

**UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ
CAMPUS DE CASCAVEL
CENTRO DE CIENCIAS EXATAS E TECNOLÓGICAS
PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA**

**FUSÃO ESPAÇO-TEMPORAL DE IMAGENS TERMAIS E AVALIAÇÃO DA REDE DE
MONITORAMENTO METEOROLÓGICO DA REGIÃO OESTE DO ESTADO DO PARANÁ**

ISAQUE DE SOUZA MENDES

**CASCAVEL – PARANÁ
AGOSTO – 2023**

ISAQUE DE SOUZA MENDES

**FUSÃO ESPAÇO-TEMPORAL DE IMAGENS TERMAIS E AVALIAÇÃO DA REDE DE
MONITORAMENTO METEOROLÓGICO DA REGIÃO OESTE DO ESTADO DO PARANÁ**

Tese de doutorado apresentada ao programa de Pós-Graduação em Engenharia Agrícola, em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração em Engenharia de Sistemas Biológicos e Agroindustriais.

Orientador: Prof. Dr. Erivelto Mercante.

Coorientadora: Prof^a. Dr^a. Ieda Del'Arco Sanches.

CASCADEL – PARANÁ

AGOSTO – 2023

de Souza Mendes, Isaque FUSÃO ESPAÇO-TEMPORAL DE
IMAGENS TERMAIS E AVALIAÇÃO DA
REDE DE MONITORAMENTO METEOROLÓGICO DA REGIÃO OESTE DO
ESTADO

DO PARANÁ / Isaque de Souza Mendes; orientador Erivelto
Mercante; coorientadora Ieda Del'Arco Sanches. -- Cascavel,
2023.

77 p.

Tese (Doutorado Campus de Cascavel) -- Universidade
Estadual do Oeste do Paraná, Centro de Ciências Exatas e
Tecnológicas, Programa de Pós-Graduação em Engenharia
Agrícola, 2023.

1. temperatura de superfície. 2. ESTAREFM. 3.
interpolação.

4. estações meteorológicas. I. Mercante, Erivelto,
orient. II. Del'Arco Sanches, Ieda, coorient. III. Título.



unioeste

Universidade Estadual do Oeste do Paraná
Reitoria
CNPJ 78.680.337/0001-84
Rua Universitária, 1619, Jardim Universitário
Tel: (45) 3220-3000 - Fax: (45) 3225-4590 - www.unioeste.br
CEP: 85819-110 - Cx. P.: 701
Cascavel - PARANÁ



ISAQUE DE SOUZA MENDES

FUSÃO ESPAÇO-TEMPORAL DE IMAGENS TERMAIS E AVALIAÇÃO DA EFICIÊNCIA DA MEDIÇÃO DA DISTRIBUIÇÃO ESPACIAL DE TEMPERATURA PELA REDE DE ESTAÇÕES METEOROLÓGICAS DA REGIÃO OESTE DO PARANÁ

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão, APROVADO(A) pela seguinte banca examinadora:

Documento assinado digitalmente
gov.br ERVELTO MERCANTE
Data: 23/08/2023 15:42:22-0300
Verifique em <https://validar.it6.gov.br>

Orientador(a) - Erivelto Mercante

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Documento assinado digitalmente
gov.br JOAO FRANCISCO GONCALVES ANTUNES
Data: 22/08/2023 09:14:09-0300
Verifique em <https://validar.it6.gov.br>

João Francisco Gonçalves Antunes

Empresa Brasileira de Pesquisa Agropecuária - EMBRAPA AGRICULTURA DIGITAL

Maritane Prior

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Documento assinado digitalmente
gov.br ANTONIO MARCOS MASSAO HACHISUCA
Data: 22/08/2023 10:58:13-0300
Verifique em <https://validar.it6.gov.br>

Antonio Marcos Massao Hachisuca

Universidade Estadual do Oeste do Paraná - Campus de Foz do Iguaçu (UNIOESTE)

Documento assinado digitalmente
gov.br SILVIA RENATA MACHADO COELHO
Data: 24/08/2023 16:26:51-0300
Verifique em <https://validar.it6.gov.br>

Silvia Renata Machado Coelho

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Cascavel, 18 de agosto de 2023.

BIOGRAFIA

Isaque de Souza Mendes, nascido em 23/01/1991, natural da cidade de Foz do Iguaçu, Paraná, Brasil, concluiu o curso de graduação em Engenharia Ambiental pelo Centro Universitário Dinâmica das Cataratas - UDC, no ano de 2014. Durante o ano de 2014 atuou como bolsista no projeto BiogásFert, realizado pelo Parque Tecnológico de Itaipu - PTI, em parceria com a ITAIPU Binacional, Embrapa, Fundação Arthur Bernardes (Funarbe), CIBiogás e Centro Internacional de Hidroinformática (CIH). Nesse projeto atuou no levantamento do plantel suíno e bovino no Brasil. Em 2015, integrou o projeto Plantio Direto com Qualidade, atuando no levantamento de dados para a avaliação da qualidade do plantio direto na Bacia do Paraná 3, bem como na disseminação do conhecimento do manejo adequado nesse sistema de cultivo. No ano de 2016, participou do projeto “Uso de geotecnologias para melhorias da agricultura familiar com vistas à produção agroecológica sustentável”, no Laboratório de Topografia e Geoprocessamento – GeoLab da Universidade Estadual do Oeste do Paraná - Unioeste, no levantamento de dados em propriedades de agricultores de base familiar. No ano de 2017 ingressou no Programa de Pós-Graduação em Engenharia Agrícola – Engenharia de Sistemas Biológicos e Agroindustriais, sob orientação do Prof. Dr. Erivelto Mercante, estudando o tema: **Potencial de geração de energia fotovoltaica e implantação de microrredes na área rural do município de Cascavel utilizando geotecnologias**, obtendo o título de Mestre em Engenharia Agrícola em 2019. No mesmo ano (2019), ingressou no Programa de Pós-Graduação em Engenharia Agrícola – Engenharia de Sistemas Biológicos e Agroindustriais, sob orientação do Prof. Dr. Erivelto Mercante, estudando o tema: **Fusão espaço-temporal de imagens termais e avaliação da rede de monitoramento meteorológico da região Oeste do Estado do Paraná**, para obtenção do título de Doutor em Engenharia Agrícola.

"A mente que se abre a uma nova ideia jamais
voltará ao seu tamanho original".

Albert Einstein

AGRADECIMENTOS

Agradeço à Universidade Estadual do Oeste do Paraná, pelo apoio e infraestrutura.

Ao meu orientador Erivelto Mercante, por apoiar minhas ideias e proporcionar um ambiente acolhedor e animado para o desenvolvimento do trabalho, e à minha coorientadora Ieda Del'arco Sanches, por ter me conduzido e orientado.

Ao Programa de Pós-graduação em Engenharia Agrícola- PGEAGRI, e ao seu corpo docente, pelos conhecimentos e ensinamentos compartilhados.

À Fundação Parque Tecnológico de Itaipu, pelo apoio.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, pela concessão de bolsa.

Ao Laboratório de Topografia e Geoprocessamento – GeoLab, que foi minha casa por esses longos anos, por disponibilizar o espaço, pelo apoio e bom humor, essenciais para o desenvolvimento do trabalho.

Aos meus amigos e colegas de laboratório, em especial ao Samuel Kuhl, pelo auxílio durante todas as etapas críticas de análise estatística e elaboração da tese. À Ana Matos, pelo auxílio no levantamento e organização de dados. Ao Ivã Luis Caon, pelo auxílio na confecção dos *scripts*. À Thamiris Pimentel Kuhn, pelo apoio em momentos desesperadores e auxílio na redação da tese. À Diandra Ganascini, por me auxiliar no escopo geral da tese e ser uma parceira de reclamações e lamentos.

MENDES, Isaque de Souza. **Fusão espaço-temporal de imagens termais e avaliação da rede de monitoramento meteorológico da região oeste do estado do Paraná**. Orientador: Erivelto Mercante; Coorientador: Ieda Del'Arco Sanches. 2023. 66 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel – Paraná, 2023.

RESUMO

As alterações climáticas globais afetam a distribuição espacial de temperatura em escala regional e local. As ferramentas de *Smart Farm* auxiliam a tomada de decisão em tempo hábil. Entretanto, a continuidade da coleta de dados é de suma importância para entender a dinâmica climática em escala local, portanto a redundância é fundamental para continuidade da captura e preenchimento de dados em caso de falhas sistêmicas. Dados de sensoriamento orbital, bem como estações governamentais distribuídas na região de interesse podem ser utilizadas como ferramentas de redundância dos sistemas de *Smart Farming*. Entretanto, analisar a variabilidade espacial da distribuição de temperatura pode ser limitada em pequenas e médias áreas de cultivo, devido à baixa resolução espacial ou baixa resolução temporal de sensores orbitais. Este trabalho objetivou avaliar a correlação entre temperatura média diária de superfície resultante de 3 e 4 observações diárias e temperatura média do ar coletada por estações meteorológicas, bem como fusionar, utilizando o algoritmo ESTAFM, e avaliar a utilização de imagens sintéticas de dados de temperatura de superfície dos sensores MODIS – Terra e Aqua e TIRS – Landsat 8 e 9. Também foi avaliada a distribuição espacial das estações públicas disponíveis na região Oeste do Estado do Paraná. As imagens de temperatura média da superfície resultantes de 3 e 4 observações apresentaram forte correlação com a temperatura média diária do ar, com coeficiente de correlação r_s de 0,92 para ambas as observações. O ajuste de modelo apresentou coeficiente de determinação $R^2_{ajustado}$ de 0,85 para 3 observações e 0,86 para 4 observações; o RMSE foi de 1,74 °C e 1,5 °C respectivamente. As imagens sintéticas de temperatura média diária de superfície apresentaram coeficiente de correlação r_s de 0,69 e coeficiente de determinação $R^2_{ajustado}$ de 0,59. Houve superestimativa dos valores médios de temperatura de superfície nas imagens sintéticas, e a cobertura de nuvens foi um empecilho para a geração de maiores volumes de dados. A avaliação das estações meteorológicas foi realizada com base em interpolação de dados e estes, quando comparados à distribuição espacial de temperatura modelada para temperatura do ar, apresentaram erros principalmente em aglomerados urbanos, com coeficientes de correlação r_s de 0,42 no verão, 0,53 no outono, 0,51 no inverno e 0,63 na primavera. Entretanto, quando comparados às estações instaladas em meio agrícola, com características ambientais semelhantes aos locais de instalação das estações, não apresentaram diferença estatística de dados e coeficiente de correlação r_s de 0,93.

Palavras-chave: temperatura de superfície, ESTARFM, interpolação, estações meteorológicas.

MENDES, Isaque de Souza. **Spatiotemporal fusion of thermal images and evaluation of the meteorological monitoring network in the western region of the state of Paraná.** Advisor: Eritelto Mercante; Co-advisor: Ieda Del'Arco Sanches. 2023. 66 p. Dissertation (Doctorate in Agricultural Engineering) – Western Paraná State University, Cascavel – Paraná, 2023.

ABSTRACT

Global climate changes affect the spatial distribution of temperature at regional and local scales. *Smart Farm* tools assist in timely decision-making. However, data collection continuity is of paramount importance in understanding local-scale climatic dynamics, thus redundancy is fundamental for the continuity of data capture and filling in case of systemic failures. Orbital sensing data, as well as government stations distributed in the region of interest, can be used as redundancy tools for *Smart Farming* systems. Nonetheless, analyzing the spatial variability of temperature distribution can be limited in small and medium cultivation areas due to the low spatial or temporal resolution of orbital sensors. This study aimed to evaluate the correlation between daily average surface temperature resulting from 3 and 4 daily observations and the daily average air temperature collected by meteorological stations. It also aimed to merge, using the ESTARFM algorithm, and evaluate the use of synthetic surface temperature data images from MODIS – Terra and Aqua sensors and TIRS – Landsat 8 and 9 sensors. Additionally, the spatial distribution of publicly available stations in the Western Region of the State of Paraná was assessed. The images of daily average surface temperature resulting from 3 and 4 observations showed a strong correlation with the daily average air temperature, with a correlation coefficient r_s of 0.92 for both observations. The model fit had an adjusted coefficient of determination R^2_{adjusted} of 0.85 for 3 observations and 0.86 for 4 observations, with RMSE values of 1.74 °C and 1.5 °C, respectively. The synthetic images of daily average surface temperature had a correlation coefficient r_s of 0.69 and an adjusted coefficient of determination R^2_{adjusted} of 0.59. There was an overestimation of average surface temperature values in synthetic images, and cloud cover posed an obstacle to the generation of larger volumes of data. The evaluation of meteorological stations was carried out based on data interpolation, and when compared to the modeled spatial temperature distribution for air temperature, they showed errors mainly in urban clusters, with correlation coefficients r_s of 0.42 in summer, 0.53 in autumn, 0.51 in winter, and 0.63 in spring. However, when compared to stations installed in agricultural areas with environmental characteristics similar to the station locations, no statistical differences in data were observed, and the correlation coefficient r_s was 0.93.

Keywords: surface temperature, ESTARFM, interpolation, meteorological stations.

SUMÁRIO

LISTA DE TABELAS.....	IX
LISTA DE FIGURAS	X
1 INTRODUÇÃO	1
2 OBJETIVOS.....	2
2.1 Objetivo geral	2
2.2 Objetivos específicos.....	2
3 REVISÃO BIBLIOGRÁFICA	3
3.1 Influências do clima na agricultura.....	3
3.2 Panorama da cultura do milho	4
3.3 Panorama da cultura do trigo	5
3.3.1 Influência das condições climáticas na cultura do trigo.....	6
3.4 <i>Smart farm</i>	8
3.4.1 Modelos de interpolação para dados meteorológicos	10
3.5 Sensoriamento remoto orbital na agricultura	11
3.5.1 Sensoriamento remoto termal	11
3.5.2 Fusão de imagens.....	14
4 MATERIAL E MÉTODOS.....	16
4.1 Aquisição e armazenamento dos dados	17
4.2 Definição dos modelos e observações utilizados.....	18
4.3 Fusão de imagens orbitais.....	20
4.3.1 Análise preliminar	21
4.3.2 Elaboração das imagens sintéticas	21
4.4 Espacialização de dados meteorológicos e avaliação da distribuição espacial das estações meteorológicas do oeste do Paraná	23
5 RESULTADOS E DISCUSSÃO	25
5.1 Estatística descritiva LST média 4 observações.....	25
5.2 Análise do modelo de 4 e 3 observações	27
5.3 Teste de correlação das imagens sintéticas	30
5.4 Espacialização de temperatura na região oeste	34
6 CONCLUSÕES	40
7 CONSIDERAÇÕES FINAIS	41

REFERÊNCIAS	42
APÊNDICES.....	49
APÊNDICE A - CÁLCULO E XXXX	50
APÊNDICE B – CÁLCULO E YYYY.....	53
APÊNDICE C - IMAGENS SINTÉTICAS ZZZZ	56

LISTA DE TABELAS

Tabela 1	Informações gerais das bandas disponíveis dos sensores a bordo do satélite Landsat 8.....	12
Tabela 2	Descrição dos produtos MODland	13
Tabela 3	Estatísticas comparativas entre modelos.....	18
Tabela 4	Apresentação das datas das imagens de predição e datas preditas.....	23
Tabela 5	Resumo descritivo dos dados de temperatura dos <i>pixels</i> nos pontos das estações utilizadas para o ano de 2020.....	25
Tabela 6	Resumo descritivo dos dados de temperatura das estações meteorológicas que coincidiram com <i>pixels</i> válidos para o ano de 2020	26
Tabela 7	Parâmetros utilizados nas interpolações de dados de temperatura média das estações	34

LISTA DE FIGURAS

Figura 1	Esquema representativo da janela móvel utilizada pelo ESTARFM.....	15
Figura 2	Distribuição das estações meteorológicas, em relação aos limites da região Oeste do Paraná.....	16
Figura 3	Fluxograma de desenvolvimento do trabalho.....	17
Figura 4	Diferença entre modelos de quatro e três observações, dada a ausência de dados em função de presença de nuvens.	19
Figura 5	Esquema de fluxo dos procedimentos estatísticos realizados na avaliação das imagens resultantes de três e quatro observações diárias.....	19
Figura 6	Fluxograma das etapas sequenciais do processamento de imagens por meio do algoritmo ESTARFM.....	22
Figura 7	Gráfico de dispersão dos dados de validação para LST 4 observações.	28
Figura 8	Gráfico de dispersão dos dados de validação para LST 3 observações.	29
Figura 9	Gráfico de dispersão dos dados brutos de temperatura de superfície e temperatura do ar.	31
Figura 10	Apresentação da imagem grosseira preditora (LST média) e a imagem predita (sintética ESTARFM).	32
Figura 11	Apresentação da imagem grosseira preditora (LST média) e a imagem predita (sintética ESTARFM), sob intenso efeito de cobertura de nuvens.	33
Figura 12	Espacialização dos erros apresentados na comparação dos dados interpolados, em relação aos dados orbitais modelados - Verão.	35
Figura 13	Espacialização dos erros apresentados na comparação dos dados interpolados, em relação aos dados orbitais modelados - Outono.	36
Figura 14	Espacialização dos erros apresentados na comparação dos dados interpolados, em relação aos dados orbitais modelados - Inverno.	37
Figura 15	Espacialização dos erros apresentados na comparação dos dados interpolados, em relação aos dados orbitais modelados - Primavera.....	38
Figura 16	Distribuição espacial do somatório dos erros das interpolações, em relação às imagens T_{ar}	39

1 INTRODUÇÃO

O aumento da demanda por alimentos é um fator que impulsiona investimentos e o desenvolvimento de técnicas de melhoramento genético e sistemas de cultivo de alimentos. Aplicações como a agricultura de precisão vêm obtendo resultados animadores com aumento de produção sem expansão de área agrícola. O próximo passo é a otimização do monitoramento de precisão com o uso de tecnologias avançadas no campo, as chamadas técnicas de *Smart farming*. Esse sistema realiza o levantamento de variáveis agrícolas por meio de sensores e armazena informações em banco de dados, possibilitando inferências e tomada de decisão em tempo hábil e com o máximo de exatidão, determinado pela quantidade e qualidade dos dados armazenados.

Um fator de extrema importância nesse sistema é a redundância, que pode ser explicada como sistema de reforço para a continuidade dos dados como, por exemplo, quando um componente do sistema de monitoramento falha, a redundância permite a obtenção do dado por outra fonte, seja de equipamentos reserva ou mesmo de uma fonte de dados diferente, como as de sensoriamento remoto orbital.

O sensoriamento remoto orbital é uma alternativa viável para o levantamento de dados de maneira indireta, pois, além da rapidez, pode proporcionar a aferição de variáveis agrícolas de maneiras não destrutivas, por não necessitar de contato com o alvo.

Contudo, a utilização de dados gratuitos encontra um empecilho, pois, a maioria dos produtos de sensoriamento remoto orbital gratuitos não reúnem duas características essenciais para o monitoramento preciso na lavoura: alta resolução espacial e alta resolução temporal. Essa dificuldade pode ser contornada integrando a resolução espacial de um sensor com a resolução temporal de outro, por meio de técnicas de fusão de imagens.

A temperatura é um importante parâmetro para o sistema de cultivo, que auxilia em análises de balanço e estresse hídrico na lavoura, detecção de doenças e indicadores de período de cultivo como graus dias, dentre outros. Existem diversas estações meteorológicas instaladas e mantidas por órgãos governamentais, mas geralmente são esparsas e muitas vezes estão distantes do local que se deseja monitorar. Por isso, o uso de técnicas de espacialização (interpolação) de dados pode contribuir para a manutenção de dados locais (nas propriedades rurais) por meio de dados de estações meteorológicas governamentais, de modo a extrapolar os valores coletados considerando a distância do ponto que se deseja monitorar.

2 OBJETIVOS

2.1 Objetivo geral

Analisar a correlação entre a temperatura da superfície e temperatura do ar, a elaboração de imagens sintéticas de temperatura de superfície e a verificação da eficiência da distribuição espacial de estações meteorológicas na modelagem da temperatura.

2.2 Objetivos específicos

- a) Avaliar a correlação entre temperatura média diária de superfície gerada com produtos MODIS de três e quatro observações e temperatura média diária do ar obtida com estações meteorológicas por meio de modelagem linear;
- b) Avaliar a correlação entre temperatura média diária do ar e imagens de temperatura média diária de superfície sintéticas gerada a partir do modelo ESTARFM com produtos dos sensores MODIS – Terra e Aqua e TIRS – Landsat 8 e Landsat 9;
- c) Realizar interpolações dos dados das estações públicas na região Oeste do Paraná e comparar a distribuição da temperatura gerada na interpolação com estações de campo e com as imagens de temperatura média de superfície modeladas para temperatura do ar.

3 REVISÃO BIBLIOGRÁFICA

3.1 Influências do clima na agricultura

As mudanças climáticas globais são um risco à produção agrícola e à segurança agroalimentar global (ZAKARIA et al., 2020), em especial aos pequenos produtores com baixo poder aquisitivo.

Em países da África Austral e da África Subsaariana já são testados modelos de produção inteligente voltados para a adaptação às mudanças climáticas globais e têm obtido resultados promissores tanto na adoção por parte da população de agricultores como na efetividade do sistema, no que diz respeito aos benefícios sociais agregados e na lucratividade do sistema de cultivo (BRANCA et al., 2020; CLAY; ZIMMERER, 2020; FALING, 2020; OGADA et al., 2020; ZAKARIA et al., 2020).

Chen e Gong (2020) apontam, em seu estudo desenvolvido utilizando dados dos últimos 35 anos na China, que a adaptação agrícola de longo prazo pode compensar as perdas no curto prazo, ocasionadas pelo aquecimento climático. Contudo, as projeções futuras ocasionadas pela progressão das alterações no clima apontam substancial diminuição na produção agrícola chinesa.

Assad et al. (2016), ao relacionarem modelos de projeção de aquecimento global e as áreas de cultivo de grãos no Brasil, apontam queda significativa nas áreas consideradas de baixo risco à produção, como é o exemplo do trigo, que pode sofrer perdas de 14,8% dessas áreas, tornando-se áreas de alto risco à produção dessa cultura. Esse entrave pode ser contornado pelo desenvolvimento de cultivares mais resistentes às altas temperaturas e as secas e adaptações no manejo, o que torna evidente a necessidade de maior controle e monitoramento da lavoura, por meio de monitoramento inteligente da fazenda produtora.

As variações de temperatura globais são passíveis de avaliação por meio de Modelos Globais de Culturas em Grade (GGCMs). Entretanto, tomando como base o impacto que essa mudança causaria no produtor rural individualmente, o prejuízo chegaria antes do manejo, e por esse motivo um monitoramento constante das condições biofísicas do talhão de cultivo forneceria subsídio para uma tomada de decisão precoce, como optar por outra cultivar mais atrativa comercialmente ou pelo investimento em sistemas de irrigação, de forma a diminuir os efeitos de alterações no clima na região de cultivo (ZILLI et al., 2020).

Como apontado por De Paula (2020), a variação do impacto econômico das mudanças climáticas nas áreas agrícolas pode ocorrer por diferenças entre o clima correspondente à

localização de cada fazenda, tecnologia empregada no sistema de cultivo e da capacidade de adaptação, onde a tecnologia aplicada ao monitoramento pode fornecer subsídios para a rápida identificação de empecilhos climáticos a variedades agrícolas, possibilitando maior agilidade de resposta ao problema.

Outro fator a ser abordado em relação às mudanças no clima é a modificação de ciclos produtivos em função dos graus-dias acumulados, em que cada cultivar e variedade apresentam um valor específico que inicia na data de plantio e determina a data de colheita, em função das médias diárias de temperatura acumuladas durante o ciclo (AKYUZ; KANDEL; MORLOCK, 2017).

O fator grau-dia é importante no planejamento estratégico do cultivo inteligente, pois, indiretamente, fornece informações a respeito da atividade metabólica das cultivares, conforme Cattani et al. (2017) verificam em seu experimento, encontrando as melhores correlações entre *Normalized Difference Vegetation Index* (NDVI) e rendimento do trigo quando o índice foi padronizado em função do tempo e graus-dias.

Akyuz, Kandel e Morlock (2017) utilizaram graus-dias de desenvolvimento para auxiliar no planejamento estratégico e gerenciamento de riscos de agricultores de Dakota do Norte, em Minnesota nos EUA, de modo que pudessem selecionar a melhor data de início de cultivo para que a colheita ocorra antes da chegada de temperaturas críticas que possam comprometer a cultura.

Graus-dias de crescimento foram utilizados para o desenvolvimento de uma ferramenta que auxilia na tomada de decisão quanto à cultura do milho, no Cinturão do Milho nos EUA, de modo que o produtor possa, além de planejar o período de cultivo, ter uma previsão de como ocorrerá o comportamento de temperaturas diárias durante o ciclo, por meio de projeções provenientes do Serviço Meteorológico Nacional (ANGEL et al., 2017).

Conforme Cammarano e Tian (2018) apontam em seu estudo, duas culturas de extrema importância econômica e base para a segurança alimentar global: trigo e milho, podem sofrer grandes impactos com a variação de temperatura, ressaltando a importância do entendimento da variação espacial desse fator.

3.2 Panorama da cultura do milho

O Brasil apresenta uma forte base agrícola, que o classifica como segundo maior produtor mundial de soja e o primeiro no que concerne a outras culturas, como café, cana-de-açúcar e suco de laranja (FAO, 2023).

No contexto nacional, o Paraná se destaca como o segundo maior produtor nacional de grãos, com produção de 33839,4 mil toneladas na safra 2021/2022 e com previsão de 45552,8 mil toneladas para a safra 2022/2023 (CONAB, 2020a, CONAB, 2023).

O milho é uma cultura de importância significativa na economia global e falhas em se obter um processo de cultivo eficiente podem resultar em perdas financeiras de altas proporções (ZERMAS et al., 2019).

Segundo dados da FAO (2023), as Américas são responsáveis por 48,9% da produção mundial de milho (cerca de 592 milhões de toneladas), sendo que o Brasil é responsável por 14,93% dessa produção, colocando-se em segundo lugar nas Américas, atrás somente dos Estados Unidos da América, com produção correspondente a 64,81%.

Dada a importância dessa cultura, a utilização de mecanismos de acompanhamento de condições meteorológicas durante a safra pode auxiliar na minimização de efeitos negativos que eventos climáticos atípicos podem causar para essa cultura, que sofre grande influência desses fatores, diminuindo riscos de déficits alimentares causados por eventuais perdas na produção (MABILANA; FONTANA; FONSECA, 2012).

Para exemplificar os efeitos de variação extrema de temperatura, Cammarano e Tian (2018) demonstraram os efeitos de temperatura mínima inferior a 8 °C e temperatura máxima superior a 34 °C nos estágios de floração e enchimento de grãos, aqui considerados os principais no cultivo. No primeiro cenário o desenvolvimento da cultura foi interrompido, enquanto o segundo resultou na aceleração do ciclo, encurtando a fase de enchimento de grãos e interrupção no crescimento.

Conforme apontado por Li et al. (2021), modelos temporais de projeção de modificações climáticas apontam que os rendimentos da produção da cultura do milho são prejudicados pelo aumento da temperatura média na fase de crescimento. Portanto, há necessidade de ampliação da capacidade de monitoramento para verificação precoce dessas modificações em diferentes locais, bem como a adoção de medidas como melhoramento genético em tempo hábil para se evitar insegurança alimentar.

3.3 Panorama da cultura do trigo

Aproximadamente, metade das calorias consumidas no mundo são provenientes dos grãos, sendo que cerca de 25% desse índice vêm do trigo. Em alguns países esse percentual é ainda mais significativo. Por isso, sua produção e distribuição são preocupações centrais da economia política mundial (GONZÁLEZ-ESTEBAN, 2017).

Segundo levantamento da CONAB (2020b), os principais produtores mundiais de trigo são: União Europeia, China, Índia, Rússia e Estados Unidos e, segundo o departamento de agricultura dos Estados Unidos (USDA, 2020), a estimativa de área colhida de trigo no mundo para a safra 2019/2020 é de 217,2 milhões de ha, apresentando um aumento de 0,8%, quando comparada à safra anterior (2018/2019). Da mesma forma, a produção estimada também apresenta incremento na ordem de 4,5%, totalizando 764,5 milhões de toneladas.

Na produção global, o Brasil se coloca em décimo sexto lugar no ranking de produção de trigo, com estimativa de 10.6 milhões de toneladas, imediatamente atrás da Argentina, com 12.6 milhões de toneladas (FAO, 2023).

No contexto nacional, o sul do país se destaca como a principal região produtora de trigo, com cerca de 6,1 mil toneladas (2019/2020), a qual teve um incremento de 36,8%. Os estados com maior produção são o Rio Grande do Sul, com 2,2 mil toneladas em 2018/2019 e 2,7 mil toneladas em 2019/2020; o Paraná apresentou produção de 2,1 mil toneladas na safra 2018/2019 e 3,3 mil toneladas na safra de 2019/2020 (CONAB, 2020b).

A demanda interna é maior que a produção, portanto, ainda se realiza importação. Em fevereiro de 2020, o Brasil importou 526,1 mil toneladas de trigo. Desse total, 87,5% foram de origem Argentina, 6,91% dos Estados Unidos, 4,73% de trigo proveniente do Paraguai e 0,76% de origem francesa. O volume importado no mês em análise foi 18,78% inferior ao do mês anterior (CONAB, 2020a).

Há uma tendência de redução de áreas cultivadas e na produção de trigo ao longo do tempo. Isso se deve, principalmente, às alterações climáticas que vêm ocorrendo, especialmente os efeitos combinados de temperatura elevada, aumento de secas e redução da disponibilidade de água para cultivo (XIAO; BAI; LIU, 2018). Estima-se que a produção global de trigo apresente redução de 6% para cada °C de aumento adicional de temperatura e se torne mais variável com o tempo e no espaço (ASSENG et al., 2015).

3.3.1 Influência das condições climáticas na cultura do trigo

De modo geral, a produção agrícola é altamente dependente dos fatores climáticos, trazendo um impacto significativo no rendimento dos grãos (HARKNESS et al., 2020). O trigo é uma cultura agrícola que sofre grande impacto com alterações no clima. Demirhan (2020), ao estudar os efeitos de anomalias de temperatura em curto prazo, bem como mudanças climáticas no longo prazo, verificou que essas alterações causam prejuízos significativos à produção desse grão. A estimativa apontada por Liu et al. (2016) confirma que, com variação positiva de 1°C na temperatura, a produção mundial de trigo pode cair entre 4,1 % e 6,4%.

Narayanan (2018) afirma que cada aumento de 1°C diminui o rendimento em, aproximadamente, 10%.

A queda na produção de trigo é um risco à segurança alimentar global devido a sua importância nutricional, e em alguns países essa produção já está estagnada, como é o exemplo da Austrália, cuja produção está estagnada desde 1990, principalmente em função da diminuição das chuvas e aumento de temperaturas (HOCHMAN; GOBBETT; HORAN, 2017). Entretanto, os autores reiteram que as projeções de queda preditas podem ser mitigadas com emprego de novas tecnologias de manejo.

As mudanças afetam a produção de trigo de forma direta e indireta, pois o trigo é afetado por diversas doenças em todo o mundo e os agentes responsáveis por essas doenças são afetados pelas condições climáticas. Portanto, à medida que ocorrem as alterações climáticas e, em especial as mudanças na temperatura, há grande tendência de aumento de patógenos. Além disso, as mudanças climáticas interferem na interface da planta daninha *versus* cultura e o manejo torna-se dificultado (BAJWA et al., 2020).

Globalmente, o trigo é a principal fonte de proteína vegetal na alimentação humana, com maior teor de proteína dentre os cereais principais, sendo que a qualidade do trigo é dependente da composição e qualidade das proteínas e, portanto, é o que o limita ao uso final. O efeito do estresse por calor ou seca, durante o enchimento dos grãos, afeta diretamente a composição das proteínas e do amido (SINGH; GUPTA; KAUR, 2012).

A fase de desenvolvimento mais indicada para a realização de análises de interferências biofísicas no trigo é a enchimento de grãos (PREY; HU; SCHMIDHALTER, 2020), já que o estresse causado por conta das altas temperaturas é maior nas fases reprodutivas do trigo que nas vegetativas, pois as altas temperaturas têm influência direta no número e peso dos grãos (NARAYANAN, 2018). Essas afirmações também corroboram as pesquisas de Asseng, Foster e Turner (2010), que indicam que as altas temperaturas, em virtude das variações climáticas atuais na fase de enchimento dos grãos de trigo, são um risco substancial à segurança alimentar, pois podem acarretar prejuízos no rendimento da cultura.

Manter a qualidade dos grãos perante as mudanças climáticas é fundamental para nutrição humana, propriedades funcionais da composição nutricional do grão são determinantes para o uso final. De modo geral, o rendimento e a qualidade de uma safra de trigo são determinados pela interação de disponibilidade de água, nutrição, meio ambiente, pragas e doenças, juntamente com a composição genética (NUTTALL et al., 2017).

No que se refere ao trigo, os impactos de curtos períodos de temperaturas extremas no desenvolvimento e na qualidade são relevantes, pois a qualidade revela sensibilidade temporal a temperaturas extremas. Vale ressaltar que as safras de baixa qualidade podem ser rejeitadas por serem inadequadas para panificação ou semeadura. Devido a isso, o trigo é avaliado comercialmente com base na qualidade do grão apresentado, sendo que grãos

com melhor qualidade conseguem obter maior valor de mercado (NASEHZADEH; ELLIS, 2017).

3.4 *Smart farm*

Capmourteres et al. (2018) destacam a necessidade da expansão agrícola, seja em extensão territorial ou em intensificação da produção, para atender o número crescente da população mundial nos próximos 30 anos. Contudo, a agricultura já se configura como um dos principais fatores impulsionadores da perda de biodiversidade, o que torna necessária a utilização de métodos de intensificação de produção em áreas já existentes para essa finalidade, minimizando a necessidade de aumento da zona agrícola, como é o caso da aplicação de técnicas de agricultura de precisão.

A agricultura de precisão consiste em uma abordagem inteligente dos parâmetros biofísicos inerentes à agricultura, visando redução de custos mediante uso eficiente de insumos, aumento de produtividade, minimização da necessidade de expansão de área e a sustentabilidade (MONDAL; BASU, 2009). Essas técnicas se valem de dados amostrais de campo a fim de determinar as necessidades físicas e químicas do solo, em relação a cultivar implantada, de modo que se possa adotar o manejo adequado a cada área.

Para tanto, os métodos de agricultura de precisão levam em consideração a variabilidade espacial das informações da lavoura, para que se possa realizar a adequação pontual do meio agrícola, e as ferramentas de sensoriamento remoto contribuem para a redução de tempo e custo na realização dessas análises (HUANG et al., 2018).

O aproveitamento e tratamento de dados de sensoriamento remoto e demais dados inerentes ao meio agrícola aliados às tecnologias de comunicação, sensores e computação de dados em nuvem, com o intuito de maximizar produtividade e fornecer subsídio técnico e científico para a tomada de decisão, culminam no conceito de *Smart farm* (O'GRADY; O'HARE, 2017; YOON; LIM; PARK, 2020). Em resumo, *Smart farm* é o termo utilizado quando um sistema produtivo passa por uma metodologia inteligente de processos, que envolve captura de informação por meio de sensores ou entrada de dados coletados por outras fontes, tratamento de dados e extração de informações que subsidiem a tomada de decisão pelo responsável pelo sistema de cultivo.

As tecnologias de *Smart farm* possibilitam ao produtor o gerenciamento eficiente do sistema produtivo, pois fornece informações a respeito das condições da lavoura, estatísticas

e previsões, facilitando a realização de manejo preventivo, de modo a evitar perdas no processo (COLEZEA et al., 2018).

A evolução computacional promoveu um rápido aumento no poder de processamento e armazenamento de um grande volume de dados, possibilitando ao *Smart farming* a realização de análises de dados provenientes de diversas bases, como demonstrado por Van De Kerkhof et al. (2015), que utilizaram dados de sensores na lavoura, sensoriamento remoto, dados de condições do solo, histórico da parcela, informações meteorológicas, dentre outros dados, para realizar inferências na lavoura mediante análise de correlação entre as variáveis, para determinar as causas de baixo rendimento no talhão.

Um dos fatores importantes para a aplicação efetiva desse conceito é o monitoramento climático, que pode ser realizado por meio de estações no local da propriedade para que se garanta a precisão da coleta de informação quanto as condições ambientais na lavoura. Contudo, Ramírez-Gil et. al. (2018) destacam o elevado custo de aquisição desses equipamentos, sendo necessário o desenvolvimento alternativo destes com materiais de baixo custo. Outra saída é a utilização de uma abordagem diferente de obtenção de dados, como a aquisição por meio de sensoriamento remoto orbital, o que aumentaria a acessibilidade de implantação desse sistema para pequenos e médios produtores, visto que existe grande quantidade de dados com acesso gratuito.

A disponibilidade de dados de sensoriamento remoto, seja orbital, aéreo ou terrestre, se configura como Big Data, já que fornece uma grande quantidade de dados em diferentes resoluções espaciais e temporais (HUANG et al., 2018), e a análise desse volume de dados de diferentes fontes auxilia tanto na validação quanto na preservação de dados em caso de falhas de *software* ou de *hardware*.

Dados provenientes de estações meteorológicas, geralmente, fornecem pouca cobertura de terreno, pois as estações, devido a custos de instalação e manutenção desencorajadores, não são instaladas de maneira regular (VIGGIANO et al., 2019). Porém, o aumento na frequência de eventos climáticos atípicos tem se tornado cada vez mais comum, em decorrência das alterações climáticas globais e, portanto, faz-se cada vez mais necessário o emprego de tecnologias de monitoramento climático nas propriedades rurais, a fim de seja incrementado o poder de resiliência do agricultor. em relação a essas eventualidades (NSABAGWA et al., 2019).

Outro fator que pode influenciar a produtividade de um talhão é a elevação do terreno (KUIAWSKI et al., 2017). Portanto, esse parâmetro deve ser considerado quando se determinar a distribuição de sensores na lavoura, a fim de monitorar as variáveis ambientais do talhão.

3.4.1 Modelos de interpolação para dados meteorológicos

A interpolação de dados provenientes de estações meteorológicas auxilia na identificação espacial de variáveis importantes para a agricultura. Dentre os diversos algoritmos, os métodos de interpolação de dados *Inverse distance weighting* (IDW) e *Ordinary kriging* (OK) são mais conhecidos. Contudo, a utilização de técnicas de aprendizado de máquina vem ganhando espaço, como o algoritmo *Random Forest* para previsões espaciais (SILVA JÚNIOR et al., 2019).

Ao comparar os modelos IDW, *Spline*, *Krigagem* universal e *Natural neighbour* para dados de radiação solar, Rodríguez-Amigo et al. (2017) obtiveram melhores resultados utilizando *Krigagem* universal com semivariograma quadrático, em função no número e distribuição das estações meteorológicas disponíveis em Castilla-León, Espanha.

Em caso de baixo número de pontos amostrais, Babak e Deutsch (2009) afirmam que o método IDW leva vantagem em relação à *Krigagem*, que necessita de maior número de pontos para a determinação de dependência espacial.

A seleção do método de interpolação de dados é uma dúvida que permeia diversos estudos espaciais. Nesse sentido, Bier e Souza (2017) propuseram o Índice de seleção de interpolador (ISI), que consiste em um índice que avalia diferentes interpoladores, com base em um conjunto de dados e sua localização espacial, dado pela Equação 1.

$$ISI = \frac{abs(EM)}{\max_{i=j}^j [abs(EM)]} + \frac{(DP_{EM} - \min_{i=j}^j DP_{EM})}{\max_{i=j}^j DP_{EM}} \quad (1)$$

em que: $abs(EM)$ é o módulo do erro médio obtido na validação cruzada das interpolações; DP_{EM} corresponde ao desvio padrão dos erros médios; $\min_{i=j}^j$ é o menor valor encontrado entre os j modelos comparados; $\max_{i=j}^j$ corresponde ao maior valor entre os j modelos comparados (BIER; SOUZA, 2017).

Portando, esse índice realiza validação cruzada e, em função dos erros de estimativa, indica o modelo com menor erro, de forma que, quanto menor o valor do índice melhor o ajuste do modelo aos dados (BIER; SOUZA, 2017).

3.5 Sensoriamento remoto orbital na agricultura

O sensoriamento remoto possibilita a compreensão da superfície terrestre e as interações que ocorrem nesse meio, adquirindo informações a respeito dos diversos elementos da paisagem, sem a necessidade de contato com esses elementos (JENSEN, 2009).

O sensoriamento remoto possibilita diferentes níveis de tomada de decisão, desde ações governamentais de gestão abrangente do meio agrícola a decisões locais, em escala de talhão, para que o agricultor realize ações de manejo preciso na lavoura (WEISS; JACOB; DUVEILLER, 2020). Dois fatores importantes ao se avaliar a superfície da Terra com dados de sensoriamento remoto orbital são as resoluções espacial e temporal.

A baixa resolução temporal de dados, que se refere ao tempo demandado para um sensor imagear um mesmo ponto do globo, pode acarretar falhas de monitoramento agrícola, que é afetado grandemente pela presença de nuvens no momento da captura (PRUDENTE et al., 2020), demandando um longo período de tempo em relação às necessidades de periodicidade no monitoramento agrícola para uma nova captura, com possibilidades de condições de baixa ou nenhuma cobertura de nuvens favorável ao monitoramento. A resolução espacial se refere ao tamanho do lado do *pixel*. Desse modo, se uma imagem tem 20 metros de resolução espacial, cada *pixel* cobre uma área de 20 m X 20 m, sendo este o limite de detecção de objetos na superfície.

3.5.1 Sensoriamento remoto termal

Pires e Ferreira Jr. (2015) afirmam que o sensoriamento remoto termal tem a vantagem de permitir a espacialização e o monitoramento multitemporal de dados de temperatura na superfície e obtiveram resultados satisfatórios ao utilizarem as bandas termais dos sensores a bordo dos satélites Landsat 7 e 8 para esse fim.

Os dados provenientes dos sensores embarcados no satélite Landsat 8 lançado em 2013, apresentam bandas espectrais com resolução espacial de 30 m captadas pelo sensor OLI, e bandas termais do sensor TIRS, com resolução nativa de 100 m reamostradas para 30 m, de modo a coincidir com a resolução das demais bandas espectrais, com resolução temporal de 16 dias (USGS, 2016). A **Tabela 1** apresenta as bandas disponíveis, bem como as informações gerais de cada uma.

Tabela 1 Informações gerais das bandas disponíveis dos sensores a bordo do satélite Landsat 8

Sensor	Bandas espectrais	Faixa correspondente	Resolução espectral (μm)
OLI	B01	Aerossol Costeiro	0,43 – 0,45
	B02	Azul	0,45 – 0,51
	B03	Verde	0,53 – 0,59
	B04	Vermelho	0,64 – 0,67
	B05	Infravermelho Próximo (NIR)	0,85 – 0,88
	B06	Infravermelho Médio (SWIR 1)	1,57 – 1,65
	B07	Infravermelho Médio (SWIR 2)	2,11 – 2,29
	B08	Banda Pancromática	0,50 – 0,68
	B09	Cirrus	1,36 – 1,38
TIRS	B10	Infravermelho Termal (TIRS 1)	10,60 – 11,19
	B11	Infravermelho Termal (TIRS 2)	11,5 – 12,51

Fonte: USGS (2016).

Desde 31 de janeiro de 2022, estão disponíveis os dados dos sensores OLI e TIRS a bordo do satélite Landsat 9, que vêm complementar o fornecimento de dados realizado pelos sensores a bordo do Landsat 8, aumentando a resolução temporal desses dados de 16 para 8 dias (SAYLER, 2023).

Seguindo a mesma linha dos produtos MODIS, os sensores OLI e TIRS também resultam na disponibilização de produtos derivados das capturas originais de informações. Os produtos C2L2 (*Collection 2 Level 2*), que são os produtos científicos derivados desses sensores, compreendem as bandas multiespectrais com valores de reflectância de superfície e uma banda termal com valores de temperatura de superfície (SAYLER, 2023).

Além das bandas infravermelhas térmicas de nível 1 coleção 2 dos sensores TIRS do Landsat 8 e 9, o processamento para C2L2 requer dados auxiliares externos, como dados ASTER, por exemplo. Na ausência desses dados, o produto de temperatura C2L2 não é gerado (COOK, 2014; HULLEY et al., 2015). Portanto, a utilização desses dados é limitada pela disponibilidade de dados auxiliares, além da cobertura de nuvens, para inferências agrícolas.

Quando a periodicidade dos dados se faz importante, os produtos gerados pelo sensor *Moderate resolution imaging spectroradiometer* (MODIS) se configuram como uma excelente fonte de dados de sensoriamento remoto, pois alguns retornam dados diários a bordo de dois satélites Terra e Aqua, com resolução temporal de 12 horas cada. Contudo, a viabilidade de utilização desses dados deve ser avaliada em função da dimensão da área que se deseja analisar, visto que dependendo do produto do sensor que se deseja utilizar sua resolução espacial pode variar, como dados de temperatura da superfície com 1000 m de resolução espacial (WAN; HOOK; HULLEY, 2015).

O sensor MODIS foi lançado a bordo do satélite Terra (1999) e Aqua (2002) com 36 bandas espectrais entre 0,405 e 14,385 μm (JUSTICE et al., 2002). Com esse conjunto de

bandas foi disponibilizada uma série de produtos para observação e inferências da superfície (Tabela 2).

Tabela 2 Descrição dos produtos MODland

ESDT	Produtos	DAAC	Data de lançamento beta	Data de início do produto beta
MOD09	Refletância de superfície	EDC	04/08/00	09/06/00
MOD11	Temperatura da superfície e emissividade	EDC	01/09/00	25/06/00
MOD43	BRDF/Albedo	EDC	29/09/00	11/07/00
MOD10	Cobertura de neve	NSIDC	13/10/00	13/09/00
MOD29	Extensão do gelo marinho	NSIDC	13/04/01	23/01/01
MOD13	Índices de vegetação	EDC	04/08/00	09/06/00
MOD15	LAI/FPAR	EDC	04/08/00	09/06/00
MOD17	NPP/PSN	EDC	16/03/01	19/12/00
MOD12	Cobertura e mudança da terra	EDC	27/04/01	15/10/00
MOD14	Anomalias térmicas e incêndio	EDC	13/10/00	20/08/00
MOD44	Conversão da cobertura vegetal/campos contínuos	UMD GLCF	30/03/01	09/06/00

Fonte: Justice et al. (2002).

A partir dessa primeira fase de produtos gerados foram desenvolvidos os produtos MOD11A1 (Terra) e MYD11A1 (Aqua), que fornecem dados de temperatura e emissividade da superfície com resolução espacial de 1000 metros. Ambos os produtos oferecem valores diurnos e noturnos de temperatura da superfície diariamente e são gerados a partir do produto MYD11_L2 e MOD11_L2, que fornecem valores de temperatura e emissividade em incrementos temporais de cinco minutos por meio de um algoritmo de janela dividida (WAN; HOOK; HULLEY, 2015).

Esse produto se encontra na versão 6.1, que conta com a calibração aprimorada e correções de polarização, em relação à versão anterior. Portanto, a utilização dessa versão é encorajada para a produção de dados (WAN; HOOK; HULLEY, 2021).

Outro aspecto importante a se considerar com os produtos MOD11A1 e MYD11A1 é que cada cena é produzida sob condições de céu claro, portando apresenta valores nulos em *pixels* em que foram detectadas contaminações por nuvens (WAN, 2019).

Khanal, Fulton e Shearer (2017) destacam que dados termais provenientes de sensores orbitais podem ser utilizados no monitoramento de secas, detecção de doenças nas variedades agrícolas, dentre outras aplicações. Entretanto, Liu (2012) aponta a limitação quanto à alta resolução espacial e à alta resolução temporal desses dados que, geralmente, não são propriedades de um mesmo sensor. Sensores de alta resolução espacial, geralmente, possuem baixa resolução temporal e vice-versa (GHOSH et al., 2020). Nesse contexto, Gao et al. (2006) propuseram o *Spatial and temporal adaptive reflectance fusion model* (STARFM), que consiste em um modelo que, de maneira resumida, combina a resolução espacial de um sensor com a resolução espacial de outro.

3.5.2 Fusão de imagens

Gevaert e García-Haro (2015) obtiveram resultados satisfatórios com imagens sintéticas produzidas por meio do algoritmo STARFM, combinando dados MODIS e OLI, quando comparados com outro algoritmo, desde que exista grande disponibilidade das imagens OLI para realizar a fusão. Liu (2012) utilizou esse algoritmo, combinando cenas termais ASTER e MODIS, para derivar variáveis ambientais, de modo a quantificar os seus efeitos na disseminação do vírus do Nilo Ocidental em Los Angeles, Califórnia.

Zhu et al. (2010) propuseram uma versão melhorada do algoritmo STARFM, o ESTARFM. As imagens sintéticas geradas, utilizando ambos os modelos, foram comparadas a imagens não sintéticas, em que o segundo (ESTARFM) obteve melhores resultados na precisão da refletância em paisagens homogêneas e, em áreas heterogêneas, a melhora foi ainda mais significativa.

Para gerar as imagens sintéticas, são necessários dois pares de imagem de entrada, ambos com uma imagem de resolução fina (maior resolução espacial) e uma de resolução grosseira (menor resolução espacial), com a mesma data de aquisição de dados, e uma imagem de resolução grosseira da data em que se deseja realizar a predição. O ESTARFM utiliza uma janela móvel para encontrar *pixels* semelhantes e, diferentemente do STARFM, faz uso de *pixels* da imagem de resolução fina, mesmo que estejam fora da janela móvel, para efetuar o cálculo do fator de conversão, contanto que coincidam com a área do *pixel* de menor resolução espacial, como indicado na Figura 1.

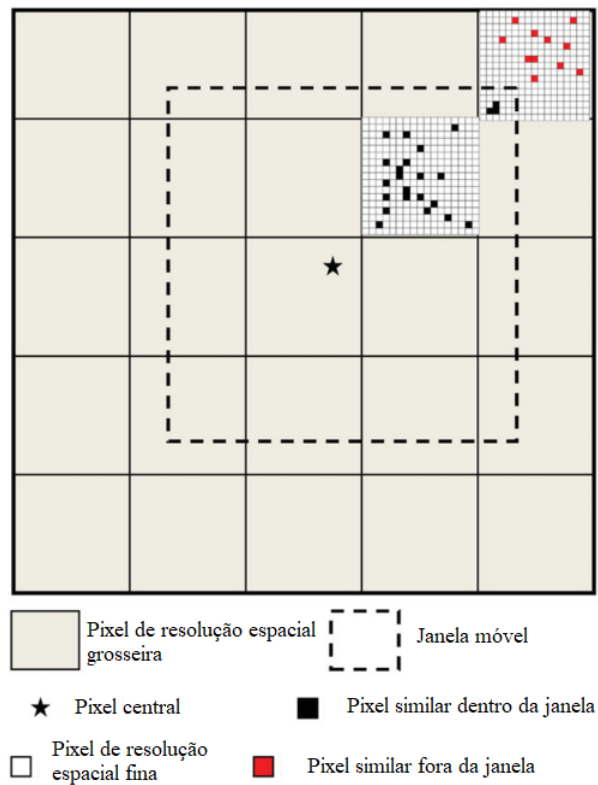


Figura 1 Esquema representativo da janela móvel utilizada pelo ESTARFM.
Fonte: Zhu et al. (2010).

Um fator de conversão é calculado por meio dos *pixels* semelhantes com o uso da janela móvel e é utilizado o mesmo fator de conversão entre *pixels* semelhantes, assumindo a consistência das características espectrais dos *pixels* de resolução fina semelhantes dentro do *pixel* de resolução grossa. Desse modo, elabora-se um modelo de regressão linear aos valores de reflectância dos *pixels* de resolução fina, semelhantes dentro da imagem de resolução grossa, para a obtenção dos coeficientes de conversão. Após a elaboração dos coeficientes de conversão, eles são utilizados juntamente com a imagem grossa da data em que se deseja realizar a predição, para elaborar a imagem de resolução fina predita (ZHU et al., 2010).

4 Material e Métodos

O trabalho foi desenvolvido na região Oeste do Paraná, de modo a abranger a totalidade de estações meteorológicas mantidas por entidades públicas na região (**Figura 2**).

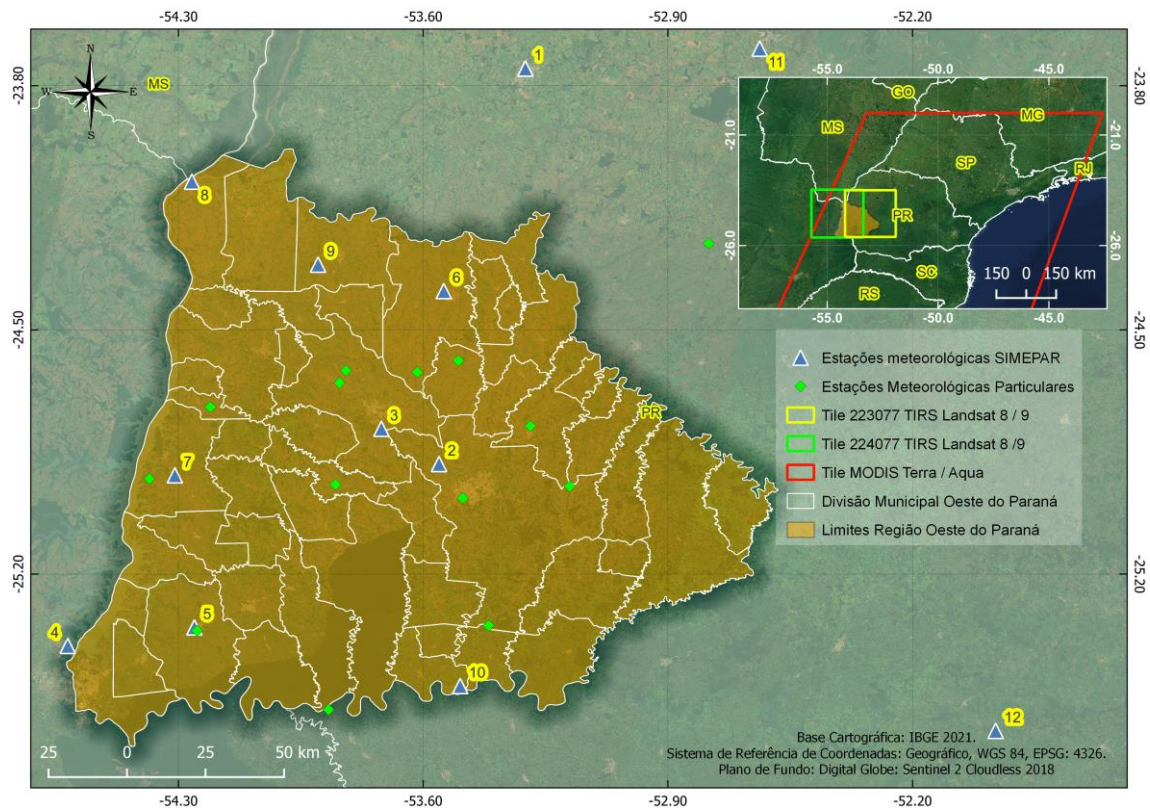


Figura 2 Distribuição das estações meteorológicas, em relação aos limites da região Oeste do Paraná.

A **Figura 2** apresenta a distribuição espacial das estações meteorológicas utilizadas, em relação aos limites da região Oeste, bem como as estações particulares utilizadas na validação das imagens sintéticas, e para comparação com os dados interpolados. Também apresenta os retângulos envolventes das cenas 223077 e 224077 Landsat 8 e 9, utilizados neste trabalho.

O trabalho proposto foi organizado em cinco etapas, como apresentado na **Figura 3**.

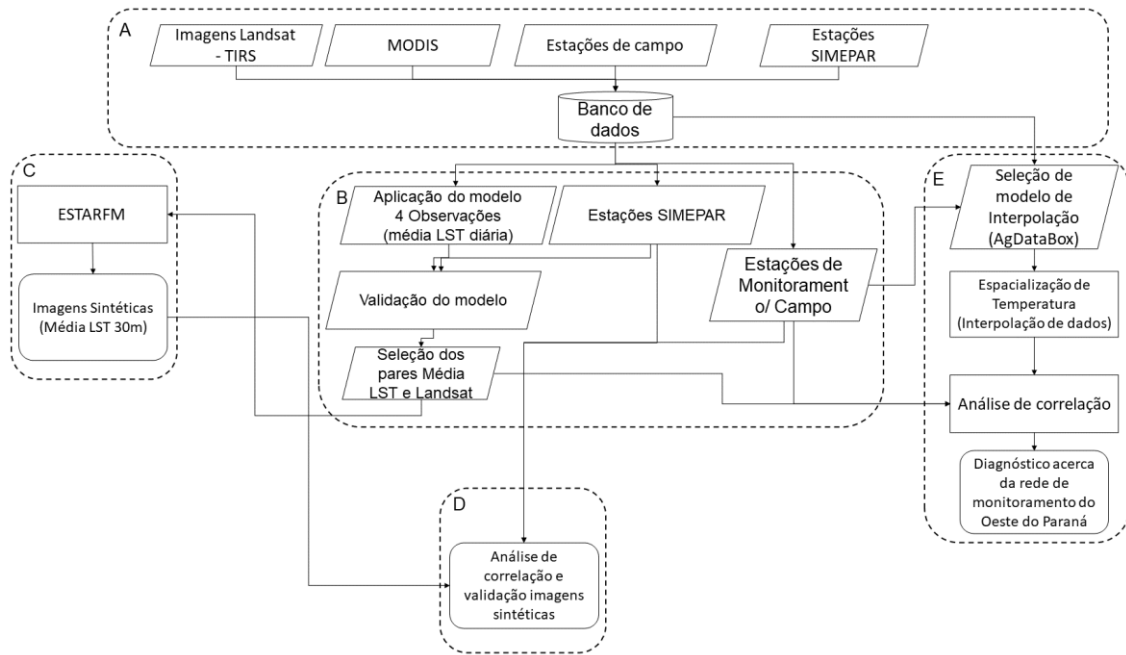


Figura 3 Fluxograma de desenvolvimento do trabalho.

4.1 Aquisição e armazenamento dos dados

Para o desenvolvimento do trabalho proposto foram utilizadas as imagens da coleção 2 e nível 2 de processamento do sensor TIRS dos satélites Landsat 8 e 9, que corresponde aos produtos científicos que trazem os valores de temperatura de superfície (em Kelvin) reamostrados para 30 m (trinta metros) de resolução espacial.

Também foram utilizadas as imagens termais do sensor MODIS em função da maior resolução temporal proporcionada, mais especificamente os produtos MOD11A1 e MYD11A1, versão 6.1.

Os parâmetros de referência da temperatura do ar foram obtidos por meio de estações distribuídas na região Oeste. Dentre essas estações, 12 são mantidas pelo Sistema de Tecnologia e Monitoramento Ambiental do Paraná (SIMEPAR), utilizadas na modelagem estatística e interpolação da temperatura do ar e 14 estações particulares utilizadas somente na validação das imagens sintéticas e na validação das interpolações de temperatura do ar.

4.2 Definição dos modelos e observações utilizados

Nesta etapa foram avaliados os modelos de estimativa de temperatura média diária de superfície. Para tanto, foram realizadas análises de correlação entre os modelos com quatro e três observações diárias, realizados utilizando-se as equações (2) e (3), respectivamente (XING et al., 2021), e modelados em relação à temperatura média das estações SIMEPAR, de acordo com a disponibilidade de dados válidos das imagens.

$$dmLST_g = k_1 \times LST_g(T^d) + k_2 \times LST_g(T^n) + k_3 \times LST_g(A^d) + k_4 \times LST_g(A^n) + b \quad (2)$$

$$dmLST_g = k_1 \times LST_g(T^n) + k_2 \times LST_g(A^n) + k_3 \times LST_g(A^d) + b \quad (3)$$

em que: $dmLST_g$ é a média diária baseada na Temperatura de superfície (LST), k_i e b são os coeficientes de ajuste; “T” e “A” correspondem aos satélites Terra e Aqua, respectivamente; “d” e “n” representam o dia e a noite, respectivamente (XING et al., 2021). Esses modelos foram escolhidos com base nos resultados apresentados pelos pesquisadores, conforme indicados na **Tabela 3**.

Tabela 3 Estatísticas comparativas entre modelos

Combinações	Coeficientes					R ²	RMSE (K)
	K1	K2	K3	K4	b		
T ⁿ A ⁿ A ^d	0.3243	0.3318	0.3582		-4.31	1.00	0.91
T ^d T ⁿ A ^d A ⁿ	0.1807	0.3210	0.1907	0.3141	-4.75	1.00	0.80

Fonte: Adaptado de Xing et al. (2021).

A **Tabela 3** apresenta os coeficientes utilizados nos modelos propostos que apresentaram os melhores coeficientes de determinação (R²), bem como os menores valores de RMSE. em relação às combinações propostas para a confecção das imagens com valores médios diários de temperatura de superfície.

Essa escolha e utilização de diferentes modelos se baseia na apresentação de dados válidos por parte das imagens, já que se uma única imagem apresentar uma área massiva com ausência de dados (**Figura 4**), os *pixels* nulos serão apresentados no modelo final, diminuindo a possibilidade de sobreposição com as estações para avaliação.

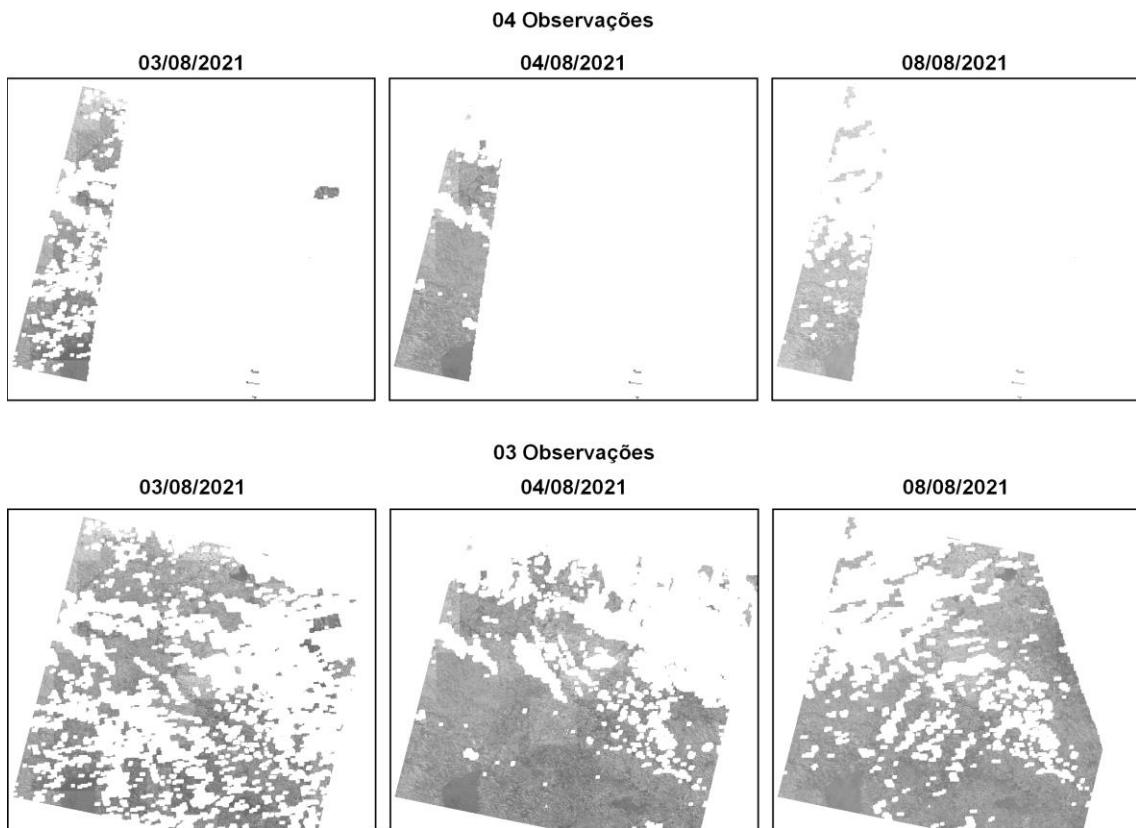


Figura 4 Diferença entre modelos de quatro e três observações, dada a ausência de dados em função de presença de nuvens.

O processo de análise das imagens resultantes dos modelos de 4 e 3 observações são descritos na Figura 5.




Figura 5 Esquema de fluxo dos procedimentos estatísticos realizados na avaliação das imagens resultantes de três e quatro observações diárias.

Para a aplicação dos modelos selecionados, foram criados dois scripts na plataforma Google Colab (BISONG, 2019), a fim de facilitar a aplicação desses modelos em uma longa série temporal de dados, bem como para realizar a conversão dos valores de *pixel* para graus Celsius e realizar a reamostragem, com base no retângulo envolvente das imagens TIRS e ajustar a projeção das imagens. As equações (3) e (4) foram aplicadas para todas as imagens disponíveis no ano de 2020. Os dados válidos foram extraídos pontualmente com base na localização geográfica das estações meteorológicas do SIMEPAR para posterior análise de modelo para verificar a similaridade entre as informações por meio de análise dos coeficientes

do modelo, coeficiente de determinação e análise de resíduos. Para tanto foram selecionados, aleatoriamente, 70% dos dados para cálculo do modelo e 30% para validação em ambos os casos. A validação dos modelos ocorreu por meio do Erro médio absoluto (MAE), Raiz do erro médio (RMSE), coeficiente de determinação (R^2), coeficiente de correlação (r) e coeficiente de concordância (d) (WILLMOTT et al., 1985). O ano de 2020 foi escolhido porque, do período de dados disponibilizados pelo SIMEPAR, esse foi o ano com menor quantidade de dados faltantes.

Após a aferição dos modelos, foram selecionadas as imagens LST média diária (quatro e três observações – MODIS) com maior quantidade de dados válidos e com data igual às imagens LST TIRS disponíveis, para que fossem realizadas as fusões com a maior quantidade de dados possível.

4.3 Fusão de imagens orbitais

Nesta etapa, foram avaliadas as imagens sintéticas geradas por meio do algoritmo ESTARFM (ZHU et al., 2010), mediante a combinação da resolução espacial obtida no produto L2C2 TIRS e da resolução temporal dos produtos MOD11A1 e MYD11A1.

Esse procedimento foi realizado em função da periodicidade de captura de dados disponíveis no produto MODIS, disponibilizando até quatro observações diurnas e noturnas da temperatura de superfície (LST). A obtenção da temperatura média diária de superfície é alcançada mediante aplicação de modelo de regressão múltipla, sendo possível a obtenção da temperatura média diária de superfície. O sensor TIRS dos satélites Landsat 8 e 9 possui resolução temporal de oito dias (Desde 31 de janeiro de 2022), enquanto o sensor MODIS realiza aferições diárias a bordo de dois satélites Terra e Aqua, disponibilizando maior volume de dados (WAN; HOOK; HULLEY, 2015). Entretanto, a fusão das imagens é necessária, devido à baixa resolução espacial, em relação aos tamanhos das glebas presentes na região Oeste do Paraná, bem como em diversas outras na região Sul do Brasil, que apresentam a mesma característica de tamanhos reduzidos, pois o produto fornecido pelo sensor MODIS corresponde a 1 km. Portanto, as imagens sintéticas possibilitarão uma melhor observação do meio, tendo em vista que a resolução espacial resultante corresponderá a 30 m (USGS, 2016).

4.3.1 Análise preliminar

Foram utilizados os produtos científicos de nível 2 (*Collection 2 Level 2*), do sensor TIRS do Landsat 8 e 9. Esse produto é resultado do processamento de dados provenientes das bandas termais TIRS *Collection 2 Level 1*, reflectância de topo de atmosfera, dados ASTER, Base de dados de emissividade global, dados de NDVI ASTER e temperatura de brilho (USGS, 2021). Primeiramente, foi verificada a disponibilidade desse produto para os anos 2019, 2020, 2021 e 2022.

Esse produto vem com a necessidade de aplicação de um fator de escala, para se obter a temperatura de superfície em Kelvin (K), apresentado na equação (4). Após a aplicação desse fator de conversão, todos os valores de *pixel* das imagens foram convertidos para graus celsius (°C).

$$LST_k = (LC * 0.00341802) + 149 \quad (4)$$

em que: LST_k corresponde à temperatura de superfície em Kelvin (K) e LC^* corresponde à imagem TIRS C2L2.

As imagens resultantes foram utilizadas com imagens finas (de maior resolução espacial) para a predição de imagens pelo algoritmo ESTARFM.

De posse das imagens finas com baixa cobertura de nuvens, disponíveis para o período de 2019 a 2022, procedeu-se com a análise de correspondência das imagens de temperatura média de superfície elaboradas com dados MODIS, a fim de verificar quais imagens de mesma data das imagens finas continham a maior quantidade de dados válidos para servirem como par de entrada. Também foi verificada, em todo o período, a disponibilidade de imagens com quantidade razoável de dados válidos para serem utilizadas como imagens preditoras, nas datas intermediárias em relação às datas dos pares de entrada.

4.3.2 Elaboração das imagens sintéticas

As etapas de processamento, realizadas pelo algoritmo ESTARFM, são apresentadas na Figura 6.

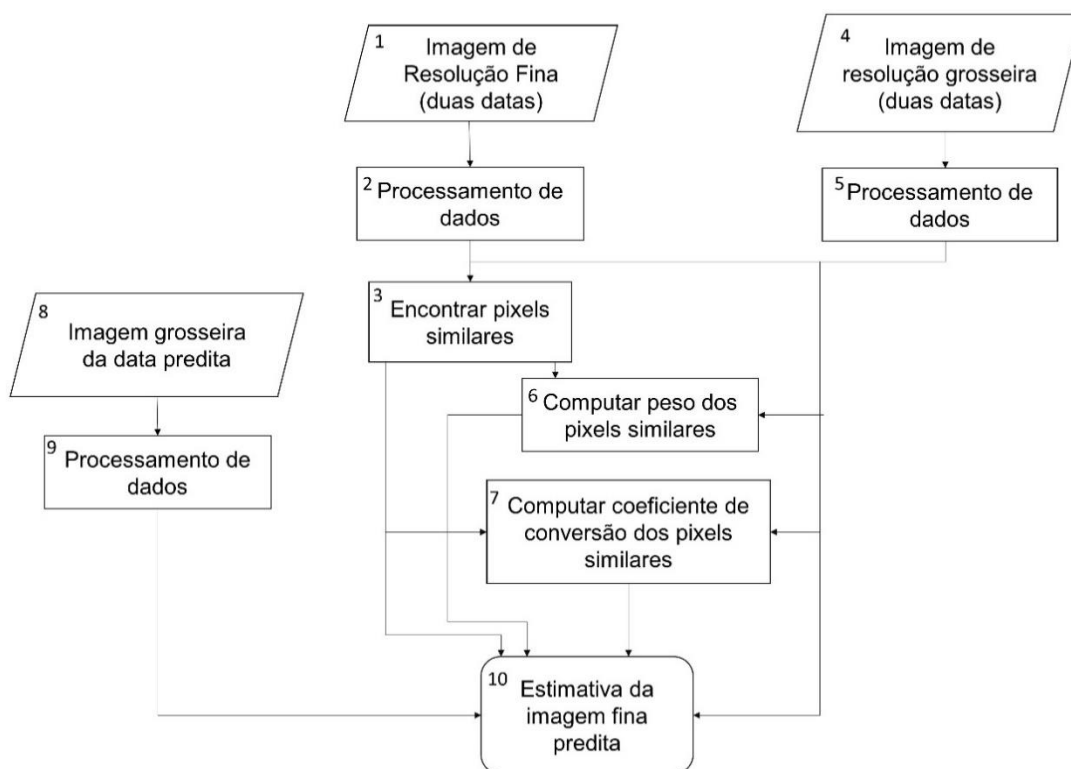


Figura 6 Fluxograma das etapas sequenciais do processamento de imagens por meio do algoritmo ESTARFM.

Fonte: Adaptado de Zhu et al. (2010).

A etapa 1 diz respeito à seleção de imagens de resolução fina (com maior resolução espacial) e as etapas 4 e 5 se referem à seleção das imagens grosseiras (com maior resolução temporal), sendo necessários dois pares de cada, compostos por uma imagem grosseira e uma fina, que devem ser da mesma data.

O processamento de dados a que se refere a etapa 2 diz respeito à reprojeção das imagens e correção atmosférica dos dados de entrada das imagens de resolução fina, o que foi contornado selecionando-se as imagens da coleção 2 e nível 2 de processamento dos produtos do sensor TIRS na página do USGS, que disponibiliza imagens já corrigidas para temperatura de superfície (VERMOTE et al., 2016).

A etapa 5 consiste na correção atmosférica das imagens grosseiras que, no caso dos produtos MOD11A1 e MYD11A1, não será necessário, pois já vêm com dados de temperatura de superfície. Entretanto, precisam passar pela conversão em graus Celsius ($^{\circ}\text{C}$), pois esse produto apresenta resultados em Kelvin (K) (WAN; HOOK; HULLEY, 2015; VERMOTE et al., 2016). Também é nesta etapa que é realizada a reamostragem de *pixels* da imagem grosseira, tendo como referência a localização e resolução espacial da imagem fina. Essa etapa foi realizada com a utilização do *script* desenvolvido na plataforma *Google Colab*.

A partir desta etapa (5), com os *pixels* de ambas as imagens reamostrados para a mesma extensão espacial e com as mesmas características de superfície, o processo segue diretamente para a fase três, correspondente à localização dos *pixels* similares e para o processamento da imagem fina preditiva (10), já que o modelo será baseado em divergências sistemáticas entre os dois sensores (ZHU et al., 2010).

Após as etapas 6 e 7 o algoritmo elabora o modelo de predição. Com base nos dados de entrada da etapa 8, em que se deve selecionar uma imagem grosseira na data em que se deseja realizar a previsão; na etapa 9, que consiste no mesmo processamento de dados que as etapas 2 e 3, realiza-se a elaboração da imagem sintética (preditiva), na etapa 10.

Para a realização das análises de modelo foram geradas imagens sintéticas para todas as datas em comum entre TIRS e MODIS com quantidade satisfatória de dados válidos dos produtos MOD11A1 e MYD11A1, condizentes com as datas das imagens C2L2 e disponíveis com baixo percentual de cobertura de nuvens entre os anos de 2019 e 2022. Para se obter a cobertura total da região Oeste do Paraná, foram utilizados os *tiles* 223077 e 224077 do sensor TIRS dos satélites Landsat 8 e 9. A Tabela 4 apresenta as datas das imagens preditas que atenderam aos requisitos.

Tabela 4 Apresentação das datas das imagens de predição e datas preditas

Data das imagens preditoras	Datas preditas
14/09/2019 e 30/09/2019	16/09/2019, 23/09/2019, 26/09/2019, 27/09/2019, 28/09/2019, 29/09/2019
02/08/2021 e 18/08/2021	03/08/2021, 04/08/2021, 08/08/2021, 09/08/2021, 17/08/2021
22/11/2021 e 08/12/2021	27/11/2021, 30/11/2021, 01/12/2021, 03/12/2021, 06/12/2021
08/11/2022 e 16/11/2022	09/11/2022 e 15/11/2022
16/11/2022 e 24/11/2022	17/11/2022, 18/11/2022, 19/11/2022
21/03/2022 e 29/03/2022	26/03/2022, 27/03/2022, 28/03/2022

4.4 Espacialização de dados meteorológicos e avaliação da distribuição espacial das estações meteorológicas do oeste do Paraná

Nesta etapa, os dados pontuais de temperatura média do ar disponibilizados pelo SIMEPAR foram interpolados quinzenalmente do período de janeiro a outubro de 2022. Isso ocorreu porque esses dados foram utilizados na verificação da quantidade de estações, bem

como da distribuição espacial, em relação às estações privadas distribuídas na região. Essas últimas contêm maior quantidade de medições no ano de 2022.

Os dados SIMEPAR também foram interpolados para datas coincidentes com as imagens resultantes do modelo de quatro e três observações diárias com maior quantidade de *pixel* válidos, contando com quatro imagens cujas datas coincidissem com as estações do ano (primavera, verão, outono e inverno), de modo a verificar a existência ou não de diferenças de padrão de distribuição de temperatura, além de realizar inferências sobre a localização e distribuição espacial das estações meteorológicas na região.

Para a seleção do melhor interpolador, bem como dos coeficientes com melhor ajuste ao conjunto de dados, foi utilizado o índice ISI, na plataforma AGDATABOX. Foi utilizado o interpolador IDW (BABAK; DEUTSCH, 2009; SILVA JÚNIOR et al., 2019), por obter melhor ajuste ao conjunto de dados.

Para a comparação dos resultados, o modelo de conversão da temperatura média de superfície para temperatura do ar (estação) foi aplicado nas imagens correspondentes para que ambos os dados estivessem na mesma escala (temperatura do ar) e foi realizado teste de normalidade e teste de correlação de Spearman entre as interpolações e as imagens modeladas da mesma data.

Foram elaborados os mapas de erro para cada data, a fim de que fosse aferida, espacialmente, a existência de erros sistêmicos na distribuição espacial das estações meteorológicas na região Oeste do Paraná.

5 Resultados e Discussão

5.1 Estatística descritiva LST média 4 observações

A **Tabela 5** apresenta a estatística descritiva dos dados de temperatura média de superfície com base em quatro observações diárias extraídas dos *pixels* que fizeram sobreposição com as estações meteorológicas.

Tabela 5 Resumo descritivo dos dados de temperatura dos *pixels* nos pontos das estações utilizadas para o ano de 2020

Imagens	Umuarama	Cascavel	Toledo	Foz do Iguaçu	São Miguel do Iguaçu	Assis Chateaubriand
Mínimo (°C)	11,55	8,64	9,08	10,48	11,59	10,68
Média (°C)	23,77	19,82	21,43	22,29	23,75	22,84
Mediana (°C)	23,48	19,44	21,27	22,92	24,01	22,66
Máximo (°C)	32,00	28,43	29,08	30,33	31,93	31,51
Desvio padrão (°C)	4,46	4,64	4,88	4,52	4,84	5,01
Variância (°C ²)	19,91	21,55	23,81	20,47	23,40	25,05
Coeficiente de variação (%)	18,77	23,42	22,77	20,30	20,37	21,91
Sw-pvalor	0,15	0,26	0,01**	0,00**	0,00**	0,05
Amplitude	20,45	19,79	20,00	19,85	20,34	20,83
Tamanho da amostra	65	81	87	100	93	81
Imagens	Santa Helena	Guaira	Palotina	Salto de Caxias	Cianorte Cocamar	Pinhão
Mínimo (°C)	11,01	13,00	9,49	10,00	11,65	6,62
Média (°C)	23,19	22,72	21,24	21,72	22,05	17,39
Mediana (°C)	23,17	22,73	21,59	22,32	21,72	18,21
Máximo (°C)	31,82	28,91	28,93	28,89	31,06	24,57
Desvio padrão (°C)	4,66	3,80	4,70	4,22	4,13	3,80
Variância (°C ²)	21,74	14,46	22,12	17,83	17,09	14,44
Coeficiente de variação (%)	20,10	16,74	22,15	19,44	18,74	21,85
Sw-pvalor	0,01*	0,00**	0,00**	0,00**	0,07	0,04*
Amplitude	20,80	15,92	19,44	18,89	19,41	17,95
Tamanho da amostra	126	117	93	112	78	80

Notas: Sw-pvalor: p-valor do teste de normalidade de Shapiro-Wilk; *: significativo a 5%; **: significativo a 1%.

A análise descritiva aponta que a estação que apresentou a maior LST média no período analisado foi a de Umuarama, e a menor foi registrada em Pinhão. A estação de Assis

Chateaubriand apresentou o menor desvio padrão do conjunto de dados e o coeficiente de variação (CV) apresentou valores entre 23,42 (Cascavel) e 16,74 (Guaíra), indicando alto coeficiente de variação para Cascavel e médio CV para Guaíra (GOMES, 2009).

O teste de normalidade indicou que das 12 estações utilizadas, apenas 4 apresentaram distribuição normal de dados. A menor coincidência de *pixels* válidos e estações ocorreu para a estação de Umuarama e a maior quantidade ocorreu com a estação de Santa Helena.

A **Tabela 6** apresenta o resumo descritivo dos valores de temperatura média do ar das estações.

Tabela 6 Resumo descritivo dos dados de temperatura das estações meteorológicas que coincidiram com *pixels* válidos para o ano de 2020

Estações	Umuarama	Cascavel	Toledo	Foz do Iguaçu	São Miguel do Iguaçu	Assis Chateaubriand
Mínimo (°C)	10,81	9,54	9,47	8,71	11,27	10,43
1º Quartil (°C)	21,49	17,85	19,11	18,67	21,31	19,63
Média (°C)	23,70	20,05	21,77	21,20	23,58	21,74
Mediana (°C)	23,69	19,53	22,30	22,07	24,22	21,95
3º Quartil (°C)	26,61	23,09	25,29	24,51	26,44	24,46
Máximo (°C)	33,57	28,98	30,27	30,26	33,20	30,19
Desvio padrão (°C)	4,06	4,15	4,47	4,63	4,60	3,92
Variância (°C ²)	16,47	17,24	19,95	21,47	21,14	15,36
Coeficiente de variação (%)	17,12	20,71	20,52	21,85	19,50	18,03
Sw-pvalor	0,20	0,60	0,16	0,00**	0,01*	0,18
Amplitude	22,76	19,44	20,80	21,54	21,93	19,76
Tamanho da amostra	65	81	87	100	93	81
Estações	Santa Helena	Guaíra	Palotina	Salto de Caxias	Cianorte Cocamar	Pinhão
Mínimo (°C)	9,38	9,97	9,31	9,36	11,18	6,70
1º Quartil (°C)	20,67	19,00	18,96	19,61	20,58	16,08
Média (°C)	22,48	21,60	21,56	22,11	22,66	18,65
Mediana (°C)	23,00	22,28	22,22	22,29	22,54	18,65
3º Quartil (°C)	25,35	24,94	25,16	25,36	25,56	22,01
Máximo (°C)	31,87	28,72	30,35	29,67	32,22	26,44
Desvio padrão (°C)	4,24	4,25	4,67	4,01	4,18	4,07
Variância (°C ²)	17,94	18,10	21,79	16,07	17,50	16,53
Coeficiente de variação (%)	18,85	19,69	21,65	18,13	18,47	21,80
Sw-pvalor	0,00**	0,00**	0,04*	0,00**	0,04*	0,16
Amplitude	22,49	18,75	21,05	20,31	21,03	19,75
Tamanho da amostra	126	117	93	112	78	80

Notas: Sw-pvalor: p-valor do teste de normalidade de Shapiro_Wilk; *: significativo a 5%; **: significativo a 1%.

Assim como os dados apresentados nos *pixels* das imagens, a análise descritiva aponta que o ponto que apresentou a maior temperatura média no período analisado foi a de Umuarama e a menor foi registrada em Pinhão, apontando para a correlação existente entre LST e temperatura do ar.

A estação de Assis Chateaubriand apresentou o menor desvio padrão do conjunto de dados e o coeficiente de variação (CV) apresentou valores entre 21,86 (Foz do Iguaçu) e 17,12 (Umuarama), indicando alto coeficiente de variação para Foz do Iguaçu e médio CV para Umuarama (GOMES, 2009).

5.2 Análise do modelo de 4 e 3 observações

Para análise inicial dos dados, foi realizado o teste de normalidade dos dados das estações e dos valores de *pixel* LST média diária correspondente; ambos os casos não apresentaram normalidade. Sendo assim, procedeu-se com a realização do teste de correlação de Spearman, já que a normalidade não é uma premissa para realização desse teste. O teste apresentou coeficiente de correlação (r_s) de 0,92 entre as variáveis, então procedeu-se com a confecção do modelo.

Os coeficientes do modelo foram significativos a 5% de significância, resultando no modelo apresentado na Equação 5.

$$Y = 2,8055 + 0,8648 * P \quad (5)$$

em que: Y é o *pixel* modelado para temperatura do ar (°C) e P corresponde ao *pixel* da imagem de LST média diária (°C).

O coeficiente de determinação $R^2_{ajustado}$ apresentou valor de 0,8627, indicando que os dados de LST média conseguem explicar 86% da variância dos dados de temperatura do ar, coletados pelas estações meteorológicas.

Os resíduos do modelo apresentaram normalidade, pelo método de Shapiro-Wilk. Também apresentaram homoscedasticidade pelos métodos de Breusch Pagan e Goldfeld Quandt e independência pelo teste de Durbin-Watson, aferindo a robustez do modelo.

A validação do modelo apresentou RMSE de 1,5 °C, MBE (viés) de 0,12 °C e índice de concordância de Wilmott de 0,94, reafirmando a robustez do modelo proposto para aferição de temperatura do ar com base nos dados de temperatura média de superfície.

A **Figura 7** mostra o gráfico de dispersão relacionando as estações de validação e os valores coincidentes (30% do conjunto de dados) dos *pixels* modelados para temperatura do ar.




Figura 7 Gráfico de dispersão dos dados de validação para LST 4 observações.

O modelo descrito na **Figura 7** indica alta proximidade com a reta 1:1 (coeficiente angular igual a 1,027), com uma leve tendência à superestimativa da temperatura do ar (viés de 0,11 °C).

Assim como os dados de temperatura das estações e imagens de 4 observações, as variáveis para 3 observações também não apresentaram normalidade. O teste de correlação de Spearman apresentou coeficiente de correlação (r_s) de 0,92, assim como para 4 observações, entretanto o coeficiente de determinação ajustado ($R^2_{ajustado}$) do modelo linear apresentou valor de 0,85. Os coeficientes do modelo se mostraram significativos a 5% de significância, e o modelo proposto é dado pela Equação 6.

$$Y = 2,1604 + 0,8750 * P \quad (6)$$

em que: Y é o *pixel* modelado para temperatura do ar (°C) e P corresponde ao *pixel* da imagem de LST média diária (°C).

Os resíduos do modelo não apresentaram normalidade, pelo método de Shapiro-Wilk. Apresentaram homoscedasticidade pelos métodos de Breusch Pagan e Goldfeld Quandt e independência pelo teste de Durbin-Watson.

A validação do modelo apresentou RMSE de 1,74 °C e MBE (viés) de -0,26 °C, ligeiramente piores que o modelo anterior, e índice de concordância de Wilmott (d) de 0,92, valor ligeiramente inferior ao modelo com 4 observações.

A **Figura 8** mostra o gráfico de dispersão relacionando as estações de validação e os valores coincidentes dos *pixels* modelados para temperatura do ar.

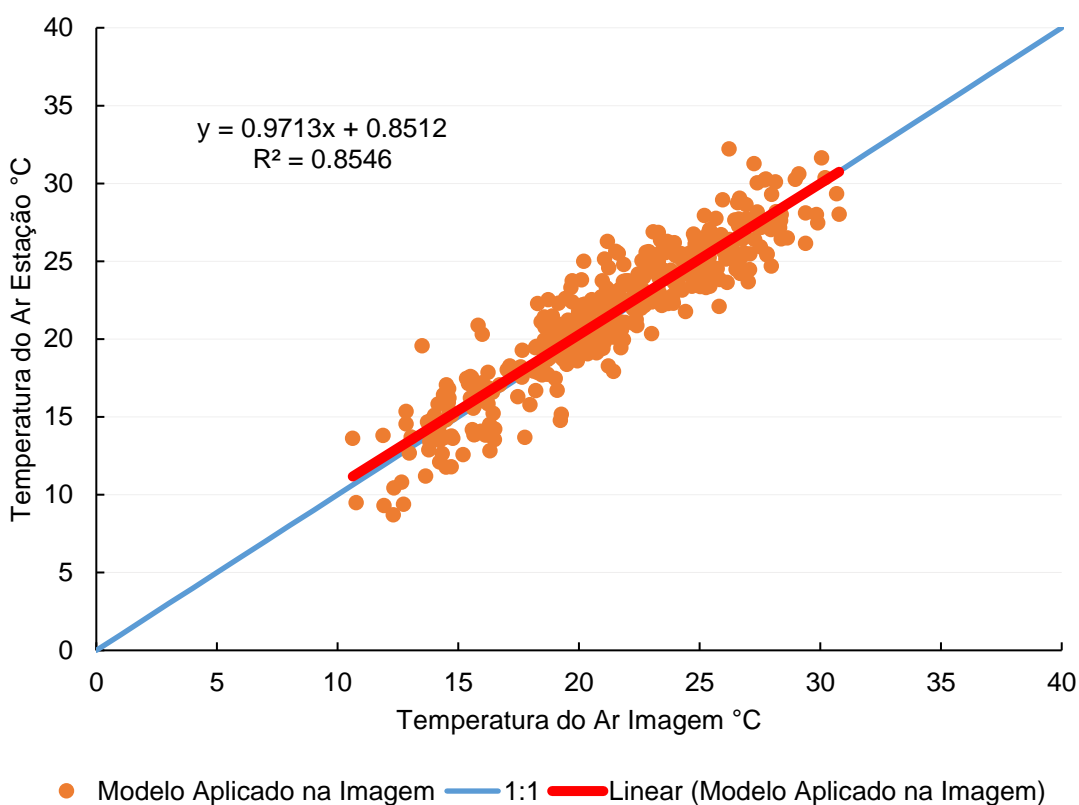


Figura 8 Gráfico de dispersão dos dados de validação para LST 3 observações.

O modelo apresentado mostra, pela análise da reta modelada em relação à reta 1:1, que o modelo tende a uma leve subestimativa dos dados de temperatura, quando se utiliza as imagens LST média com 3 observações.

Vancutsem et al. (2010) utilizaram dados de temperatura de superfície MODIS para estimar a temperatura de superfície e para os valores mínimos de estimativa obtiveram erro médio de 1,73 °C.

Zhu, Lu e Jia (2013) utilizaram dados MODIS para estimativa da temperatura mínima e máxima diária e obtiveram para a temperatura mínima RMSE de 2,97 °C e coeficiente de correlação de 0,94. Para dados noturnos, obtiveram RMSE de 7,45 °C e coeficiente de

correlação de 0,83. A aplicação de um método em que se introduz o NDVI na estimativa, a fim de se melhorar a estimativa, reduziu o RMSE para 3,79 °C.

De modo geral, a abordagem utilizada neste trabalho se mostrou mais assertiva na estimativa da temperatura do ar, posto que abordou a estimativa da temperatura média do ar com base na temperatura média de superfície, ao invés de estimar a máxima e a mínima individualmente.

5.3 Teste de correlação das imagens sintéticas

Com os dados combinados das 24 imagens sintéticas geradas foi elaborado modelo para verificar a similaridade com as 12 estações SIMEPAR disponíveis e as 14 estações particulares distribuídas na região. Os dados provenientes das estações não apresentaram normalidade, portanto foi realizada a análise de correlação de Spearman (r_s) que apresentou valor de 0,69.

Foi gerado o modelo linear, cujos coeficientes foram significativos a 5% de significância e o coeficiente de determinação R^2_{ajustado} que apresentou valor de 0,59, resultado semelhante ao obtido por Sisheber et al. (2022) de 0,54, ao utilizarem o algoritmo ESTARFM para prever o Índice de vegetação aprimorado (EVI). O modelo resultante é apresentado na Equação 7.

$$Y = 7,3225 + 0,4380 * P \quad (7)$$

em que: Y é o resultado do *pixel* modelado (°C) e P é o *pixel* correspondente à imagem predita pelo algoritmo ESTARFM (°C).

O gráfico de dispersão dos dados de temperatura de superfície (imagens sintéticas LST média) e temperatura do ar (estações) é apresentado na **Figura 9**.

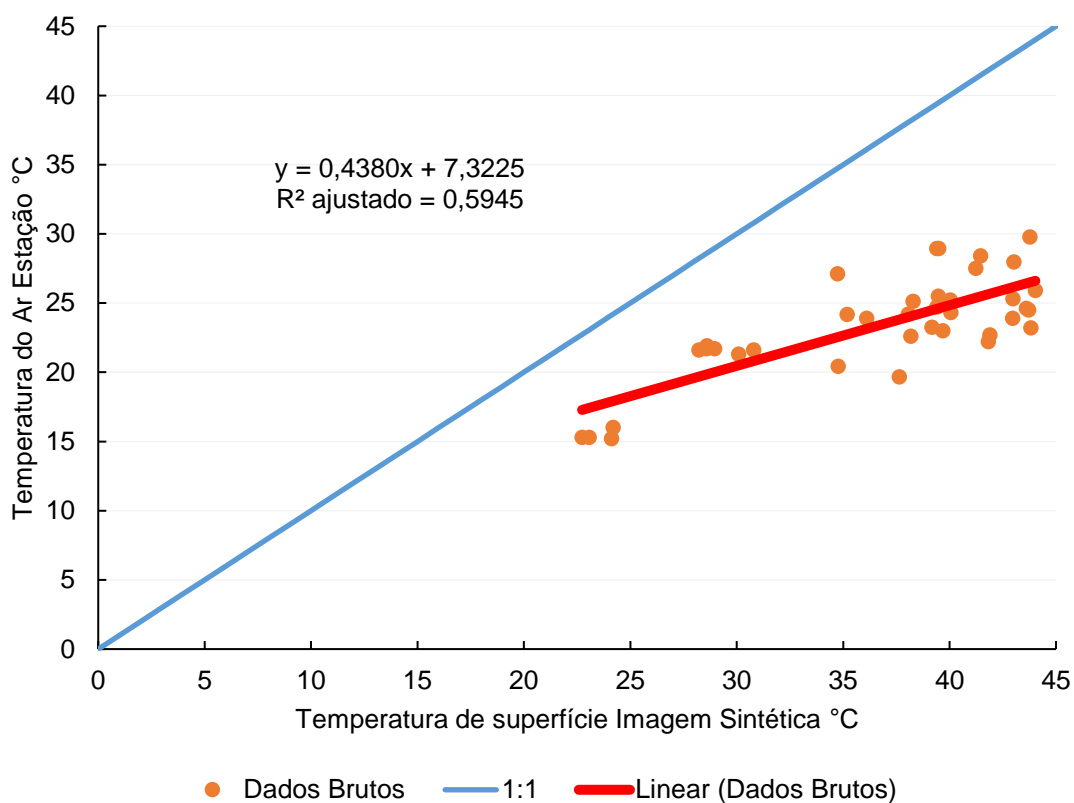


Figura 9 Gráfico de dispersão dos dados brutos de temperatura de superfície e temperatura do ar.

A Figura 9 mostra que a temperatura de superfície se apresenta mais elevada em relação à temperatura do ar. A relação que existe entre a LST e a temperatura do ar (VANCUTSEM et al., 2010; ZHU; LU; JIA, 2013) foi menos acentuada com o uso de imagens sintéticas, se comparada com as médias de LST de 4 e 3 observações diárias, visto seu R^2_{ajustado} menor. Isso ocorreu pois houve superestimativa dos valores médios de LST, após a aplicação do algoritmo ESTARFM, como pode ser observado na **Figura 10**.

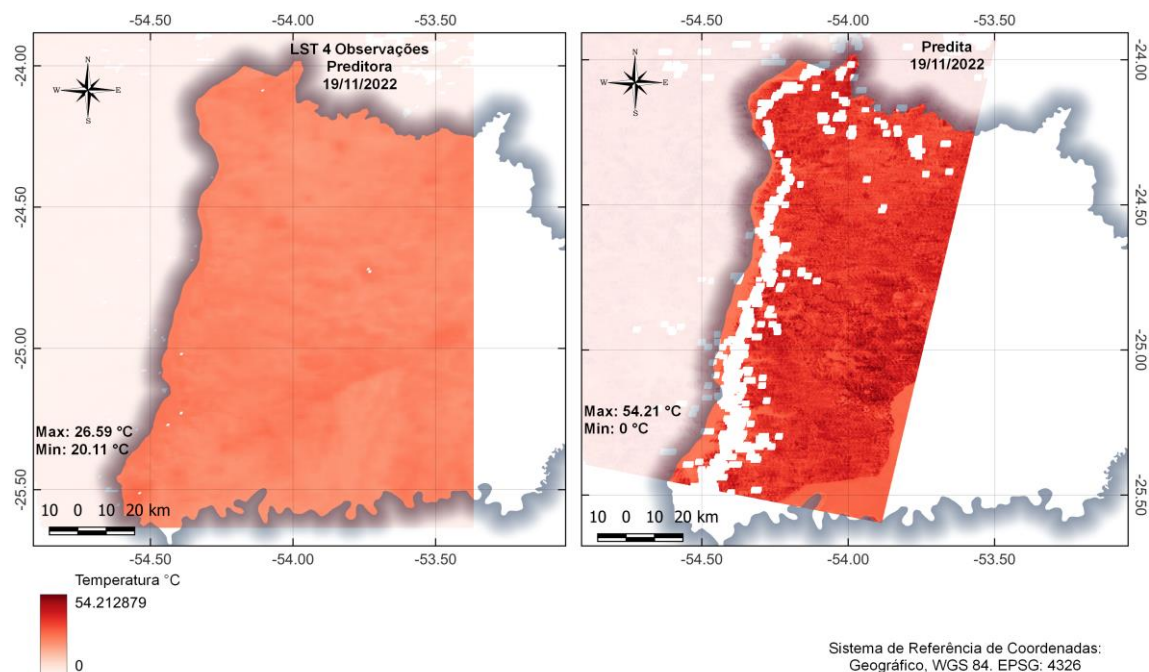


Figura 10 Apresentação da imagem grosseira preditora (LST média) e a imagem predita (sintética ESTARFM).

Na **Figura 10**, observa-se que houve aumento no detalhamento da variabilidade espacial de temperatura, o que, em razão do aumento de resolução espacial, facilitaria a análise de variação de temperatura em talhões agrícolas de menor porte (SISHEBER et al., 2023), como ocorre na região Oeste do Paraná.

Também houve superestimativa nos valores de temperatura média de superfície para todas as imagens geradas (Apêndice C). Uma hipótese para explicar essa ocorrência é a de que a LST média se baseia em 4 ou 3 observações diárias para a computação da média. Dentre elas, encontram-se ao menos duas observações noturnas, que correspondem às temperaturas mais baixas apresentadas na data observada (XING et al., 2021). Já as imagens finas de LST TIRS são observações instantâneas realizadas durante o dia, expressando valores maiores de temperatura.

A separação entre dados para elaboração do modelo e validação não foi realizado, em função da baixa quantidade de pares *pixel/estação*, o que ocorreu em função de *pixels* nulos provocados pela cobertura de nuvens nas imagens utilizadas (**Figura 11**).

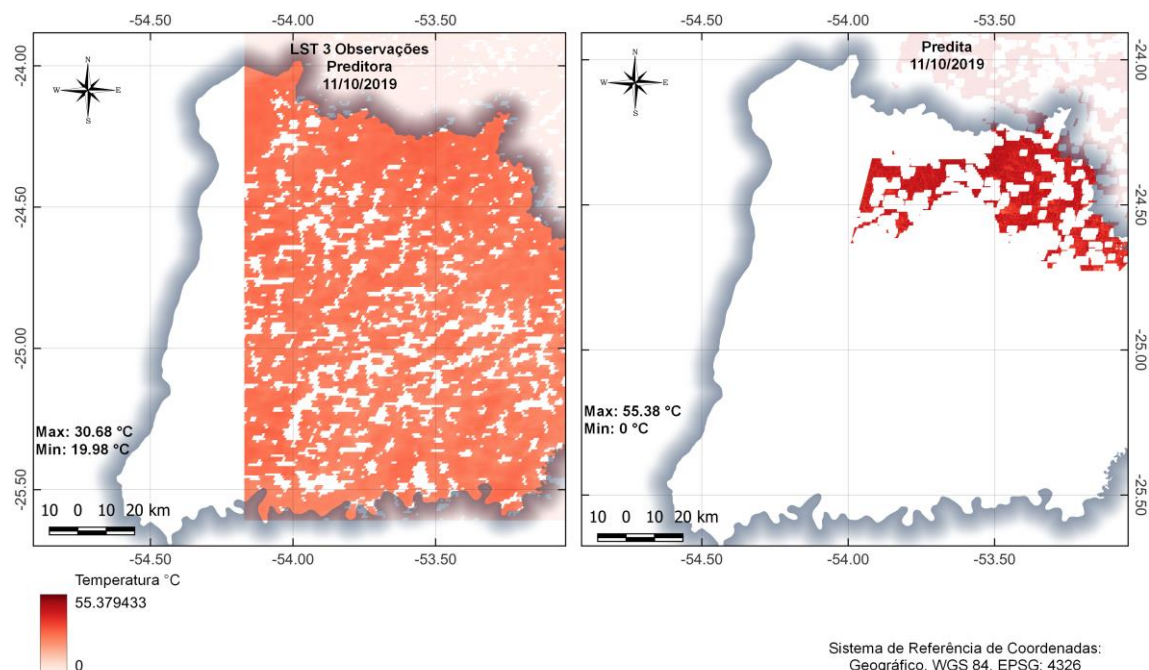


Figura 11 Apresentação da imagem grosseira preditora (LST média) e a imagem predita (sintética ESTARFM), sob intenso efeito de cobertura de nuvens.

A **Figura 11** exemplifica o empecilho causado pela cobertura de nuvens na abordagem utilizada. Apesar de a imagem preditora apresentar uma quantidade razoável de *pixels* com valores válidos, qualquer imagem inserida no modelo que gera cada LST média (utilizada como imagem grosseira dos pares para o modelo ESTARFM), que contenha excessiva cobertura de nuvens, compromete a geração da imagem predita. Ou seja, esse valor nulo de *pixel*, gerado no processo de confecção dos produtos MOD11A1 e MYD11A1, será transferido para a imagem predita resultante do ESTARFM.

Conforme Prudente et al. (2020), a presença de nuvens é um fator limitante para o uso de sensoriamento remoto agrícola em toda a América do Sul. Também espacializaram o percentual de cobertura de nuvens por períodos, sendo que no período de setembro a novembro, que abrange a maior quantidade de imagens geradas neste trabalho, a região analisada se enquadra na frequência de cobertura de nuvens de 50% a 60%.

A escolha de períodos diferenciados para a coleta de imagens e geração de imagens sintéticas é limitada pela disponibilidade de imagens finas sem cobertura de nuvens no período, pois as nuvens implicam a subestimativa de temperaturas pelo sensor termal (VANCUTSEM et al., 2010) e pela cobertura de nuvens em pelo menos uma das imagens resultantes das 4 observações diárias do produto MOD11A1 e MYD11A1. Uma possível solução para esse problema pode ser a aplicação de uma metodologia de preenchimento de dados utilizando uma janela móvel, como utilizado por Xu et al. (2023), que usaram o produto MOD11 para realizar a estimativa da temperatura do ar diária.

De modo geral, as imagens sintéticas de temperatura média diária de superfície mostraram maior variabilidade espacial, em relação às imagens obtidas dos produtos MODIS, o que era esperado, entretanto geraram superestimativas de temperatura na mesma comparação.

5.4 Espacialização de temperatura na região oeste

Utilizando a ferramenta AgDataBox foram selecionados os melhores métodos de interpolação para cada data pelo índice ISI. Os interpoladores e parâmetros são apresentados na **Tabela 7**.

Tabela 7 Parâmetros utilizados nas interpolações de dados de temperatura média das estações

Estação / Data	ISI	Interpolador	Expoente	Vizinhos
Verão 14/03/2020	0,705	IDW	1	7
Outono 04/04/2020	0,032	IDW	3,5	7
Inverno 01/08/2020	0,434	IDW	6	6
Primavera 05/11/2020	0,004	IDW	6	7

Para todas as datas o índice ISI indicou o interpolador IDW. Isso ocorre em função da necessidade de maior número de pontos por parte de interpoladores mais robustos, como a *krigagem* por exemplo (BABAK; DEUTSCH, 2009).

Tomando-se, como verdade de campo, as imagens LST média modelada para temperatura do ar da mesma data (T_{ar}) para realização de análise de correlação com as interpolações, o teste de correlação de Spearman resultou em um coeficiente de correlação r_s de 0,42 para a imagem de verão. Para a imagem correspondente ao outono o r_s foi de 0,53, para inverno e primavera foi de 0,51 e 0,63, respectivamente. Aqui não foram utilizadas as imagens sintéticas, devido ao baixo número de pares e à baixa quantidade de dados, pela presença de nuvens.

Procedeu-se também com a realização do teste de Mann-Whitney, para verificar a igualdade estatística entre esses conjuntos de dados e, para todas as datas, o teste apresentou diferença estatística entre as interpolações de temperatura do ar e as imagens T_{ar} .

Entretanto, a análise realizada entre as interpolações, em relação às estações particulares, apresentou igualdade estatística pelo mesmo método, com p-valor de 0,724,

aceitando a hipótese de igualdade (H_0) estatística entre os dados interpolados e as medições de temperatura do ar nas estações particulares distribuídas na região Oeste do Paraná. A matriz de correlação de Spearman apresentou coeficiente de correlação (r_s) de 0,93.

As Figuras 12, 13, 14 e 15 apresentam os mapas de erro confrontados com o índice de vegetação, que possibilitam conhecer a relação entre a localização das estações meteorológicas, a cobertura do solo e o período do ano, tendo como critério a estação do ano.

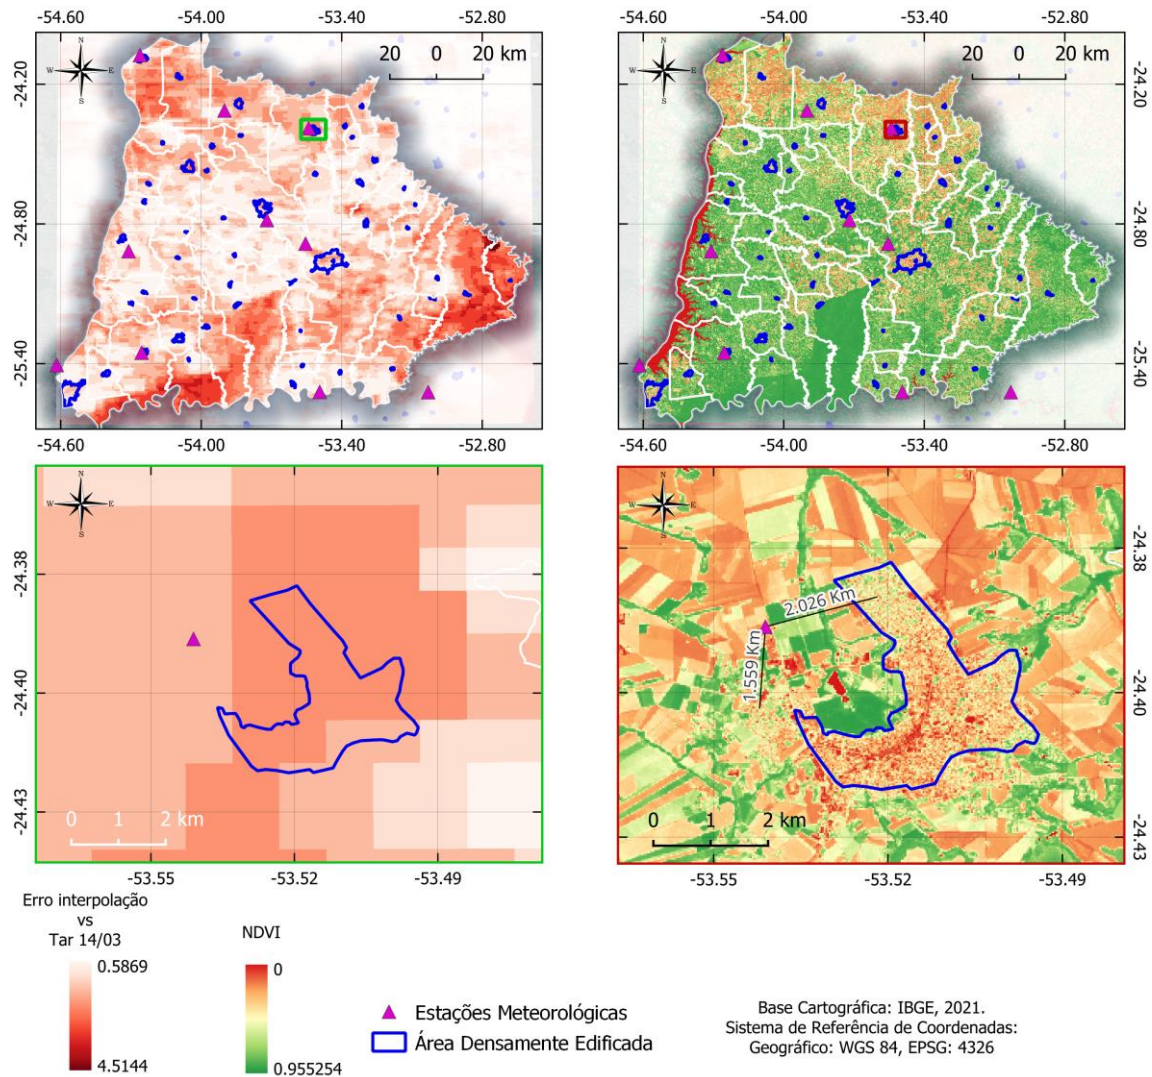


Figura 12 Espacialização dos erros apresentados na comparação dos dados interpolados, em relação aos dados orbitais modelados - Verão.

Para o dia selecionado (14/03) os erros variaram de 0,59 °C a 4,51 °C, para mais ou para menos, com maiores valores nas extremidades Leste, Sudoeste e Noroeste da região estudada.

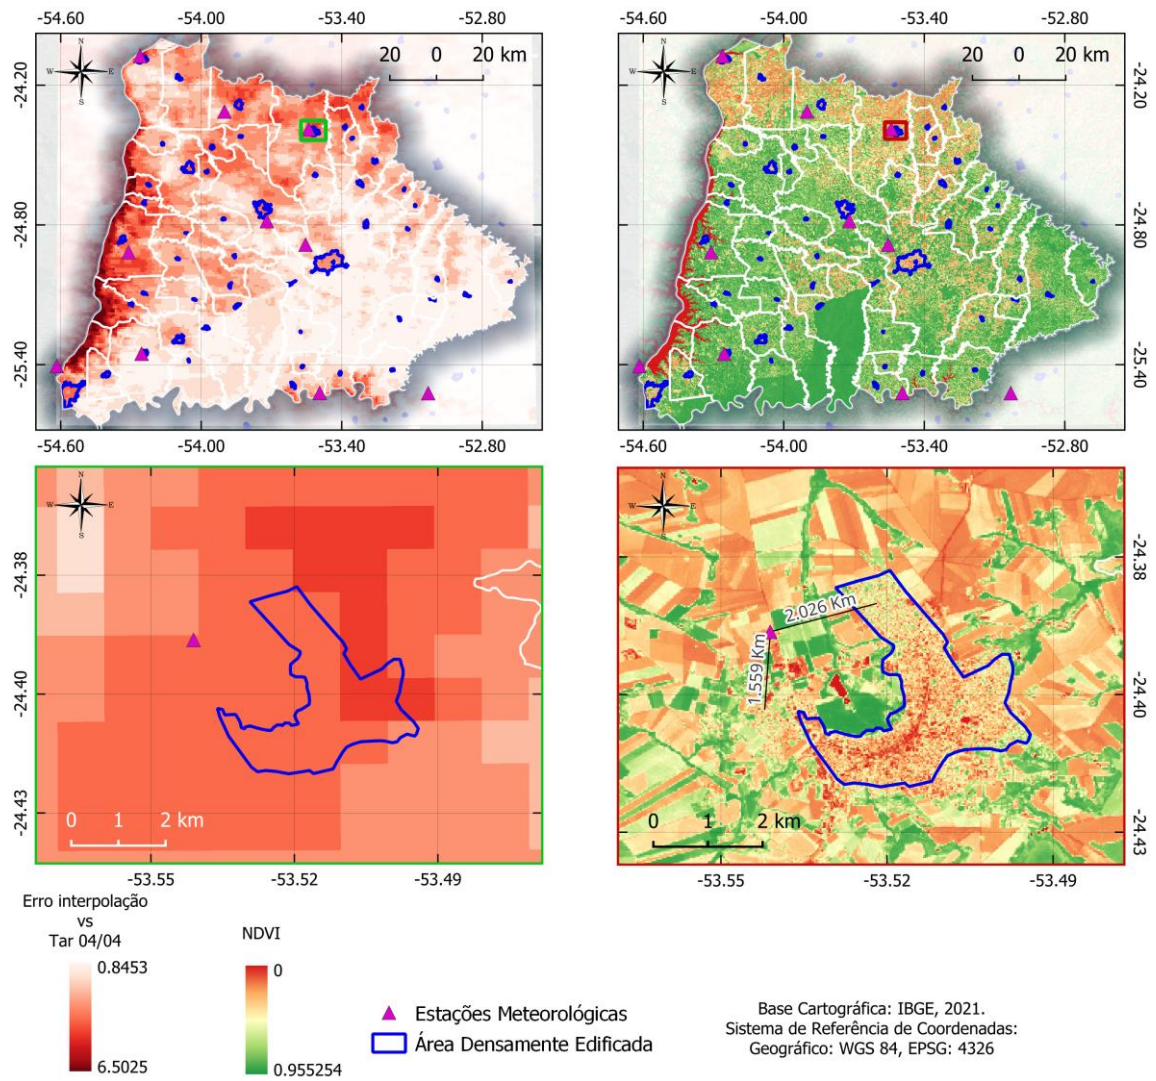


Figura 13 Espacialização dos erros apresentados na comparação dos dados interpolados, em relação aos dados orbitais modelados - Outono.

Na imagem do outono a maior concentração de erro se deu nas regiões lindeiras ao rio Paraná e, no geral, nas regiões mais urbanizadas.

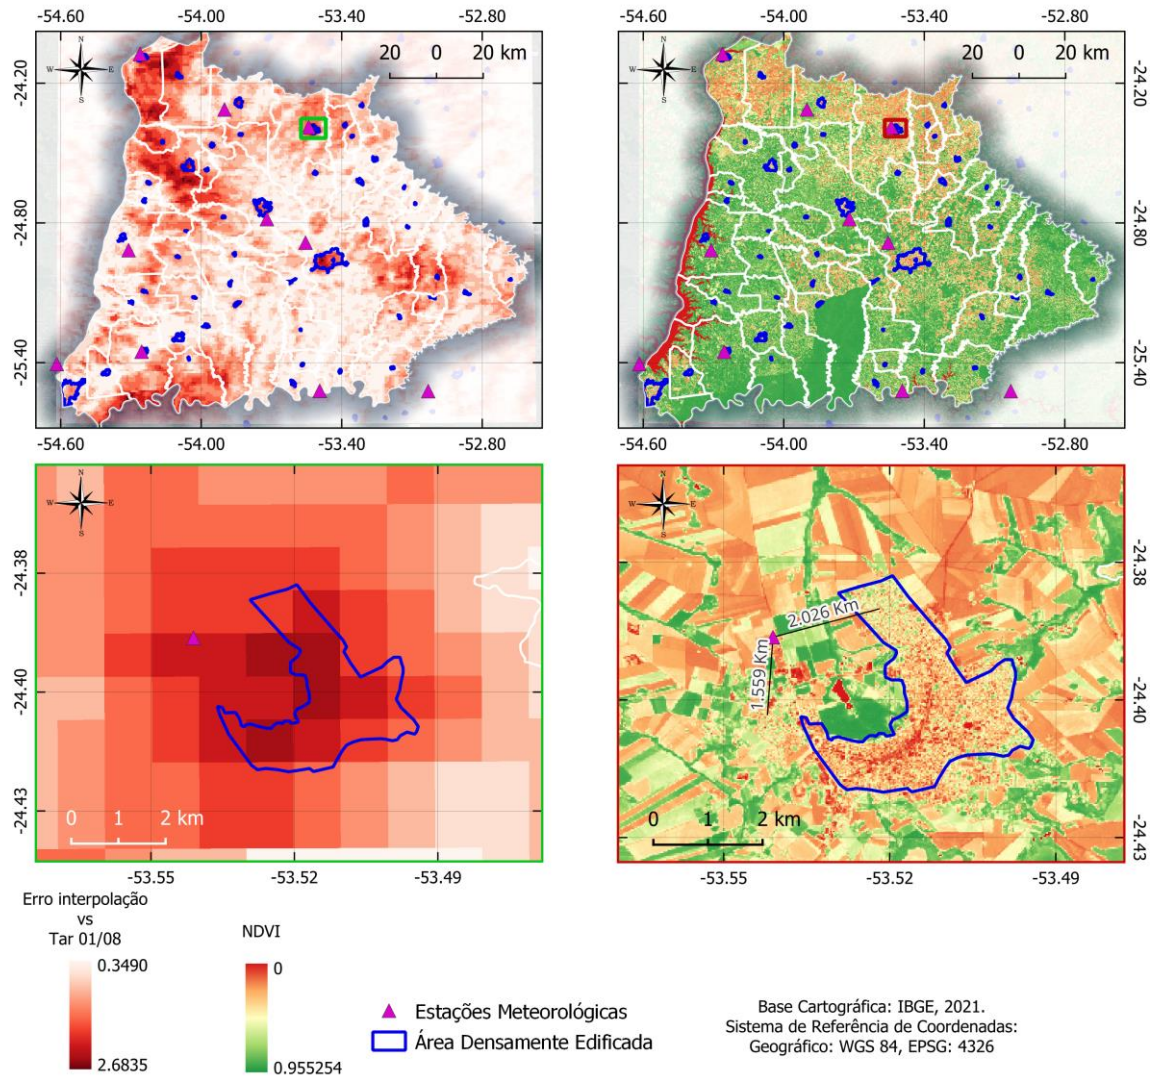


Figura 14 Espacialização dos erros apresentados na comparação dos dados interpolados, em relação aos dados orbitais modelados - Inverno.

No inverno ocorreu a menor amplitude de erro absoluto: 2,33 °C, o que corrobora a afirmação de Iqbal e Ali (2022), que, em razão da menor variação espacial da temperatura, os modelos de estimativa de temperatura do ar em função da LST tendem a apresentar melhor desempenho no inverno.

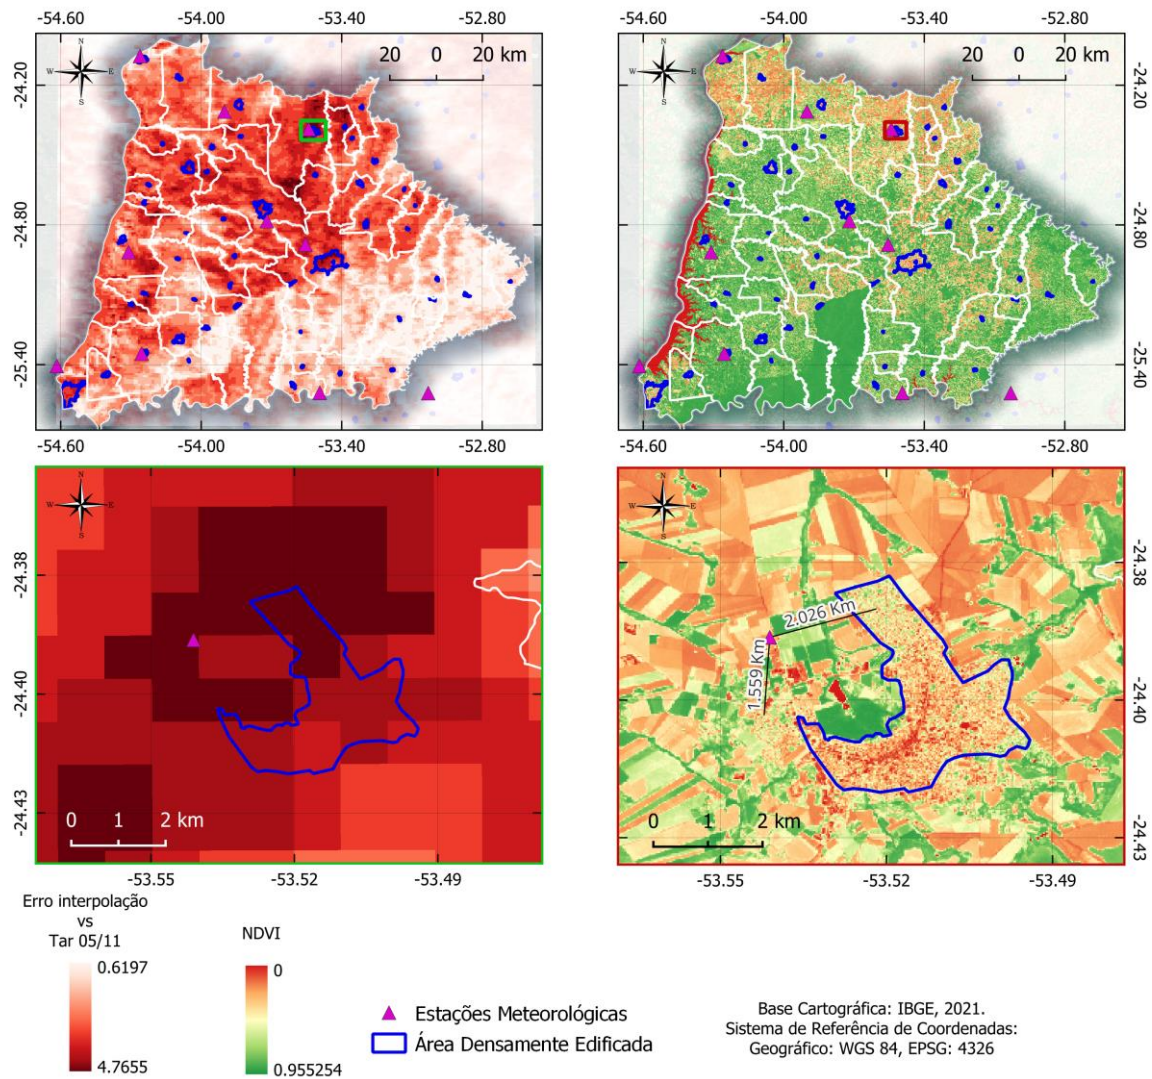


Figura 15 Espacialização dos erros apresentados na comparação dos dados interpolados, em relação aos dados orbitais modelados - Primavera.

Na primavera houve maior ocorrência de erros ao longo de toda a região, apresentando erros entre 0,62 °C e 4,77 °C, para mais ou para menos.

Destacam-se as quatro figuras (7, 8, 9 e 10), da estação de Assis Chateaubriand, que apresentam elevadas concentrações de erros nos *pixels* do entorno. Isso pode ocorrer em função da localização da estação, pois a interpolação não considera a distribuição espacial da cobertura do solo. Essa estação meteorológica está localizada em área aberta e predominantemente agrícola, com remanescentes florestais nas proximidades. Entretanto, localiza-se a uma distância de 1,559 Km de área com adensamento de edificações em estágios iniciais e a 2,026 Km de área densamente edificada no município.

Para melhor visualização da distribuição espacial de erro, foi confeccionado o mapa do somatório de erros, apresentado na **Figura 16**.

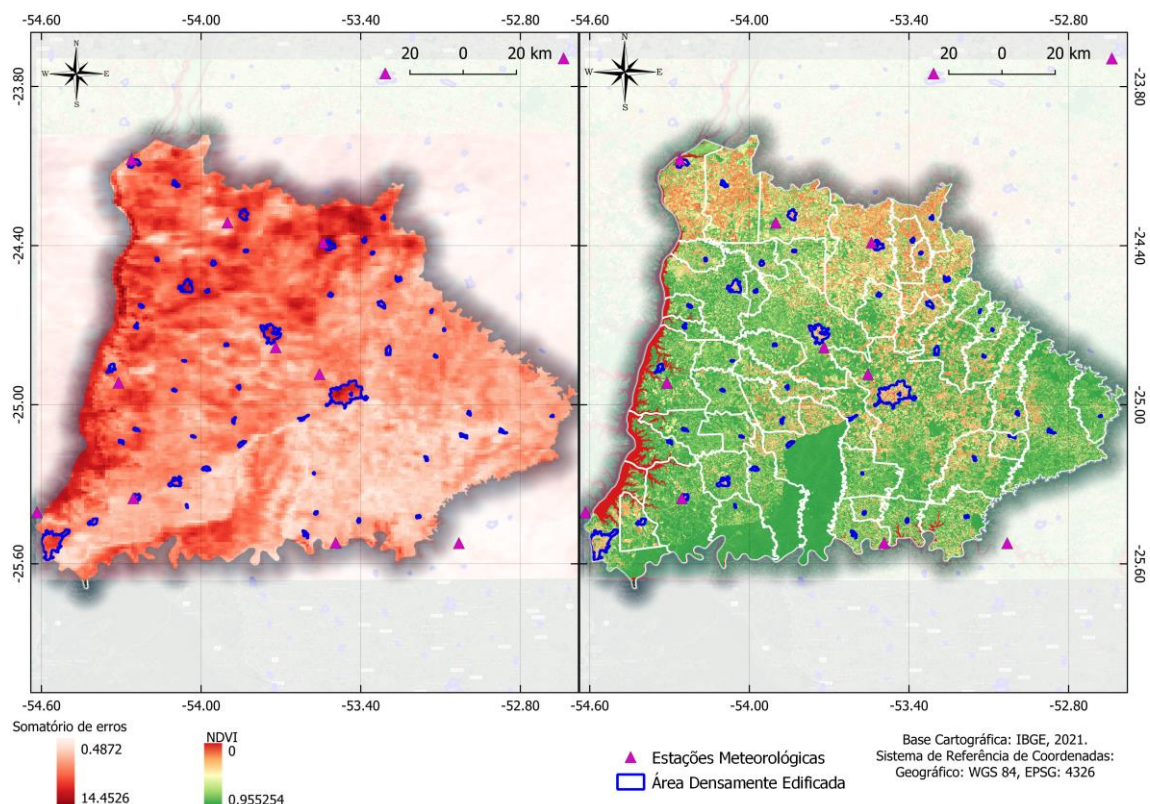


Figura 16 Distribuição espacial do somatório dos erros das interpolações, em relação às imagens T_{ar} .

De modo geral, quando a estação instalada está próxima a áreas com vegetação, como é o caso da maioria das estações utilizadas, os maiores erros se concentram nas localidades urbanizadas e quanto maior o aglomerado urbano maior tende a ser o erro acumulado.

Amani-Beni et al. (2022) realizaram testes com 23 pontos de medição de temperatura para verificar a variação microclimática com diferentes usos do solo. Foram instalados pontos de medição nas proximidades de um parque, em ruas, em área edificada, e em área gramada, dentre outras variações de uso. Constatou-se que os usos do solo nas imediações dos pontos de medição influenciam fortemente a variação espacial de temperatura.

Benali et al. (2012) utilizaram dados temporais de LST MODIS para estimar a temperatura do ar e verificaram que as estações localizadas em áreas urbanizadas apresentaram menor desempenho no modelo, bem como as amostras em florestas obtiveram maior desempenho. De modo geral, a localização das estações influencia o modelo em relação ao uso do solo.

6 Conclusões

A temperatura média diária de superfície, obtida com produtos MODIS de 3 e 4 observações, apresenta alta correlação com a temperatura do ar obtida por estações meteorológicas e resultaram em modelos robustos de estimativa de temperatura do ar.

As imagens sintéticas geradas a partir dos modelos de 3 e 4 observações e as imagens TIRS apresentaram correlação significativa com a temperatura do ar obtida pelas estações meteorológicas. Entretanto, a presença de nuvens nos dados de entrada prejudicou a quantidade de pares observáveis para a elaboração do modelo. O aumento na quantidade de dados de entrada pode resultar em melhor modelagem de dados.

Apesar de apresentar elevada distribuição de erros ao longo da região, quando a interpolação é comparada com a imagem modelada para temperatura de superfície, os dados interpolados apresentam boa correlação com os dados pontuais das estações particulares utilizadas na avaliação. Portanto, é factível a utilização dos dados interpolados das estações meteorológicas SIMEPAR da região Oeste do Paraná para preenchimento de dados faltantes em estações instaladas em ambientes agrícolas, como é o caso de todas as estações particulares utilizadas neste trabalho.

7 CONSIDERAÇÕES FINAIS

Diante da frequente cobertura de nuvens observada, uma medida necessária para aumentar a aplicabilidade das imagens sintéticas é o preenchimento de dados das imagens grosseiras de entrada. A possibilidade de utilização de uma janela móvel para análise de *pixel* nulos e preenchimento ponderado de dados, se apresenta como uma provável solução para esse problema.

REFERÊNCIAS

AKYUZ, F. A.; KANDEL, H.; MORLOCK, D. Developing a growing degree day model for North Dakota and Northern Minnesota soybean. **Agricultural and Forest Meteorology**, v. 239, p. 134-140, maio 2017.

AMANI-BENI, M.; CHEN, Y.; VASILEVA, M.; ZHANG, B.; XIE, G. di. Quantitative-spatial relationships between air and surface temperature, a proxy for microclimate studies in fine-scale intra-urban areas? **Sustainable Cities and Society**, v. 77, A. 103584, 1 fev. 2022. . Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S2210670721008490>. Acesso em: 23 jul. 2023.

ANGEL, J. R.. WIDHALM, M.; TODEY, D.; MASSEY, R.; BIEHL, L. The U2U corn growing degree day tool: Tracking corn growth across the US Corn Belt. **Climate Risk Management**, v. 15, p. 73–81, jan. 2017.

ASSAD, E. D. OLIVEIRA, A. F.; NAKAI, A. M.; PAVÃO, E.; PELLEGRINO, G.; MONTEIRO, J. E. Impactos e vulnerabilidades da agricultura brasileira às mudanças climáticas. In: TEIXEIRA, B. S.; ORSINI, J. A. M.; CRUZ, M. R. (Ed.). **Modelagem climática e vulnerabilidades setoriais à mudança do clima no Brasil**. Brasília: Ministério da Ciência, Tecnologia e Inovação, 2016. p. 127–186.

ASSENG, S.; EWERT, F.; MARTRE, P.; RÖTTER, R. P.; LOBELL, D. B.; CAMMARANO, D. et al. Rising temperatures reduce global wheat production. **Nature Climate Change**, v. 5, n. 2, p. 143–147, jan. 2015.

ASSENG, S.; FOSTER, I. A. N.; TURNER, N. The impact of temperature variability on wheat yields. **Global Change Biology**, v. 17, p. 997–1012, 2010.

BABAK, O.; DEUTSCH, C. V. Statistical approach to inverse distance interpolation. **Stochastic Environmental Research and Risk Assessment**, v. 23, n. 5, p. 543–553, mar. 2009.

BAJWA, A. A. FAROOQ, M.; AL-SADI, A. M.; NAWAZ, A.; JABRAN, K.; SIDDIQUE, K. H. M. Impact of climate change on biology and management of wheat pests. **Crop Protection**. v. 137, A. 105304 nov. 2020.

BENALI, A.; CARVALHO, A. C.; NUNES, J. P.; CARVALHAIS, N.; SANTOS, A. Estimating air surface temperature in Portugal using MODIS LST data. **Remote Sensing of Environment**, v. 124, p. 108–121, 1 set. 2012.

BIER, V. A.; SOUZA, E. G. Interpolation selection index for delineation of thematic maps. **Computers and Electronics in Agriculture**, v. 136, p. 202–209, 15 abr. 2017.

BISONG, E. **Google colabatory**. Building machine learning and deep learning models on Google cloud platform, p. 59–64, 2019. Disponível em: <https://link.springer.com/chapter/10.1007/978-1-4842-4470-8_7>. Acesso em: 1 ago. 2023.

BRANCA, G. BRAIMOH, A.; ZHAO, Y, RATII, M. LIKOETLA, P. Are there opportunities for climate-smart agriculture? Assessing costs and benefits of sustainability investments and planning policies in Southern Africa. **Journal of Cleaner Production**, v. 278, A. 123847, ago. 2020.

CAMMARANO, D.; TIAN, D. The effects of projected climate and climate extremes on a winter and summer crop in the southeast USA. **Agricultural and Forest Meteorology**, v. 248, p. 109-118, 15 jan. 2018. . Acesso em: 26 abril. 2023.

CAPMOURTERES, V.; ADAMS, J.; BERG, A.; FRASER, E.; SWANTON, C.; ANAND, M. Precision conservation meets precision agriculture: A case study from southern Ontario. **Agricultural Systems**, v. 167, p. 176–185, 1 nov. 2018. . Acesso em: 25 jul. 2023.

CATTANI, C. E. V.; GARCIA, M. R.; MERCANTE, E.; JOHANN, J. A.; CORREA, M. M.; OLDONI, L. V. Spectral-temporal characterization of wheat cultivars through NDVI obtained by terrestrial sensors. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 11, p. 769–773, nov. 2017.

CHEN, S.; GONG, B. Response and adaptation of agriculture to climate change: evidence from China. **Journal of Development Economics**, A. 102557, ago. 2020.

CLAY, N.; ZIMMERER, K. S. Who is resilient in Africa's green revolution? Sustainable intensification and climate smart agriculture in Rwanda. **Land Use Policy**, v. 97, A. 104558, set. 2020.

COLEZEA, M., MUSAT, G., POP, F., NEGRU, C., DUMITRASCU, A., MOCANU, M. (2018). Integrated web-service platform for smart farms. *Computers and electronics in agriculture*, 154, 134-154.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Grãos**. Dados estatísticos da produção nacional de grãos. 2023. Brasília - DF: Conab, 2023. Disponível em: <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras/itemlist/category/907-graos-por-unidades-da-federacao>. Acesso em: 29 jul. 2023.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Análise mensal**. Trigo. Fevereiro de 2020. Brasília - DF: Conab, 2020b. Disponível em: <https://www.conab.gov.br/>. Acesso em 18/07/2021.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Boletim de monitoramento agrícola**. Cultivos de inverno. v. 9. b. 9. set. 2020a. Brasília - DF: Conab; INM, 2020. Disponível em: <https://www.conab.gov.br/>. Acesso em: 21/09/2021.

COOK, M. **Atmospheric compensation for a Landsat Land Surface temperature product**. 22 out. 2014. 223 f. Thesis. Rochester Institute of Technology, Rochester, New York, EUA, 2014. Disponível em: <<https://scholarworks.rit.edu/theses/8513>>. Acesso em: 29 jul. 2023.

DEMIRHAN, H. Impact of increasing temperature anomalies and carbon dioxide emissions on wheat production. **Science of the Total Environment**, v. 741, p. 139616, nov. 2020.

DEPAULA, G. The distributional effect of climate change on agriculture. Evidence from a Ricardian quantile analysis of Brazilian census data. **Journal of Environmental Economics and Management**, v. 104, p. 102378, nov. 2020.

FALING, M. Framing agriculture and climate in Kenyan policies: a longitudinal perspective. **Environmental Science and Policy**, v. 106, p. 228–239, abr. 2020.

FOOD AND AGRICULTURE ORGANIZATION - FAO (Itália). **Food outlook biannual report on global food markets**. Rome: FAO United Nations, 2023. 160 p. Disponível em: <https://www.fao.org/3/cc3020en/cc3020en.pdf>. Acesso em: 15 mar. 2023.

GAO, F. et al. On the blending of the Landsat and MODIS surface reflectance: Predicting daily Landsat surface reflectance. **IEEE Transactions on Geoscience and Remote sensing**, v. 44, n. 8, p. 2207-2218, 2006.

GEVAERT, CAROLINE M.; GARCÍA-HARO, F. JAVIER. A comparison of STARFM and an unmixing-based algorithm for Landsat and MODIS data fusion. **Remote sensing of Environment**, v. 156, p. 34-44, 2015.

GHOSH, R.; GUPTA, P. K.; TOLPEKIN, V.; SRIVASTAV, S.K. An enhanced spatiotemporal fusion method – Implications for coal fire monitoring using satellite imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 88, A. 102056, jun. 2020.

GOMES, F. P. **Curso de estatística experimental**. 15. ed. Piracicaba: Fealq, 2009. 451 p.

GONZÁLEZ-ESTEBAN, Á. L. ¿Por qué el trigo? Pautas en la demanda internacional de trigo, 1939-2010. **Investigaciones de Historia Económica**, v. 13, n. 3, p. 135–150, out. 2017.

HARKNESS, C. SEMENOV, M. A. ; AREAL, F.; SENAPATI,N.; TRNKA, M.; BALEK, J.; BISHOP, J. Adverse weather conditions for UK wheat production under climate change. **Agricultural and Forest Meteorology**, v. 282–283, A. 107862, mar. 2020.

HOCHMAN, Z.; GOBBETT, D. L.; HORAN, H. Climate trends account for stalled wheat yields in Australia since 1990. **Global Change Biology**, v. 23, n. 5, p. 2071–2081, maio 2017.

HUANG, Y.; ZHONG-XIN, C.; TAO, Y.; XIANG-ZHI, H. XING-FA, G. Agricultural remote sensing big data: management and applications *Journal of Integrative Agriculture*. **Chinese Academy of Agricultural Sciences**, set. 2018.

HULLEY, G. C.; HOOK, S. J.; ABBOTT, E.; MALAKAR, N.; ISLAM, T.; ABRAMS, M. The ASTER Global emissivity dataset (ASTER GED): Mapping earth's emissivity at 100 meter spatial scale. **Geophysical Research Letters**, v. 42, n. 19, p. 7966–7976, 16 out. 2015. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/2015GL065564>>. Acesso em: 29 jul. 2023.

IQBAL, BENAZEER; ALI, MUHAMMAD. Estimation of spatio-temporal air temperature from satellite based LST under semi-arid to arid environment in Peshawar Basin, Northwest Pakistan. **Advances in Space Research**, v. 70, n. 4, p. 961-975, 2022.

JENSEN, J. R. **Sensoriamento remoto do ambiente**. 2. ed. São José dos Campos: Parêntese, 2009.

JUSTICE, C. O.; TOWNSHEND, J. R. G.; VERMOTE, E. F.; MASUOKA, E.; WOLFE, R. E.; SALEOUS, N.; ROY, D. P.; MORISETTE, J. T. An overview of MODIS Land data processing and product status. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 3–15, 1 nov. 2002. . Acesso em: 29 jul. 2023.

KHANAL, S.; FULTON, J.; SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, v. 139, p. 22–32, 15 jun. 2017. . Acesso em: 28 jul. 2023.

KUIAWSKI, C. A. M. B. SAFANELLI, J. L.; BOTTEGA, E. L.; OLIVEIRA NETO, A. M.; GUERRA, N. Índices de vegetação na delimitação de zonas de manejo para a soja. **Pesquisa Agropecuária Tropical**, n. 2, p. 168–177, jul. 2017.

LI, Y.; TIAN, D.; FENG, G.; YANG, W.; FENG, L. Climate change and cover crop effects on water use efficiency of a corn-soybean rotation system. **Agricultural Water Management**, v. 255, A. 107042, 1 set. 2021. . Acesso em: 28 jul. 2023.

LIU, B.; ASSENG, S.; MÜLLER, C.; EWERT, F.; ELLIOTT, J. DAVID, B. L. et al. Similar estimates of temperature impacts on global wheat yield by three independent methods. **Nature Climate Change**, v. 6, n. 12, p. 1130–1136, nov. 2016.

LIU, H. YIN, C.; GAO, Z.; HOU, L. Evaluation of cucumber yield, economic benefit and water productivity under different soil matric potentials in solar greenhouses in North China. **Agricultural Water Management**, v. 243, A. 106442, jan. 2021.

LIU, HUA; WENG, QIHAO. 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, p. 57-71, 2012.

MABILANA, H. A.; FONTANA, D. C.; FONSECA, E. L. Desenvolvimento de modelo agrometeorológico espectral para estimativa de rendimento do milho na Província de Manica-Moçambique. **Revista Ceres**, v. 59, n. 3, p. 337–349, maio 2012.

MONDAL, P.; BASU, M. Adoption of precision agriculture technologies in India and in some developing countries: scope, present status and strategies. **Progress in Natural Science**, v. 19, n. 6, p. 659–666, 10 jun. 2009. . Acesso em: 28 jul. 2023.

NARAYANAN, S. Effects of high temperature stress and traits associated with tolerance in wheat. **Open Access Journal of Science**, v. 2, n. 3, maio 2018.

NASEHZADEH, M.; ELLIS, R. H. Wheat seed weight and quality differ temporally in sensitivity to warm or cool conditions during seed development and maturation. **Annals of Botany**, v. 120, n. 3, p. 479–493, set. 2017.

NSABAGWA, M. BYAMUKAMA, M.; KONDELA, E.; OTIM, J. S. Towards a robust and affordable automatic weather station. **Development Engineering**, v. 4, A. 100040, jan. 2019.

NUTTALL, J. G.; O'LEARY, G. J.; PANOZZO, J. F.; WALKER, C. K.; BARLOW, K. M.; FITZGERALD, G. J. Models of grain quality in wheat. A review. **Field Crops Research**, v. 202, p. 136-145, 2017.

O'GRADY, M. J.; O'HARE, G. M. P. Modelling the smart farm. **Information Processing in Agriculture**, v. 4, n. 3, p. 179–187, 1 set. 2017. Acesso em: 28 jul. 2023.

OGADA, M. J. RAO, E. J.O.; RADENY, M. RECHA, J. W.; SOLOMON, D. Climate-smart agriculture, household income and asset accumulation among smallholder farmers in the Nyando basin of Kenya. **World Development Perspectives**, v. 18, A. 100203, jun. 2020.

PIRES, É. G.; FERREIRA JR, L. G. Mapeamento da temperatura de superfície diurna e noturna a partir de dados do Sensor MODIS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, 17. 2015. João Pessoa - PB. **Anais...** São José dos Campos: INPE, 2015.

PREY, L.; HU, Y.; SCHMIDHALTER, U. High-throughput field phenotyping traits of grain yield formation and nitrogen use efficiency: optimizing the selection of vegetation indices and growth stages. **Frontiers in Plant Science**, v. 10, p. 1672, jan. 2020.

PRUDENTE, V. H. R.; MARTINS, V. S.; VIEIRA, D. C.; SILVA, N. R. F.; ADAMI, M.; SANCHES, I. D. A. Limitations of cloud cover for optical remote sensing of agricultural areas across South America. **Remote Sensing Applications: Society and Environment**, v. 20, A. 100414, 1 nov. 2020. . Acesso em: 25 jul. 2023.

RAMÍREZ-GIL, J. G.; MARTÍNEZ, G. O. G.; MORALES OSORIO, J. G. Design of electronic devices for monitoring climatic variables and development of an early warning system for the avocado wilt complex disease. **Computers and Electronics in Agriculture**, v. 153, p. 134--143, out. 2018.

RODRÍGUEZ-AMIGO, M. C.; DÍEZ-MEDIAVILLA, M.; GONZÁLEZ-PEÑA, D.; PÉREZ-BURGOS, A.; ALONSO-TRISTÁN, C. Mathematical interpolation methods for spatial estimation of global horizontal irradiation in Castilla-León, Spain. A case study. **Solar Energy**, v. 151, p. 14–21, jul. 2017.

SAYLER, Kristi. **Landsat 8-9 collection 2 (C2) level 2 science product (L2SP) guide**. 5. ed. Sioux Falls: Department of the interior U.S. Geological Survey, 2023. 43 p. Disponível em: https://d9-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/s3fs-public/media/files/LSDS-1619_Landsat8-9-Collection2-Level2-Science-Product-Guide-v5.pdf. Acesso em: 30 jul. 2023.

SILVA JÚNIOR, J. C.; MEDEIROS, V. W. C.; GARROZI, C.; MONTENEGRO, A.; GONÇALVES, G. E. Random forest techniques for spatial interpolation of evapotranspiration data from Brazilian's Northeast. **Computers and Electronics in Agriculture**, v. 166, A. 105017, nov. 2019.

SINGH, S.; GUPTA, A. K.; KAUR, N. Influence of drought and sowing time on protein composition, antinutrients, and mineral contents of wheat. **The Scientific World Journal**, v. 2012, A. ID 485751, 2012.

SISHEBER, B.; MARSHALL, M.; AYALEW, D.; NELSON, A. Tracking crop phenology in a highly dynamic landscape with knowledge-based Landsat–MODIS data fusion. **International Journal of Applied Earth Observation and Geoinformation**, v. 106, A. 102670, 1 fev. 2022. Acesso em: 25 jul. 2023.

SISHEBER, B.; MARSHALL, M.; MENGISTU, D.; NELSON, A. Detecting the long-term spatiotemporal crop phenology changes in a highly fragmented agricultural landscape. **Agricultural and Forest Meteorology**, v. 340, A. 109601, 15 set. 2023. Acesso em: 30 jul. 2023.

UNITED STATES DEPARTMENT OF AGRICULTURE - USDA. **Economic Research Service**. 2020. Disponível em: <https://www.usda.gov/>. Acesso em: 29 jul. 2021.

UNITED STATES GEOLOGICAL SURVEY - USGS. Landsat earth observation satellites. Ver. 1.1, August 2016. U.S. **Geological Survey Fact Sheet 2015–3081**. Reston - VA August, 2020.

VAN DE KERKHOF, B. VAN PERSIE, M.; NOORBERGEN, H.; SCHOUTEN, L.; GHAUHARALI, R. Spatio-temporal analysis of remote sensing and field measurements for smart farming. **Procedia Environmental Sciences**, v. 27, p. 21–25, jan. 2015.

VANCUTSEM, C.; CECCATO, P.; DINKU, T.; CONNOR, S. J. Evaluation of MODIS land surface temperature data to estimate air temperature in different ecosystems over Africa. **Remote Sensing of Environment**, v. 114, n. 2, p. 449–465, 15 fev. 2010. . Acesso em: 25 jul. 2023.

VERMOTE, E. JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46–56, nov. 2016.

VIGGIANO, M. Busetto, L.; CIMINI, D. DI PAOLA, F.; GERALDI, E.; RANGHETTI, L.; RICCIARDELLI, E.; ROMANO, F. A new spatial modeling and interpolation approach for high-resolution temperature maps combining reanalysis data and ground measurements. **Agricultural and Forest Meteorology**, v. 276–277, A. 107590, out. 2019.

WAN, Z.; HOOK, S.; HULLEY, G. **MOD11A1** - MODIS/Terra land surface temperature/emissivity daily L3 global 1km SIN grid V006. NASA EOSDIS Land Processes DAAC, 2015.

WAN, Z. **MODIS land surface temperature products users' guide**. Collection-6. Santa Barbara: Eri, University Of California, 2019. 37 p. Disponível em: https://lpdaac.usgs.gov/documents/715/MOD11_User_Guide_V61.pdf. Acesso em: 15 mar. 2022.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications. A meta-review. **Remote Sensing of Environment**, v. 236, A. 111402, jan. 2020.

WILLMOTT, C. J.; ACKLESON, S. G.; DAVIS, R. E.; FEDDEMA, J. J.; KLINK, K. M.; LEGATES, D. R.; O'DONNELL, J.; ROWE, C. M. Statistics for the evaluation and comparison of models. **Journal of Geophysical Research**, v. 90, n. C5, A. 8995, 1985. Disponível em: <https://www.researchgate.net/publication/259475985_Statistics_for_the_Evaluation_and_Comparison_of_Models>. Acesso em: 30 jul. 2023.

XIAO, D.; BAI, H.; LIU, D. Impact of future climate change on wheat production. A simulated case for China's wheat system. **Sustainability**, v. 10, n. 4, p. 1277, abr. 2018.

XING, Z.; LI, Z. L.; DUAN, S. B.; LIU, X.; ZHENG, X.; LENG, P.; GAO, M.; ZHANG, X.; SHANG, G. Estimation of daily mean land surface temperature at global scale using pairs of daytime and nighttime MODIS instantaneous observations. **Journal of Photogrammetry and Remote Sensing**, v. 178, p. 51–67, 1 ago. 2021. Acesso em: 13 jul. 2023.

XU, C.; LIN, M.; FANG, Q.; CHEN, J.; YUE, Q.; XIA, J. Air temperature estimation over winter wheat fields by integrating machine learning and remote sensing techniques. **International Journal of Applied Earth Observation and Geoinformation**, v. 122, A. 103416, 1 ago. 2023. Acesso em: 1 ago. 2023.

YOON, C.; LIM, D.; PARK, C. Factors affecting adoption of smart farms: The case of Korea. **Computers in Human Behavior**, v. 108, A. 106309, jul. 2020.

ZAKARIA, A.; AZUMAH, S. B.; APPIAH-TWUMASI, M.; DAGUNGA, G. Adoption of climate-smart agricultural practices among farm households in Ghana: The role of farmer participation in training programmes. **Technology in Society**, v. 63, A. 101338, nov. 2020.

ZERMAS, D. MORELLAS, V.; MULLA, D.; PAPANIKOLOPOULOS, N. 3d model processing for high throughput phenotype extraction – the case of corn. **Computers and Electronics in Agriculture**, A. 105047, 6 nov. 2019.

ZHU, X. CHEN, J.; GAO, F.; CHEN, X.; MASEK, J.; An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. **Remote Sensing of Environment**, v. 114, n. 11, p. 2610–2623, nov. 2010.

ZHU, W.; LU, A.; JIA, S. Estimation of daily maximum and minimum air temperature using MODIS land surface temperature products. **Remote Sensing of Environment**, v. 130, p. 62-73, 15 mar. 2013. Acesso em: 30 jul. 2023.

ZILLI, M.; SCARABELLO, M.; SOTERRONI, A. C.; VALIN, H. MOSNIER, A. LECLÈRE. D. et al. The impact of climate change on Brazil's agriculture. **Science of the Total Environment**, v. 740, A. 139384, out. 2020.

APÊNDICES

APÊNDICE A - Cálculo e importação de dados históricos da média de temperatura de superfície diária com 4 observações MOD1A1 e MYD11A1

https://colab.research.google.com/drive/1gQNhVdxDO5OvS0vD-5cZM_00RSdYJYJq?usp=sharing

```
import ee
```

```
try:
```

```
    ee.Initialize()
```

```
except:
```

```
    ee.Authenticate(auth_mode='notebook')
```

```
    ee.Initialize()
```

```
imageCollection = ee.ImageCollection("MODIS/061/MOD11A1")
```

```
imageCollection2 = ee.ImageCollection("MODIS/061/MYD11A1")
```

```
geometry = ee.Geometry.Polygon(
```

```
    [[[-53.36770085158315, -25.63504981276063],
```

```
        [-53.36770085158315, -23.470008366372014],
```

```
        [-55.71221582815509, -23.470008366372014],
```

```
        [-55.71221582815509, -25.63504981276063]]], None, False);
```

```
dati = '2022-01-01'
```

```
datf = '2022-12-31'
```

```
#Fiz uma para o MOD e uma para o MYD para aplicar o rename personalizado
```

```
def convclipMOD(image):
```

```
    return image.multiply(0.02).clip(geometry) \
```

```
        .select('LST_Day_1km','LST_Night_1km').rename('MODd','MODn')
```

```
def convclipMYD(image):
```

```
    return image.multiply(0.02).clip(geometry) \
```

```
        .select('LST_Day_1km','LST_Night_1km').rename('MYDd','MYDn')
```

```
#Chama as coleções MOD e MYD, aplicando a multiplicação, recorte, seleção de bandas e rename das mesmas
```

```
ColMOD = imageCollection.filterDate(dati,datf).map(convclipMOD)
```

```
ColMYD = imageCollection2.filterDate(dati,datf).map(convclipMYD)
```

```
#Cria o filtro que será usado para unir as coleções MOD e MYD
```

```

filter = ee.Filter.equals(**{
  'leftField': 'system:index',
  'rightField': 'system:index'
})
#Cria a coleção unida por um inner join e ja remapeia para a coleção primary e secondary
gerarem apenas uma imagem
def func_osj(feature):
  return ee.Image.cat(feature.get('primary'), feature.get('secondary'))

ColMCD = ee.ImageCollection(ee.Join.inner().apply(ColMOD, ColMYD, filter)).map(func_osj)

#Define a função de calculo usando as bandas MOD e MYD
def calculo(image):
  return
  ((image.select('MODd').multiply(0.1807)).add((image.select('MODn').multiply(0.3210))) \
  .add((image.select('MYDd').multiply(0.1907))).add((image.select('MYDn').multiply(0.3241))) \
  .add(-4.75)).subtract(273.15).rename('LSTmedio')

#Aplica o calculo
LST = ColMCD.map(calculo)
#Função de exportação
def Exports (col):
  colList = col.toList(col.size())
  n = colList.size().getInfo()
  for j in range(n):
    img = ee. Image(colList.get(j))
    ee.batch.Export.image.toDrive(**{
      'image':img.toFloat(),
      'description': ('LST_Medio_4Obs-'+img.get('system:index').getInfo()),
      'folder': "Media_LST_Dia_4_Observacoes_2022_2022_Colab30m_224077_4326",
      'scale': 30,
      'region': geometry,
      'maxPixels': 1e13,
      'crs': 'EPSG:4326'}).start()

#Exporta a coleção com os valores calculados
Exports(LST).

```


APÊNDICE B – Cálculo e importação de dados históricos da média de temperatura de superfície diária com 3 observações MOD1A1 e MYD11A1

```
https://colab.research.google.com/drive/1Pd7T-
2MGxLvI97aCTYTxCYz6yeCZKRRRe?usp=sharing
import ee
```

```
try:
```

```
    ee.Initialize()
```

```
except:
```

```
    ee.Authenticate(auth_mode='notebook')
```

```
    ee.Initialize()
```

```
imageCollection = ee.ImageCollection("MODIS/061/MOD11A1")
```

```
imageCollection2 = ee.ImageCollection("MODIS/061/MYD11A1")
```

```
geometry = ee.Geometry.Polygon(
    [[[-51.9625, -25.6494],
      [-51.9625, -23.6937],
      [-54.6167, -23.6937],
      [-54.6167, -25.6494]]], None, False);
```

```
dati = '2020-01-01'
```

```
datf = '2021-01-01'
```

```
#Fiz uma para o MOD e uma para o MYD para aplicar o rename personalizado
```

```
def convclipMOD(image):
```

```
    return image.multiply(0.02).clip(geometry) \
        .select('LST_Day_1km','LST_Night_1km').rename('MODd','MODn')
```

```
def convclipMYD(image):
```

```
    return image.multiply(0.02).clip(geometry) \
        .select('LST_Day_1km','LST_Night_1km').rename('MYDd','MYDn')
```

```
#Chama as coleções MOD e MYD, aplicando a multiplicação, recorte, seleção de bandas e
rename das mesmas
```

```
ColMOD = imageCollection.filterDate(dati,datf).map(convclipMOD)
```

```

ColMYD = imageCollection2.filterDate(dati, datf).map(convclipMYD)
#Cria o filtro que será usado para unir as coleções MOD e MYD
filter = ee.Filter.equals(**{
  'leftField': 'system:index',
  'rightField': 'system:index'
})
#Cria a coleção unida por um inner join e ja remapeia para a coleção primary e secondary
gerarem apenas uma imagem
def func_osj(feature):
  return ee.Image.cat(feature.get('primary'), feature.get('secondary'))

ColMCD = ee.ImageCollection(ee.Join.inner().apply(ColMOD, ColMYD, filter)).map(func_osj)

#Define a função de calculo usando as bandas MOD e MYD
def calculo(image):
  return
  ((image.select('MODn').multiply(0.3243)).add((image.select('MYDn').multiply(0.3318)))
  .add((image.select('MYDd').multiply(0.3582))).subtract(4.31)).subtract(273.15).rename('LST
  medioC')

#Aplica o calculo
LST = ColMCD.map(calculo)
#Função de exportação
def Exports (col):
  colList = col.toList(col.size())
  n = colList.size().getInfo()
  for j in range(n):
    img = ee. Image(colList.get(j))
    ee.batch.Export.image.toDrive(**{
      'image':img.toFloat(),
      'description': ('LST_Medio_4Obs-'+img.get('system:index').getInfo()),
      'folder': "Media_LST_Dia_3_Observacoes_2020_Colab_ANA",
      'scale': 1000,
      'region': geometry,
      'maxPixels': 1e13,
      'crs': 'EPSG:4326'}).start()
#Exporta a coleção com os valores calculados

```

Exports(LST)

APÊNDICE C - Resultados da elaboração das imagens sintéticas

