar as seguintes variações ocorridas no entorno do sítio SMA: Ligeiro incremento da área de infraestrutura urbana ao longo do período disponível de estudo, e redução da área classificada como agricultura.

Com relação ao clima nas áreas de estudo, a classificação de Köppen para a região é o grupo Cfa, clima subtropical úmido com verão quente e sem estação seca (RUBERT et al., 2018; SOUZA et al., 2019). A Tabela 3 apresenta as médias anuais de diferentes variáveis climatológicas obtidas a partir do Atlas Climático do Rio Grande do Sul (MATZENAUER et al., 2011).

Tabela 3 – Estimativa das médias anuais das variáveis climatológicas nas estações de amostragem SMA (Santa Maria), PAS (Pedras Altas), e PRS (Paraíso do Sul).

Variável	SMA	PAS	PRS
Temperatura Média do Ar (°C)	20	18	20
Média de Temperatura Máxima (°C)	25	23	25
Média de Temperatura Mínima (°C)	17	12	17
Precipitação Pluviométrica (mm)	1.800	1.600	1.900
Umidade Relativa do Ar (%)	70	70	73
Evapotranspiração Potencial (mm)	940	850	940

Fonte: Adaptado de Matzenauer et al., 2011.

3.1.1 Medições em campo para das estimativas de T_s e ET

As medições de T_s nos sítios de SMA e PAS foram realizadas por meio de radiômetros infravermelhos SI-111 (Apogee Instruments), obtendo-se assim a temperatura de superfície (*skin temperature*). No caso do sítio PRS, a medições de temperatura foram realizadas numa profundidade² de 2 cm por meio de sensores termais do tipo STP01 (Hukseflux).

As medições de temperatura em todos os sítios são realizadas a cada 30 minutos. O intervalo de datas com medições disponíveis de T_s e conseqüentemente ET é de 12/11/2014 à 23/10/2019 para o sítio SMA; 01/09/2014 à 01/09/2016 para o sítio PAS; e 02/07/2003 à 22/07/2004 para o sítio PRS. A Figura 9 mostra as estações existentes nos sítios PAS e PRS.

² Diante da escassez de dados, optou-se por utilizar tais medições de temperatura em profundidade neste estudo.

Figura 9 – Estações micrometeorológicas nos sítios de Pedras Altas (PAS) (Esquerda) e Paraíso do Sul (PRS) (Direita).



Fonte: Débora Regina Roberti (2022).

As medições de ET nos sítios amostrados foram obtidas por meio do método *Eddy Covariance*, conforme equação 35, a partir de medições de LE de alta frequência. O fechamento do balanço energético foi realizado por meio da razão de Bowen (Equação 36), conforme Twine et al. (2000), distribuindo a energia residual disponível entre H e LE (Equações 37 e 38). Salienta-se que nenhum preenchimento de dados foi realizado, sendo a ET diária estimada somente em dias com mais de 75% dos dados disponíveis. Uma descrição detalhada dos equipamentos utilizados para as medições dos sítios SMA e PAS pode ser vista em Rubert et al. (2022) e para o sítio PRS, Souza et al. (2019). A Tabela 4 apresenta um resumo dos equipamentos das estações micrometeorológicas usadas.

$$ET_{24h} = LE/\lambda \quad (\text{Equação 35})$$

$$\beta = H/LE \quad (\text{Equação 36})$$

$$H = \beta(Rn - G)/1 + \beta \quad (\text{Equação 37})$$

$$LE = (Rn - G)/1 + \beta \quad (\text{Equação 38})$$

Tabela 4 – Equipamentos utilizados nas medições de campo nos sítios SMA (Santa Maria), PAS (Pedras Altas), e PRS (Paraíso do Sul).

Variável	Equipamento	Sítios
Componentes da velocidade do vento	Anemômetros Wind Master Pro e IRGASON	SMA
	Anemômetros CSAT3	PAS; PRS
Temperatura do ar	Termohigrômetro HMP155	SMA; PAS
	Termohigrômetro HMP45C-L	PRS
Concentração de H ₂ O	Analisador de gases LI-7500 e IRGASON	SMA; PAS
	Analisador de gases LI-7500	PRS
Umidade relativa	Termohigrômetro HMP155	SMA; PAS
	Dados do LI-7500 e CSAT3	PRS
Precipitação	Pluviômetro TR525USW	SMA; PAS
	Pluviômetro TB4	PRS
Radiação líquida	Radiômetro CNR4	SMA
	Radiômetro CNR2	PAS
	Radiômetro NR Lite	PRS
Radiação global	Radiômetro CNR4	SMA
	Piranômetro Li 200S	PAS
	Piranômetro CMB6	PRS
Fluxo de calor no solo	Sensor termal HFP01	SMA; PAS
	Sensor termal HFP01SC-L	PRS
Umidade do solo	Sonda TDR CS616	SMA; PAS
Temperatura do solo	Sensor termal T108	SMA; PAS
	Sensor termal STP01 Hukseflux	PRS

Fonte: Adaptado de Rubert et al. (2022) e Souza et al. (2019).

3.2 Métodos de Obtenção de T_s

As imagens MODIS de T_s apresentam resolução espacial de 1 km e temporal diária. No GEE, a T_s está disponível no *dataset* denominado “*MOD11A1.006 Terra Land Surface Temperature and Emissivity Daily Global 1km*”, especificamente na banda ‘LST_Day_1km’. A aquisição da hora da passagem do satélite foi feita usando a banda ‘Day_view_time’, permitindo a interpolação das medições *in situ* para coincidir com a hora da passagem do satélite. Além disso, a análise da qualidade dos pixels, por meio da banda ‘QC_Day’, foi realizada de forma a obter somente pixels com erros na T_s inferiores à 1 K.

Nas imagens Landsat (Coleção 1) no GEE, as bandas utilizadas para obter a T_s (i.e. B6 no Landsat 5 e B10 no Landsat 8) apresentam resolução espacial de 30 m (reamostrado de 90 m) e temporal de 16 dias. Por tratarem-se de temperatura de brilho, três métodos para obtenção da T_s das imagens Landsat 5 e Landsat 8 foram

testados tanto para avaliar sua acurácia com as medições *in situ* quanto na aplicação do *downscaling*. A lista a seguir descreve os métodos utilizados para cálculo da T_s no Landsat, sendo também apresentados as siglas que serão adotadas para sua representação ao longo deste estudo:

- Jiménez-Munoz e Sobrinho (JM&S): Método baseado nos trabalhos de Jimenez-Munoz et al. (2009) e Jimenez-Munoz et al. (2014), onde é aplicado algoritmo de banda única (*Single-channel*) para obtenção da T_s ;
- geeSEBAL (GS): Método baseado no trabalho de Artis e Carnahan (1982) e Laipelt et al. (2021), onde a T_s é obtida por meio da inversão da Lei de Planck;
- Ermida et al (ERM): Método baseado no trabalho de Ermida et al. (2020), onde foi utilizado o algoritmo de janela única estatístico (*Statistical Mono-Window*) desenvolvido pela *Climate Monitoring Satellite Application Facility*.

Salienta-se que para as imagens Landsat 5, no método JM&S, foram usados os coeficientes atmosféricos derivados da base de dados SAFREE, visto que, conforme demonstra Parastatidis et al. (2017), estes apresentaram menores erros. Para o Landsat 8, os coeficientes de Jimenez-Munoz et al. (2014) foram utilizados. Além disso, a hora de passagem dos satélites Landsat foi obtida por meio da propriedade 'system:time_start' para interpolar as medições *in situ*. Por fim, a remoção de pixels com nuvens ou sombras nas imagens foi realizada por meio da banda 'pixel_qa'. A Tabela 5 apresenta a descrição dos dados utilizados e disponíveis no GEE.

Tabela 5 - Descrição dos dados disponíveis no GEE e utilizados no *downscaling* da T_s .


Produto	GEE ID	Bandas/Propriedades	Resolução
MODIS	MODIS/006/MOD11A1	LST_Day_1km; QC_Day; Day_time_view	1000 m
Landsat 8 OLI/TIRS	LANDSAT/LC08/C01/T1_SR	B10; pixel_qa; system:time_start	30* m
Landsat 5 ETM+	LANDSAT/LT05/C01/T1_SR	B6; pixel_qa; system:time_start	30* m

* A resolução espacial de todas as bandas das imagens Landsat são reamostradas para 30 m.

3.3 Comparação com dados existentes

A presença de nuvens pode prejudicar significativamente as comparações entre as medições in situ e aquelas obtidas por meio de sensoriamento remoto. Desta forma, na análise de T_s das imagens Landsat e sua comparação com as medições in situ, inspeções visuais foram realizadas caso a diferença entre elas fosse muito elevada. A inspeção visual ocorreu usando as imagens Landsat, MODIS termal (i.e. MOD11A1) e MODIS espectral (MOD09GA). Nas situações em que se observou a presença significativa de nuvens no entorno do pixel do sítio amostrado, assim como nuvens na imagem espectral do MODIS (e.g. Figura 10), foram retiradas essas datas da avaliação. As datas resultantes deste procedimento são apresentadas na Tabela 6.

Figura 10 – Exemplo de cobertura de nuvens nas imagens Landsat (Topo) e MODIS (Inferior) adquiridas na data 01/01/2019 para o sítio SMA (Santa Maria), em vermelho.



Fonte: GEE, 2021.

Tabela 6 - Datas utilizadas na validação dos dados de campo com dados Landsat 5 e 8.

Sítio	Datas disponíveis	N
SMA	28/11/2014; 05/12/2014; 07/05/2015; 27/08/2015; 12/09/2015; 18/01/2016; 11/11/2017; 24/02/2018; 27/02/2019; 19/06/2019; 21/07/2019.	11
PAS	27/10/2014; 28/11/2014; 12/09/2015; 15/11/2015; 18/01/2016.	5
PRS	10/08/2003; 13/10/2003; 05/03/2004; 06/04/2004; 09/06/2004; 11/07/2004.	6

Na comparação entre imagens Landsat e MODIS, após a agregação dos pixels das imagens Landsat para obter a mesma resolução espacial do MODIS, foram selecionadas imagens com mais de 50% de pixels disponíveis nos limites das orbitas-pontos do Landsat. A Tabela 7 mostra as datas disponíveis onde a cobertura de nuvens (no caso do Landsat) e existência de pixels (no caso do MODIS) eram superiores à 50%, sendo estas datas utilizadas na análise proposta.

Tabela 7 - Datas utilizadas na comparação entre as imagens Landsat e as imagens MODIS.

Sítio	Datas disponíveis	N
SMA*	05/12/2014; 22/01/2015; 07/02/2015; 28/04/2015; 15/06/2015; 21/10/2015; 06/11/2015; 08/12/2015; 13/03/2016; 19/07/2016; 21/09/2016; 24/11/2016; 27/01/2017; 20/06/2017; 11/11/2017; 27/11/2017; 30/01/2018; 15/02/2018; 07/06/2018; 26/08/2018; 18/02/2019; 25/05/2019; 26/06/2019; 13/08/2019; 29/08/2019; 30/09/2019	26
PAS	25/09/2014; 27/10/2014; 28/11/2014; 07/05/2015; 27/08/2015; 12/09/2015; 28/09/2015; 15/11/2015; 18/01/2016; 10/06/2016; 13/08/2016	11
PRS	10/08/2003; 13/10/2003; 05/03/2004; 09/06/2004; 11/07/2004	5

Obs.: SMA (Santa Maria); PAS (Pedras Altas); PRS (Paraíso do Sul).

* SMA1 e SMA2.

3.4 *Downscaling* da Temperatura

O procedimento de *downscaling* baseia-se em duas datas distintas e que possuam imagens MODIS e Landsat, sendo estas denominadas datas de referência (t1 para a data inicial e t3 para a data final). A partir delas, foi realizado o *downscaling* nas datas-alvo (t2), as quais apresentam uma imagem MODIS e estão inseridas no intervalo entre as duas datas de referência. Desta forma, buscou-se no GEE imagens Landsat e MODIS cujas datas coincidissem para serem utilizadas como datas de referência. Filtros de qualidade também foram utilizados, de forma a remover os pixels que apresentassem nuvens, sombras, distância inferior à 100 m de nuvens e sombras

e erro de obtenção da T_s superior à 1 K. Após a aplicação destes filtros, foram selecionadas apenas as imagens com cobertura de, no mínimo, 50% de pixels. Após a obtenção de uma lista de datas que apresentam imagens MODIS e Landsat, buscou-se datas que não estivessem muito distantes entre si, ou seja, que não ultrapassassem o intervalo de 60 dias. A definição do intervalo de 60 dias foi realizada considerando que no trabalho de Tavares (2019) e Weng et al. (2014) foram adotados os intervalos de 48 e 144 dias, respectivamente, sendo que ambos também desenvolveram métodos de *downscaling* da temperatura.

Com as datas de referência definidas, foi realizado o pré-processamento das imagens Landsat e MODIS. Nas imagens Landsat foram obtidos dados para o cálculo da T_s (tais como albedo e emissividade) nos métodos já apresentados (i.e. JM&S, GS e ERM). Nas imagens MODIS foram realizadas a reprojeção (SR-ORG:6974 - MODIS Sinusoidal para EPSG:4326 - WGS84) e reamostragem para projeção e resolução do Landsat.

Para cada data de referência, foi calculado a diferença espacial (*diff*) entre as imagens MODIS e Landsat, i.e. subtração de uma imagem pela outra (Equação 39). A diferença espacial parte do princípio de que existe uma correlação entre as imagens Landsat e MODIS, possibilitando transferir, por meio das diferenças das imagens das datas de referência, o detalhamento espacial para as imagens MODIS nas datas-alvo (LUO et al., 2018). Essa diferença pode ocorrer em função de erros de medição, geometria dos ângulos de visada e solar, ruídos ou erros sistemáticos (ZHU et al. 2010). Cabe comentar que o método de *downscaling* proposto por Luo et al. (2018) realiza a fusão espacial e temporal da reflectância de superfície, não sendo seu foco a T_s .

$$diff_{(x,y,t)} = Landsat_{(x,y,t)} - MODIS_{(x,y,t)} \quad (\text{Equação 39})$$

onde *diff* é a diferença espacial no pixel localizado nas coordenadas x,y e data t; Landsat se refere ao pixel nas coordenadas x,y e data t da imagem Landsat; e MODIS é o pixel nas coordenadas x,y e data t da imagem MODIS.

Além da diferença espacial, também se considerou a diferença temporal, visto que a diferença espacial entre as T_s das imagens Landsat e MODIS pode variar significativamente ao longo do intervalo das datas de referência. Isso se faz

necessário visto que, diferente da reflectância de superfície³, a T_s não permanece com valores similares entre uma data de referência para outra, havendo ainda outros fatores ambientais (e.g. umidade do solo) que interferem em seu valor. Dessa forma, buscou-se, entre as imagens MODIS das datas de referência, aquela que apresenta menor diferença média com a imagem MODIS da data-alvo. A data de referência que apresentar menor diferença média quando comparada com a data alvo terá maior peso, e vice-versa. A equação da diferença temporal (T_w) é baseada no trabalho de Weng et al. (2014), sendo esta apresentada na equação 36.

$$TW_{(tp)} = \frac{1/(\text{MODIS}_{tp} - \text{MODIS}_{t2})}{1/(\text{MODIS}_{t1} - \text{MODIS}_{t2}) + 1/(\text{MODIS}_{t3} - \text{MODIS}_{t2})} \quad (\text{Equação 40})$$

onde T_w é a diferença temporal na data de referência tp ($t1$ ou $t3$), MODIS são as imagens MODIS, $t2$ se refere a imagem na data-alvo e tp se refere às datas de referência $t1$ ou $t3$.

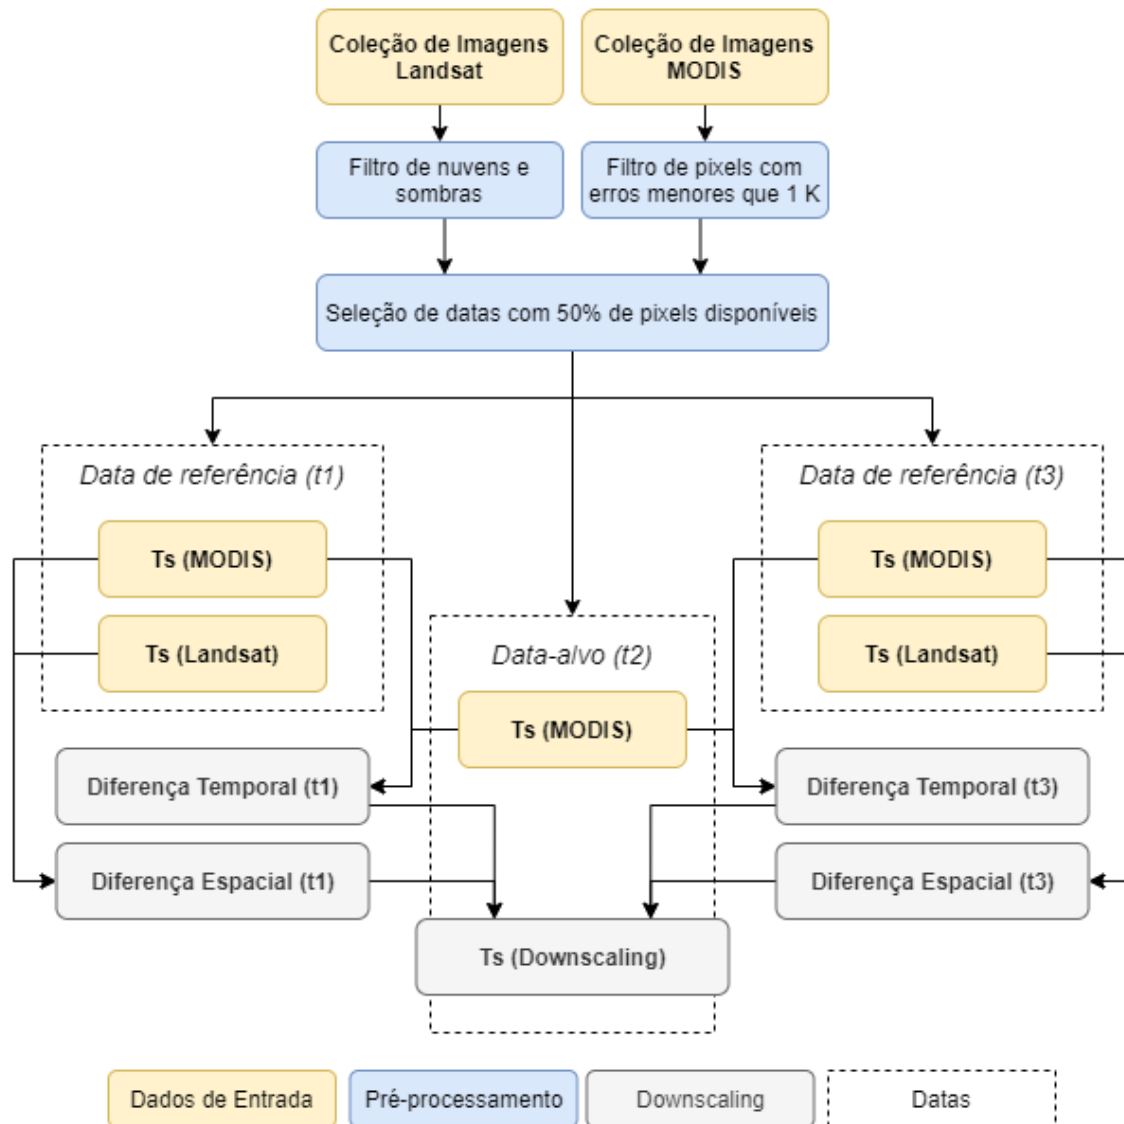
Por fim, o *downscaling* foi obtido pela multiplicação da diferença temporal e espacial para as duas datas de referência, sendo posteriormente somada à imagem MODIS na data-alvo, de forma similar ao método proposto por Luo et al. (2018). Após o procedimento, foi obtido uma imagem T_s de alta resolução espacial para a data alvo $t2$ (T_s *Downscaling*). A equação 37 e a Figura 11 apresentam esse procedimento.

$$Ts \text{ Downscaling} = Tw1 \times Diff1 + Tw3 \times Diff3 + \text{MODIS}_{t2} \quad (\text{Equação 41})$$

onde $Tw1$ e $Tw3$ são as diferenças temporais das datas de referência ($t1$ e $t3$); $Diff$ são as diferenças espaciais nas datas de referência ($t1$ e $t3$); MODIS_{t2} é a imagem MODIS na data-alvo; e Ts *Downscaling* é a imagem da T_s na data-alvo obtida por meio do *downscaling*.

³ Caso não haja mudança de uso do solo ou interferências atmosféricas em uma determinada área, imagens de reflectância de superfície tendem a ter seus valores muito similares em diferentes datas.

Figura 11 - Representação gráfica do procedimento de *downscaling* de T_s .

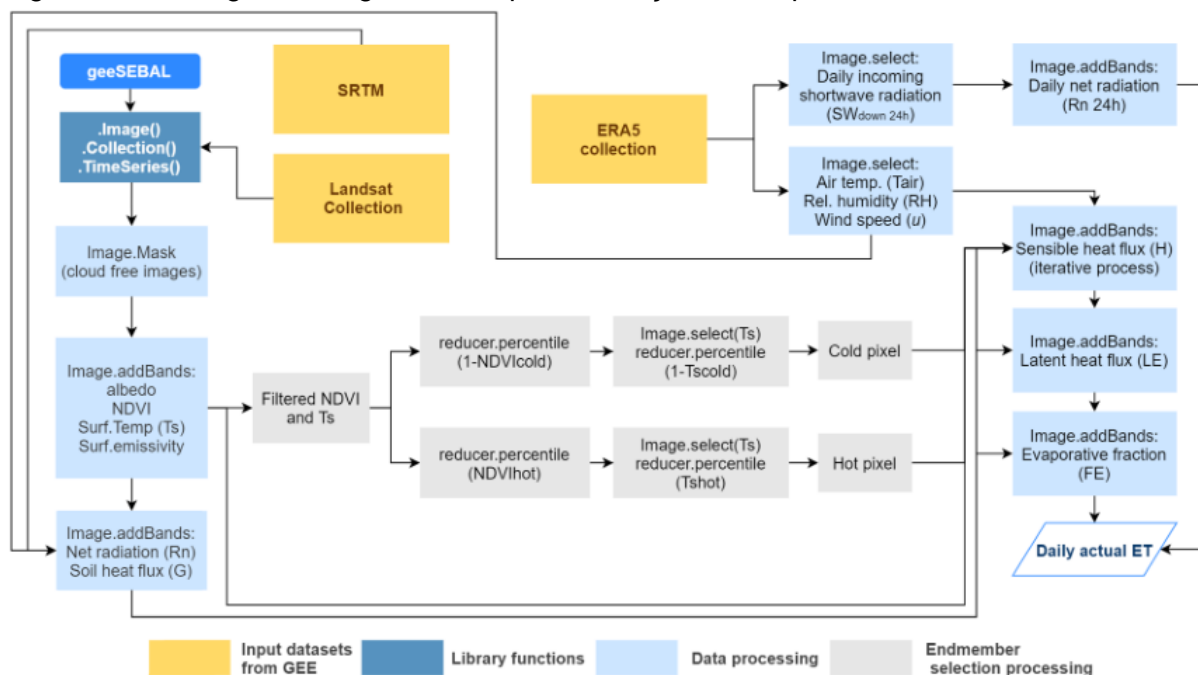


Todas essas equações e procedimentos foram implementados em *Python*, sendo utilizado o GEE para o processamento das imagens. Salienta-se que o procedimento de *downscaling* proposto não faz uso de janelas móveis, como é adotado em outros métodos (e.g. STARFM e SADFAT), em virtude da inexistência, até o momento, de opções que permitam executar tal procedimento diretamente no GEE tal como é concebido originalmente. A seleção de pixels semelhantes também não foi utilizada, pois sem a janela móvel, este procedimento deixa a imagem com muitas discontinuidades.

3.5 Séries temporais de ET

As séries temporais de ET foram obtidas por meio do algoritmo geeSEBAL, sendo a descrição deste pode ser encontrada em Laipelt et al. (2021), ou ainda, no referencial teórico desta pesquisa. De maneira geral, o algoritmo pega como entrada imagens Landsat, aplica uma máscara de nuvens e calcula os valores de albedo, NDVI, T_s , e emissividade da superfície. Deste ponto, calcula-se a radiação líquida e o fluxo de calor no solo; sendo realizado a correção da T_s em função do relevo (dados SRTM). Seleciona-se os pixels frios e quentes⁴ para o cálculo do calor sensível; o qual recebe dados do ERA5 (radiação de ondas curtas de entrada; temperatura do ar; umidade e velocidade do vento). Tais dados também são usados para o cálculo da radiação líquida. Por fim, são calculados o calor latente, fração evaporativa e a ET diária. A Figura 12 resume o processo de obtenção de ET pelo algoritmo geeSEBAL.

Figura 12 - Fluxograma do geeSEBAL para obtenção de ET por sensoriamento remoto.



Fonte: Laipelt et al. (2021).

Para o *downscaling*, foram substituídos os dados do Landsat por aqueles gerados no *downscaling* da T_s , possibilitando a estimativa da ET em alta resolução

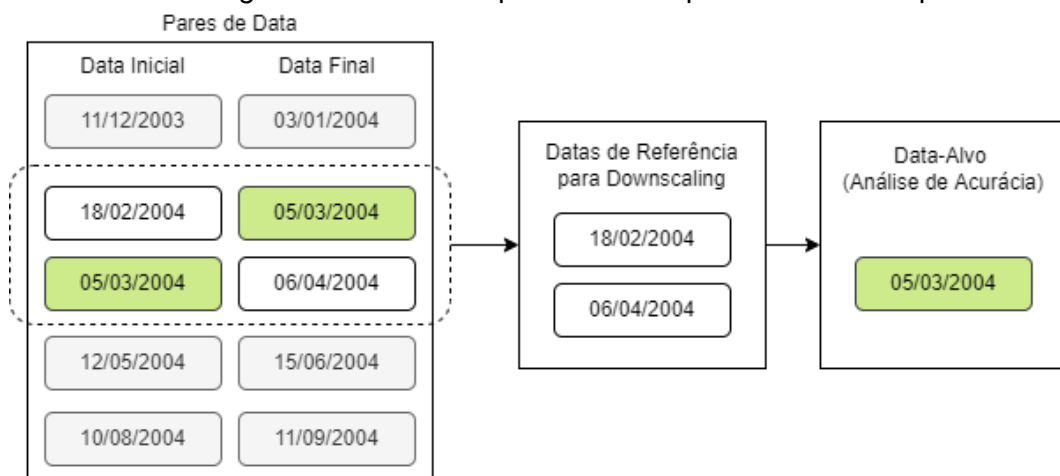
⁴ Percentil de 20% tanto para a temperatura mais fria e mais quente e 5% e 10% para NDVI mais baixo e alto, respectivamente.

espacial e temporal (30 m diário). As bandas de reflectância de superfície também são necessárias na obtenção de ET pelo geeSEBAL, sendo realizado uma interpolação linear baseada na diferença (em dias) da data-alvo e das datas de referência. Dessa forma, a data de referência mais próxima no tempo da data-alvo terá um peso maior, e vice-versa. O procedimento de *downscaling* adotado para a T_s não gera bons resultados para a reflectância de superfície, razão da adoção deste processo diferenciado.

3.6 Análise de Acurácia

As análises de acurácia foram realizadas de duas formas distintas. A primeira foi por meio da comparação das imagens obtidas com o *downscaling* diretamente com as imagens Landsat disponíveis na data-alvo. Neste processo, após a definição dos pares de datas de referência, foram selecionados dois pares de datas de referência cuja data final do primeiro par coincida com a data inicial do segundo par. Essa imagem com data disponível em ambos pares foi removida temporariamente do processo, sendo o *downscaling* realizado com a imagem da data inicial do primeiro par e a imagem da data final do segundo par. Posteriormente, a imagem removida foi utilizada para a análise de acurácia (Figura 13).

Figura 13 – Procedimento para seleção de datas com imagens Landsat para a análise de acurácia do *downscaling*. Data em verde representa data presente em dois pares de data.



A segunda forma usada para a análise da acurácia foi por meio da comparação das imagens obtidas com os dados *in situ*, especificamente com o pixel no qual o sítio se encontra.

As métricas utilizadas foram Erro Médio Absoluto (*Mean Absolute Error* - MAE), Coeficiente de Correlação (R), Viés (*Bias*) e Raiz do Erro Médio Quadrático (*Root Mean Square Error* – RMSE), os quais foram calculadas entre os dados observados (Obs) e os dados estimados (Est), conforme equações apresentadas a seguir (WILKS, 2011; MOREIRA et al., 2019):

$$MAE = \frac{1}{n} \sum_{k=1}^n |Est_k - Obs_k| \quad (\text{Equação 42})$$

$$R = \frac{\sum_{k=1}^n (Obs_k - \overline{Obs})(Est_k - \overline{Est})}{\sqrt{[\sum_{k=1}^n (Obs_k - \overline{Obs})^2][\sum_{k=1}^n (Est_k - \overline{Est})^2]}} \quad (\text{Equação 43})$$

$$Bias = \frac{1}{n} \sum_{k=1}^n (Est_k - Obs_k) = \overline{Est} - \overline{Obs} \quad (\text{Equação 44})$$

$$RMSE = \sqrt{\sum_{k=1}^n \frac{(Est_i - Obs_i)^2}{n}} \quad (\text{Equação 45})$$

Além da análise de acurácia do *downscaling*, também foi realizada avaliação do viés existente nos dados e imagens existentes. Foram comparados os dados de campo diretamente com valores respectivos valores do pixel na imagem MODIS e Landsat. Uma avaliação entre as imagens MODIS e Landsat também foi realizada. Todos esses procedimentos foram realizados com as equações já mencionadas acima.

4 RESULTADOS E DISCUSSÃO

4.1 Diferenças entre estimativas de temperatura baseadas em imagens MODIS e Dados de Campo

A análise da relação entre os dados das medições de campo e seus respectivos valores de pixels nas imagens MODIS e Landsat possibilitará compreender, para os sítios em estudo, os erros existentes em função da diferença de escalas entre as medições de T_s . Os resultados para o sensor MODIS são sintetizados na Figura 14. Mais detalhes podem ser visualizados no trabalho de Souza et al. (2021).

Figura 14 - Comparação dos dados de campo com os do sensor MODIS (Terra) durante o dia para os três sítios analisados (SMA - Santa Maria; PAS - Pedras Altas; e PRS - Paraiso do Sul) nos intervalos de datas com disponibilidade de dados.

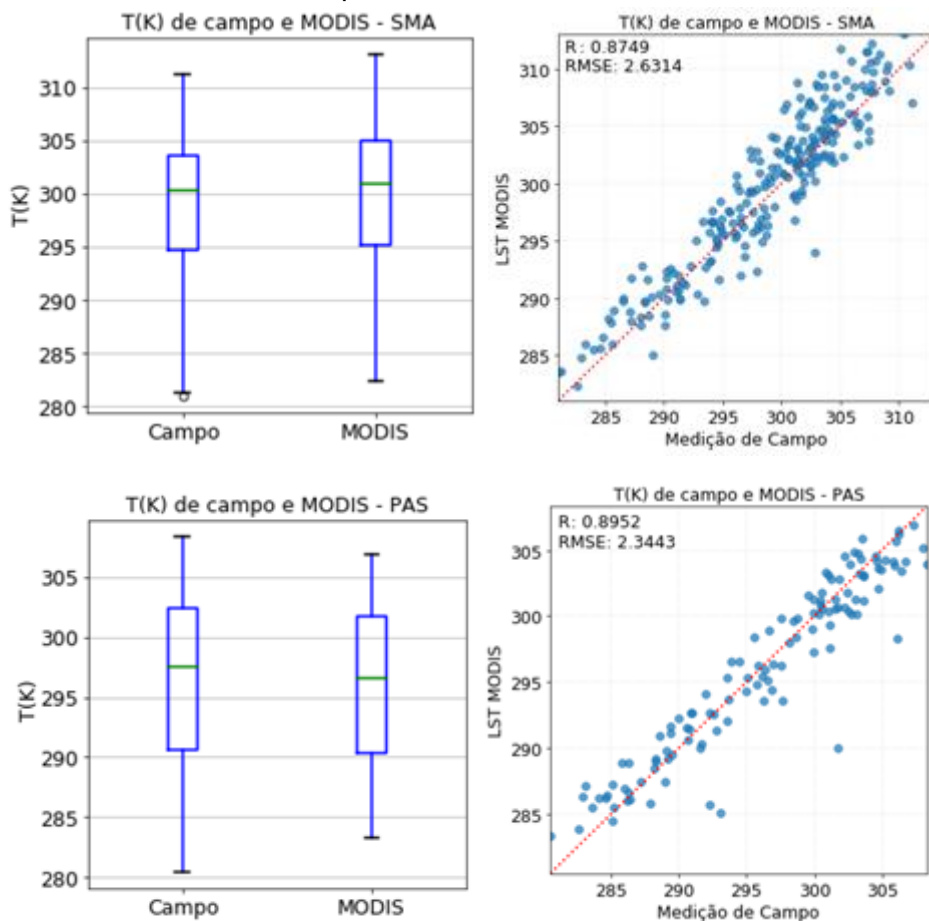
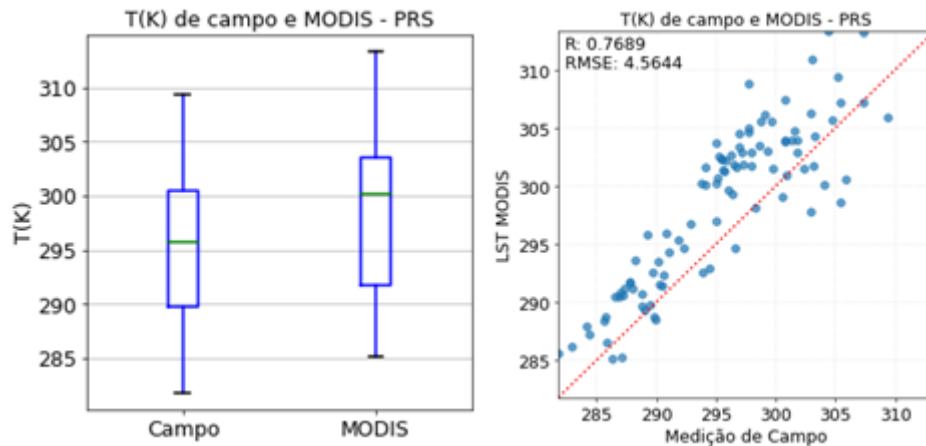


Figura 14 - Comparação dos dados de campo com os do sensor MODIS (Terra) durante o dia para os três sítios analisados (SMA - Santa Maria; PAS - Pedras Altas; e PRS - Paraíso do Sul) nos intervalos de datas com disponibilidade de dados. (Continuação)



No sítio SMA, para as 240 medições de temperatura, foi obtido um coeficiente de correlação (R) de 0,8749 e um RMSE de 2,6314. A diferença média (*bias*) apresentada entre os conjuntos de medidas foi de 0,9558 com um desvio padrão de 2,45. Para o sítio PAS, foram obtidos 121 valores de temperatura, resultando num R igual à 0,8952 e um RMSE de 2,3443. Além disso, a diferença média entre as medições foi de -0,19, com um desvio padrão de 2,33. No sítio PRS foram obtidos 97 valores de temperatura, o que resultou em um R igual à 0,7689 e um RMSE de 4,5644. A diferença média entre as medições foi de 3,12, apresentando um desvio padrão de 3,33. Tais dados são sintetizados na Tabela 8.

Tabela 8 - Resultados da acurácia entre os dados de T_s *in situ* e T_s no respectivo pixel MODIS.

Sítio	N	RMSE	Bias	r
SMA	240	2,6314	0,96	0,8749
PAS	121	2,3443	-0,19	0,8952
PRS	97	4,5644	3,12	0,7689
Geral*	458	3,0810	1,11	0,8357

Obs.: SMA (Santa Maria); PAS (Pedras Altas); PRS (Paraíso do Sul).

* Todas os sítios juntos.

Também foram realizados procedimentos para a remoção de padrões sazonais (i.e. dessazonalização) por meio da subtração da média do mês do período analisado do valor observado, seguido pela divisão pelo desvio padrão do mês. Os resultados obtidos são apresentados na Figura 15 e Figura 16.

Figura 15 – Histograma da variação das anomalias nas séries temporais de T_s para as medições de campo (SMA - Santa Maria; PAS - Pedras Altas; e PRS - Paraíso do Sul) e respectivo pixel nas imagens MODIS.




Figura 15 – Histograma da variação das anomalias nas séries temporais de Ts para as medições de campo (SMA - Santa Maria; PAS - Pedras Altas; e PRS - Paraíso do Sul) e respectivo pixel nas imagens MODIS. (Continuação)

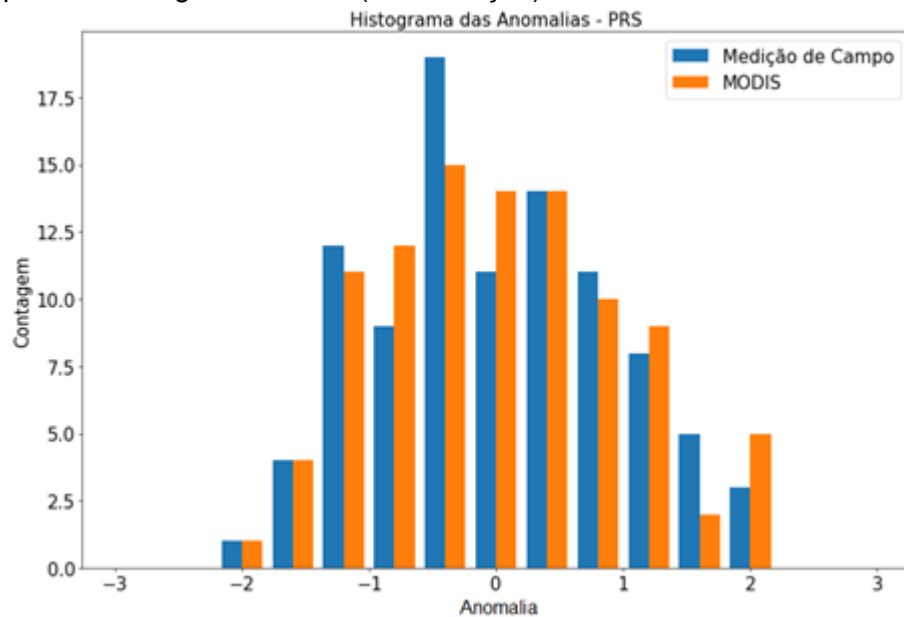



Figura 16 - Dispersão das anomalias encontradas nos dados MODIS de Ts comparadas com as medições de campo (SMA - Santa Maria; PAS - Pedras Altas; e PRS - Paraíso do Sul).



Ao observarmos a distribuição das anomalias, é possível observar que sua existência ao longo de todas as séries temporais, tanto naquelas das medições de campo quanto das imagens MODIS. Entretanto, verifica-se que em alguns momentos, tais anomalias não coincidem entre as medições, possivelmente gerando os erros observados. Embora tais medições de acurácia pareçam elevadas, é importante destacar que a diferença entre as escalas das medições (pixel do MODIS tem 1 km e a medição *in situ* registra a temperatura de forma mais pontual) interfere significativamente nos dados, bem como a profundidade do medidor (no caso do sítio PRS, que está a 2 cm de profundidade no solo), heterogeneidade do uso do solo e o

método de medição da temperatura. Outros autores já registraram tais diferenças nos procedimentos de validação dos dados dos sensores MODIS.

Na América do Norte, Wan et al. (2002) ao validarem os dados T_s dos sensores MODIS obtiveram diferenças entre -0,2 e 0,9 K ao comparar com medições feitas com radiômetros em campo. Cabe destacar um teste realizado por estes autores numa pastagem visivelmente mais úmida que outros pontos de pastagem amostrados pelos autores, resultando numa diferença de temperatura de até 7 K. Wang e Liang (2009) compararam os dados dos sítios SURFRAD (EUA) com os do sensor MODIS (durante o período noturno), encontrando diferenças de -0,2 a 1,6 e desvios padrões entre 1,5 e 2,5. Hachem et al. (2011) compararam os dados de T_s do MODIS com as temperaturas do ar (1 a 2 m de altura) e do solo (3 a 5 cm de profundidade) medidas no norte canadense e no Alaska (EUA). Os resultados, obtidos comparando as médias diárias e agrupando todas as estações analisadas, apresentaram boa correlação (R maior que 0,93 e diferença média de -1,86 °C). Entretanto, as diferenças médias variaram entre -0,51 e 5,13 °C devido à heterogeneidade da superfície no pixel MODIS.

Outros trabalhos abrangeram áreas diferentes, especialmente na busca de climas distintos. Duan et al. (2019) compararam os dados de T_s dos sensores MODIS com medições locais por meio de radiômetros instalados em diferentes pontos de monitoramento (i.e. EUA, Portugal, Namíbia e China). Os autores obtiveram RMSE que variaram entre 0,74 a 5,58 K, que variam conforme o local, a coleção comparada e o período de aquisição da medição (diário ou noturno). De forma mais direta, os autores Trentin et al. (2011) compararam os dados de T_s dos sensores MODIS com as temperaturas a 2 m de altura de estações meteorológicas do estado do Paraná (Brasil), encontrado diferenças que variavam entre -1,43 a 16,23 K, mesmo com uma boa correlação entre os dados (R entre 0,78 e 0,90).

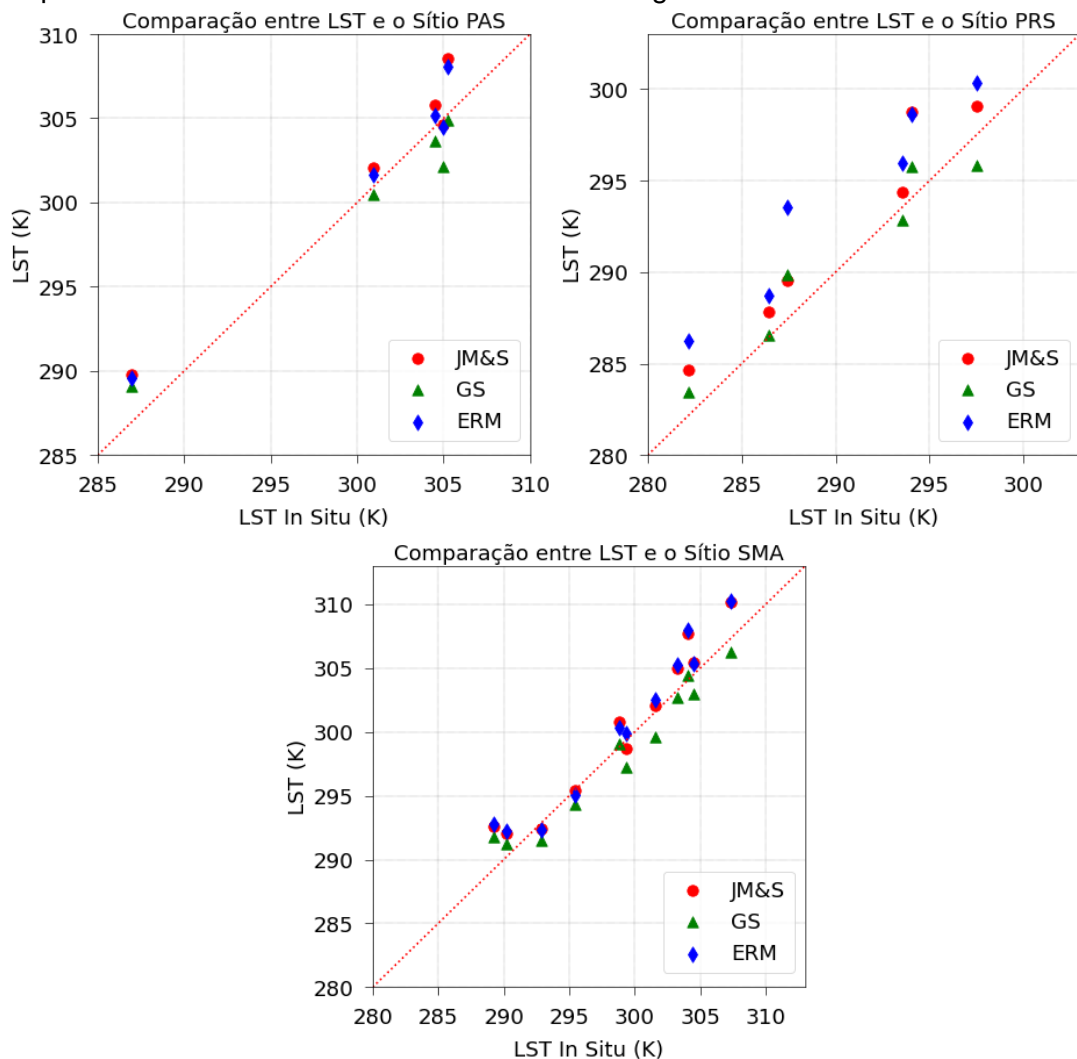
Outros trabalhos já buscam a compreensão do efeito de escala, em função da heterogeneidade dos pixels. Yu e Ma (2015) demonstram, que para sua área de estudo (China), a heterogeneidade da região levou a um efeito de escala maior nas observações. Tal efeito de escala levou aos autores obterem, em um dos seus conjuntos de dados, diferenças maiores que 3 K (entre T_s MODIS e T_s de campo) para 41,8% das observações. Liang e Wang (2019) comentam que um dos pontos críticos da validação de produtos de sensoriamento remoto é o efeito de escala ao comparar medições 'pontuais' com pixels quilométricos em áreas heterogêneas. Guillevic et al.

(2018, pg. 14) comentam que a validação, seguindo os preceitos apresentados por eles, de T_s medidas em campo devem se limitar às medições noturnas, quando as superfícies tendem a atingir um equilíbrio termal. Wang e Liang (2009) já comentavam sobre problemas da variação espacial, especialmente durante o dia.

4.2 Diferenças entre estimativas de temperatura baseadas em imagens Landsat e Dados de Campo

Assim como as imagens MODIS, a comparação com as imagens Landsat permite continuar a análise do impacto do fator de escala nos resultados de acurácia. Dessa forma, os valores obtidos nas imagens Landsat 5 e 8 foram comparados com aqueles de campo (Figura 17).

Figura 17 - Comparação das T_s medidas *in situ* com aquelas obtidas por sensoriamento remoto por meio de diferentes métodos usando as imagens Landsat.



A partir desses dados, cálculos de erro absoluto médio (MAE), raiz do erro médio quadrático (RMSE), viés (Bias) e coeficiente de correlação (r) foram realizados para avaliar a incerteza dos valores (Tabela 9).

Tabela 9 - Resultados da acurácia entre as T_s in situ e T_s das imagens Landsat.

Sítio	Sensor/Método	MAE	RMSE	Bias	r
SMA	MODIS	2,54	3,47	-1,08	0,86
SMA	JM&S	1,62	2,01	1,42	0,95
SMA	GS	1,27	1,45	-0,49	0,95
SMA	ERM	1,74	2,12	1,58	0,95
PAS	MODIS	3,36	5,46	-3,35	0,66
PAS	JM&S	1,79	2,11	1,64	0,96
PAS	GS	1,32	1,67	-0,47	0,98
PAS	ERM	1,47	1,79	1,25	0,97
PRS	MODIS	3,56	3,96	2,54	0,71
PRS	JM&S	2,17	2,51	2,17	0,94
PRS	GS	1,31	1,51	0,52	0,93
PRS	ERM	3,71	3,96	3,71	0,93
Geral*	MODIS	3,00	4,13	-0,61	0,68
Geral*	JM&S	1,81	2,18	1,67	0,96
Geral*	GS	1,29	1,52	-0,21	0,97
Geral*	ERM	2,22	2,69	2,09	0,95

Obs.: SMA (Santa Maria); PAS (Pedras Altas); PRS (Paraíso do Sul).

* Todas os sítios juntos.

Observa-se que para o sensor MODIS e as estações de forma separada, o erro absoluto médio variou de 2,54 a 3,56 K. Já o erro RMSE teve como valor mínimo 3,47 e máximo 5,46 K, com viés entre -3,35 e 2,54 K. Com as imagens Landsat, os métodos de obtenção de T_s obtiveram acurácias distintas. O método proposto por JM&S teve erro médio absoluto variando entre 1,62 a 2,17 K, com RMSE variando entre 2,01 e 2,51 K e viés de 1,42 a 2,17 K. O método utilizado em GS apresentou erro absoluto médio variando entre 1,27 e 1,32 K, com RMSE variando entre 1,45 e 1,67 K e viés

de -0,49 a 0,52 K. Por fim, o método ERM teve erro absoluto médio de 1,47 a 3,71 K, com RMSE e viés de 1,79 a 3,96 K e 1,25 a 3,71 K, respectivamente.

Observa-se que para as estações estudadas, pode-se afirmar que, de modo geral, a obtenção de T_s pelo satélite Landsat apresenta erros inferiores àqueles do MODIS, quando comparados com os dados de campo. Entre os métodos de obtenção de T_s , percebe-se que o GS apresenta os melhores resultados.


Outros autores também realizaram tais procedimentos de comparação, especialmente aqueles ao desenvolverem algoritmos para obtenção de T_s a partir das imagens Landsat. Sobrinho et al. (2004) aplicaram o algoritmo desenvolvido por Jiménez-Muñoz e Sobrinho (2003) em uma região da Espanha, comparando os dados de T_s obtidos com os de temperatura obtidos por radiossondas e pelo código MODTRAN 3.5. Seus resultados mostraram valores de RMSE de 0,93, com diferenças entre as medições entre -1,39 e 0,22. Ao comparar os dados do algoritmo com dados do Landsat, o RMSE variou entre 0,5 e 0,6.

Parastatidis et al. (2017) avaliaram diferentes combinações de parâmetros na obtenção de T_s a partir de imagens Landsat 5, 7 e 8, comparando os dados com imagens de referência como as do satélite ASTER. De modo geral, os autores verificaram que para o Landsat 5 o erro foi de 1,40 °C (com viés de -0,31) e para o Landsat 8, o erro foi de 1,31 °C (viés de 0,1), otimizando os parâmetros de entrada como coeficientes atmosféricos e método de obtenção da emissividade (que tem sua melhor performance conforme heterogeneidade da área).

4.3 Diferenças entre estimativas de temperatura baseadas em imagens Landsat e MODIS

De forma a avaliar as T_s obtidas das imagens Landsat, comparou-se elas com as imagens MODIS. Essa comparação permitiu identificar o erro associado existente para as imagens Landsat cujas orbitas pontos são: 223/80; 223/81; 222/81 e 222/82. Foram realizados cálculos de acurácia como erro absoluto médio (MAE), raiz do erro médio quadrático (RMSE), viés (BIAS) e correlação (r), onde as imagens Landsat tiveram seus pixels agregados (valor médio) para atingir o tamanho dos pixels do MODIS, sendo então, a comparação realizada pixel a pixel. A figura 18 mostra alguns exemplos de histogramas e gráficos de dispersão dos dados de temperatura obtidos.

Figura 18 – Distribuição dos valores de T_s dos pixels das imagens Landsat e MODIS para três diferentes datas e métodos de obtenção da T_s ao longo da cena Landsat.



A partir das datas obtidas, foram realizados os cálculos de acurácia já mencionados, sendo que a Tabela 10 apresenta os valores médios de acurácia obtidos.

Tabela 10 – Valores médios de acurácia entre a T_s das imagens Landsat e MODIS para todos os sítios amostrados.

Sítio	Método	MAE*	RMSE*	Bias*	r^*
SMA1	JM&S	2,65	3,05	2,12	0,64
SMA1	GS	1,65	2,00	0,03	0,63

Sítio	Método	MAE*	RMSE*	Bias*	r*
SMA1	ERM	2,80	3,17	2,16	0,63
SMA2	JM&S	1,96	2,29	1,50	0,56
SMA2	GS	1,28	1,59	-0,12	0,56
SMA2	ERM	1,98	2,28	1,47	0,58
PAS	JM&S	2,23	2,64	1,60	0,55
PAS	GS	1,53	1,98	0,25	0,57
PAS	ERM	2,05	2,47	1,47	0,56
PRS	JM&S	2,00	2,57	-0,76	0,47
PRS	GS	2,63	3,00	-2,48	0,48
PRS	ERM	1,65	2,21	-0,49	0,54
Geral**	JM&S	2,23	2,62	1,52	0,57
Geral**	GS	1,55	1,91	-0,21	0,58
Geral**	ERM	2,22	2,59	1,52	0,59

Obs.: SMA (Santa Maria); PAS (Pedras Altas); PRS (Paraíso do Sul).

* Valores médios.

** Todos os sítios juntos.

De modo geral, observa-se nos resultados de acurácia que o método que apresenta menores erros absolutos é o GS, quando comparamos seus valores aos das imagens MODIS. Os métodos JM&S e ERM apresentam resultados similares, mas com erros superiores ao GS. Com relação ao RMSE, o método GS novamente apresenta melhores resultados, seguido de ERM e JM&S com valores semelhantes. Já o viés, o método GS se destaca, seguido de JM&S e ERM. Salienta-se que, mesmo com a simplicidade do método GS, este apresentou bons resultados. A correlação entre os valores ficou com valores semelhantes para todos os métodos, apresentando valores médios próximos de 0,60. Cabe salientar que tais comparações podem apresentar erros mais elevados em função da heterogeneidade dos ambientes analisados (i.e. sítios analisados), visto que estamos comparando a média de um conjunto de pixels de 30x30 metros (i.e. imagens reamostradas de Landsat) que totalizam um pixel final de 1x1 km com o valor de um pixel de 1x1 km (i.e. imagens MODIS).

Luo et al. (2018) comentam que a correlação é uma ótima medida para avaliar se o método de fusão de imagem obteve o padrão de textura similar à imagem alvo. Entretanto, os autores estavam avaliando fusão para reflectância de superfície, diferente do que é proposto nesta pesquisa (i.e. fusão de T_s), sendo que para a T_s os resultados podem ser vistos como o grau de heterogeneidade do local quando a comparação é realizada com as imagens MODIS. Nas situações que forem comparadas duas imagens Landsat, a premissa de Luo et al. (2018) é válida para temperatura também.

4.4 Downscaling da Temperatura

4.4.1 *Downscaling* para datas com imagem Landsat

Os resultados obtidos no *downscaling* considerando como data-alvo uma data que tem disponível uma imagem Landsat são apresentados na Figura 19. Os boxplots apresentados na Figura 20 demonstram os resultados dos cálculos de acurácia, salientando que os sítios PRS, PAS, SMA1 e SMA2 apresentaram, respectivamente, 1; 4; 5 e 9 imagens de *downscaling* de T_s . As figuras 21 e 22 apresentam a comparação entre as imagens de T_s obtidas do Landsat, MODIS e *downscaling* e a diferença entre o Landsat e o *downscaling*. Por fim, a Figura 23 apresenta alguns usos do solo distintos e as suas respectivas imagens termais e o *downscaling*.

Figura 19 - Comparação da imagem obtida pelo *downscaling* de T_s com a respectiva imagem Landsat oriunda de diferentes métodos de obtenção de T_s .

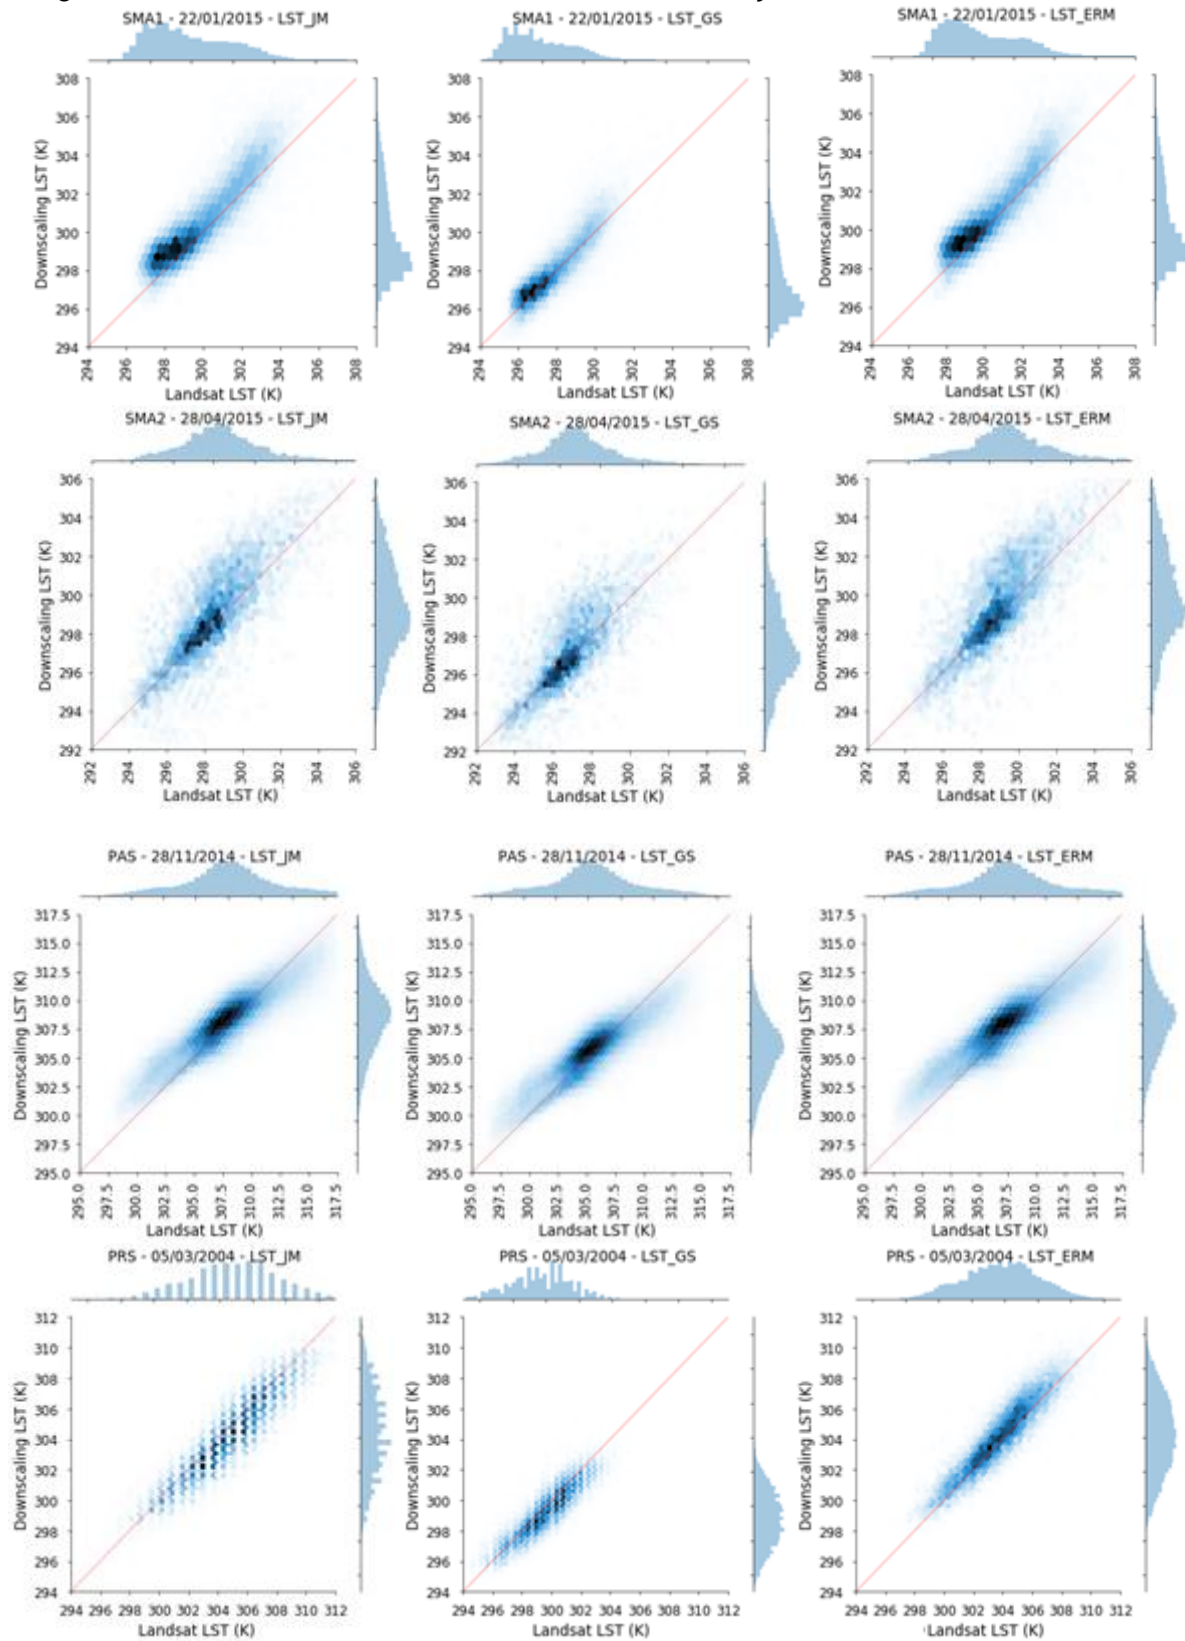


Figura 20 – Resumo das métricas de acurácia dos resultados do *downscaling* da T_s , comparando-se com imagens Landsat (SMA1 e SMA2: Santa Maria em diferentes orbitas-ponto; PAS: Pedras Altas; PRS: Paraíso do Sul).


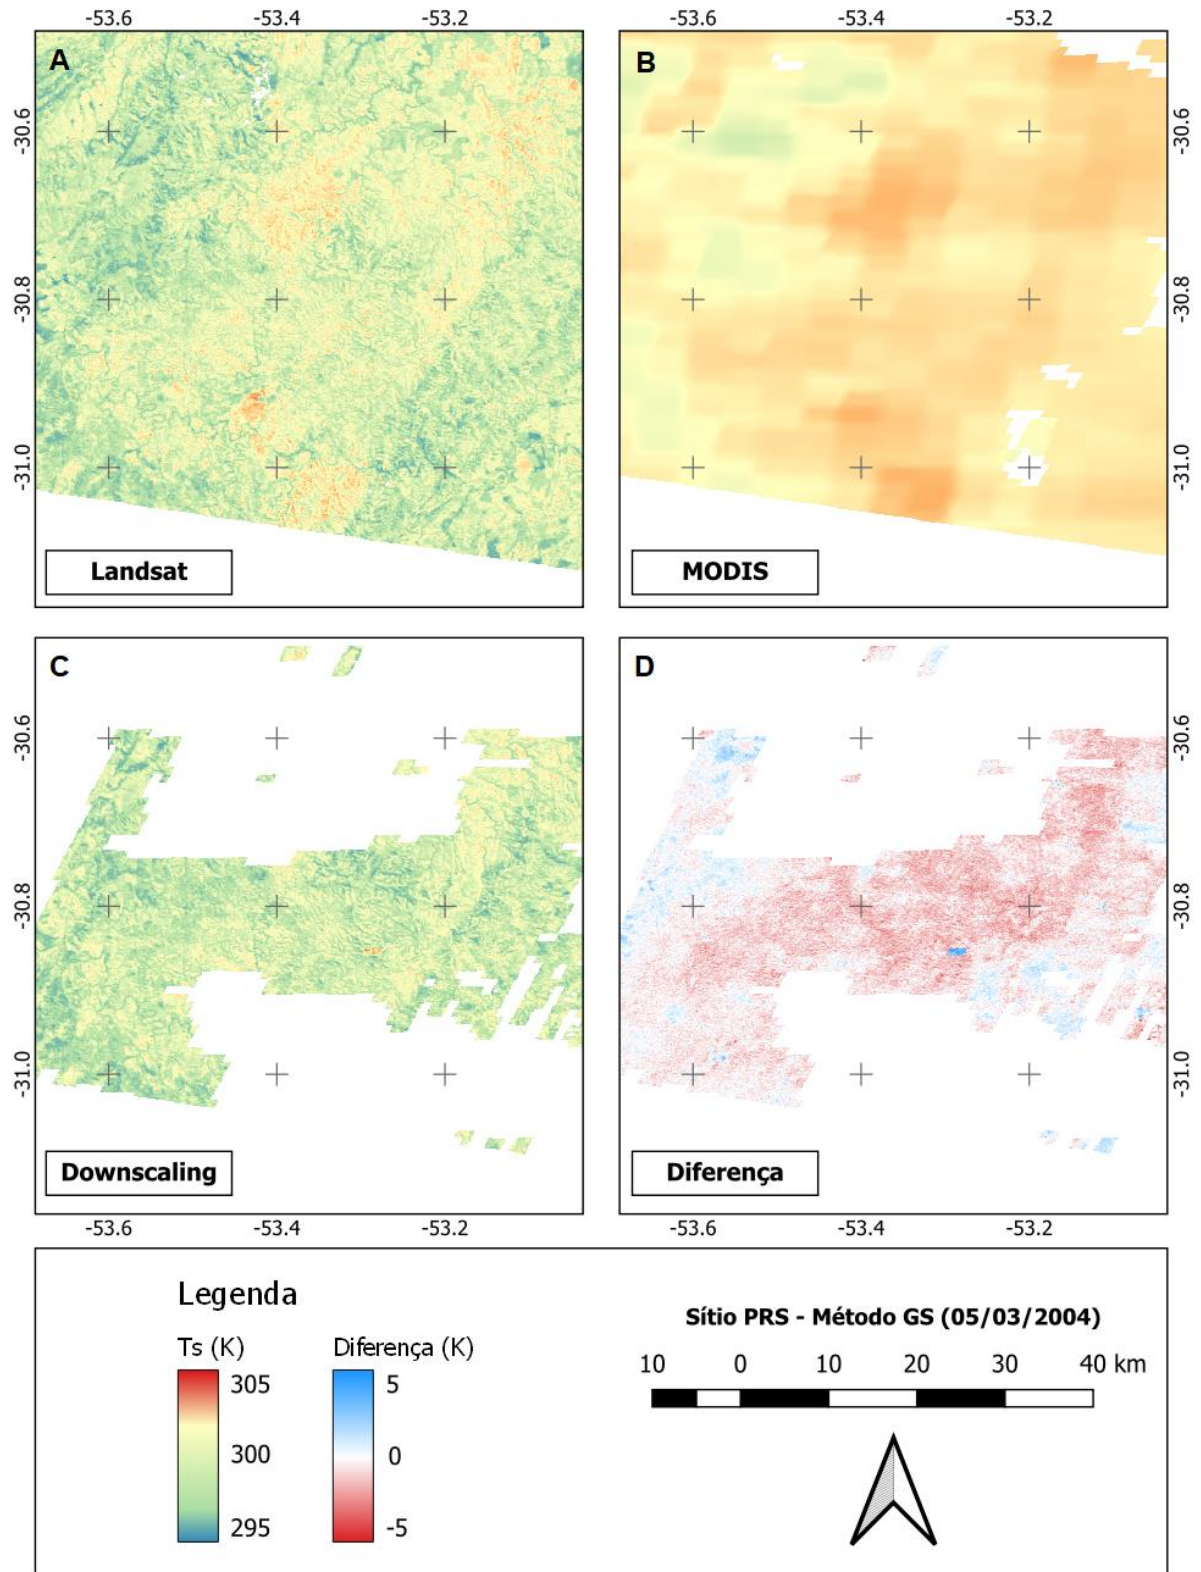
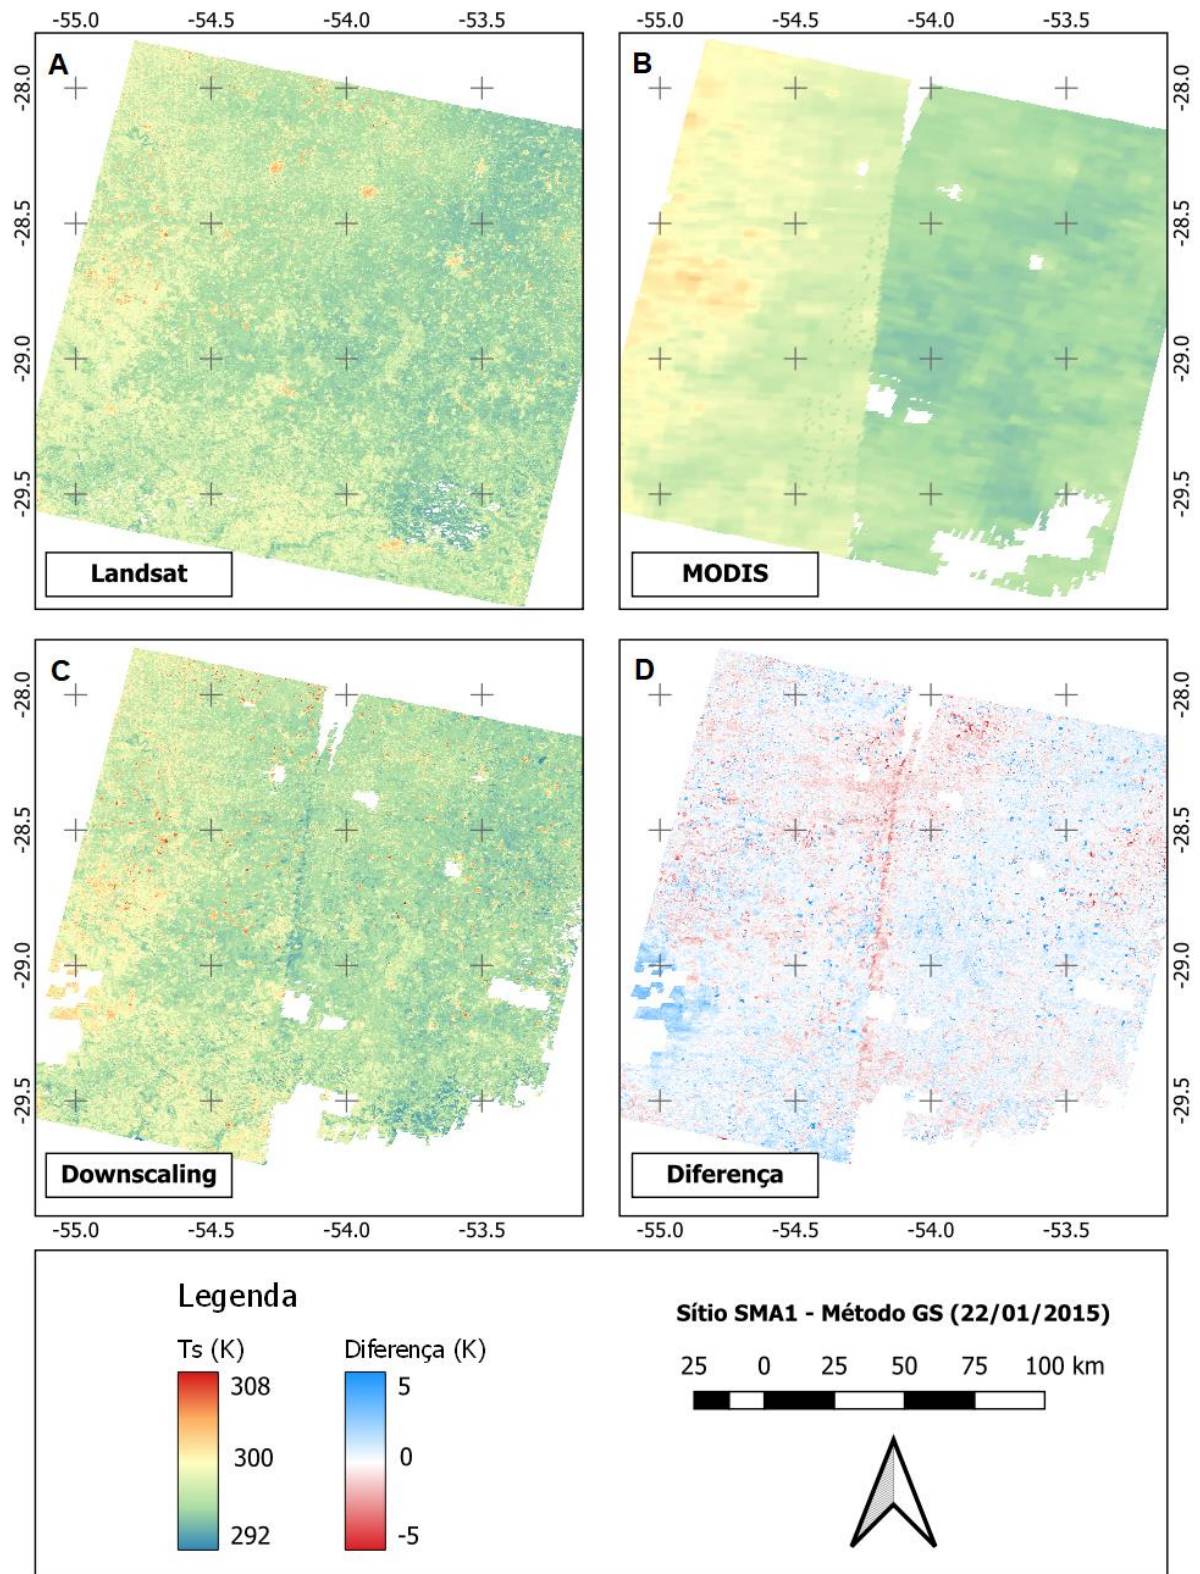


Figura 21 – Comparação das imagens de T_s obtidas no sítio PRS (Orbita-ponto 222/081; Data 05/03/2004). A: Landsat de referência; B: MODIS; C: *downscaling*; e D: Diferença entre *downscaling* e imagem Landsat de referência.



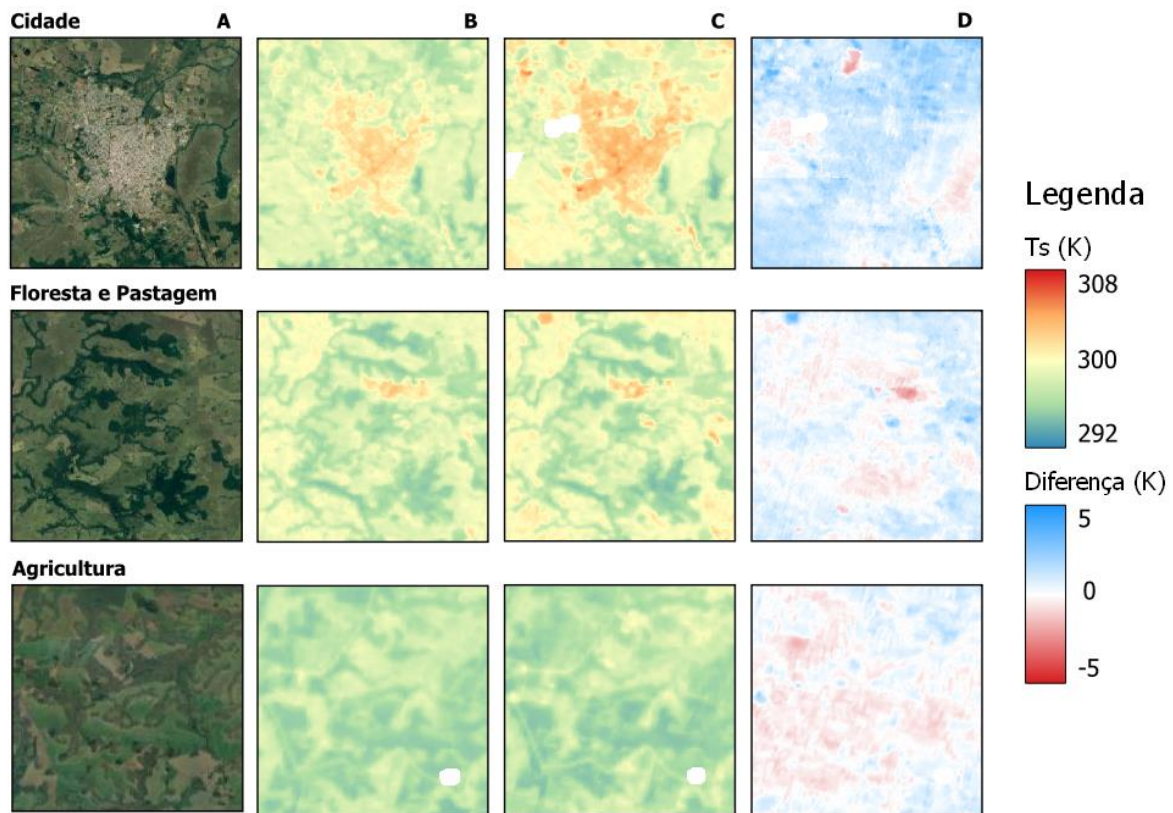
* Diferença = Downscaling menos Landsat.

Figura 22 - Comparação das imagens de T_s no sítio SMA1 (Orbita-ponto 223/080; Data 22/01/2015). A: Landsat de referência; B: MODIS; C: *downscaling*; e D: Diferença entre *downscaling* e Landsat de referência.



* Diferença = Downscaling menos Landsat.

Figura 23 - Detalhamento das imagens termais (Landsat e *Downscaling*) com diferentes usos do solo (Sítio SMA1, data 22/01/2015). Coluna A: Google Earth; B: Landsat; C: *Downscaling*; D: Diferença (*Downscaling* menos Landsat).



Observa-se que, considerando todos os métodos de obtenção de T_s utilizados, 84% dos resultados de MAE e quase 2/3 (65%) dos RMSE apresentaram valores inferiores à 2 K. Dos métodos estudados, aquele que apresentou menor média de erro foi o GS, tendo valor médio de 1,40 K e 1,81 K para MAE e RMSE, respectivamente. O método JM&S apresentou MAE de 1,82 K e RMSE de 2,31 K e o método ERM obteve MAE de 1,75 K e RMSE de 2,24 K. Os valores do coeficiente de correlação (R) também se demonstraram bons, onde grande parte (77%) dos *downscaling* realizados obtiveram coeficientes superiores à 0,70. Somente uma pequena parte (8%) obtiveram valores menores que 0,50. Os métodos adotados tendem, em média, a superestimar os valores observados de T_s . Grande parte (84%) dos resultados obtidos ficaram com viés superior à -2 e inferior à 2 K e caso esse intervalo fosse -1 e 1 K, o percentual de valores cai para 65%. Embora a análise de acurácia tenha sido feita somente com a imagem controle neste momento, tentou-se realizar uma comparação com os dados de campos, porém, não sendo possível devido à ausência de pixels no local da medição em grande parte das datas em análise.

De modo geral, os erros mais elevados podem estar vinculados à contaminação por nuvens tanto nas imagens de referência quando na imagem da data alvo. Mesmo aplicando máscaras de nuvens e sombra e um buffer de 100 metros no entorno desses pixels, é possível que algumas nuvens não sejam detectadas ou que seus efeitos sobre a T_s (seja por meio da sombra ou precipitação) tenham sido significativos, de forma que as relações realizadas entre as imagens (i.e. MODIS e Landsat) na data de referência não consigam capturar tal modificação. Imagens com resolução espacial mais grosseira (e.g. km), mesmo após aplicação de máscara de nuvens, podem ainda apresentar pixels contaminados por nuvens (LIANG E WANG, 2019). Erros no algoritmo de detecção de nuvens do Landsat (e.g. Fmask) também podem ocorrer (CHEN et al., 2021c).

Outra fonte de erro possível é a modificação do uso do solo em porções de áreas menores que da área do pixel do MODIS. Porém, este último erro não foi muito significativo, não ocorrendo com frequência. Embora também pouco frequentes, baixas correlações entre as imagens MODIS e Landsat também podem aumentar os erros observados. Outro fator a ser levado em consideração é a quantidade de pixels disponíveis. Observou-se que nas situações onde havia poucos pixels disponíveis, resultado dos filtros aplicados (i.e. havia presença de nuvens, sombras e pixels ruins na imagem), a probabilidade dos erros serem elevados é maior. Coberturas da cena Landsat menores que 5% podem aumentar o erro em até 7 K, embora possa haver situações excepcionais onde erros significativos possam ocorrer com maior disponibilidade de pixels. Dong et al. (2020) observou maiores erros no processo de *downscaling* da T_s devido ao contraste termal, onde este pode ocorrer em maior ou menor proporção conforme estação, relevo, clima e cobertura do solo.

Outros autores também desenvolveram métodos de *downscaling* que se baseiam em diferentes abordagens (e.g. Inteligência Artificial e Estatística), sendo que os erros obtidos aqui se assemelham aos encontrados na literatura. Técnicas de inteligência artificial foram usadas por Bindhu et al. (2013); Bartkoviak et al. (2019) e Dong et al. (2020). O primeiro aplicou Redes Neurais Artificiais para extrair a relação não linear entre T_s e NDVI, de forma a obter melhor resolução espacial de T_s das imagens MODIS. Os resultados foram comparados com imagens do Landsat 7, sendo encontrado valores de RMSE entre 0,72 e 0,96 K e de coeficiente de Nash-Sutcliff de 0,80 e 0,90. Os mesmos autores avaliaram o uso das novas imagens para a obtenção

da ET por meio do SEBAL, tendo resultados de RMSE de 0,16 mm/dia e coeficiente de Nash-Sutcliff de 0,16 ao comparar os resultados com imagens MODIS.

Bartkoviak et al. (2019) aplicaram método de *downscaling* estatístico por meio de *Random Forest* para prever T_s com base na altitude e NDVI. A análise utilizou imagens MODIS e Landsat, obtendo valores de MAE entre 1,18 K e 2,16 K e de RMSE entre 1,66 e 2,67 K. Os autores ainda comentam que, conforme o tipo de vegetação, a acurácia pode variar de forma significativa. Dong et al. (2020) avaliaram diferentes técnicas de inteligência artificial e a quantidade de variáveis envolvidas no *downscaling* estatístico de T_s . Dependendo da técnica adotada e número de variáveis, valores de RMSE podem variar entre 0,60 a 1,25 K, comparando-se com uma imagem sintética obtida por *upscaling* de diferentes resoluções.

Outras propostas também apresentaram bons resultados, sem o uso de inteligência artificial. Weng et al. (2014) desenvolveram o algoritmo SADFAT e compararam os seus resultados de T_s com 5 imagens Landsat. Os valores de diferença entre as médias obtidas pelos autores variaram entre -0,47 e 1,08 K, enquanto a variação da diferença absoluta e do coeficiente de correlação foram entre 1,25 e 2,03 K, e 0,87 e 0,96, respectivamente. Amazirh et al. (2019) propuseram método de *downscaling* espacial usando dados do Sentinel 1 para incluir umidade do solo no processo usando imagens de T_s do MODIS. Os resultados do algoritmo apresentaram RMSE entre 0,83 e 6,71 °C e R de 0,13 a 0,86.

4.4.2 Estimativa de Séries Temporais de T_s com *Downscaling*

A figura 24 apresenta as comparações entre os dados das medições *in situ* e os valores obtidos nos pixels das imagens de *downscaling* de T_s . A Tabela 11 apresenta os valores de acurácia destas comparações.

Figura 24 - Comparação das medições in situ de T_s e aquelas obtidas por downscaling com diferentes métodos de obtenção da T_s .

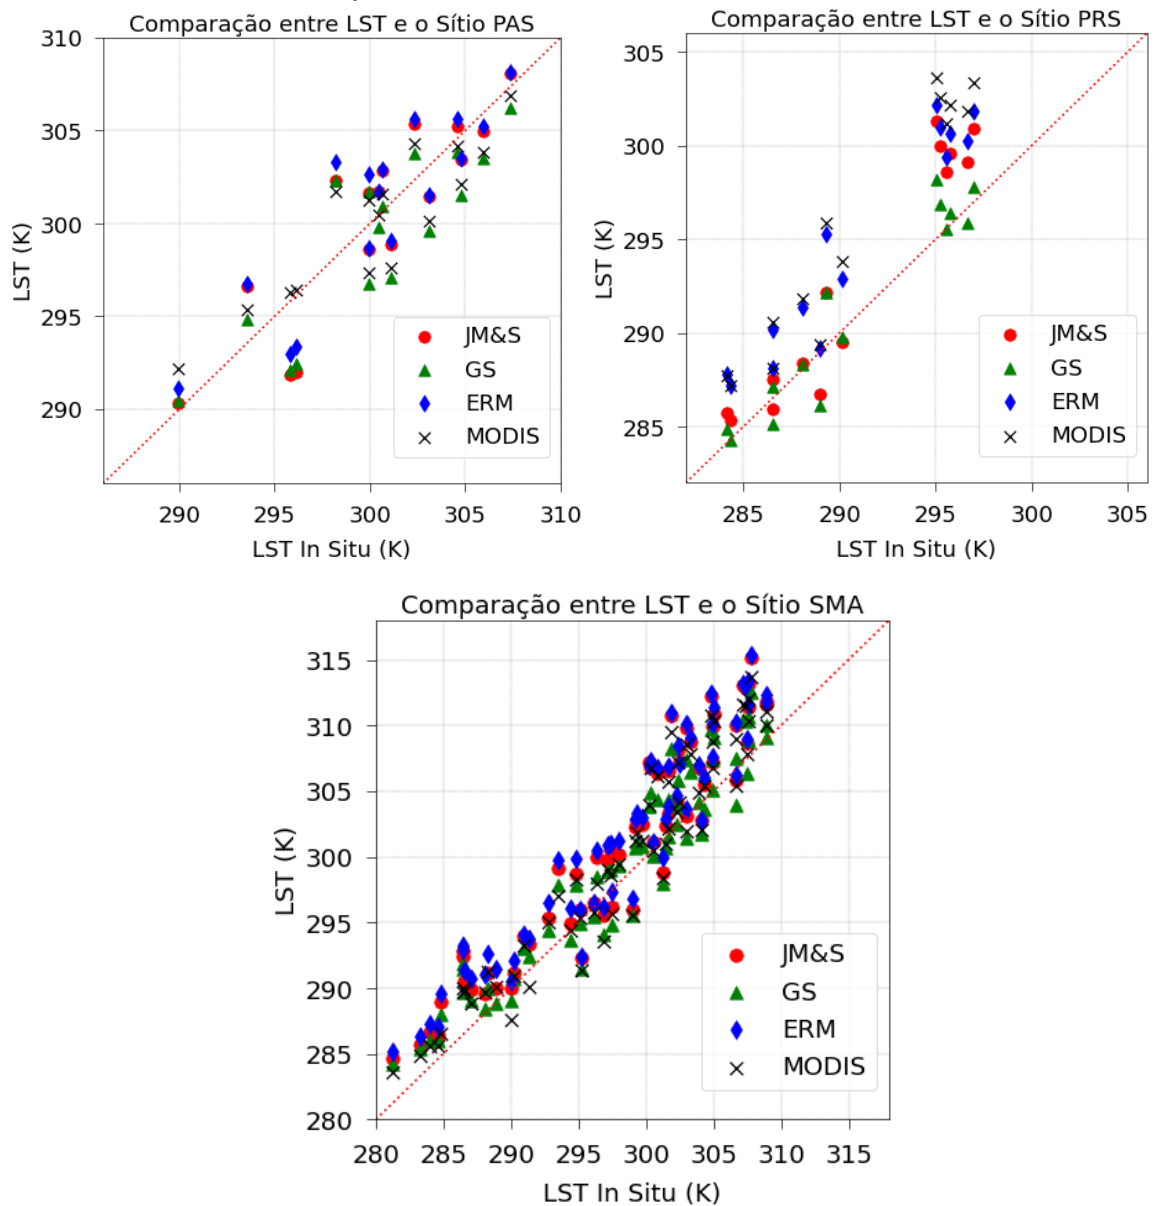


Tabela 11 - Comparação dos pixels de T_s obtidos por *downscaling* com as medições *in situ*.

Sítio	Método	MAE	RMSE	BIAS	R
SMA*	MODIS	2,70	3,23	2,01	0,91
SMA*	JM&S	3,33	3,92	2,92	0,90
SMA*	GS	2,22	2,67	1,34	0,91
SMA*	ERM	3,70	4,26	3,44	0,90
PAS	MODIS	1,71	2,06	-0,15	0,80
PAS	JM&S	2,14	2,49	0,82	0,78
PAS	GS	2,24	2,61	-1,07	0,74

Sítio	Método	MAE	RMSE	BIAS	R
PAS	ERM	2,09	2,37	0,52	0,77
PRS	MODIS	5,21	5,58	5,21	0,93
PRS	JM&S	2,60	3,12	2,13	0,93
PRS	GS	1,18	1,55	0,44	0,92
PRS	ERM	3,96	4,32	3,96	0,93
Geral**	MODIS	3,13	3,77	2,40	0,84
Geral**	JM&S	3,01	3,60	2,45	0,89
Geral**	GS	2,06	2,52	0,80	0,89
Geral**	ERM	3,47	4,02	3,03	0,88

Obs.: SMA (Santa Maria); PAS (Pedras Altas); PRS (Paraíso do Sul).

* Inclui SMA1 e SMA2.

** Todos os sítios.

Os valores de acurácia demonstraram-se variáveis tanto em função do método de obtenção da T_s quando do sítio em estudo. De modo geral, os erros foram inferiores ao compararmos com os dados do sensor MODIS, o qual apresentou MAE que variaram entre 1,71 e 5,21 K e RMSE entre 2,06 e 5,58 K. Dos métodos de T_s para Landsat, o método GS demonstrou melhores resultados com erros entre 1,18 e 2,24 K (MAE) e 1,55 e 2,61 K (RMSE). Em seguida, os métodos JM&S e o ERM apresentaram erros na ordem de grandeza 2 a 4 K. A correlação entre os dados mostrou-se elevada em todos os métodos, ficando próxima de 0,90.

Com relação as medições em profundidade da T_s no sítio PRS, observou-se pouco impacto no método GS. Diferente dos outros métodos (JM&S e ERM), os quais apresentaram erros mais elevados. O uso do solo também pode ter contribuído nestes erros, visto que o entorno do sítio PRS apresenta certa heterogeneidade (grande parte do entorno é composto por lavouras temporárias). Além disso, por tratar-se de áreas de rizicultura, há ainda a presença de uma lâmina d'água para impactar as medições de T_s . Nas medições realizadas em superfície (i.e. sítios PAS e SMA), comportamento dos erros foi similar entre os métodos no sítio PAS, apresentando pouco diferença entre os métodos. Já no sítio SMA, erros foram mais distintos entre si, apresentando diferenças maiores que 1,5 K. Visto que o uso do solo em ambos sítios é o mesmo (formação campestre), o comportamento visto nos erros pode ter ocorrido em função do tipo de solos nestes sítios, onde SMA tem um solo mais profundo com alta capacidade de retenção de água, enquanto PAS tem um solo raso, arenoso e

pedregoso, conseqüentemente com baixa retenção de água (RUBERT et al., 2018). Wan et al. (2002) já havia comentado sobre erros elevados em superfície com maior quantidade de umidade do solo na comparação entre resultados de medições de sensoriamento remoto e medições em campo. Outro fator a interferir nessa distinção de erros é que o entorno do sítio PAS é muito mais homogêneo (predominância de formação campestre) do que o entorno do sítio SMA (mistura de formação campestre, outras lavouras temporárias, formação florestal e soja).

Jaafar et al. (2022), ao desenvolver método híbrido para balanço energético, utilizou o algoritmo TsHARP (AGAM et al. 2007) para melhorar a resolução das imagens de T_s . Os autores usaram como entrada tanto imagens MODIS quanto Landsat. Comparando os resultados com diferentes medições de campo, obteve RMSE e R de 7,8 K e 0,82, respectivamente, para imagens de T_s do MODIS; e 4,5 K e 0,90 para imagens de T_s do Landsat.

Trabalhos levantados por Zhan et al. (2013) de *downscaling* de T_s demonstram que os erros aumentam conforme aumenta-se a distância entre a resolução espacial da imagem usada como base e a resolução final do *downscaling* (i.e. quanto mais detalhe o *downscaling* fornece, maior é o erro). Os autores também comentam sobre o impacto da fenologia da vegetação e do relevo sobre os métodos de *downscaling*, onde valores de acurácia superiores foram observados no verão (devido à dependência do método ao NDVI), e maiores erros nas áreas montanhosas foram encontrados devido à diferença de T_s entre área exposto ao sol e área sombreada (i.e. orientação do terreno).

4.5 Downscaling da ET

4.5.1 Downscaling de ET para datas com imagem Landsat

Os resultados obtidos no *downscaling* da ET considerando como data-alvo uma data que tem disponível uma imagem Landsat são apresentados na Figura 25. Os boxplots apresentados na Figura 26 demonstram, de forma resumida, os resultados dos cálculos de acurácia, salientando que os sítios PRS, PAS, SMA1 e SMA2 apresentaram, respectivamente, 1; 4; 5 e 9 imagens de *downscaling* de ET. As figuras 27 e 28 apresentam a comparação entre as imagens de ET obtidas do Landsat e *downscaling* e a diferença entre o Landsat e o *downscaling* (em conjunto com uma

imagem do Google Earth como referência). Por fim, a Figura 29 apresenta alguns usos do solo distintos e as suas respectivas imagens de ET e o respectivo *downscaling*.

Figura 25 - Comparação dos resultados de *downscaling* da ET com a ET obtida da imagem Landsat de referência.




Figura 25 - Comparação dos resultados de downscaling da ET com a ET obtida da imagem Landsat de referência. (Continuação)

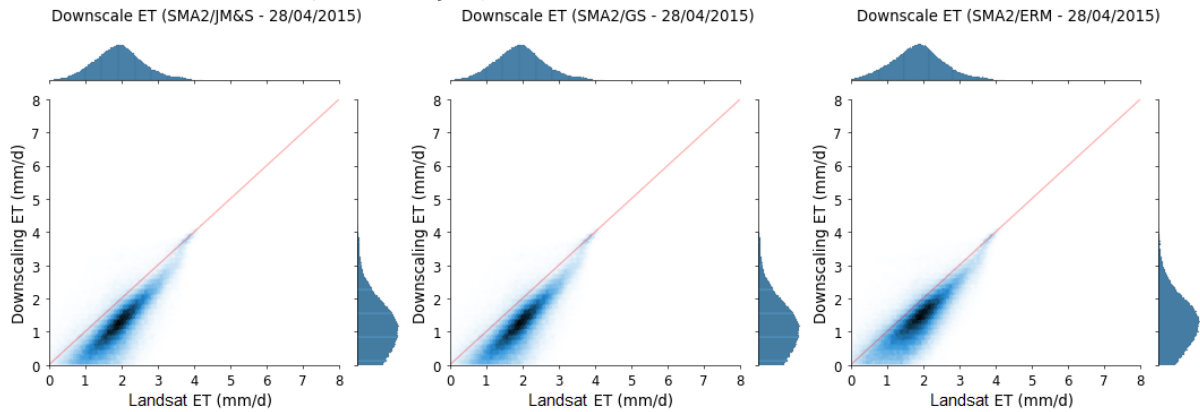


Figura 26 - Resumo das métricas de acurácia dos resultados do downscaling da ET, comparando-se com a ET obtida das imagens Landsat de referência.

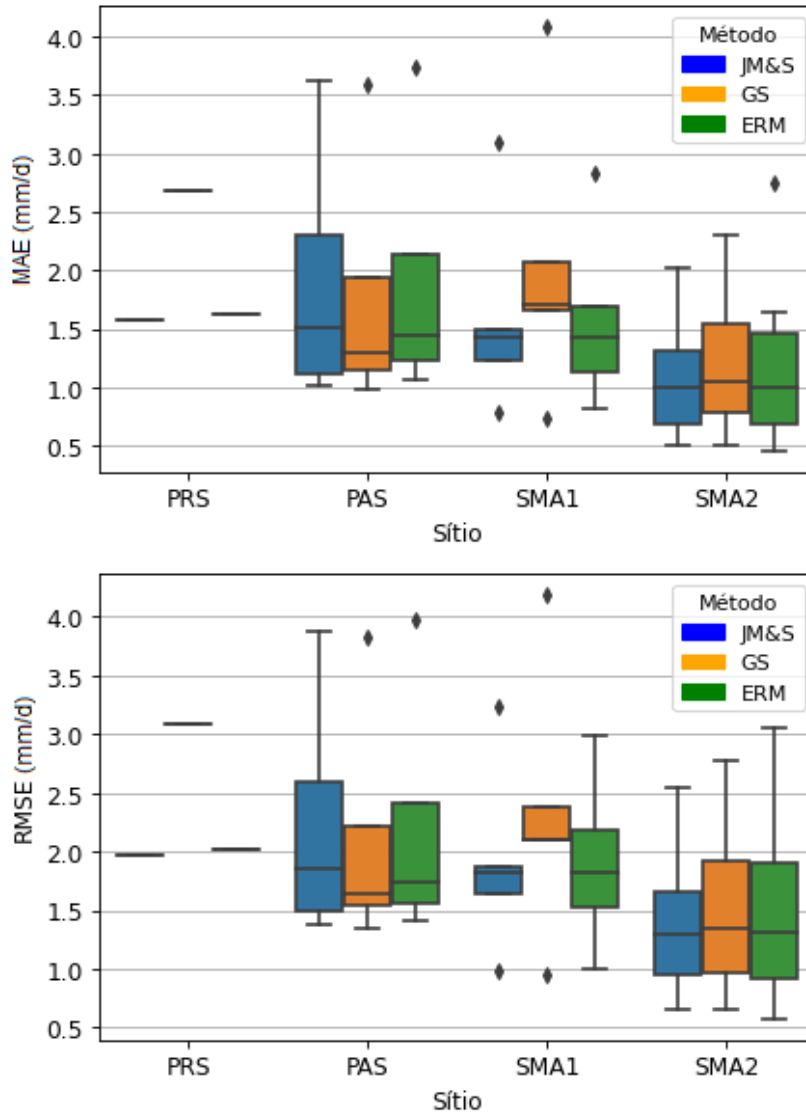


Figura 26 - Resumo das métricas de acurácia dos resultados do downscaling da ET, comparando-se com a ET obtida das imagens Landsat de referência. (Continuação)


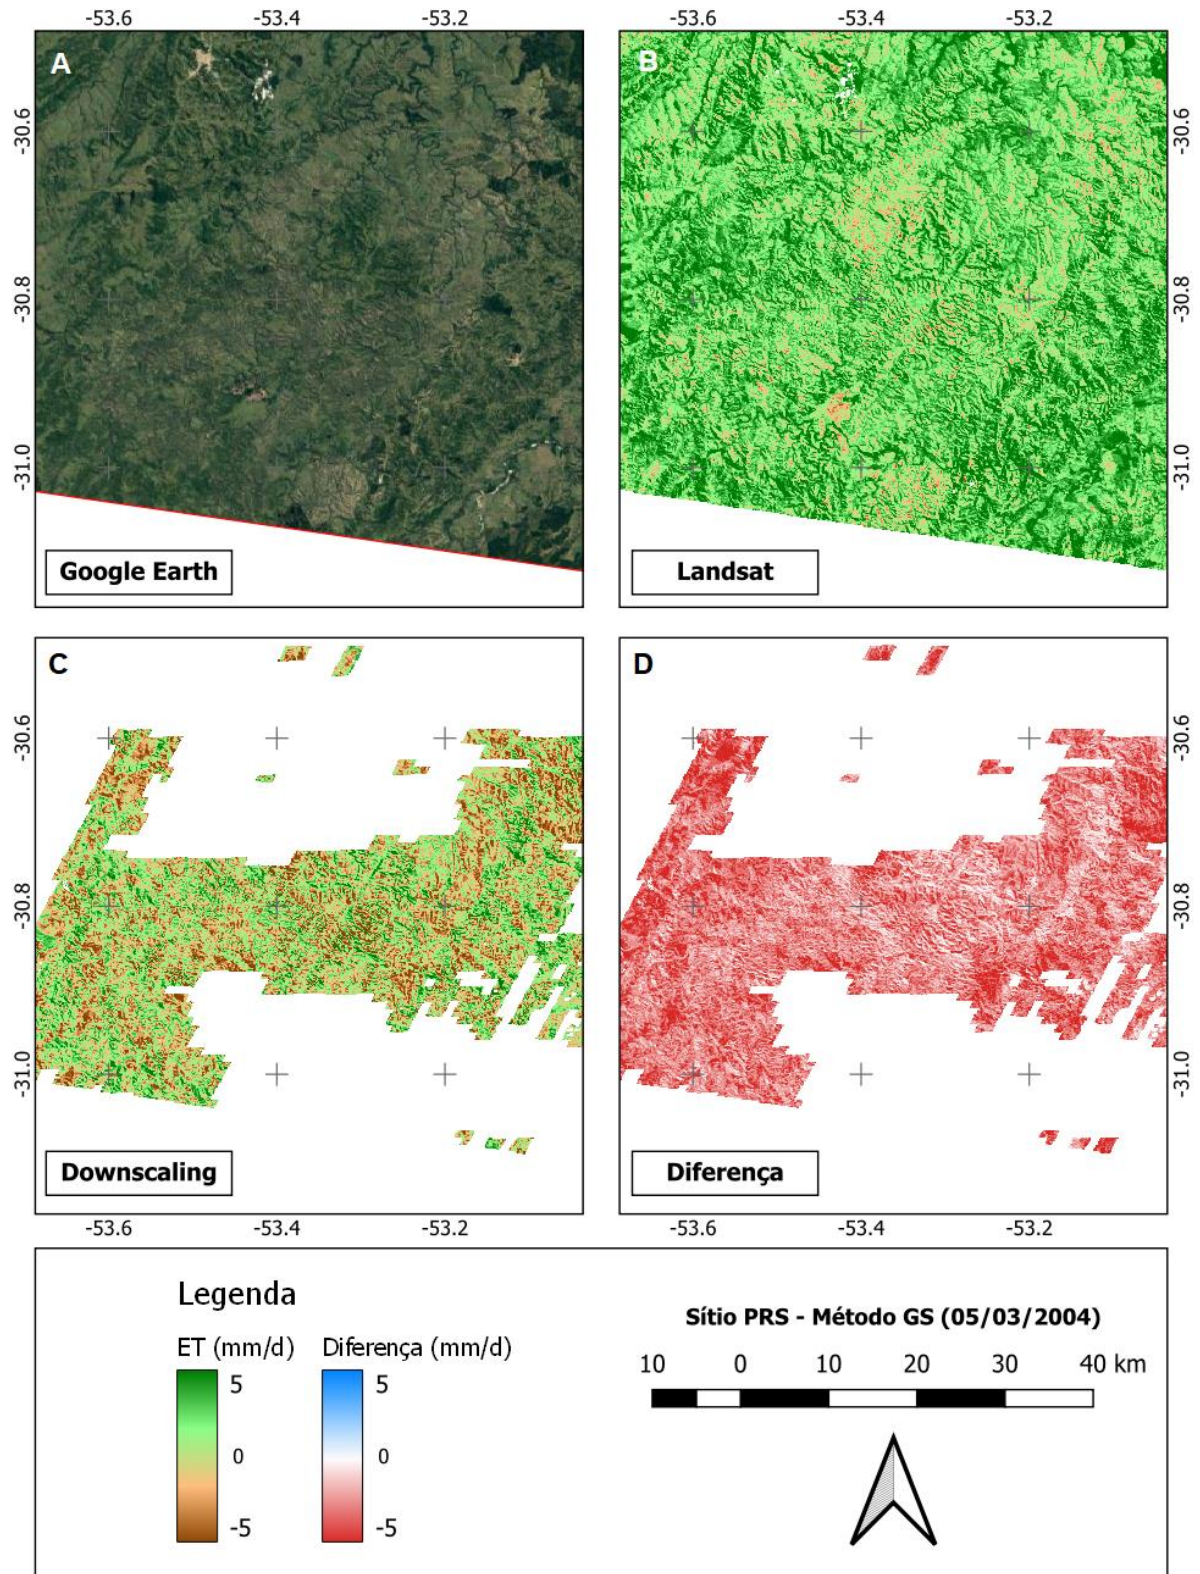
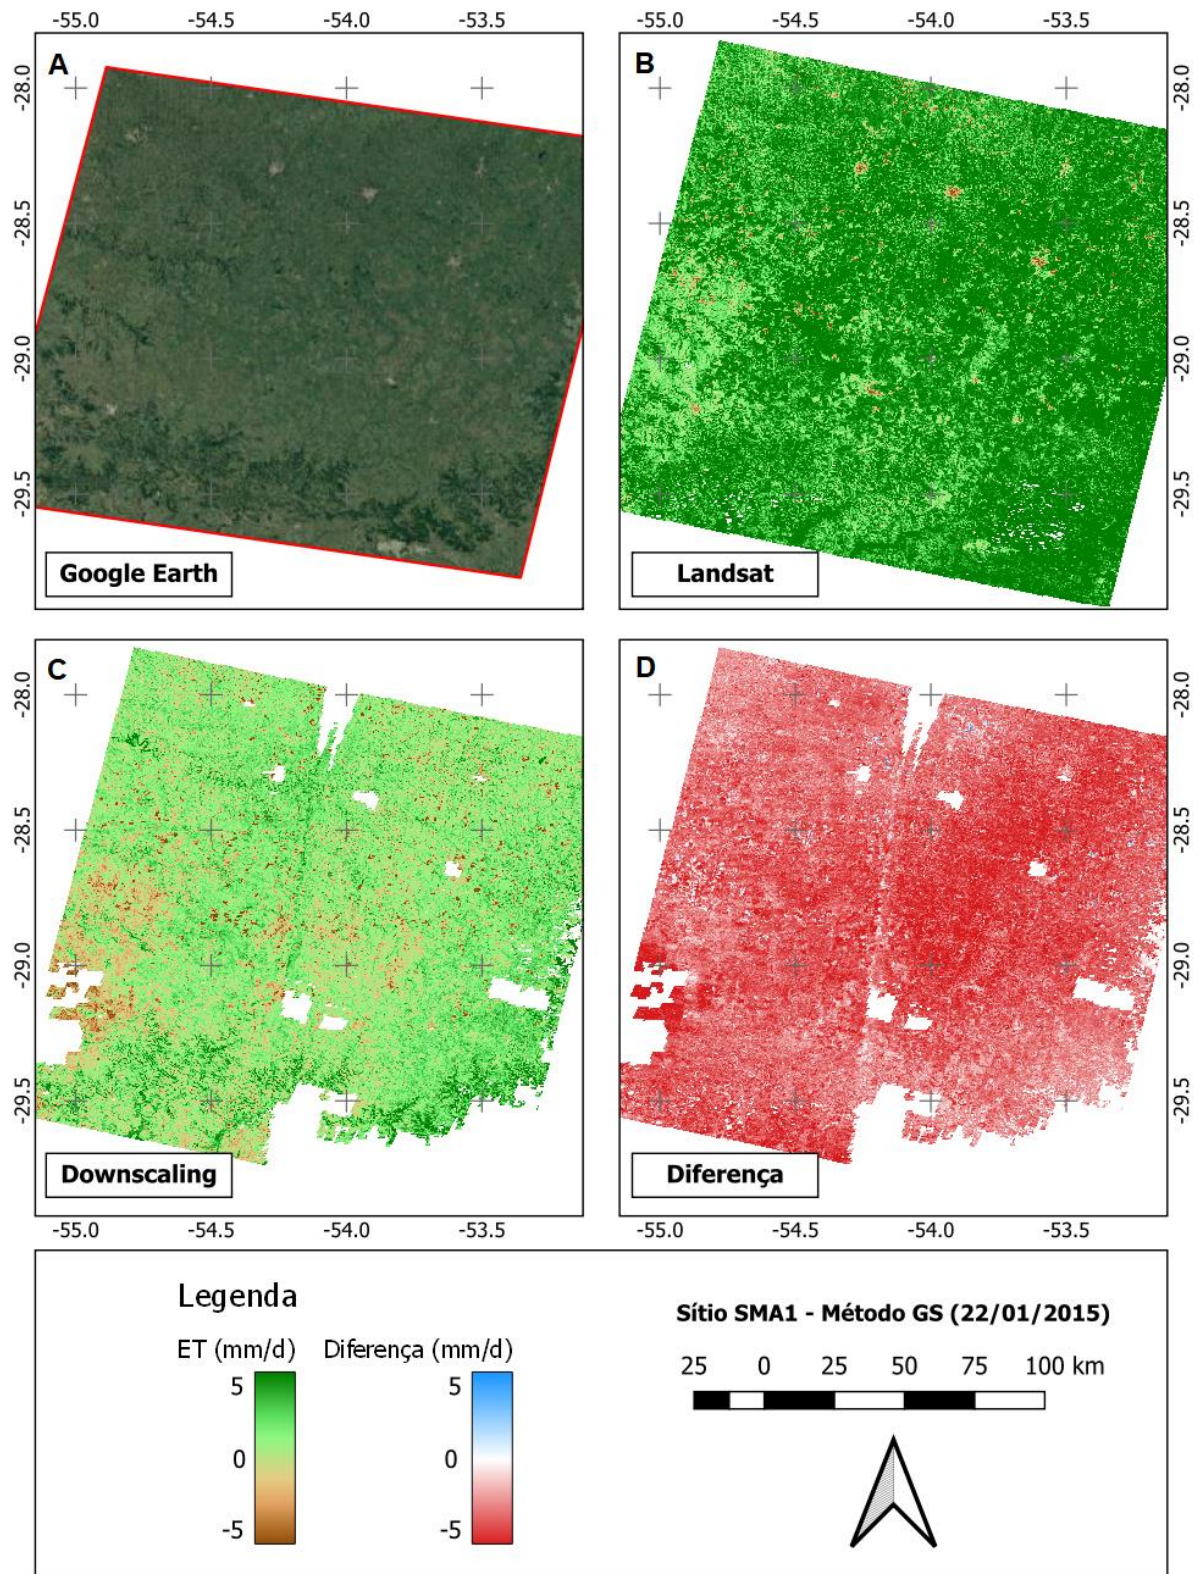


Figura 27 – Comparação de imagens no sítio PRS (Orbita-ponto 222/081, Data 5/3/2004). A: Imagem aérea do Google Earth; B: Imagem de ET oriunda do Landsat de referência; C: *Downscaling* de ET; D: Diferença entre ET de referência e ET *downscaling*.




* Diferença = Downscaling menos Landsat.

Figura 28 - Comparação de imagens no sítio SMA1 (Orbita-ponto 223/080, Data 22/1/2015). A: Imagem aérea do Google Earth; B: Imagem de ET oriunda do Landsat de referência; C: *Downscaling* de ET; D: Diferença entre ET de referência e ET *downscaling*.



* Diferença = Downscaling menos Landsat.

Figura 29 - Detalhamento das imagens de ET (Landsat e Downscaling) com diferentes usos do solo (Sítio SMA1, data 22/01/2015). Coluna A: Google Earth; B: Landsat; C: Downscaling; D: Diferença (Downscaling menos Landsat).



Considerando todos os métodos de obtenção de T_s utilizados para estimar a ET, observa-se que 61% dos resultados de MAE e quase 39% dos RMSE apresentaram valores inferiores à 1,5 mm/d. Diferente do *downscaling* de T_s , para a ET, os métodos que apresentaram melhores resultados foram JM&S e ERM, onde ambos apresentaram médias de erro semelhantes, sendo elas 1,44 mm/d e 1,75 mm/d para MAE e RMSE, respectivamente. Já o método GS apresentou 1,61 mm/d para o MAE e 1,91 mm/d para RMSE. Os valores do coeficiente de correlação (R) também se demonstraram bons, onde grande parte (84%) dos *downscaling* realizados obtiveram coeficientes superiores à 0,70. Somente uma pequena parte (5%) obtiveram valores menores que 0,50. Os métodos adotados tendem, em média, a subestimar os valores de ET obtidas a partir da imagem Landsat de referência. Grande parte (74%) dos resultados obtidos ficaram com viés superior à -1,5 e inferior à 1,5 mm/d e caso esse intervalo fosse -1 e 1 mm/d, o percentual de valores cai para 58%. Da mesma forma que a T_s , a análise de acurácia com as medições de campo nas datas deste tópico

não foi possível devido à ausência de pixels no local da medição em grande parte das datas em análise.

Os erros mais elevados podem estar relacionados à sensibilidade do modelo SEBAL à T_s . Kich (2018) demonstra que para a ET diária, a variável mais sensível do deste modelo é o gradiente de temperatura (dT), o qual depende da T_s de entrada. A mesma autora também levanta outros parâmetros sensíveis do modelo, tais como Albedo e NDVI, que podem também estar contribuindo nos erros observados, principalmente se considerarmos que foi adotado uma interpolação linear entre as variáveis de reflectância de superfície (utilizadas no cálculo das variáveis mencionadas). A área de domínio da simulação, bem como a disponibilidade de pixels, também pode interferir nos erros, visto que ela vai impactar a seleção dos pixels âncoras do geeSEBAL. Tang et al. (2013) comenta que a variação máxima dos coeficientes a e b (utilizados na estimativa de dT) podem chegar à 37,8%, impactando na estimativa de ET.

Observou-se também a presença de valores negativos de ET, os quais estão relacionados às suposições adotadas pelo modelo SEBAL (TRAORE, 2007; IRMAK, 2011; KAYUMBA et al., 2021). De todas as imagens obtidas por *downscaling*, verifica-se que os pixels menores que zero abrangem de 0,26 a 53,69% dos pixels totais, com uma mediana de 11,36%. Caso estes fossem removidos das análises de acurácia, haveria uma redução média de 15% dos erros de MAE e RMSE (podendo chegar até 35%), e de 7% do coeficiente de correlação. No viés, haveria uma redução próxima de zero, mas com desvio padrão de quase 300% (ou seja, o viés irá variar conforme a data e local).

4.5.2 Estimativa de Séries Temporais de ET com Downscaling

A Figura 30 apresenta as comparações entre os dados das medições *in situ* e os valores obtidos nos pixels das imagens de *downscaling* de ET. A Tabela 12 apresenta os valores de acurácia destas comparações. Cabe ressaltar que, em função da indisponibilidade dados para algumas datas, o sítio SMA apresentou, nas datas testadas, quantidade menor de resultados.

Figura 30 - Comparação dos dados pontuais de ET obtidos por downscaling com cobertura de nuvens inferior à 50% e intervalo de dias entre datas de referência de 60 dias.

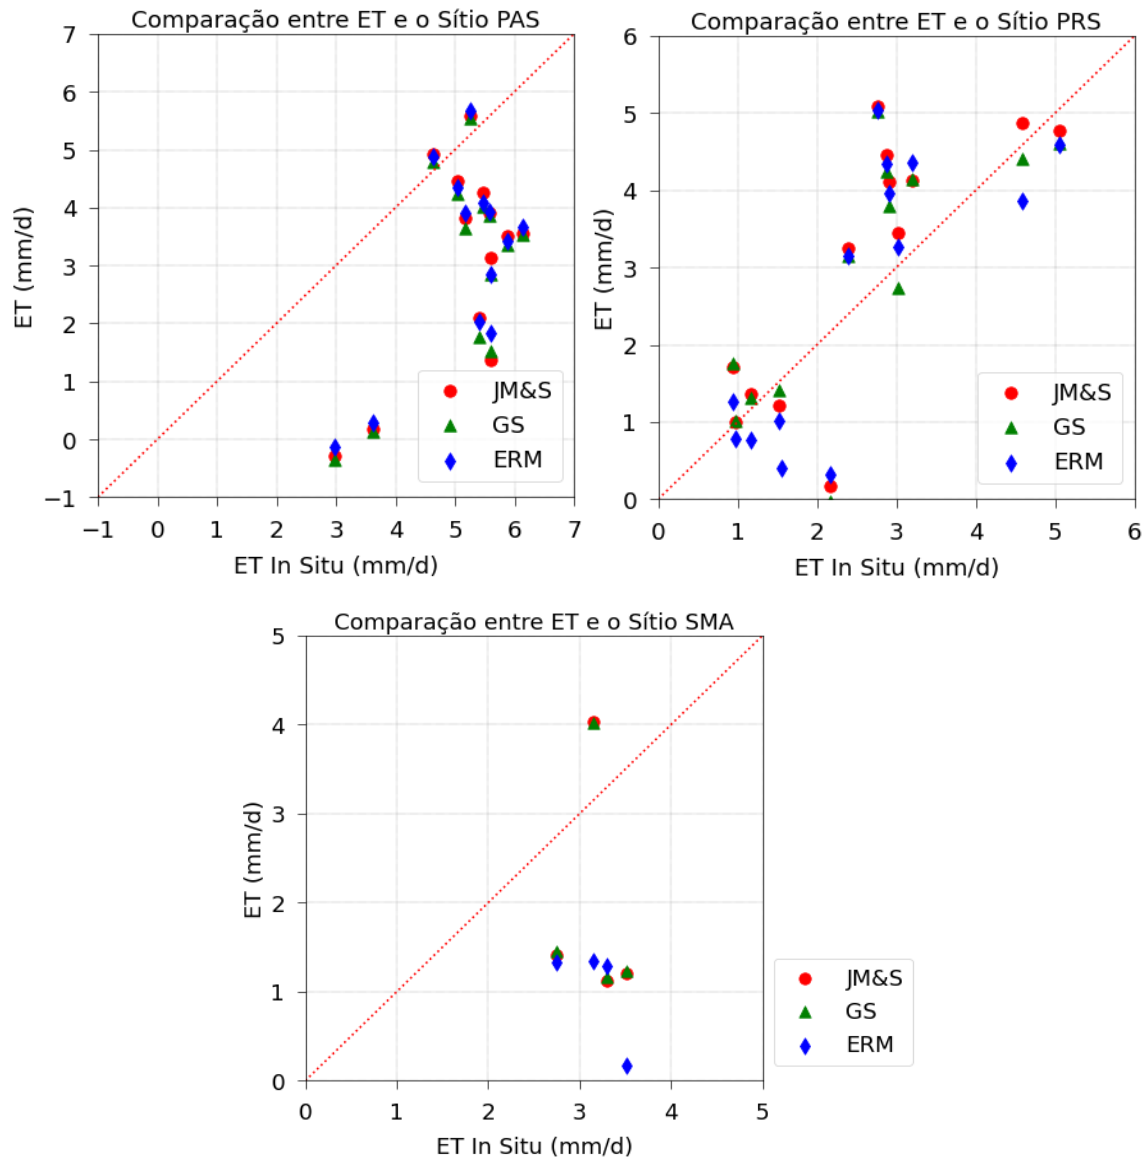


Tabela 12 - Comparação dos dados de *downscaling* de ET com as medições *in situ* utilizando cobertura de nuvens máximo de 50% e intervalo entre as datas de 60 dias.

Sítio	Método	MAE	RMSE	BIAS	R
SMA*	JM&S	2,55	2,88	-2,25	0,26
SMA*	GS	2,52	2,86	-2,23	0,27
SMA*	ERM	2,85	3,08	-2,85	0,48
PAS	JM&S	3,17	4,06	-3,10	0,02
PAS	GS	3,32	4,23	-3,26	0,01
PAS	ERM	3,12	3,94	-3,04	0,02
PRS	JM&S	0,92	1,16	0,31	0,62

Sítio	Método	MAE	RMSE	BIAS	R
PRS	GS	0,87	1,13	0,16	0,57
PRS	ERM	0,90	1,08	0,14	0,61
Geral**	JM&S	2,19	3,04	-1,63	0,01
Geral**	GS	2,23	3,13	-1,76	0,01
Geral**	ERM	2,21	2,99	-1,77	0,02

Obs.: SMA (Santa Maria); PAS (Pedras Altas); PRS (Paraíso do Sul).

* Inclui SMA1 e SMA2.

** Todos os sítios.

Os valores de acurácia variaram significativamente entre os sítios analisados, demonstrando pouca diferenciação entre os métodos de obtenção da T_s . De modo geral, o sítio PRS apresentou melhores resultados, alcançando valores próximos daqueles encontrados na literatura científica. De forma contrária, os sítios SMA e PAS apresentaram erros elevados e pouca ou nenhuma correlação. Tais resultados insatisfatórios podem estar relacionados aos erros propagados do método de *downscaling*, tanto do procedimento adotado para a T_s , quanto para a interpolação linear utilizada para as bandas de reflectância de superfície.

Em virtude dos resultados não satisfatórios, realizou-se, para fins de comparação, *downscaling* da ET com as mesmas condições já citadas, diferenciando apenas a cobertura de nuvens e o intervalo máximo entre as datas de referência, que passaram de 50% para 10% e 60 para 120 dias, respectivamente. A Figura 31 apresenta os gráficos de dispersão obtidos com a comparação dos dados de campo com a ET do *downscaling* e a Tabela 13 demonstra os resultados de acurácia.

Figura 31 - Comparação dos dados pontuais de ET obtidos por downscaling com cobertura de nuvens inferior à 10% e intervalo de dias entre datas de referência de 120 dias.

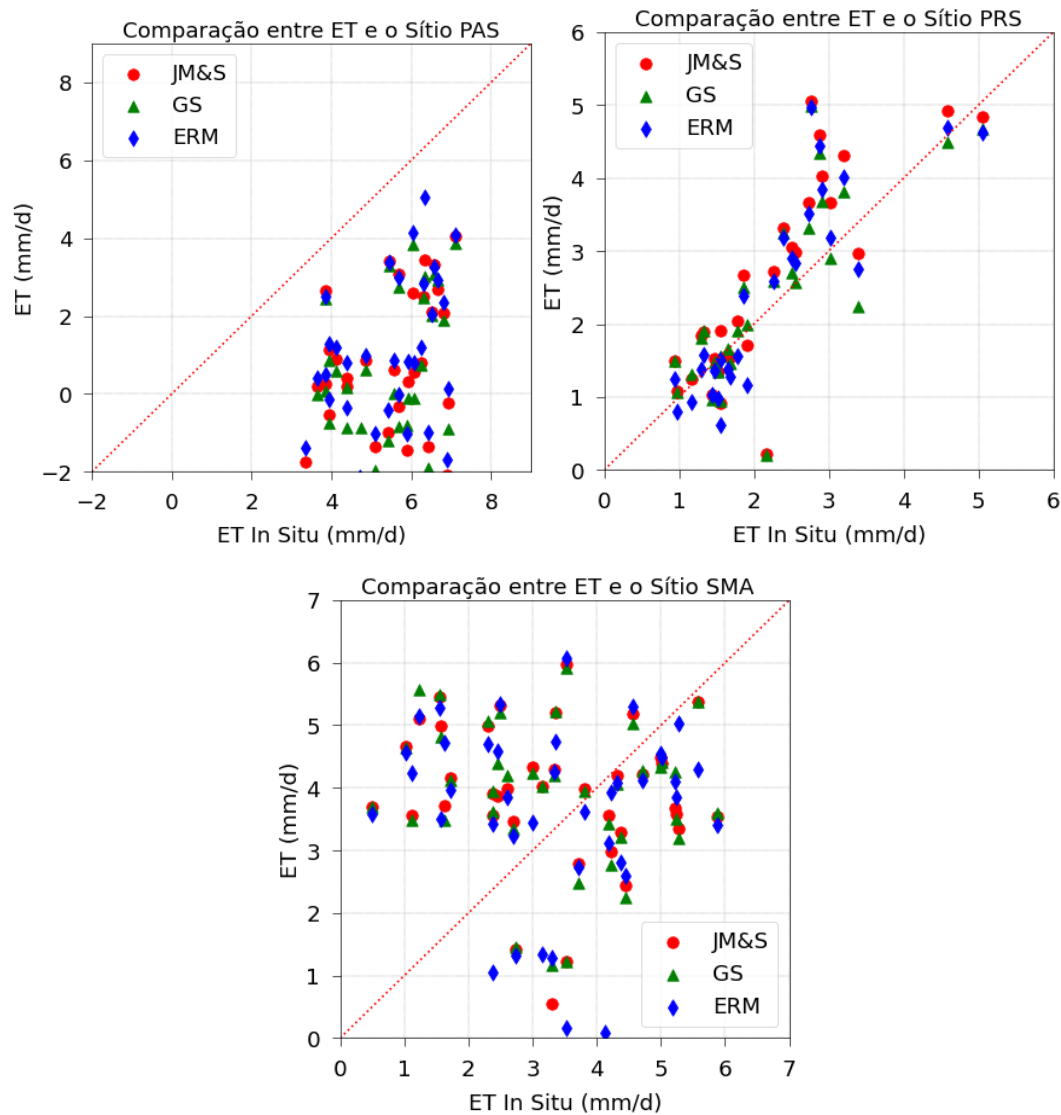


Tabela 13 - Comparação dos dados de *downscaling* de ET com as medições *in situ* utilizando cobertura de nuvens máximo de 10% e intervalo entre as datas de 120 dias.

Sítio	Método	MAE	RMSE	BIAS	R
SMA*	JM&S	1,90	2,25	0,25	0,03
SMA*	GS	1,90	2,26	0,25	0,03
SMA*	ERM	1,85	2,21	0,10	0,01
PAS	JM&S	4,87	5,23	-4,87	0,11
PAS	GS	5,02	5,37	-5,02	0,11
PAS	ERM	4,56	4,94	-4,56	0,14
PRS	JM&S	0,62	0,83	0,33	0,69
PRS	GS	0,52	0,76	0,16	0,63
PRS	ERM	0,59	0,82	0,07	0,67

Sítio	Método	MAE	RMSE	BIAS	R
Geral**	JM&S	2,51	3,33	-1,39	0,06
Geral**	GS	2,53	3,40	-1,48	0,06
Geral**	ERM	2,38	3,17	-1,42	0,02

Obs.: SMA (Santa Maria); PAS (Pedras Altas); PRS (Paraíso do Sul).

* Inclui SMA1 e SMA2.

** Todos os sítios.

Observa-se uma ligeira melhora dos erros obtidos com os dados do sítio SMA e a continuidade das tendências obtidas nas condições anteriores para os sítios PAS e PRS. Os resultados obtidos também foram segmentados em função da estação⁵ para avaliar seu impacto. Embora nem todos os sítios tiveram resultados em todas as estações, verificou-se menores erros na estação de verão para os sítios SMA e PAS, seguidos da primavera. O inverno apresentou os piores erros em SMA. No sítio PRS, outono apresentou os menores erros, seguido do verão. Os coeficientes de correlação não se diferenciaram dos valores médios já apresentados.

Laipelt et al. (2021) comenta sobre a possibilidade dos erros na escolha dos pixels quentes e frios estarem associados à sua às condições climáticas, visto que estes têm seu padrão ajustado para climas áridos e semiáridos (percentil de 20%). Os autores também citam a sensibilidade do modelo (i.e. SEBAL) à T_s e à seleção dos pixels na calibração automática.

Kayser et al. (2022), ao analisar as incertezas do modelo geeSEBAL em clima subtropical úmido nos sítios SMA, PAS e PRS, demonstram que áreas com agricultura (e.g. PRS) foram menos sensíveis à seleção dos pixels âncoras, enquanto locais com pastagens naturais (e.g. SMA e PAS) foram mais sensíveis. Os autores também estimaram a sensibilidade da T_s no geeSEBAL, onde variações de 1,5 a 2 K, tanto no pixel frio quanto quente, podem resultar em uma variação média entre 0,25 até 0,45 mm/d na ET. Foi observado que as estimativas do geeSEBAL de ET tendem a subestimar as medições in situ.

Ao comparar modelos de estimativa de ET e medições em torres de fluxo, Cao et al. (2021, pg. 12) apontam que incertezas podem ser originadas das diferenças entre as escalas (pontual e regional), fechamento do balanço energético e uso do solo. Jaafar et al. (2022) adicionam à lista de incertezas variáveis como horário de

⁵ Verão: Janeiro, Fevereiro e Março; Outono: Abril, Maio e Junho; Inverno: Julho, Agosto e Setembro; Primavera: Outubro, Novembro e Dezembro.

passagem do satélite, cobertura de nuvens, dados meteorológicos e a sensibilidade do modelo adotado. Além disso, relatam que estimativas de ET em escalas de campo (*agricultural field-scale*) usando dados de sensoriamento remoto têm suas dificuldades devido à estimativa do fluxo de calor sensível (H), o qual depende da resistência aerodinâmica e da superfície. Os autores ainda comentam que a parametrização destas variáveis é difícil devido às mudanças nas forçantes atmosféricas e heterogeneidade da superfície. A presença de nuvens também pode comprometer a estimativa e *downscaling* de ET (YANG et al., 2022).

Ao comparar as estimativas de ET usando como variável T_s baseada no MODIS e em *downscaling* (usando ESTARFM) para obtenção de imagens completas de 1 km x 1 km com medições in situ, Zhang et al. (2021) obtiveram valores de RMSE entre 0,80 e 0,89 mm/d quando usando *downscaling* da T_s ; e 0,95 e 1,21 mm/d quando usando T_s do MODIS.

Mahour et al. (2017) desenvolveram método de *downscaling* baseado em geoestatística para obtenção de T_s e ET. Os autores obtiveram valores de RMSE (R) para ET e T_s de 1,26 mm/d (0,49) e 3,67 K (0,48), respectivamente, ao comparar os resultados de *downscaling* com imagens de referência. Embora os valores de T_s do *downscaling* foram similares, os autores apontaram que para a ET há uma maior variabilidade espacial ao obtê-la com dados de *downscaling*.

Anderson et al. (2021) avaliaram o uso das imagens T_s do ECOSTRESS de 2018 para o desenvolvimento de séries temporais de ET de alta resolução espacial (30 m) e temporal (diário). Considerando todas as estações estudadas combinadas e o período de imagens do ECOSTRESS, os autores encontraram valores de RMSE para ET diária e semanal de 1,18 e 0,94 mm/d, respectivamente. Para o ano completo, o erro na ET diária foi de 1,03 mm/d e na ET semanal de 0,82 mm/d.

Laipelt et al. (2021) comparou os resultados de ET obtidos pelo algoritmo geeSEBAL com os dados obtidos em torres de fluxo em diferentes biomas do Brasil, obtendo valor médio de RMSE de 0,67 mm/d (com variações entre 0,48 e 0,91 mm/d). Para o sítio SMA, valores de RMSE e R foram iguais à 0,91 mm/d e 0,77, respectivamente.

Valores de 0,23 mm/d e 0,66 mm/d foram encontrados por Andrade et al. (2021, pg. 12) ao comparar as estimativas de ET obtidas pelo algoritmo SSEBop com modelos de balanços hídricos com (estimativa anual) e sem (estimativa mensal) fechamento, respectivamente.

O modelo híbrido de balanço energético proposto por Jaafar et al. (2022) para obter valores de ET com melhoramento da resolução espacial da Ts, ao comparar os todos os resultados de ET diária, obtiveram valores médios de RMSE e R de 1,31 mm/d e 0,8, respectivamente. Os valores de RMSE nas diferentes torres analisadas variaram entre 0,85 e 2,03 mm/d e os de R entre 0,32 e 0,93.

Yang et al. (2022) aplicaram um sistema de fusão de imagens de satélite, o qual utilizada modelo de balanço energético da superfície para obter ET usando imagens MODIS e Landsat (i.e. ALEXI/DisALEXI), seguido da aplicação do algoritmo STARFM para o *downscaling* da ET. Utilizando imagens sintéticas de MODIS obtidas a partir da agregação das imagens Landsat, os autores obtiveram resultados de MAE, RMSE e Viés entre 0,85 – 1,13 mm/d; 1,05 – 1,41 mm/d; e -0,38 – 0,71 mm/d, respectivamente, ao comparar com os dados de ET medidos em campo. Os autores também apresentaram a comparação das ET de campo e das estimativas de ET para o dia do ano 173-2014, obtendo valores de RMSE de 0,79 mm/d e coeficiente de correlação de 0,56. Valores mais elevados de RMSE podem estar associados às mudanças rápidas de ET durante a drenagem e estágio de plantio nos sítios que ocorrem cultura de arroz.

5 CONSIDERAÇÕES FINAIS

Plataformas de computação em nuvem trouxeram grandes avanços, especialmente na área de sensoriamento remoto. Aliando a extensa base de dados disponíveis no GEE e seu poder computacional, metodologias de *downscaling* podem ser empregadas para obtenção de novos dados ambientais. No *downscaling* de variáveis como T_s , é necessário averiguar o método de conversão da temperatura de brilho para T_s , bem como o ambiente em estudo, visto que os erros podem variar significativamente entre os locais de estudo, especialmente se considerarmos que o método GS teve erros 30% e 40% menores que aqueles do método JM&S e ERM, respectivamente. Observação similar também é aplicável para o *downscaling* da ET, onde diferentes sítios de medição demonstraram erros variados, onde apenas PRS demonstrou resultados compatíveis com aqueles encontrados na literatura e os sítios PAS e SMA obtiveram, em média, erros 2 a 3 vezes superiores, respectivamente.

Diante do exposto, sugere-se para trabalhos futuros: 1) a realização de testes usando a Coleção 2 das imagens Landsat e MODIS, disponibilizadas recentemente no GEE; 2) Teste com diferentes procedimentos de *downscaling* no GEE, tais como trabalhar relação entre as variáveis NDVI e T_s e adoção de uma equação para o ciclo anual ou diário da T_s com os dados de campo, visto que essa pesquisa focou em abordagem similar ao ESTARFM e STAIR; 3) Teste com outros satélites (e.g. Sentinel e GOES); e 4) preenchimento de pixels vazios devido a presença de nuvens. Abordagens com inteligência artificial, mineração de dados e geoestatística também são sugeridas, desde que disponíveis no GEE e passíveis de serem executadas por completo na nuvem (*server-side*).

6 REFERÊNCIAS

- ABEL, B. Domaines du spectre électromagnétique. Wikimedia Commons. 2012. Disponível em: <https://commons.wikimedia.org/wiki/File:Domaines_du_spectre_%C3%A9lectromagn%C3%A9tique.svg>. Acesso em 19 jun. 2021.
- AGAM, N. et al. A vegetation index based technique for spatial sharpening of thermal imagery. **Remote Sensing of Environment**. Elsevier. V. 107, 2007. Pg. 545-558.
- ALLAM, M. et al. Monthly 10-m evapotranspiration rates retrieved by SEBALI with Sentinel-2 and MODIS LST data. **Agricultural Water Management**. Elsevier, n. 243. 2021. 11 p.
- ALLEN, R.G. et al. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration METRIC Model. **Journal of Irrigation and Drainage Engineering**. ASCE. n. 133. 2007. pg. 380-394.
- AMAZIRH, A. et al. Including Sentinel-1 radar data to improve the disaggregation of MODIS land surface temperature data. **ISPRS Journal of Photogrammetry and Remote Sensing**. Elsevier, n. 150. 2019. pg. 11-26.
- ANDERSON, M.C. et al. A two-source time-integrated model for estimating surface fluxes using thermal infrared remote sensing. **Remote Sensing of Environment**, v. 60, n. 2. 1997. Pg. 195-216.
- ANDERSON, M.C. et al. A Multiscale Remote Sensing Model for Disaggregating Regional Fluxes to Micrometeorological Scales. **Journal of Hydrometeorology**. V. 5, n. 2. 2004. Pg. 343-363.
- ANDERSON, M.C. et al. Mapping daily evapotranspiration at field to global scales using geostationary and polar orbiting satellite imagery. **Hydrology and Earth System Sciences Discussions**, n. 7, 2010. Pg. 1-34.
- ANDERSON, M.C. et al. Mapping daily evapotranspiration at field to continental scales using geostationary and polar orbiting satellite imagery. **Hydrology and Earth System Sciences Discussions**, n. 15, 2011. Pg. 223-239.
- ANDERSON, M.C. et al. Interoperability of ECOSTRESS and Landsat for mapping evapotranspiration time series at sub-field scales. **Remote Sensing of Environment**. Elsevier, n. 252. 2021. 19 p.
- ANDRADE, B.C.C. et al. Remote sensing-based actual evapotranspiration assessment in a data-scarce area of Brazil: A case study of the Urucuia Aquifer System. **International Journal of Applied Earth Observations and Geoinformation**. Elsevier, n. 98. 2021. 16 p.
- ARTIS, D.A.; CARNAHAN, W.H. Survey of Emissivity Variability in Thermography of Urban Areas. **Remote Sensing of Environment**. Elsevier, n. 12. 1982. pg. 313-329.

ATKINSON, P.M. Downscaling in Remote Sensing. **International Journal of Applied Earth Observation and Geoinformation**. Elsevier, n. 22. 2013. pg. 106-114.

BARTKOVIK, P. et al. Downscaling Land Surface Temperature from MODIS Dataset with Random Forest Approach over Alpine Vegetated Areas. MDPI. **Remote Sensing**. v. 11, n. 1319. 2019. 19 p.

BAI, B. et al. A Simple Spatio–Temporal Data Fusion Method Based on Linear Regression Coefficient Compensation. **Remote Sensing**. MDPI. n. 12, v. 3900. 2020. 16 p.

BASTIAANSEN, W.G.M. et al. A remote sensing surface energy balance algorithm for land (SEBAL) 1. Formulation. **Journal of Hydrology**. V. 212, n. 213. 1998. Pg. 198-212.

BINDHU, V.M. et al. Development and verification of a non-linear disaggregation method (NL-DisTrad) to downscale MODIS land surface temperature to the spatial scale of Landsat thermal data to estimate evapotranspiration. Elsevier, **Remote Sensing of Environment**. N. 135. 2013. Pg.118-129.

CABALLERO, C.B. et al. Land use and land cover changes and their impacts on surface-atmosphere interactions in Brazil: A systematic review. *Science of Total Environment*. Elsevier. v. 808. 2022. 17 p.

CAO, M. et al. Multiple sources of uncertainties in satellite retrieval of terrestrial actual evapotranspiration. Elsevier: **Journal of Hydrology**. n. 601. 2021. 16 p.

CHEN, L. et al. Seasonal Variations of Daytime Land Surface Temperature and Their Underlying Drivers over Wuhan, China. MDPI. **Remote Sensing**. v. 13, n. 2. 2021a. 22 p.

CHEN, B. et al. Deep Learning for Feature-Level Data Fusion: Higher Resolution Reconstruction of Historical Landsat Archive. **Remote Sensing**. v. 13, n. 167. 2021b. 23 p.

CHEN, Y. et al. A practical approach to reconstruct high-quality Landsat NDVI time-series data by gap filling and the Savitzky–Golay filter. **ISPRS Journal of Photogrammetry and Remote Sensing**. n. 180. 2021c. pg. 174-190.

CHEN, J.; KUSTAS, W.P. Using Very High Resolution Thermal Infrared Imagery for More Accurate Determination of the Impact of Land Cover Differences on Evapotranspiration in an Irrigated Agricultural Area. **Remote Sensing**. v. 11, n. 613. 2019. 18 p.

COLTIN, B. et al. Automatic boosted flood mapping from satellite data. **Int. J. Remote Sens.** v. 37, n. 5. 2016. pg. 993–1015.

DAVIE, T. **Fundamentals of Hydrology**. 2 ed. London: Routledge, 2008. 200 p.

DONG, P. et al. Global comparison of diverse scaling factors and regression models for downscaling Landsat-8 thermal data. *ISPRS Journal of Photogrammetry and Remote Sensing*. N. 169. 2020. Pg. 44-56.

DUAN, S. et al. Validation of Collection 6 MODIS land surface temperature product using in situ measurements. **Remote Sensing of Environment**. Elsevier, n. 225. 2019. p. 16–29.

EAGLESON, P.S. The Emergence of Global-Scale Hydrology. **Water Resources Research**. v. 22, n. 9, 1986. pg. 6S-14S.

ERMIDA, S.L. et al. Google Earth Engine Open-Source Code for Land Surface Temperature Estimation from the Landsat Series. **Remote Sensing**. MDPI, v.12. n. 1471. 2020. pg. 1-21.

FASHAE, O.A. et al. Land use/land cover change and land surface temperature of Ibadan and environs, Nigeria. **Environmental Monitoring Assessment**. Springer, v. 192, n. 109. 2020. Pg. 1-18.

FISHER, J.B. et al. The future of evapotranspiration: Global requirements for ecosystem functioning, carbon and climate feedbacks, agricultural management, and water resources. **Water Resources Research**. n. 53, 2017. pg. 2618-2626.

GAO, F. et al. On the blending of the Landsat and MODIS surface reflectance: Predicting daily Landsat surface reflectance. **IEEE Trans. Geosci. Remote Sens.** N. 44, 2006. pg. 2207–2218.

GILLESPIE, A. Land Surface Temperature. In: NJOKU, E.G. (ed.). **Encyclopedia of Remote Sensing**. Springer, 2014. Pg. 314-319.

GORELICK, Noel et al. Google Earth Engine: Planetary-scale Geospatial Analysis for Everyone. **Remote Sensing of Environment**. Elsevier, n. 202, 2017. pg. 18-27.

GUILLEVIC, P. et al. Land Surface Temperature Product Validation Best Practice Protocol. Version 1.1. In: P. GUILLEVIC, F. GÖTTSCHE, J. NICKESON & M. ROMÁN (Eds.), **Best Practice for Satellite-Derived Land Product Validation** (p. 58): Land Product Validation Subgroup (WGCV/CEOS). 2018.

HACHEM, S. et al. Comparison of MODIS-derived land surface temperatures with near-surface soil and air temperature measurements in continuous permafrost terrain. **The Cryosphere Discuss.**, n. 5, 2011. p. 1583–1625.

IRMAK. A. **Evapotranspiration** – Remote Sensing and Modeling. InTech. 2011. 526 p.

JAAFAR. H. et al. A global 30-m ET model (HSEB) using harmonized Landsat and Sentinel-2, MODIS and VIIRS: Comparison to ECOSTRESS ET and LST. **Remote Sensing of Environment**. Elsevier. V. 274, 2022. 24 p.

JENSEN, J.R. **Remote Sensing of the Environment: An Earth Resource Perspective**. 2 ed. Pearson, 2014. 619 p.

JIMÉNEZ-MUÑOZ, J.J. et al. Revision of the Single-Channel Algorithm for Land Surface Temperature Retrieval From Landsat Thermal-Infrared Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 1. 2009. pg. 339-349.

JIMÉNEZ-MUÑOZ, J.J. et al. Land Surface Temperature Retrieval Methods From Landsat-8 Thermal Infrared Sensor Data. **IEEE Geoscience and Remote Sensing Letters**. v. 11, n. 10. 2014. pg. 1840-1843.

JIMÉNEZ-MUÑOZ, J.J.; SOBRINHO, J.A. A generalized single-channel method for retrieving land surface temperature from remote sensing data. **Journal of Geophysical Research**, v. 108, n. D22. 2003. 10 p.

JIN, M. et al. The Footprint of Urban Areas on Global Climate as Characterized by MODIS. **Journal of Climate**. American Meteorological Society, v. 18, n. 10. 2005. Pg. 1551-1565.

KAYSER, R.H. et al. Assessing geeSEBAL automated calibration and meteorological reanalysis uncertainties to estimate evapotranspiration in subtropical humid climates. **Agricultural and Forest Meteorology**. Elsevier. V. 314. 2022. 16 p.

KAYUMBA, P.M. et al. Modeling the Near-Surface Energies and Water Vapor Fluxes Behavior in Response to Summer Canopy Density across Yanqi Endorheic Basin, Northwestern China. **Remote Sensing**. V. 13, 2021. 25 p.

KARNIELI, A. et al. Use of NDVI and Land Surface Temperature for Drought Assessment: Merits and Limitations. **Journal of Climate**. American Meteorological Society, v. 23, n. 3. 2010. Pg. 618-633.

KHANAL, S. et al. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computer and Electronics in Agriculture**. Elsevier, v. 139. 2017. Pg. 22-32.

KICH, E.M. Calibração Automática do Modelo de Estimativa de Evapotranspiração por Sensoriamento Remoto (SEBAL). **Dissertação (Mestrado)**. PPG-RHSA, IPH/UFRGS. 2018. 99 p.

KUENZER, C.; DECH, S. (ed.). **Thermal Infrared Remote Sensing: Sensors, Methods, Applications**. Dordrecht: Holanda, Springer. 2013. 546 p.

LAFORTEZZA, R. et al. Benefits and well-being perceived by people visiting green spaces in periods of heat stress. **Urban Forestry & Urban Greening**. Elsevier, v. 8, n. 2. 2009. Pg. 97-108.

LAIPELT, L. et al. Long-term monitoring of evapotranspiration using the SEBAL algorithm and Google Earth Engine cloud computing. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 178, 2021. Pg. 81-96.

LEE, T.; SINGH, V.P. **Statistical Downscaling for Hydrological and Environmental Applications**. CRC Press, 2018. 179 p.

LEI, F. et al. Data assimilation of high-resolution thermal and radar remote sensing retrievals for soil moisture monitoring in a drip-irrigated vineyard. **Remote Sensing of Environment**. Elsevier, n. 239. 2020. Pg. 1-16.

LI, L. et al. High Resolution Mapping of Cropping Cycles by Fusion of Landsat and MODIS Data. **Remote Sensing**. MDPI. v. 9, n. 12. 2017. 19 p.

LI, Z.L. et al. Satellite-derived land surface temperature: Current status and perspectives. **Remote Sensing of Environment**, Elsevier. v. 131. 2013. Pg. 14-37.

LIANG, S.; WANG, J. **Advanced Remote Sensing: Terrestrial Information Extraction and Applications**. 2 ed. Academic Press (Elsevier). 2019. 992 pg.

LIOU, Y. KAR, S.K. Evapotranspiration Estimation with Remote Sensing and Various Surface Energy Balance Algorithms - A Review. **Energies**. MDPI. v. 7. 2014. Pg. 2821-2849.

LIU, H.; WENG, Q. Enhancing temporal resolution of satellite imagery for public health studies: A case study of West Nile Virus outbreak in Los Angeles in 2007. **Remote Sensing of Environment**. v. 117. 2012. Pg. 57-71.

LIU, W.T.H. **Aplicações de Sensoriamento Remoto**. 2 ed. Campo Grande: Oficina de Textos, 2006. 908 p.

LONG, D. et al. How sensitive is SEBAL to changes in input variables, domain size and satellite sensor?. **J. Geophys. Res.**, v. 116. 2011. 20 p.

LONG, D. et al. Generation of MODIS-like land surface temperatures under all-weather conditions based on a data fusion approach. **Remote Sensing of Environment**. Elsevier, v. 246. 2020. pg. 1-17.

LUO, Y. et al. STAIR: A generic and fully-automated method to fuse multiple sources of optical satellite data to generate a high-resolution, daily and cloud-/gap-free surface reflectance product. **Remote Sensing of Environment**. Elsevier. v. 214. 2018. pg. 87-99.

LUO, Y. et al. STAIR 2.0: A Generic and Automatic Algorithm to Fuse Modis, Landsat, and Sentinel-2 to Generate 10 m, Daily, and Cloud-/Gap-Free Surface Reflectance Product. **Remote Sensing**. MDPI, v. 12, n. 3209. 2020. 21 p.

MATZENAUER, R. et al. (ed). **Atlas Climático do Rio Grande do Sul**. Porto Alegre: CEMETRS (Centro Estadual de Meteorologia), 2011. 196 pg.

MIRALLES, D.G. et al. On the use of the term 'Evapotranspiration'. **Water Resources Research**. N. 56. 2020. 5 p.

MOLETTA-LOBOS, I. et al. Performance of Satellite-Based Evapotranspiration Models in Temperate Pastures of Southern Chile. MDPI: **Water**. v. 12, n. 3587. 2020. 16 pg.

MOREIRA, A.A. et al. Assessment of terrestrial water balance using remote sensing data in South America. **Journal of Hydrology**. Elsevier, v. 575, 2019. pg. 131-147.

MAHOUR, M. et al. A comparison of two downscaling procedures to increase the spatial resolution of mapping actual evapotranspiration. **ISPRS Journal of Photogrammetry and Remote Sensing**. Elsevier. V. 126, 2017. Pg. 56-67.

NDOSSI, M.I.; AVDAN, U. Inversion of Land Surface Temperature (LST) Using Terra ASTER Data: A Comparison of Three Algorithms. **Remote Sensing**. MDPI. v.8, n.12. 2016. 19 p.

NJOKU, E.G. (ed.). **Encyclopedia of Remote Sensing**. California, EUA: Springer Reference, 2014. 939 p.

PARASTATIDIS, D. et al. Online Global Land Surface Temperature Estimation from Landsat. **Remote Sensing**. MDPI, v. 9. n. 1208. 2017. 16 p.

PATTERSON, D. et al. **Geospatial ESG: The Emerging Application of Geospatial Data for gaining Environmental Insights on the Asset, Corporate and Sovereign Level**. WWF-UK, 2022. 37 p.

PROJETO MAPBIOMAS. Coleção 5 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil. Acesso em 27 mar. 2021. Disponível em: <<https://mapbiomas.org/>>.

PROJETO RADAMBRASIL. Mapa de Solos da Folha SH.22 - Porto Alegre. 2018. Disponível em: <https://dados.gov.br/dataset/cren_pedologias22>. Acesso em 31 jul. 2021.

RUIZ, M.O. et al. Local impact of temperature and precipitation on West Nile virus infection in Culex species mosquitoes in northeast Illinois, USA. **Parasites and Vectors**. BioMed Central. V. 3, n. 9. 2010. 16 p.

RUBERT, G.C. et al. Evapotranspiration of the Brazilian Pampa biome: seasonality and influential factors. **Water**. MDPI, v. 10, n. 12. 2019. 18 p.

SCHOWENGERDT, R. A. **Remote Sensing: Models and Methods for Image Processing**. 3 ed. Academic Press, 2006. 560 p.

SHUTTLEWORTH, W.J. **Terrestrial Hydrometeorology**. Wiley-Blackwell. 2012. 473 p.

SIVAPALAN, M.; BLÖSCHL, G. The Growth of Hydrological Understanding: Technologies, Ideas, and Societal Needs Shape the Field. **Water Resources Research**. AGU Publications. n. 53. 2017. Pg. 8137-8146.

SOBRINHO, J.A.; JIMÉNEZ-MUÑOZ, J.C.; PAOLINI, L. Land surface temperature retrieval from LANDSAT TM 5. **Remote Sensing of Environment**. Elsevier, n. 90, 2004. Pg. 434-440.

SCHOTT, J.R. **Remote Sensing: The Image Chain Approach**. Nova Iorque, EUA: Oxford University Press, 2007. 688 p.

SOUZA, V.A. et al. Evaluation of MOD16 algorithm over irrigated rice paddy using flux tower measurements in Southern Brazil. **Water**. MDPI, v.11, n. 9. 2019. 23 p.

SOUZA, C.M. et al. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**. MDPI, v. 12, n. 17. 2020. 27 p.

SOUZA, F.B. et al. Análise e Comparação de Medições de Temperatura In Situ e de Sensoriamento Remoto no Sul do Brasil. **Anais. XXIV Simpósio Brasileiro de Recursos Hídricos**. ABRHidro. Belo Horizonte – MG. 2021. Disponível em <<https://anais.abrhidro.org.br/job.php?Job=13428>>. Acesso em 11 maio 2022.

TANG, et al. Spatial-scale effect on the SEBAL model for evapotranspiration estimation using remote sensing data. **Agricultural and Forest Meteorology**. 174-175. pg. 28-42.

TAVARES, M.H. Estimativas da temperatura superficial da água por sensores remotos: acurácia e aplicabilidade com modelos de temperatura. Dissertação (Mestrado), UFRGS – PPGRHSA, Porto Alegre, 2019. 102 f.

TRAORE, F. Méthodes d'estimation de l'évapotranspiration réelle à l'échelle du bassin versant du Kou au Burkina Faso. **Dissertação**. Université de Liège. 2007. 133 p.

TRENTIN, R. et al. Análise comparativa da temperatura de superfície MODIS e temperatura do ar em diferentes situações no estado do Paraná. Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.7745.

TWINE, T.E. et al. Correcting eddy-covariance flux underestimates over a grassland. **Agric. For. Meteorol.** 103, 2000. Pg. 279–300

VENTER, Z.S. et al. Hyperlocal mapping of urban air temperature using remote sensing and crowdsourced weather data. **Remote Sensing of Environment**. Elsevier. v. 242, 2020. 14 p.

XIE, D. et al. Improving Spatial-Temporal Data Fusion by Choosing Optimal Input Image Pairs. **Remote Sensing**. MDPI. v. 10, n. 1142. 2018. 25 p.

XIONG, X. et al. Multiyear On-Orbit Calibration and Performance of Terra MODIS Thermal Emissive Bands. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 6. 2008. Pg. 1790-1803.

XU, L.; WANG, AIHUI. Application of the Bias Correction and Spatial Downscaling Algorithm on the Temperature Extremes From CMIP5 Multimodel Ensembles in China. **Earth and Space Science**. AGU. V. 6. 2019. Pg. 2508-2524.

YANG, B. et al. Spatio-temporal Cokriging method for assimilating and downscaling multi-scale remote sensing data. **Remote Sensing of Environment**. Elsevier, n. 255. 2021. 15 p.

YANG, Y. et al. Improved Daily Evapotranspiration Estimation Using Remotely Sensed Data in a Data Fusion System. **Remote Sensing**. MDPI. v. 14, n. 1772. 2022. 16 p.

YU, W.; MA, M. Scale mismatch between in situ and remote sensing observations of land surface temperature: Implications for the validation of remote sensing LST products. **IEEE Geoscience and Remote Sensing Letters**. V.12, n. 3. Mar. 2015. pg. 497-501.

WAN, Z. et al. Validation of the land-surface temperature products retrieved from Terra Moderate Resolution Imaging Spectroradiometer data. **Remote Sensing of Environment**. Elsevier, n. 83. 2002. p. 163–180.

WANG, K. LIANG, S. Evaluation of ASTER and MODIS land surface temperature and emissivity products using long-term surface longwave radiation observations at SURFRAD sites. **Remote Sensing of Environment**. Elsevier, n. 113. 2009. Pg. 1556-1565.

WENG, Q. Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends. **ISPRS Journal of Photogrammetry and Remote Sensing**. Elsevier, v. 64, n. 4. 2009. pg. 335-344.

WENG, Q. et al. Generating daily land surface temperature at Landsat resolution by fusing Landsat and MODIS data. **Remote Sensing of Environment**. Elsevier, n. 145. 2014. pg. 55-67.

WEISS, D.J. et al. An effective approach for gap-filling continental scale remotely sensed time-series. **ISPRS Journal of Photogrammetry and Remote Sensing**. Elsevier, n. 98. 2014. Pg. 106-118.

WILKS, D.S. **Statistical Methods in the Atmosphere Sciences**. 3 ed. Academic Press. 2011. 704 p.

ZAKSEK, K.; OSTIR, K. Downscaling land surface temperature for urban heat island diurnal cycle analysis. **Remote Sensing of Environment**. Elsevier, n. 117. 2012. pg. 114-124.

ZHAN, W. et al. Disaggregation of remotely sensed land surface temperature: Literature survey, taxonomy, and caveats. **Remote Sensing of Environment**. Elsevier, n. 131, 2013. Pg. 119-139.

ZHANG, K. et al. A review of remote sensing based actual evapotranspiration estimation. **WIREs Water**. Wiley Periods. 2016. 20 p.

ZHANG, C. et al. A decadal (2008–2017) daily evapotranspiration data set of 1 km spatial resolution and spatial completeness across the North China Plain using TSEB and data fusion. **Remote Sensing of Environment**. Elsevier, n. 262. 2021. 22 p.

ZHU, X. et al. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. **Remote Sensing of Environment**. Elsevier, n. 114. 2010. pg. 2610-2623.

ZHU, X. et al. A Framework for Generating High Spatiotemporal Resolution Land Surface Temperature in Heterogeneous Areas. **Remote Sensing**. MDPI, n. 13, n. 3885. 2021. pg. 1-25