

UNIVERSIDADE FEDERAL DE PELOTAS
Faculdade de Agronomia Eliseu Maciel
Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água

Tese



**PRODUTIVIDADE DA SOJA NO RIO GRANDE DO SUL ESTIMADA POR MEIO
DE DADOS OBTIDOS POR SATÉLITES**

Gabriel da Silva Lemos

Pelotas, 2021.

Gabriel da Silva Lemos

**PRODUTIVIDADE DA SOJA NO RIO GRANDE DO SUL ESTIMADA POR MEIO
DE DADOS OBTIDOS POR SATÉLITES**

Tese apresentada ao Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água da Faculdade de Agronomia Eliseu Maciel da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Doutor em Ciências (na área de concentração: Manejo e Conservação do Solo e da Água).

Orientador: Prof. Dr. Rodrigo Rizzi

Pelotas, 2021.

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

L555p Lemos, Gabriel da Silva

Produtividade da soja no Rio Grande do Sul estimada por meio de dados obtidos por satélites / Gabriel da Silva Lemos ; Rodrigo Rizzi, orientador. — Pelotas, 2021.

131 f.

Tese (Doutorado) — Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água, Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, 2021.

1. Estatísticas agrícolas. 2. Modelagem agrometeorológica. 3. Sensor MODIS. 4. Monitoramento agrícola. 5. Sistemas de Informação Geográfica. I. Rizzi, Rodrigo, orient. II. Título.

CDD : 631.42

Gabriel da Silva Lemos

**PRODUTIVIDADE DA SOJA NO RIO GRANDE DO SUL ESTIMADA POR MEIO
DE DADOS OBTIDOS POR SATÉLITES**

Tese aprovada, como requisito parcial, para obtenção do grau de Doutor em ciências, Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água, Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas.

Data da defesa: 18 de fevereiro de 2021

Banca examinadora:

.....
Prof. Dr. Rodrigo Rizzi, (Orientador) Doutor em Sensoriamento Remoto pelo Instituto Nacional de Pesquisas Espaciais - INPE

.....
Dr. Ivan Rodrigues de Almeida, Doutor em Geografia pela Universidade Estadual Paulista Júlio de Mesquita Filho - UNESP

.....
Dr. José Maria Filippini Alba, Doutor em Geociências pela Universidade de São Paulo - USP

.....
Dr. Marcos Adami, Doutor em Sensoriamento Remoto pelo Instituto Nacional de Pesquisas Espaciais - INPE

Agradecimentos

Agradeço aos meus pais, Milton Canez Lemos e Sandra da Silva Lemos, pela dedicação e apoio nos momentos mais difíceis.

Ao professor Dr. Rodrigo Rizzi, pela excelente orientação, conhecimentos transmitidos, paciência e dedicação.

Ao Dr. Marcos Adami, pelo auxílio na análise estatística dos dados deste trabalho.

Ao colega de PPG MACSA Luis Carlos Nunes Weymar Junior, pela amizade e pelo auxílio nos momentos necessários.

Aos amigos que conheci no PPG MACSA.

Ao corpo docente do PPG MACSA.

Ao professor Rogério Oliveira de Sousa, pelo empenho em obter uma bolsa emergencial, da qual, fui beneficiado durante parte do doutorado.

À empresa Agrosatélite Geotecnologia aplicada, onde trabalhei concomitantemente à fase final do doutorado.

A FAPERGS/CAPES - Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul/Coordenação de Aperfeiçoamento de Pessoal de nível Superior, pela bolsa de Doutorado.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

“Mar calmo nunca fez bom marinheiro.” (Dito popular).

Resumo

LEMOS, Gabriel da Silva. **Produtividade da soja no Rio Grande do Sul estimada por meio de dados obtidos por satélites**. Orientador: Rodrigo Rizzi. 2021. 131 f. Tese (Doutorado em Ciências) – Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, Pelotas, 2021.

A grande expansão da soja no estado do Rio Grande do Sul (RS) demanda informações atualizadas sobre a produtividade da cultura e a extensão dos danos meteorológicos ocorridos ao longo da safra. Os modelos matemáticos de estimativa da produtividade baseados na resposta das culturas aos fatores meteorológicos são uma importante ferramenta na obtenção dessas informações. Entretanto, sua utilização sobre grandes regiões é dificultada pela pouca disponibilidade de dados meteorológicos, função da distribuição esparsa das estações de medição para boa parte do território nacional. Assim, este trabalho objetivou testar um modelo de monitoramento e estimativa da produtividade agrícola da soja para o RS em um Sistema de Informações Geográficas (SIG), a partir de dados meteorológicos e espectrais obtidos majoritariamente através de sensores orbitais. Utilizou-se o modelo de Doorenbos e Kassam (1979) com dados de precipitação estimados pelo sistema *Global Precipitation Measurement* (GPM), de umidade relativa do ar estimados pelo sensor AIRS e de temperatura do ar estimados a partir dos dados de temperatura de superfície oriundos do sensor MODIS, além de dados de velocidade do vento e insolação obtidos por estações meteorológicas, para as safras de 2016 a 2018. Os dados meteorológicos estimados foram primeiramente comparados aos observados por estações meteorológicas convencionais. Então, devido as diferentes características edafoclimáticas, subdividiu-se o RS nas porções norte e sul, ajustando-se o modelo distintamente em cada região. Para todo o RS, aplicou-se o modelo com valores de Índice de Área Foliar (IAF) obtidos em literatura (Modelo Agrometeorológico - MA). Já para a porção norte, utilizaram-se ainda valores de IAF estimados pelo *Normalized Difference Vegetation Index* (NDVI) do sensor MODIS (Modelo Agrometeorológico Espectral - ME), além de um mapa contendo as áreas de soja produzido via imagens do sensor MODIS para ambos os modelos. Os valores de produtividade modelados foram comparados aos dados oficiais disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE), em nível de microrregião, pelo teste de Kolmogorov-Smirnov (KS), para $\alpha=5\%$. Para o monitoramento espaço-temporal da produtividade, utilizou-se o Índice de Penalização (IP). O viés observado para os dados de precipitação do GPM (5,33 mm), de umidade relativa do ar oriundos do sensor AIRS (de -3,30 a 4,43%) e de temperatura do ar estimados a partir do sensor MODIS (-0,3°C) foram considerados satisfatórios para sua utilização no modelo. Quando aplicado para todo o RS, não se observaram diferenças significativas entre os valores de produtividade oriundos do MA frente aos do IBGE, para todas as safras. Para a porção norte, observaram-se diferenças significativas entre os dados estimados pelos MA e ME frente aos do IBGE apenas para a safra 2016. Com relação ao IP, a porção norte foi pouco penalizada, à exceção de IPs de 0,7 a 0,8 observados na região Oeste, na safra 2018. Já a porção sul foi bastante penalizada, sendo as fronteiras sul e sudoeste as regiões mais prejudicadas, com IPs de 0,1 e 0,2, na safra 2018. Em suma, o modelo proposto mostrou ser uma eficiente ferramenta de auxílio para monitorar e estimar a produtividade da soja no RS.

Palavras-chave: estatísticas agrícolas. modelagem agrometeorológica. sensor MODIS. monitoramento agrícola. Sistemas de Informação Geográfica.

Abstract

LEMOS, Gabriel da Silva. **Soybean yield in Rio Grande do Sul estimated through data obtained by satellites**. Advisor: Rodrigo Rizzi. 2021. 131 f. Thesis (Doctorate in Sciences) – Faculty of Agronomy Eliseu Maciel, Federal University of Pelotas, Pelotas, 2021.

The great soybean expansion in Rio Grande do Sul State (RS), Brazil, demands updated information regarding the crop grain yield as well as the extent of meteorological damage occurred during the season. Mathematical models used to estimate grain yield based on crop response to meteorological factors are an important tool in obtaining this information. However, its use over large regions is hampered by the limited availability of meteorological data, due to the sparse distribution of *in situ* weather measurement stations over a large part of the national territory. Thus, this work aimed to test a model to monitor and estimate soybean grain yield in RS coupled in a Geographic Information System (GIS), based on spectral and meteorological data obtained mainly through orbital sensors. To estimate soybean grain yield from 2016 to 2018 crop seasons the model proposed by Doorenbos and Kassam (1979) was used with rainfall data from the Global Precipitation Measurement (GPM) system, relative air humidity from the AIRS sensor and air temperature estimated from surface temperature data from MODIS sensor, along with wind speed and insolation data obtained by weather stations. We first compared estimated meteorological data from GPM, AIRS and MODIS to those observed from weather stations. Then, due to the different edaphoclimatic characteristics, we subdivided the RS into north and south portions, so that the model was distinctly adjusted between these regions. Moreover, for the entire RS we used Leaf Area Index (LAI) data obtained from literature (Agrometeorological Model - MA). For the North portion, we also used LAI values estimated by the Normalized Difference Vegetation Index (NDVI) (Agrometeorological-Spectral Model - ME) and a soybean cropped map obtained from MODIS images for both MA and ME models. Modeled grain yield data were compared with the official ones provided by the Brazilian Institute for Geography and Statistics (IBGE), in micro-region level, using the Kolmogorov-Smirnov (KS) test for $\alpha=5\%$. For the spatio-temporal yield monitoring, we used the Penalty Index (IP). The observed bias we observed for rainfall data from GPM (5.33 mm), relative air humidity data from AIRS sensor (from -3.30 to 4.43%) and air temperature data from MODIS sensor (-0.3°C) was suitable to their use in the estimation model. When applied to the entire RS, no significant difference was observed between MA data and those provided by the IBGE. For the north portion, we observed significant difference between MA and ME data compared to those provided by IBGE only for the 2016 crop season. Regarding the IP, the north portion was barely penalized, with the exception of IPs from 0.7 to 0.8, mainly in the West region in 2018 crop season. The south portion was very penalized, with the south and southwest borders the most affected regions, with IPs of 0.1 and 0.2 in the 2018 crop season. Overall, the proposed model showed to be a useful aid tool to monitor and estimate soybean grain yield in RS.

Key-words: Agricultural statistics. agrometeorological modeling. MODIS sensor, Crop monitoring. Geographic Information Systems.

Lista de Figuras

Figura 1	Evolução e periodicidade das exportações de soja no Brasil.....	26
Figura 2	Distribuição do percentual de área cultivada com soja por microrregião brasileira em relação à área total da microrregião para a safra de 2020.....	27
Figura 3	Área cultivada com soja no Brasil.....	28
Figura 4	Área cultivada com soja no RS.....	28
Figura 5	Precipitação pluvial (mm) mensal normal (1931-60) para as Metades Norte e Sul (latitude maior ou menor do que 30°S, respectivamente) do RS.....	33
Figura 6	Comparação entre as bandas espectrais de diferentes sensores.....	43
Figura 7	Subdivisão da área de estudo nas porções norte e sul do RS.....	57
Figura 8	Esquema do Algoritmo de seleção de pixel, para o cálculo de temperatura média da superfície através dos satélites Terra e Aqua, de passagens diurnas e noturnas, visando à composição das imagens LST do primeiro período do ano civil.....	62
Figura 9	Localização das estações meteorológicas convencionais do INMET no RS utilizadas no presente estudo.....	63
Figura 10	Mapa contendo as áreas de cultivo de soja para a porção norte do RS, na safra 2015.....	78
Figura 11	Regressão linear entre a área de soja obtida através da metodologia CEI e a disponibilizada pelo IBGE para a safra 2015 nas microrregiões da porção norte do RS.....	79
Figura 12	Séries quinzenais ao longo de um ano e regressão linear entre os dados do sistema de satélites GPM e a estação meteorológica de Pelotas/RS, para os produtos <i>Early</i> e <i>Late</i> no ano de 2016 e <i>Final</i> no ano de 2015.....	81
Figura 13	Séries temporais quinzenais dos dados de umidade relativa do ar adquiridos pelo sensor AIRS/Aqua e estações	

	meteorológicas convencionais ao longo da safra 2015/16.....	82
Figura 14	Diagrama de dispersão entre os dados de temperatura média LST do MODIS e de temperatura média do ar das estações meteorológicas convencionais para o RS para o ano de 2016.....	83
Figura 15	Séries temporais de oito dias da temperatura média LST/MODIS e do ar estimada pela equação de regressão em comparação à observada pelas estações meteorológicas convencionais para o ano de 2017.....	84
Figura 16	Histograma e curva normal para os dados de produtividade da soja obtidos pelo IBGE para o estado do RS e para a porção norte do RS, nas safras 2016, 2017 e 2018.....	87
Figura 17	Histograma e curva normal para as produtividades da soja obtidas pelos modelos agrometeorológico para o RS, agrometeorológico para a porção norte do RS e modelo agrometeorológico espectral para a porção norte do RS, nas safras 2016, 2017 e 2018.....	87
Figura 18	Mapa de produtividade obtido pelo modelo agrometeorológico para as áreas de cultivo de soja da porção norte do RS na safra 2016.....	96
Figura 19	Mapa de produtividade obtido pelo modelo agrometeorológico para as áreas de cultivo de soja da porção norte do RS na safra 2017.....	96
Figura 20	Mapa de produtividade obtido pelo modelo agrometeorológico para as áreas de cultivo de soja da porção norte do RS na safra 2018.....	97
Figura 21	Mapa de produtividade obtido pelo modelo agrometeorológico espectral para as áreas de cultivo de soja da porção norte do RS na safra 2016.....	97
Figura 22	Mapa de produtividade obtido pelo modelo agrometeorológico espectral para as áreas de cultivo de soja da porção norte do RS na safra 2017.....	98
Figura 23	Mapa de produtividade obtido pelo modelo agrometeorológico espectral para as áreas de cultivo de soja da porção norte do RS na safra 2018.....	98
Figura 24	Mapa de produtividade obtido pelo modelo	

	agrometeorológico para a porção sul do RS na safra 2016.	101
Figura 25	Mapa de produtividade obtido pelo modelo agrometeorológico para a porção sul do RS na safra 2017.	101
Figura 26	Mapa de produtividade obtido pelo modelo agrometeorológico para a porção sul do RS na safra 2018.	102
Figura 27	Índice de penalização acumulado para a porção norte do RS na safra 2016.....	104
Figura 28	Índice de penalização acumulado para a porção norte do RS na safra 2017.....	104
Figura 29	Índice de penalização acumulado para a porção norte do RS na safra 2018.....	105
Figura 30	Índice de penalização acumulado para a porção sul do RS na safra 2016.....	105
Figura 31	Índice de penalização acumulado para a porção sul do RS na safra 2017.....	106
Figura 32	Índice de penalização acumulado para a porção sul do RS na safra 2018.....	106

Lista de Tabelas

Tabela 1	Classificação da resolução espacial de um sensor a bordo de um satélite.....	41
Tabela 2	Microrregiões do IBGE utilizadas na análise do modelo e divididas entre as porções norte e sul do RS.....	58
Tabela 3	Fator de resposta à produtividade (ky), para a cultura da soja, utilizados no modelo de produtividade em cada quinzena.....	67
Tabela 4	Radiação extraterrestre- Ra (mm dia ⁻¹) e fotoperíodo- N (hora dia ⁻¹) para a latitude 30° S.....	69
Tabela 5	Coeficiente de cultura (kc) para a cultura da soja utilizados no modelo de produtividade em cada quinzena.	70
Tabela 6	Capacidade de retenção de água no solo (CAD) para as diferentes Classes de Solo.....	71
Tabela 7	Índices de Área Foliar (IAF) estimados para a cultura da soja, utilizados no modelo de produtividade.....	71
Tabela 8	Valores de taxa de produção de matéria seca da cultura em função da temperatura (yc) e taxa bruta de produção de matéria seca de uma cultura padrão para um dia completamente nublado (yo).....	74
Tabela 9	Radiação de onda curta.....	74
Tabela 10	Comparação entre a área de soja obtida através metodologia CEI e a disponibilizada pelo IBGE, para a safra 2015, nas microrregiões da porção norte do RS.....	79
Tabela 11	Acurácia dos dados obtidos pelo sistema de satélites GPM em relação aos observados pela estação meteorológica de Pelotas, sendo obtidos no ano de 2016 para os dados <i>Early</i> e <i>Late</i> e 2015 para o <i>Final</i>	81
Tabela 12	Análise de acurácia dos dados AIRS de aquisição noturna, em comparação aos dados observados por estações meteorológicas convencionais.....	83
Tabela 13	Teste de normalidade de Shapiro-Wilk para os dados de produtividade do IBGE, modelo agrometeorológico e modelo agrometeorológico espectral, para as safras de	

	2016, 2017 e 2018.....	86
Tabela 14	Teste de Kolmogorov-Smirnov entre os dados de produtividade modelados e do IBGE.....	89
Tabela 15	Produtividade estimada pelos modelos agrometeorológico e agrometeorológico espectral (kg ha ⁻¹) para a porção norte do RS, e disponibilizada pelo IBGE nas safras de 2016, 2017 e 2018.....	90
Tabela 16	Diferença entre a produtividade estimada pelos modelos agrometeorológico e agrometeorológico espectral (kg ha ⁻¹) para a porção norte do RS e a informada pelo IBGE, nas safras de 2016, 2017 e 2018.....	91
Tabela 17	Produtividade estimada pelo modelo agrometeorológico para a porção sul do RS e disponibilizada pelo IBGE nas safras de 2016, 2017 e 2018.....	93
Tabela 18	Diferença entre a produtividade estimada pelo modelo agrometeorológico para a porção sul do RS e a informada pelo IBGE, nas safras de 2016, 2017 e 2018...	94
Tabela 19	Média e desvio padrão para o Modelo agrometeorológico no estado do RS e dados do IBGE, nas safras de 2016, 2017 e 2018.....	95

Lista de abreviaturas

AIRS - *Atmospheric Infrared Sounder*

AVHRR - *Advanced Very High Resolution Radiometer*

CAD - Capacidade de água do solo

CEI - *Crop Enhancement Index*

CERES - Sensor de energia radiante da superfície terrestre e das nuvens

DPR - *Dual-frequency precipitation radar*

ea - Pressão atual de vapor

es - Pressão de saturação do vapor

ET₀ - Evapotranspiração de referência

ET_c - Evapotranspiração de cultura

ET_m - Evapotranspiração máxima

ETM+ - *Enhanced Thematic Mapper Plus*

ETP - Evapotranspiração potencial

ET_r - Evapotranspiração real

EVI - *Enhanced Vegetation Index*

FOV - *Field Of View*

Fpa - Fator de produtividade agrícola

GMI - *GPM Microwave Imager*

GMR - Grupos de Maturação Relativa

GIFOV - *Ground instantaneous field of view*

GPM - *Global Precipitation Measurement*

IAF - Índice de Área Folhar

IBGE - Instituto Brasileiro de Geografia e Estatística

IFOV - *Instantaneous Field Of View*

INMET - Instituto Nacional de Meteorologia

IP - Índice de Penalização

IR - Infravermelho termal

IV - Índice de Vegetação

ISNA - Índice de Satisfação das Necessidades de Água

JAXA - *Japan Aerospace Exploration Agency*

K_c - Coeficiente de cultura

ky - Fator de resposta à produtividade

LIS - Sensor imageamento de relâmpagos

LST - *Land Surface Temperature*

MA - Modelo Agrometeorológico

MAPA - Ministério da Agricultura, Pecuária e Abastecimento

MDIC - Ministério da Indústria, Comércio Exterior e Serviços

ME - Modelo Agrometeorológico Espectral

mm - Milímetros

MODIS - *Moderate Resolution Imaging Spectroradiometer*

NAFTA - Acordo de livre comércio entre as Américas

NASA - *National Aeronautics and Space Administration*

NDVI - *Normalized Difference Vegetation Index*

NIR - Infravermelho próximo

NOAA - *National Oceanic and Atmospheric Administration*

P - Precipitação

PM - Produtividade Máxima

PMW - Microondas passivas

PR - Produtividade Real

Proagro - Programa de Garantia da Atividade Agropecuária

OLI - *Operational Land Imager*

REM - Radiação eletromagnética

RMS - Raiz do Erro Médio Quadrático

SWIR - *Short Wave Infrared*

TIROS - *Television InfraRed Observational Satellite*

TM - *Thematic Mapper*

TMI - Imageador de microondas

TMPA - *Multi-satellite Precipitation Analysis*

TRMM - *Tropical Rainfall Measuring Mission*

UR - Umidade relativa do ar

USDA - *United States Department of Agriculture*

VRS - Radiômetro no visível e no infravermelho

Sumário

1.	Introdução.....	21
2.	Hipótese.....	23
3.	Objetivos.....	23
3.1.	Objetivo geral	23
3.2.	Objetivos específicos.....	23
4.	Revisão de literatura.....	24
4.1.	Panorama mundial, nacional e local do mercado da soja	24
4.2.	A cultura da soja e os fatores meteorológicos	29
4.3.	Clima	32
4.3.1.	Precipitação	32
4.3.2.	Temperatura	35
4.3.3.	Balanço hídrico.....	36
4.4.	Princípios de Sensoriamento Remoto	39
4.5.	Sensores meteorológicos a bordo de satélites	44
4.5.1.	Sensores na banda do Termal	44
4.5.2.	Sensores de precipitação	47
4.6.	Modelos de produtividade agrícola.....	51
5.	Metodologia.....	56
5.1.	Processamento do Modelo.....	56
5.2.	Área em estudo	56
5.3.	Mapeamento da cultura da soja na porção norte do RS	58
5.4.	Dados meteorológicos obtidos por satélite.....	59
5.4.1.	Acurácia dos sensores meteorológicos adquiridos por satélite	62
5.5.	Dados meteorológicos obtidos por estações convencionais	65
5.6.	Resolução temporal do modelo.....	65
5.7.	Resolução espacial do modelo.....	66
5.8.	Modelagem da produtividade	66
5.8.1.	Componente meteorológico do modelo.....	67
5.8.2.	Componente espectral do modelo.....	74
5.9.	Cálculo da produtividade média	75
5.10.	Monitoramento espaço-temporal por meio do Índice de Penalização acumulado.....	76
5.11.	Parametrização e validação do modelo	77
6.	Resultados e discussões.....	77
6.1.	Mapa de cultivo da soja para a porção norte do RS.....	77

6.2. Acurácia dos dados meteorológicos obtidos por satélites	80
6.2.1. Acurácia dos dados de precipitação GPM.....	80
6.2.2. Acurácia dos dados AIRS de Umidade Relativa do ar.....	81
6.2.3. Estimativa e acurácia da temperatura do ar através do sensor MODIS.....	83
6.3. Validação do modelo de produtividade.....	85
6.4. Estimativa de produtividade pelos modelos agrometeorológico e agrometeorológico espectral.....	89
6.5. Monitoramento espacial e temporal por meio do Índice de Penalização.. ..	103
7. Conclusões.....	108
Referências.....	110
Apêndices.....	120

1. Introdução

A soja é uma das culturas agrícolas mais importantes para o Brasil, segundo a Companhia Nacional de Abastecimento (CONAB, 2020), na safra de 1990/91 o Brasil possuía uma área de cultivo de aproximadamente 9,74 milhões de ha. Já na safra 2019/20 alcançou 36,9 milhões de ha, com uma produção de 124,8 milhões de toneladas de grãos. Somente no estado do Rio Grande do Sul (RS), a cultura ocupou aproximadamente 5,9 milhões de hectares na safra 2019/20, com uma produção de mais de 11 milhões de toneladas. Na safra 1990/91, a cultura ocupava uma área de 3,26 milhões de ha, com produção de 2,35 milhões de toneladas de grãos, ou seja, com esses dados é possível notar a grande expansão da soja no Brasil e, ainda que em menor proporção, no RS.

Tradicionalmente, a porção norte do RS é a principal produtora do grão. Entretanto, nos últimos anos observou-se importante incremento do seu cultivo em regiões da Metade Sul, possivelmente em função do seu preço de comercialização. Pois analisando o histórico das cotações da saca de 60 kg de soja no RS, percebe-se que em março de 2005 a saca era vendida a R\$ 30,60 e em março de 2008 chegou a R\$ 45,08. No mesmo período em 2020 a soja alcançou R\$ 83,70, sendo que o seu maior preço histórico foi em outubro de 2020, chegando a R\$ 147,50 (AGROLINK, 2020).

A forte expansão da soja no RS gera uma demanda por informações a respeito da produção, produtividade e área plantada pela cultura, tornando-se muito importante a obtenção de dados precisos e atualizados. De acordo com Krüger et al. (2007), esses dados são úteis ao planejamento das atividades agrícolas, especialmente com relação à armazenagem, ao transporte e a comercialização de grãos, incluindo planejamento de importações e exportações.

Para identificar os fatores limitantes ao máximo potencial de produtividade da soja no Brasil e auxiliar na tomada de decisão e no manejo da cultura, Sentelhas et al. (2015) utilizaram um modelo de produtividade para verificar a diferença entre a produtividade potencial (quando atendida as necessidades hídricas da cultura) e a produtividade real, assim como a diferença entre a produtividade real e a média da região, sendo que, de

acordo com os autores, essas diferenças tem como causa o déficit hídrico e falhas de manejo, respectivamente. Os mesmos autores comentam que a produção de soja no Brasil pode ser aumentada racionalmente sem expansão das áreas de cultivo, pois existe uma enorme oportunidade para reduzir as lacunas entre a produtividade potencial e a real, aumentando a produtividade através da adoção de estratégias de manejo e irrigação, reduzindo as diferenças a um máximo de 10% da produtividade potencial, atendendo as futuras demandas de alimento.

Pode-se constatar que o uso de modelos matemáticos que relacionam as variáveis meteorológicas à produtividade das culturas agrícolas apresenta certa precisão em suas estimativas. Araujo et al. (2011), utilizando sete diferentes modelos de estimativa de produtividade para 11 safras de soja, constataram que o modelo de Stewart et al. (1976), proposto por Doorenbos e Kassam (1979), apresentou coeficiente de determinação de aproximadamente 0,77, sendo esse um dos melhores modelos para a região do Paraná. Melo et al. (2003), utilizando um modelo agrometeorológico-espectral para a estimativa de produtividade da soja no estado do RS, observaram que 90% das frequências de ocorrência dos desvios entre as produtividades estimadas e observadas encontraram-se abaixo de 300 kg ha⁻¹.

Os modelos de estimativa de produtividade tiveram grande importância para o zoneamento de culturas no Brasil, pois permitiram a identificação dos períodos de semeadura e regiões mais propícias ao desenvolvimento das culturas, onde há menor probabilidade de danos causados por déficit hídrico. O zoneamento agrícola para a cultura da soja no RS elaborado por Cunha et al. (2001) demonstra que, para as cultivares de ciclo precoce, médio e tardio, a melhor época de semeadura, com ocorrência de menores perdas por déficit hídrico, é a de dezembro, para todas as regiões do estado. Identificando também, que há um gradiente que indica o aumento na magnitude das perdas de produtividade, que se desloca do sentido nordeste para sudoeste do estado, além de identificar que na Metade Sul essas perdas são sempre maiores.

Os modelos de produtividade são baseados principalmente na resposta das culturas aos fatores meteorológicos. Entretanto, sua utilização sobre

grandes regiões é dificultada pela pouca disponibilidade de dados meteorológicos, que se deve à distribuição esparsa das estações de medição para boa parte do território nacional, visto que o Instituto Nacional de Meteorologia (INMET) conta com apenas 18 estações meteorológicas convencionais e 43 estações meteorológicas automáticas no RS.

Segundo Camargo et al. (2005), 80 e 12 km de distância entre estações meteorológicas são os limites máximos admitidos para explicar mais de 90% da variação espacial, respectivamente para dados de temperatura máxima e pluviosidade, no período de primavera e verão. Desta forma, o uso de dados provenientes de sensores a bordo de satélites pode tornar-se uma alternativa para uma ampla cobertura, tanto espacial quanto temporal desses dados. Nesse sentido, o presente estudo explora o uso de satélites para a obtenção de informações meteorológicas e espectrais, pois estes possuem uma cobertura espacial uniforme, o que não ocorre em se tratando da atual distribuição das estações meteorológicas no RS.

2. Hipótese

A hipótese central deste trabalho é de que é possível monitorar e estimar a produtividade agrícola da soja para o RS a partir de um modelo, utilizando dados espectrais e meteorológicos majoritariamente obtidos a partir de sensores a bordo de satélites orbitais.

3. Objetivos

3.1. Objetivo geral

Testar um modelo de monitoramento e estimativa da produtividade agrícola para a cultura da soja para o RS, utilizando como informações de entrada dados espectrais e informações meteorológicas obtidas majoritariamente através de sensores a bordo de satélites orbitais.

3.2. Objetivos específicos

- a) Mapear as áreas cultivadas com soja, para a porção norte do RS, a partir de imagens MODIS e da metodologia CEI (*Crop Enhancement Index*; Rizzi

et al., 2009), visando aplicar o modelo de estimativa de produtividade unicamente sobre áreas de soja;

- b) Estimar a acurácia dos dados de precipitação obtidos pelo sistema de satélites GPM (*Global Precipitation Measurement*), em relação aos dados observados por uma estação meteorológica convencional;
- c) Estimar a acurácia dos dados de umidade relativa do ar obtidos pelo sensor AIRS, a bordo do satélite Aqua, em relação aos dados observados por estações meteorológicas convencionais;
- d) Estimar a temperatura do ar a dois metros de altura a partir de dados LST (*Land Surface Temperature*) obtidos pelo sensor MODIS, a bordo dos satélites Terra e Aqua;
- e) Estimar a acurácia dos dados citados no item *d* em relação aos observados por estações meteorológicas convencionais;
- f) Aplicar o modelo agrometeorológico da FAO (Organização das Nações Unidas para Alimentação e Agricultura) (Doorenbos & Kassam, 1979) para o RS, para as safras de 2016 a 2018;
- g) Substituir os valores tabelados de Índice de Área Foliar (IAF) utilizados no item *f* por um componente espectral oriundo de imagens do sensor MODIS, para a porção norte do RS;
- h) Monitorar espacial e temporalmente os indicadores de penalização acumulada da produtividade da soja;
- i) Estimar a produtividade média da soja por microrregião para as safras estudadas e compará-la aos dados oficiais.

4. Revisão de literatura

4.1. Panorama mundial, nacional e local do mercado da soja

Com teor de proteína de aproximadamente 40%, a soja se tornou um produto de grande valor comercial no mercado mundial. Isso se deve principalmente, ao mercado de soja ser influenciado e totalmente dependente do mercado de carnes, pois o seu principal produto derivado, o farelo

proteico, é direcionado principalmente para a nutrição animal, sobretudo aves, suínos e bovinos (Hirakuri & Lazzarotto, 2014).

Nesse contexto, a China se destaca como grande produtor de carnes e, por consequência, um grande consumidor de proteína derivada da soja. Embora a China se destaque por ser o quarto maior produtor de soja do mundo, não apresenta produção suficiente dessa fonte de proteína vegetal em seu território, necessitando importar grande parte dos grãos que consome. Até dezembro de 2020 a China importou 98,5 milhões de toneladas desse grão (USDA, 2020a), sendo que, 60,6 milhões de toneladas foram de origem Brasileira, o que corresponde a 73% das exportações da soja brasileira (MDIC, 2020).

Outros grandes mercados importadores dessa commodity são a União Europeia, o Sudeste Asiático e o México, que corresponderam a 15,66, 9,32 e 6 Mt até dezembro de 2020, respectivamente (USDA, 2020a). Destaques também podem ser dados aos países que compram soja do Brasil, como Holanda (3,24 Mt), Espanha (2,74 Mt), Tailândia (2,65 Mt), Turquia (2,07 Mt), Paquistão (1,24 Mt) e Taiwan (1,00 Mt), o que corresponde respectivamente, a 3,9%, 3,3%, 3,2%, 2,5%, 1,5% e 1,2%, das exportações Brasileiras de soja (MDIC, 2020).

Com relação aos países que importam soja dos EUA, a China ainda se destaca em primeiro lugar. As grandes demandas de proteína vegetal fazem com que o país asiático ainda seja o principal importador dos EUA, com transações de 7,989 bilhões de dólares no ano de 2019 (USDA, 2020b). O bloco econômico da União Europeia é responsável por transações de 1,953 bilhões de dólares, embora com queda de 37% em relação ao ano de 2018, ainda é o segundo maior importador da soja dos EUA (USDA, 2020b). Já o México, devido ao acordo de livre comércio entre as Américas (NAFTA), foi o terceiro maior importador de soja do mercado norte americano no ano de 2019, sendo responsável por transações de 1,867 bilhões de dólares (USDA, 2020b).

A partir dos dados apresentados é possível notar a grande demanda mundial por essa commodity. Em decorrência disso, países com grande potencial climático e com disponibilidade de terras agricultáveis se

destacaram como os maiores produtores de soja do mundo. Segundo o relatório de dezembro do USDA (2020a), na safra de 2019/20, os países que contaram com as maiores produções de soja foram o Brasil (126 Mt), EUA (96,67 Mt), Argentina (49 Mt), China (18,10 Mt) e o Paraguai (9,90 Mt).

Em se tratando de Brasil e EUA, principais produtores mundiais de soja, por estarem localizados em hemisférios opostos, estes países apresentam calendários agrícolas distintos, o que também reflete nos diferentes períodos de maior oferta do produto no mercado. No EUA, de forma geral, o plantio é concluído em meados de maio, com a maturação ocorrendo ao final de setembro e a colheita se estendendo do início até o final de outubro (Li et al., 2007). Neste contexto, o Brasil se beneficia da entressafra norte-americana, principalmente devido à colheita nos principais estados produtores do Brasil se dar entre janeiro e abril (CONAB, 2019), momento em que os estoques americanos estão em baixa. A Figura 1 demonstra a evolução e a periodicidade das exportações da soja Brasileira.




Figura 1: Evolução e periodicidade das exportações de soja no Brasil (MDIC, 2020).

A partir da Figura 1, também é possível notar o grande acréscimo nos totais exportados pelo Brasil, de modo que, de janeiro a dezembro de 2010 o Brasil havia exportado 29 Mt e o mesmo período de 2020 contabiliza 83 Mt (MDIC, 2020). Isso corresponde a um acréscimo de 186% em 11 anos, embora tenha ocorrido uma retração nas exportações no ano de 2019. As exportações de janeiro a dezembro de 2020 somaram 28,6 bilhões de

dólares, somente abaixo do ano de 2018, que contabilizou 33,1 bilhões de dólares no mesmo período.

Com relação à produção Brasileira de soja para a safra de 2020, de acordo com dados da CONAB (2020), a área total cultivada é de 37,88 milhões de hectares (Mha), o que corresponde por 59,3% de toda a área ocupada por culturas de verão. Os principais estados brasileiros em área plantada de soja são o Mato Grosso (10 Mha), RS (5,9 Mha) e Paraná (5,5 Mha) (CONAB, 2020). Na Figura 2 é demonstrado o percentual da área de soja cultivada por microrregião em relação a área total das microrregiões do Brasil, segundo o IBGE (IBGE, 2020).

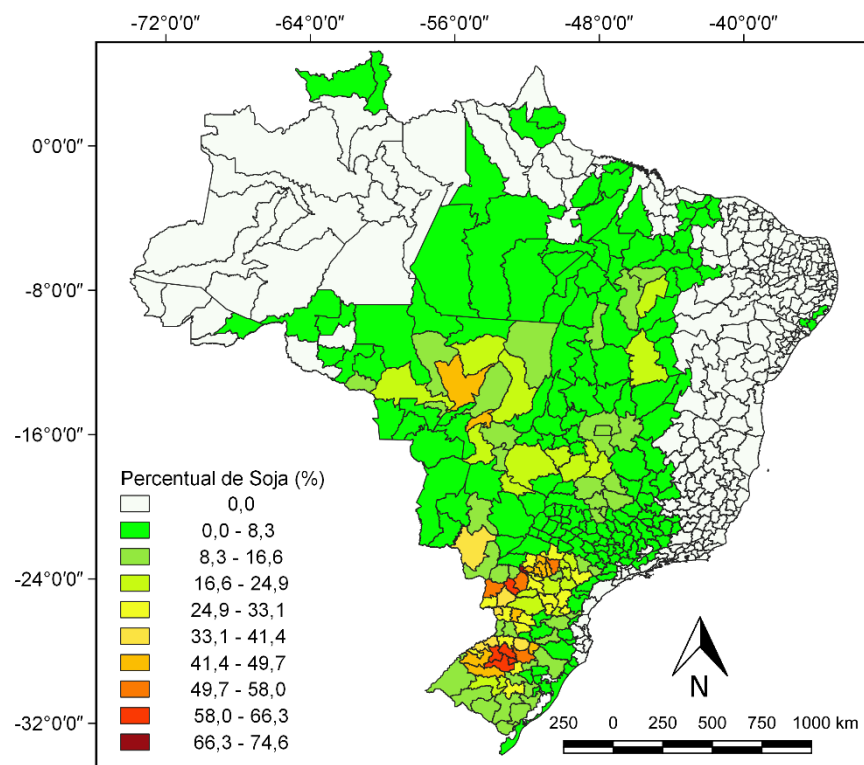


Figura 2: Distribuição do percentual de área cultivada com soja por microrregião brasileira em relação à área total da microrregião para a safra de 2020 (IBGE, 2020).

A Figura 3 apresenta o histórico de área cultivada no Brasil com base nos dados do IBGE (2020). É possível verificar que no ano de 1988 o Brasil contava com 10,6 Mha e que essa área expandiu 239%, chegando a 35,9 Mha em 2019. Embora, tenha ocorrido uma retração da área entre as safras de 2005 e 2007, o crescimento foi retomado a partir de 2008.




Figura 3: Área cultivada com soja no Brasil (IBGE, 2020).

A mesma tendência apresentada em nível nacional é observada no RS (Figura 4), de forma que, no ano de 1988 a área cultivada era de 3,4 Mha, expandindo em 68,4% até o ano de 2019, quando alcançou uma área de 5,8 Mha (IBGE, 2020). É possível observar que a área se manteve praticamente estável entre as safras de 2006 a 2009, retomando o crescimento a partir de 2010.




Figura 4: Área cultivada com soja no RS (IBGE, 2020).

Uma peculiaridade do RS é a presença de duas regiões distintas, tanto em suas características climáticas, quanto nas culturas agrícolas tradicionalmente cultivadas. Nas porções norte e nordeste do estado, ocupadas em grande parte pelo Bioma Mata Atlântica, apresentam-se maiores acumulados de precipitação e solos mais desenvolvidos. Enquanto

que nas porções sul e oeste, caracterizadas pelo Bioma Pampa, encontram-se volumes menores de precipitação e de modo geral, solos mais rasos.

A cultura da soja sempre foi tradicionalmente cultivada nas porções norte e noroeste do estado, sendo que as demais regiões não apresentavam uma área expressiva desta cultura. Já a porção sul se caracterizava pela pecuária extensiva sobre o campo nativo e pelo cultivo do arroz irrigado nos solos hidromórficos.

Este cenário apresentou mudanças expressivas nos últimos anos, principalmente devido à valorização do preço de comercialização da soja, que incentivou os produtores rurais a cultivá-la e até mesmo substituir as atividades da pecuária e do cultivo de arroz. Avaliando imagens NDVI (*Normalized Difference Vegetation Index*) do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) para o RS, Silveira et al. (2017) observaram que as áreas de cultivo de verão no bioma Mata Atlântica (porção norte) aumentaram de 3,04 Mha em 2000/01 para 3,41 Mha em 2014/15, um incremento de 12,2% em 15 anos, já para o bioma Pampa (porções sul e oeste), as áreas de cultivo de verão foram de 2,69 Mha em 2000/01 para 4,22 Mha em 2014/15, 57,0% de incremento no mesmo período.

4.2.A cultura da soja e os fatores meteorológicos

Devido a soja ser uma planta de dias curtos (ou noites longas), a indução do seu florescimento ocorre a partir do momento em que o fotoperíodo diminui, por ocasião do final da primavera e início do verão. O Brasil apresenta latitudes que variam de 5°16'19" norte (estado de Roraima), até 33°44'52" sul (RS). Isto implica em grandes variações no fotoperíodo ao longo do seu território. Em regiões próximas à Linha do Equador, a duração do dia é em torno de 12 horas ao longo de todo o ano. Por outro lado, no extremo sul do Brasil, o fotoperíodo varia de 14 horas em dezembro até 10 horas em junho.

Esta grande variabilidade no fotoperíodo ao longo do território nacional, somado ao fato da soja possuir características de dias curtos, incentivou o desenvolvimento de várias cultivares, a fim de adaptar a cultura às diversas

condições presentes no Brasil. Levando em consideração que o número de dias até o florescimento pode variar dependendo da latitude onde uma mesma cultivar é semeada, classificar a mesma como precoce, média ou tardia, somente torna-se válido quando se trata de uma mesma região.

No entanto, para comparar cultivares em diversas regiões, pode-se utilizar a classificação por Grupos de Maturação Relativa (GMR). A classificação possui 13 grupos (000, 00, 0, I, II, III, IV, V, VI, VII, VIII, IX, X), sendo que para o Brasil os grupos recomendados variam de V a VII, para as regiões mais ao sul, até VIII a IX para as regiões mais próximas ao Equador (ALLIPRANDINI et al., 2009).

Com relação às cultivares recomendadas para o RS, as do GMR < VI apresentam ciclo de desenvolvimento precoce e semiprecoce, enquanto as do GMR VI e VII apresentam ciclos médios e tardios (MAPA, 2020). Isto significa que as cultivares mais tardias apresentam maior número de dias até o florescimento, quando semeadas na época recomendada, em comparação às precoces.

As datas de semeadura da soja recomendadas para o RS podem variar de 21 de setembro a 31 de dezembro, dependendo do GMR e do tipo de solo (MAPA, 2020). De acordo com o zoneamento agrícola para a cultura da soja no estado do RS, elaborado por Cunha et al. (2001), para as cultivares de ciclo precoce, médio e tardio, a melhor época de semeadura, com ocorrência das menores perdas por déficit hídrico, é a de 15 de dezembro, para todas as regiões do estado.

Estas recomendações corroboram com Matzenauer et al. (2003) que avaliaram o consumo relativo de água para a cultura da soja em dez municípios do RS ao longo de 26 safras, concluindo que a época de semeadura de maior risco por deficiência hídrica para a cultura é a de início de outubro, que em todos os locais apresentou o mais baixo índice de satisfação das necessidades de água (ET_r/ET_m), seguindo-se da semeadura de novembro, sendo a época de dezembro a de menor risco para a cultura.

Theisen et al. (2009) ressalta que, em solos hidromórficos, as melhores produções de soja são obtidas com semeaduras entre 21 de outubro e 10 de

dezembro. Contudo, as cultivares mais precoces geralmente são as menos tolerantes ao encharcamento e as mais tardias podem finalizar o ciclo no final de maio ou mesmo em junho, época caracterizada pela abundância de chuvas, o que dificulta a colheita e prejudica a qualidade da produção.

As cultivares de soja também podem ser classificadas quanto ao seu hábito de crescimento, podendo ser determinado ou indeterminado. As cultivares de hábito de crescimento determinado possuem caules terminados por racemos florais, sendo que após o início da floração as plantas crescem pouco e não ramificam, o florescimento é praticamente simultâneo em toda a extensão da planta, as vagens e os grãos do topo e da base da planta se desenvolvem praticamente ao mesmo tempo (Neumaier et al., 2020).

Já as cultivares de hábito de crescimento indeterminado não apresentam racemos florais terminais no caule, mas sim pequenos racemos axilares. De modo que, a produção de nós no caule principal e o crescimento continuam após o início do florescimento, podendo dobrar a estatura da planta até a maturação. O florescimento e o desenvolvimento das vagens e dos grãos ocorrem de baixo para cima na planta, podendo existir, ao mesmo tempo, vagens bem desenvolvidas na base e flores no topo da planta. A diferença de tempo entre o surgimento das vagens basais e o das vagens apicais é compensada pela maior taxa de crescimento dos grãos das vagens apicais, permitindo que todas as vagens da planta cheguem à maturação aproximadamente ao mesmo tempo (Neumaier et al., 2020).

Nos últimos anos, a pesquisa de cultivares de soja com crescimento indeterminado aumentou significativamente no Brasil, isto é devido à necessidade de datas de semeadura anteriores para permitir a semeadura de milho como a segunda safra e a redução do dano causado pela ferrugem asiática, uma vez que as plantas com hábito de crescimento indeterminado têm um dossel mais aberto, o que permite a aplicação de pesticidas mais facilmente chegar ao terço inferior da planta (Machado Júnior et al., 2017). Segundo Zanon et al. (2015) o maior período de sobreposição entre a fase vegetativa e reprodutiva nas cultivares de tipo indeterminado pode conferir a elas maior capacidade de se adaptarem a diferentes épocas de semeadura, apresentando assim, maior capacidade de se recuperar de períodos curtos de

estresse, como a ausência de chuvas, excesso hídrico no solo ou temperaturas elevadas.

4.3. Clima

4.3.1. Precipitação

Para atender o ciclo completo da cultura, Neumaier et al. (2020) afirmam que o volume total de água varia entre 450 mm a 800 mm, sendo que a necessidade de água é maior na medida em que ocorre o desenvolvimento da planta, atingindo o máximo durante a floração-enchimento de grãos e decrescendo após esse período. Para atender as necessidades da cultura da soja durante a fase crítica (R1-R6), o volume de água ideal situa-se entre 120 a 300 mm, bem distribuídos ao longo deste período, que se encontra entre 30 a 60 dias a partir do início da floração (Farias et al., 2007). Comparativamente à outras culturas produtoras de grãos, como o milho, por exemplo, a soja é relativamente tolerante ao déficit hídrico na sua fase vegetativa, mas é muito sensível ao estresse durante a formação dos componentes da produtividade, ou seja, florescimento e enchimento de grãos (Torrion et al., 2011).

Pode-se dizer que o principal limitante para maximizar a produtividade da cultura da soja no RS é o fator hídrico. Para Matzenauer et al. (2002), além das características de manejo, conservação, fertilidade do solo e temperaturas extremas, a principal causa das baixas produtividades, e principalmente da grande variabilidade observada na produtividade da soja para o RS, é a variação na disponibilidade hídrica, em função da baixa quantidade e/ou má distribuição das chuvas. Sentelhas et al. (2015) observaram que no RS, em comparação aos demais estados produtores do Brasil, encontraram-se as maiores diferenças entre a produtividade potencial e a produtividade real, sendo estas uma consequência do déficit hídrico.

Em dezembro e janeiro, grande parte da metade sul do RS apresenta probabilidade de até 40% da precipitação ser maior ou igual a Evapotranspiração potencial (ETP), sendo que em grande parte do Litoral Sul e partes da Campanha essa probabilidade baixa para 30%. Em fevereiro, ainda toda a metade sul do estado apresenta probabilidade abaixo de 50% da

precipitação ser maior ou igual a ETP, sendo que no oeste do estado (Baixo Vale do Uruguai e da Campanha) essa probabilidade cai para 40%. Somente a região do Planalto (a única contida majoritariamente no bioma Mata Atlântica) apresenta probabilidades de até 60% em dezembro e até 70% em janeiro e fevereiro (ÁVILA et al. 1996).

A Figura 5 apresentada por Matzenauer et al. (2002) demonstra a normal climatológica da precipitação (1931 a 1960) para o RS. Nesta, observa-se que na metade norte chove mais do que na metade sul, em todos os meses do ano, sendo que outubro é o mês de maior precipitação pluvial e novembro o de menor, em ambas as regiões. No entanto, observa-se uma tendência de haver maiores diferenças entre a metade norte e a metade sul durante as estações de primavera e verão.




Figura 5: Precipitação pluvial (mm) mensal normal (1931-60) para as Metades Norte e Sul (latitude maior ou menor do que 30°S, respectivamente) do RS. (Fonte: Matzenauer et al., 2002).

Ao correlacionar os valores de precipitação ocorridos para as safras de 1975/76 a 1994/95, com a produtividade média da metade norte do RS durante o mesmo período, Berlato & Fontana (1999) concluíram que em média para a metade norte do RS, para cada dez safras de soja, três foram prejudicadas por estiagem.

O fenômeno El Niño - Oscilação Sul (ENOS), influencia fortemente as precipitações no RS, que por consequência, também afeta as produtividades agrícolas das safras de primavera-verão. O El Niño (fase quente do fenômeno) é um aquecimento anômalo das águas do oceano Pacífico na costa Equatorial da América do Sul. Normalmente, a corrente oceânica do Pacífico flui das águas mais frias da América do Sul em direção às águas mais quentes da costa da Oceania (PEREIRA et al., 2007). Porém, devido à diminuição na intensidade dos ventos alísios, a corrente oceânica (que segue a direção dos ventos) também se enfraquece e as águas da América do Sul se aquecem, causando um equilíbrio térmico da célula de circulação atmosférica entre as duas costas continentais (OLIVEIRA, 2001). Por consequência, há uma elevação da temperatura e do nível do mar na costa da América do Sul. Esse fenômeno tem impacto global, podendo causar chuvas e secas dependendo da região. No RS, o El Niño provoca elevação do volume de chuvas e da temperatura do ar (PEREIRA et al., 2007).

Já a fase fria do fenômeno ENOS, denominada La Niña, é causada pela intensificação dos ventos alísios que sopram em direção à Oceania, represando as massas de águas quentes e úmidas próximas a esse continente (OLIVEIRA, 2001). Na América do Sul, há um aumento da ressurgência de águas frias na costa equatorial e diminuição da temperatura do oceano. Pode apresentar, embora nem sempre, consequências opostas ao El Niño, sendo que no RS, muitas vezes causa eventos de seca e precipitações abaixo da média do estado (OLIVEIRA, 2001).

O ENOS é cíclico e de difícil previsibilidade, de modo que eventos de El Niño e La Niña têm uma tendência a se alternar entre três e sete anos (OLIVEIRA, 2001). Em um estudo realizado entre 1961 a 2010 no RS, Matzenauer et al. (2017) observaram a ocorrência de eventos ENOS em 50,8% dos meses, sendo 26,8% de El Niño e 24% de La Niña. Além disso, do total de meses com evento 66% ocorreram entre os meses de outubro a janeiro.

Como visto, as porções norte e sul do RS apresentam consideráveis diferenças de precipitação, que refletem em diferenças de produtividade da soja entre estas. Em anos de El Niño, o aumento das precipitações em todo

estado pode gerar grandes discrepâncias de produtividade nas porções norte e sul. Berlato & Fontana (1999) comentam que, em anos de ocorrência de El Niño, a produtividade de soja tende a aumentar na porção norte do estado. Em contrapartida, para Theisen et al. (2009), o cultivo da soja em terras baixas em safras caracterizadas pelo El Niño e com previsão de chuvas abundantes, o excesso de água diminui a viabilidade das sementes, prejudicando o desenvolvimento das plantas de soja e ocasionando o aparecimento de doenças com maior intensidade que nos anos mais secos.

Quando da ocorrência de La Niña, a precipitação pluvial na metade norte do RS fica acima de 1.400 mm em praticamente toda a área, enquanto que na metade sul, a precipitação fica abaixo de 1.400 mm anuais, chegando, no extremo sul do estado, a valores inferiores a 1.200 mm (Matzenauer et al., 2017). No entanto, os mesmos autores destacam que em muitas regiões ecoclimáticas do RS, principalmente as de maior produção de grãos, as menores quantidades de precipitação pluvial durante os meses de verão, ocorrem em eventos Neutros e não em eventos La Niña.

4.3.2. Temperatura

Com relação à temperatura, a soja se adapta a temperaturas que oscilam entre 20 e 30 °C, sendo o ideal em torno de 30 °C, não recomendando-se semear a soja com temperaturas do solo abaixo de 20 °C, pois há um comprometimento da germinação e da emergência. Temperaturas do ar acima de 40 °C têm efeito adverso na taxa de crescimento, na floração e diminuem a capacidade de retenção de vagens (Farias et al., 2007). Avaliando a influência das temperaturas do dossel sobre a qualidade das sementes de soja, Khan et al. (2011) concluíram que, quando as temperaturas médias máximas do dossel estavam entre 31 e 37 °C, durante os estágios de plena floração e início da formação das sementes (R4 a R5), foram ocasionados efeitos negativos na massa seca das plântulas e na emergência de campo da soja.

Matzenauer et al. (2002) comentam que os períodos de deficiência hídrica, típicos do RS, são agravados pela maior demanda evaporativa do

verão, determinada por valores mais elevados de radiação solar global e de temperatura do ar. Isso é corroborado por Gusso et al. (2014), que utilizaram dados de temperatura média da superfície obtida pelo sensor MODIS/Aqua e de precipitação acumulada fornecidas pela FEPAGRO (Fundação Estadual de Pesquisa Agropecuária), durante o período de cultivo da soja no RS, comparando-os aos dados de produtividade obtidos pelo IBGE para as safras de 2003 a 2012. Os autores concluíram que as produtividades mais baixas nesse período, 695 e 1.601 kg ha⁻¹, ocorreram em 2005 e 2012, respectivamente, principalmente em função de temperaturas médias mais elevadas, em torno de 35 °C e precipitações acumuladas mais baixas durante a safra (460 a 500 mm).

4.3.3. Balanço hídrico

O balanço hídrico é a diferença entre as entradas de água no solo, por precipitação ou irrigação e as saídas, causadas principalmente por evapotranspiração, mas também por drenagem profunda e drenagem lateral (Thorntwaite & Mather, 1957). Outro fator determinante é a capacidade de água no solo (CAD), sendo caracterizada pela profundidade do solo, profundidade efetiva das raízes e classe textural do solo (do arenoso ao argiloso).

A evapotranspiração é formada por dois processos, sendo eles: a evaporação, que é a transferência de água do solo para a atmosfera e a transpiração, que é a transferência de água do solo através da planta para a atmosfera. Esses processos são controlados pela demanda atmosférica (radiação solar, temperatura, umidade relativa do ar e vento), potencial matricial de solo (força com que a água está retida na estrutura do solo) e pela planta, através da abertura estomática (Reichardt & Timm, 2012).

Em um solo sem cobertura vegetal, a evaporação é o único processo dominante de transferência de água do solo para a atmosfera. À medida que uma cultura agrícola se desenvolve e cobre o solo, a transpiração passa a ser o processo dominante. A evapotranspiração de uma cultura aumenta na

proporção em que aumenta o seu IAF, alcançando o ápice durante a floração e decaindo após a senescência.

A evaporação pode ser medida ou estimada, sendo que o método mais comum em estações meteorológicas convencionais no Brasil é o do tanque classe A. Este consiste em um tanque de água feito de chapa galvanizada, com volume padrão (1,21 m de diâmetro e 0,255 m de profundidade), a 0,15 m de altura acima do solo e instalado no centro uma área coberta por grama. Neste método, as perdas de água para a atmosfera são medidas diariamente e estão correlacionadas positivamente como a evapotranspiração de uma cultura, sem restrições hídricas e em pleno desenvolvimento.

Outro método muito utilizado é o de Penman-Monteith, descrito por Allen et al. (1998). Nesse método, a evapotranspiração de uma cultura padrão é estimada por uma equação que incorpora os principais fatores que influenciam nas perdas de água para a atmosfera (radiação líquida total, curva de saturação de vapor, temperatura do ar, déficit de pressão de vapor e velocidade do vento). A evapotranspiração pode ser caracterizada de distintas formas, dependendo de qual processo está sendo avaliado.

A ETP ou *Evapotranspiração de referência* (ET_0) é a perda de água para a atmosfera de uma área gramada (padrão), sem restrições hídricas e em crescimento ativo. Nessas condições, a evapotranspiração seria função apenas das condições atmosféricas, não considerando as limitações hídricas do solo ou limitações bióticas (pragas, doenças e plantas daninhas). Vários métodos de estimativa podem ser utilizados, dentre eles o método de Penman (1948), Thornthwaite (1948), Camargo (1962) e o método de Penman-Monteith, descrito por Allen et al. (1998), sendo este recomendado pela FAO.

A *Evapotranspiração de cultura* (ET_c) ou *Evapotranspiração máxima* (ET_m) é a perda de água para a atmosfera, por uma cultura agrícola, em crescimento ativo e sem restrições hídricas. Pode ser estimada a partir das evapotranspirações obtidas pelo tanque de classe A ou pelas equações de ET_0 . Esta estimativa é realizada através da multiplicação da evapotranspiração (Tanque de classe A ou ET_0) por um coeficiente de cultura (k_c).

O k_c pode ser obtido através da relação entre a ET_m medida experimentalmente e a ET_0 , ou seja, $ET_m/ET_0 = K_c$. Experimentalmente, a ET_m pode ser medida por um lisímetro de pesagem, que consiste em uma balança instalada sob uma massa conhecida de solo, onde é cultivada a cultura de interesse e cuja qual são medidas as entradas e saídas de água do sistema, sendo assim, a ET_m é resultante deste balanço hídrico. O valor de k_c varia com o estágio de desenvolvimento da cultura, entre diferentes espécies e entre cultivares, sendo, portanto, uma função do IAF e apresentando maior valor durante a floração da cultura.

Matzenauer et al. (2002) comentam que, dentre as culturas mesófitas (exigências climáticas intermediárias) que foram pesquisadas no RS (milho, soja, trigo, girassol, sorgo, feijão), a soja é a que apresenta os maiores valores de ET_m para todo o ciclo, podendo chegar a 823 mm, com média de $6,1 \text{ mm.dia}^{-1}$ (Berlato et al., 1986). Comparativamente aos cultivos do RS durante a primavera-verão, para o milho, foram encontrados valores de ET_m que variaram de 575 a 732 mm (média de $4,6 \text{ mm.dia}^{-1}$) (Bergamaschi et al., 2001). Já para o arroz irrigado, Magalhães Júnior et al. (2004) encontram valores que variaram de $6,7$ a $7,7 \text{ mm.dia}^{-1}$, com totais de 655,4 mm, em Uruguiana, a 801,6 mm, em Santa Vitória do Palmar.

Vale ressaltar que a ET_m , além de outros fatores, varia muito em função do IAF, sendo que durante a fase de floração, a soja pode atingir um IAF de 6,9 (Fontana et al. 1992), enquanto que para o milho, Bergamaschi et al. (2001) encontraram valores de IAF que variaram de 5 a 6 no ápice do desenvolvimento.

A *Evapotranspiração real* (ET_r) é caracterizada como a perda de água para a atmosfera, realizada por uma cultura, em qualquer fase do seu desenvolvimento, sobre condições vigentes de disponibilidade hídrica. A ET_r é calculada a partir do método do balanço hídrico sequencial da cultura (Thorntwait-Matter, 1955), tendo as precipitações, como entradas de água no sistema e a ET_m como as perdas, sendo que estas interações são reguladas pela CAD.

Partindo do pressuposto que a ET_r retrata o estado hídrico vigente de uma cultura e a ET_m representa o estado de melhor disponibilidade hídrica

desta cultura, ao se avaliar a Evapotranspiração relativa (E_{Tr}/E_{Tm}), é possível compreender a proporção do estresse hídrico atual, em função do estado ideal de abastecimento de água. Quando a E_{Tr} é igual a E_{Tm} , não há restrição no fornecimento hídrico. No entanto, se E_{Tr} é menor do que E_{Tm} , dependendo do estágio de desenvolvimento em que ocorrer, a restrição hídrica poderá prejudicar seriamente a produtividade final da cultura.

Para o zoneamento da cultura da soja no RS, Cunha et al. (2001) utilizaram os valores do Índice de Satisfação das Necessidades de Água (ISNA), que corresponde à relação E_{Tr}/E_{Tm} , para o subperíodo floração-enchimento de grãos, definindo-os em três classes, com frequência mínima de 80% de probabilidade de ocorrência (8 anos a cada 10), sendo elas: $E_{Tr}/E_{Tm} > 0,65$ (favorável), $0,65 > E_{Tr}/E_{Tm} > 0,55$ (intermediária) e $E_{Tr}/E_{Tm} < 0,55$ (desfavorável).

A fim de evitar a utilização do coeficiente de cultura, Fontana et al. (2001) utilizaram a relação E_{Tr}/E_{T0} , com o qual foram obtidos coeficientes de correlação (r) significativos, quando correlacionados à média da produtividade de soja para a região norte do RS e para a produtividade média do estado, sendo que os maiores coeficientes de correlação corresponderam aos meses de janeiro (0,68), fevereiro (0,58) e março (0,70).

Este resultado também é corroborado por Berlato et al. (1992), que obtiveram correlações significativas a 1% de probabilidade entre a produtividade de grão de soja e as variáveis Precipitação (P), P/E_{T0} e E_{Tr}/E_{T0} durante o período de floração. Sendo que o índice composto pela razão E_{Tr}/E_{T0} apresentou uma maior associação com a produtividade de grãos tanto para o período reprodutivo quanto para o vegetativo, explicando 89%, 86% e 85% da produtividade de grãos para os grupos de maturação precoce, médio e tardio, respectivamente (Berlato et al., 1992).

4.4.Princípios de Sensoriamento Remoto

O sensoriamento remoto se trata da obtenção de informações da superfície terrestre, oceânica e da atmosfera, a partir de sensores a bordo de plataformas orbitais, suborbitais e terrestres, de forma que não haja contado

direto entre o objeto estudado (alvo) e o sensor (Jensen, 2011). De maneira que a obtenção da informação do objeto dê-se pela interação entre este e a radiação eletromagnética (REM) originária do Sol (passiva) ou emitida pelo próprio sensor (ativa).

Segundo Jensen (2011), o sensoriamento remoto é realizado utilizando um instrumento, frequentemente chamado de sensor, que detecta e registra a REM proveniente de uma fonte e que se desloca à velocidade da luz (3×10^8 m s⁻¹). Dessa forma, a REM representa um canal de comunicação muito eficiente e em alta velocidade entre o sensor e o objeto remoto. Assim, mudanças na quantidade ou propriedade da REM detectadas pelo sensor são uma valiosa fonte de dados para interpretar importantes propriedades do objeto.

Dando maior enfoque aos sensores a bordo de plataformas orbitais (satélites), é possível melhor compreender a potencialidade de cada sensor, ao distingui-los a partir de suas características de resoluções: espacial, temporal, espectral e radiométrica.

A resolução espacial pode ser definida como a menor porção da superfície terrestre individualizada por um sensor. Esta resolução está relacionada à uma unidade chamada de IFOV (*Instantaneous Field Of View*-Campo de Visada Instantâneo), que corresponde a seção angular observada pelo sensor em um determinado momento, cuja REM contida no ângulo sólido dessa seção sensibiliza um detector do sensor. Assim, o IFOV é, juntamente com a altitude do satélite, responsável por determinar o tamanho do GIFOV (*Ground instantaneous field of view*), que é a área que essa seção angular corresponde, na superfície. Na Tabela 1, Belward & Skoien (2014) classificam os sensores com base em sua resolução espacial.

Tabela 1: Classificação da resolução espacial de um sensor a bordo de um satélite.

Resolução espacial	Classificação
0,5 – 4,9 m	Muito Alta
5,0 – 9,9 m	Alta
10,0 – 39,9 m	Média
40 – 249,9 m	Moderada
250 m–1,5 km	Baixa

Fonte: Belward & Skoien (2014).

Outra propriedade muito importante relacionada à resolução espacial é o FOV (*Field Of View*), pois determina a largura da faixa de imageamento de um sensor, ou *Swath width*. Essa unidade apresenta relação direta com a resolução temporal, pois determina o quanto da superfície terrestre será recoberta por um sensor em um determinado tempo e, conseqüentemente, também determina o tempo necessário para que o sensor imageie toda a superfície da Terra.

A resolução temporal diz respeito à frequência com que um sensor a bordo de um satélite obtém informações de uma mesma região. Esta resolução é dependente das características orbitais do satélite, como a sua altitude, velocidade e inclinação e principalmente a faixa de imageamento.

As resoluções espaciais e temporais de um sistema sensor estão intimamente correlacionadas, uma vez que para recobrir a superfície terrestre em menor período (alta resolução temporal) é necessário abranger uma maior quantidade de área em uma única passagem do sensor, comprometendo a resolução espacial. Por exemplo, o sensor MODIS a bordo dos satélites Terra e Aqua, obtém informações de um mesmo ponto da superfície terrestre com aproximadamente 1 dia de resolução temporal e resolução espacial de 250 metros nas bandas 1 e 2 (*Swath* de 2.230 km). Em comparação, o sensor OLI (*Operational Land Imager*) a bordo do satélite Landsat-8 possui resolução temporal de 16 dias e resolução espacial de 30 metros (*Swath* de 185 km). Assim, há um ganho na qualidade espacial para o sensor OLI em detrimento do tempo de cobertura da superfície terrestre.

Porém, não é possível dizer que um sensor é melhor do que o outro, pois cada um é adaptado a um tipo de aplicação. Assim, o sensor MODIS obtém informações da superfície terrestre quase diariamente, minimizando problemas de perdas de informação devido à presença de nuvens. Já o sensor OLI obtém informações sobre a cobertura terrestre com melhor detalhamento da informação de área e possibilitando melhor distinção entre os alvos. De acordo com Jensen (2011), para análises urbanas, resoluções espaciais maiores que 10 m são praticamente inúteis, sendo que para resoluções de 0,5 a 2 m não há diferença significativa quanto à interpretabilidade dos dados em áreas urbanas. No entanto, para resoluções espaciais tão refinadas, a frequência de imageamento para a mesma área da superfície terrestre tende a ser pequena, o que, aliada à alta cobertura de nuvens, dificulta seu uso para o monitoramento de cultivos agrícolas, devido ao alto dinamismo, embora o problema da baixa frequência de revisita dos sensores de alta resolução espacial esteja sendo contornado pelo uso de constelações de satélites.

A resolução espectral indica o número e a largura das bandas espectrais de um sensor. Esta resolução encontra aplicabilidade na capacidade de representar os alvos da superfície terrestre em diferentes bandas, levando em consideração os diferentes comportamentos espectrais dos alvos.

O número e a largura das bandas espectrais de um sensor são determinados previamente pelos tipos de alvos que se pretende detectar, como diferentes coberturas vegetais, água, solo, atmosfera, temperatura da superfície etc. A escolha de uma banda muito larga, ou seja, que abrange uma grande porção do espectro eletromagnético pode dificultar a distinção entre os alvos de interesse, pois as diferenças entre os alvos podem não ser representadas por esta banda.

Na Figura 6, nota-se que as bandas 4 (NIR- *Near InfraRed*) e 5 (SWIR- *Short Wave Infrared*) do sensor ETM+ (*Enhanced Thematic Mapper Plus*)/Landsat-7 são mais largas que as bandas 5 (NIR) e 6 (SWIR) do sensor OLI/Landsat-8. Apesar de estarem posicionadas sobre as mesmas faixas espectrais, as bandas do sensor ETM+ abrangem uma maior porção do

espectro. Assim como a banda 8 (pancromática) do sensor ETM+, que abrange os comprimentos de onda das bandas 2, 3 e 4 do mesmo sensor e, portanto, perde boa parte da capacidade de distinção espectral entre os alvos, apesar da melhora na resolução espacial. Cabe salientar que a largura e o posicionamento das bandas são amplamente pesquisados, tanto em campo quanto em laboratório, para que estas sejam projetadas para proporcionar uma identificação mais acurada dos alvos.




Figura 6: Comparação entre as bandas espectrais de diferentes sensores. Fonte: Nasa, 2020a.

A resolução radiométrica é a capacidade de um sensor em discretizar e quantificar o sinal emitido ou refletido pelo alvo, em outras palavras, a sua sensibilidade à energia provinda do alvo. Assim, um sensor com 8 bits pode discretizar o sinal dentro de 256 níveis, variando do valor zero, menor nível de energia, para o valor 255 com maior nível de energia, de acordo com a Equação 1. Já um sensor com 12 bits, pode discretizar os valores do sinal de zero a 4.095 níveis, possuindo uma maior resolução radiométrica em comparação ao sensor de 8 bits, assim como uma maior capacidade de representar um determinado fenômeno em estudo.

$$\text{Resolução radiométrica} = 2^n \quad (1)$$

em que n é o número de bits.

Se o sensor imagear um alvo da superfície terrestre, como uma estrada, por exemplo, que possuem dimensões inferiores à sua resolução

espacial, esse alvo pode ser identificado se a resolução radiométrica for suficiente para que haja contraste entre a estrada e os alvos adjacentes, no caso deles terem comportamentos espectrais distintos. Então, é possível concluir que as diferentes resoluções são complementares, auxiliando na distinção entre os alvos na superfície terrestre.

4.5. Sensores meteorológicos a bordo de satélites

4.5.1. Sensores na banda do Termal

Todos os objetos com temperatura acima do zero absoluto ($-273,15\text{ }^{\circ}\text{C}$ ou 0 K) emitem radiação eletromagnética e, de acordo com a lei de Stefan-Boltzman, um corpo negro emite REM a quarta potência de sua temperatura. Segundo a Lei de Wien, quanto maior for a temperatura de um corpo, menor será o comprimento de onda dominante da REM por ele emitida. Assim, o comprimento de onda predominante da REM emitida pelo Sol, com aproximadamente 6.000 K , está localizado na porção visível do espectro eletromagnético. Já a superfície Terrestre, com temperatura média de aproximadamente 300 K , apresenta um comprimento de onda predominante de emissão da REM na porção do infravermelho termal ($9,67\text{ micrometros}$).

Com relação às medidas de temperatura realizadas por sensores termais, é necessário destacar que a temperatura detectada do objeto imageado difere da sua temperatura cinética verdadeira (medida do grau de agitação das moléculas). Isso se deve à temperatura radiante aparente (medida pelo sensor) depender da emissividade desse objeto.

A emissividade é a razão entre a radiância real emitida por um corpo e a radiância que um corpo negro emitiria à mesma temperatura, ou seja, o potencial em emitir radiação. Dessa forma, embora a temperatura radiante aparente de dois objetos possa ser a mesma, se a emissividade desses objetos for diferente, suas temperaturas cinéticas podem diferir, por isso é importante conhecer a emissividade de cada objeto antes de se estimar a sua temperatura cinética.

Vale destacar que um corpo negro é um objeto teórico que absorve a totalidade da radiação sobre ele incidida e irradia energia na máxima taxa

possível por unidade de área em cada comprimento de onda para uma dada temperatura. Sendo que o Sol se aproxima de um corpo negro a 6.000 K e a Terra a 300 K.

Atualmente, sensores termais a bordo de plataformas orbitais podem ser utilizados como forma de detectar a temperatura em grandes extensões territoriais. Estes sensores atuam dentro da região do espectro eletromagnético compreendida pelo infravermelho termal (IR), que se encontra entre 3 e 14 micrômetros, sendo que as principais janelas atmosféricas estão entre os 3-5 micrômetros e 10,5-12,5 micrômetros, de modo que os demais intervalos são bloqueados pela atmosfera. Dentre os sensores mais utilizados com o objetivo do monitoramento agrícola ou ambiental, é possível destacar o *Advanced Very High Resolution Radiometer* (AVHRR-NOAA), MODIS (Terra e Aqua), TM- *Thematic Mapper* (Landsat-5), ETM+ (Landsat-7) e TIRS- *Thermal Infrared Sensor* (Landsat-8).

O sensor AVHRR, a bordo da série de satélites NOAA, desde 1978 disponibiliza um grande histórico de dados de temperatura do ar e da superfície, com resolução espacial de 1,1 x 1,1 km. Embora os sensores apenas detectem a radiância termal da superfície, é possível estimar a temperatura do ar a partir de correlações estabelecidas entre as temperaturas adquiridas por estações meteorológicas e os dados de superfície obtidos através de sensores. Nesse sentido, Gusso et al. (2007) estimaram a temperatura do ar (Tar), através da temperatura da superfície (LST) obtidas pelo satélite NOAA/AVHRR, concluindo que, embora a natureza entre Tar e LST seja distinta, relações podem ser estabelecidas entre estas, podendo assim, ter muitas aplicações agrometeorológicas.

Já as bandas termais dos sensores a bordo dos satélites Landsat apresentam resoluções espaciais de 120 metros no caso do TM/Landsat-5, 60 metros para o ETM+/Landsat-7 e de 100 metros no TIRS/Landsat-8. Embora as resoluções espaciais dos sensores a bordo dos satélites da série Landsat apresentem um melhor detalhamento espacial em comparação ao AVHRR (1,1 km) e MODIS (1 km), devido à resolução temporal de 16 dias do Landsat, não é possível um monitoramento frequente do estresse térmico de culturas agrícolas.

Dando maior ênfase ao sensor MODIS, lançado pela *National Aeronautics and Space Administration* (NASA) a bordo dos satélites Terra em 1999 e Aqua em 2002, destaca-se a sua ampla capacidade de cobertura da superfície terrestre, com uma faixa de imageamento (*Swath*) de 2.330 km. Isso permite uma resolução temporal de 1 a 2 dias (1 dia em regiões de maiores latitudes), com resolução espacial de 1 km para as bandas do infravermelho termal. Ambos os satélites apresentam duas passagens diárias sobre a superfície terrestre. O satélite Terra passa sobre a Linha do Equador em torno de 10h30 e 22h30 e o Aqua em torno de 01h30 e 13h30, horário local. Essa característica permite a obtenção de temperaturas diurnas e noturnas da superfície terrestre - LST, favorecendo o uso deste sensor em estudos agrícolas e ambientais.

Outra característica importante do sensor MODIS é o algoritmo de composição de imagens. Devido a sua passagem diária, as imagens que são disponibilizadas como produtos são compostas a partir de imagens obtidas em um intervalo maior (p. ex. oito dias). De modo que, cada valor de pixel no do produto de 8 dias é uma média simples de todos os pixels LST do produto diário (NASA, 2021c).

Os dados de LST do sensor MODIS apresentam grande acurácia com relação à realidade observada em campo. Ao estimar a temperatura do ar através da temperatura da superfície obtida pelo sensor MODIS, Kloog et al. (2014) obtiveram RMSPE (Raiz quadrada dos erros de predição quadráticos médios) de 1,2 °C. De acordo com estes autores, considerando que as medições de temperatura do ar obtidas por estações meteorológicas fornecem dados pontuais e geralmente em uma distribuição espacial esparsa, os dados de temperatura da superfície baseados em satélite podem ser usados para uma visão espacialmente contínua e de alta cobertura espacial, se comparada à distribuição das estações meteorológicas.

Com o objetivo de monitorar as produtividades da soja e do milho cultivados nos Estados Unidos, Johnson (2014) observou correlações (r) negativas de -0,58 e -0,51, respectivamente para as produtividades do milho e da soja, com relação às temperaturas diurnas do LST/MODIS, principalmente durante o período de máximo desenvolvimento das culturas. Resultados

similares também foram encontrados por Gusso et al. (2014), que por meio de uma relação não linear, observaram que as variações relativas à temperaturas do dossel obtida pelo sensor MODIS/Aqua ocorrida no mês de fevereiro (máximo desenvolvimento da soja), tanto em nível regional quanto estadual, estão associadas às variações na produtividade da cultura da soja no RS. Neste sentido, as temperaturas do dossel abaixo da média, conjugada com precipitação acumulada acima da média, favorecem a maior produtividade.

Ao teorizar um sistema ideal de monitoramento de propriedades agrícolas por meio de sensoriamento remoto, Jackson (1984) sugere um sistema com resolução temporal diária, resolução espacial de no máximo 20 x 20 metros e tempo máximo para a disponibilização dos dados de cinco dias. Embora, alguns atributos idealizados por Jackson (1984) ainda não estejam disponíveis em sistemas remotos atuais, houve muita evolução e muitas das técnicas criadas para o monitoramento agrícola são aplicáveis na prática, desde que respeitadas às limitações tecnológicas de cada método.

4.5.2. Sensores de precipitação

Embora haja grande importância na medição da precipitação, visto que esta informação pode ser empregada no dimensionamento de obras hidráulicas e no planejamento da agricultura, a baixa densidade de estações meteorológicas em países em desenvolvimento, dificultam estes estudos. De acordo com Silva-Fuzzo et al. (2016), as estações meteorológicas convencionais fornecem registros pontuais, frequentemente sujeitos a falhas que limitam o seu uso, além de apresentar baixa densidade de pluviômetros e distribuição irregular, não permitindo, devido ao seu caráter pontual, a captura da variabilidade espacial da precipitação pluvial, gerando incertezas nos resultados de diversos estudos.

Com o objetivo de testar o uso de satélites para a obtenção de dados meteorológicos em escala global, em 1960, a NASA lançou o TIROS 1 (*Television InfraRed Observational Satellite*), o primeiro satélite meteorológico. Operando por apenas 78 dias, demonstrou a viabilidade do

monitoramento da cobertura de nuvens e dos padrões climáticos do planeta Terra a partir do espaço (NASA, 2020b). Através da NASA, o projeto TIROS se manteve operacional até 1968, lançando 10 plataformas espaciais.

Em 1978 o projeto TIROS passou a ser gerenciado pela NOAA (*National Oceanic and Atmospheric Administration*), que incorporou o sensor AVHRR à plataforma. Desde então, este sensor esteve presente em diversas plataformas e ainda está em atividade (NASA, 2020b). O AVHRR obtém a temperatura no topo das nuvens e na superfície dos oceanos com uma resolução espacial de 1,1 x 1,1 m, resolução temporal de 1 dia e órbita polar heliosíncrona (Jensen, 2009).

Outro programa de satélites para a observação meteorológica em nível global, também operado pela NOAA, é o GOES (*Geostationary Operational Environmental Satellite*). O programa GOES consiste em satélites geoestacionários que obtém dados nas bandas do visível e do termal, em resoluções de 1 x 1 km e de 4 x 4 km.

Tapiador et al. (2012) comentam que, sistemas de satélites que utilizam a banda do IR para estimar a precipitação seguem a lógica de que os topos das nuvens frias indicam um grande desenvolvimento vertical da nuvem e, portanto, maior capacidade de precipitação. No entanto, a relação entre os topos de nuvens frias e a precipitação em superfície é indireta e muitas vezes não apresentam a correspondência em superfície. O problema é ainda mais complexo com sistemas de nuvem que possuem várias camadas, pois a camada de nuvem que realmente se precipita pode não estar sendo imageada pelo sistema sensor. Outro problema conhecido dos métodos de IR é que a relação estatística entre a temperatura máxima da nuvem e a precipitação do solo é altamente dependente da estação climática e do local.

Segundo D'Oliveira et al. (2010), os satélites meteorológicos geoestacionários que operam na faixa do IR estão limitados a observar as formações de nuvens avaliando suas temperaturas do topo, mas sem obter sua composição vertical. Já satélites polares, de órbita mais baixa operam na faixa de micro-ondas e podem fazer medidas mais diretas da física das nuvens.

Isso corrobora com o fato de que as estimativas de micro-ondas passivas (PMW) fornecem a melhor medida de precipitação, enquanto que as observações de IR fornecem as melhores informações sobre o movimento do sistema de precipitação. Dessa forma, uma técnica conjunta entre as duas bandas gera estimativas de precipitação a partir dos dados do PMW, enquanto as observações de IR geram os vetores de movimento (Tapiador et al., 2012).

Foi com o objetivo específico de monitorar e estudar a precipitação em áreas tropicais, que a parceria entre as agências espaciais NASA e JAXA (*Japan Aerospace Exploration Agency*) lançou, em 27 de novembro de 1997, o satélite TRMM (*Tropical Rainfall Measuring Mission*).

O satélite TRMM carregava a bordo os sensores TMI (imageador de micro-ondas), PR (radar de precipitação), VRS (radiômetro no visível e no infravermelho), CERES (sensor de energia radiante da superfície terrestre e das nuvens), e LIS (sensor imageamento de relâmpagos). Os dados são disponibilizados através dos produtos TMPA (*Multi-satellite Precipitation Analysis*), nas versões 3B42 *Real Time* e 3B42 *research*, sendo que ambos apresentam resolução temporal de 3 horas, e resolução espacial de 0,25°, atuando entre as latitudes de 50°S e 50°N. A diferença entre estes produtos consiste na indisponibilidade do sensor PR em tempo real, sendo que este apresenta importância na correção das informações através da estrutura vertical das nuvens (Collischonn et al., 2007; Quirino et al., 2015).

Após o sucesso do sistema TRMM, que encerrou sua atividade em 2015, houve a necessidade de manter a continuidade das estimativas da precipitação na superfície terrestre. O projeto GPM (*Global Precipitation Measurement*), lançado em 2014, consiste em uma parceria entre cinco agências espaciais, que coordenam até o momento nove satélites. A constelação de satélites GPM possui uma resolução espacial de aproximadamente 10 km e uma resolução temporal de 3 horas. A constelação é coordenada pelo satélite GPM Core (parceria entre NASA e JAXA), que carrega a bordo os sensores GMI (*GPM Microwave Imager*) e DPR (*dual-frequency precipitation radar*). O satélite GPM Core possui a função de padronizar a informação obtida pelos demais satélites da constelação, sendo

que estes também são equipados com radiômetros do tipo GMI ou instrumentos de sonda micro-ondas (Hou et al., 2014).

Com relação à precisão dos sensores de micro-ondas, Silva-Fuzzo et al. (2013) encontraram valores de erros absolutos médios (EMA) que variaram de 15 a 40 mm, quando compararam as precipitações obtidos pelo satélite TRMM com dados de estações meteorológicas convencionais no vale do médio Paranapanema/SP. Para as estações meteorológicas do INMET localizadas no RS, Mota (2015) obteve aproximadamente 18% (14 mm) de superestimativa nos dados TRMM.

Ao comparar a precipitação média diária obtida pelo satélite TRMM com pluviômetros na bacia do Alto Paraguai, Collischonn et al. (2007) concluíram que, embora houvesse algumas super e subestimativas de precipitação, os produtos do TRMM apresentam a importante capacidade de estimar corretamente a ausência de chuva. Assim, a alternância entre estações úmidas e secas é bem representada. Anderson et al. (2015) avaliaram as anomalias (desvio em relação à média de 11 anos) para os dados TRMM no RS, concluindo que as anomalias negativas, são condizentes em representar os eventos de seca, como por exemplo nas safras 2005 e 2012.

Para modelos de estimativa da produtividade da soja, Silva-Fuzzo et al. (2015) utilizaram como dados de entrada, tanto precipitações obtidas por estações meteorológicas, quanto do sistema TRMM. Os autores encontraram EMA da produtividade que variaram entre 306 e 618 kg ha⁻¹, quando da utilização dos dados de estações meteorológicas, enquanto que, ao estimar a produtividade com dados de precipitação do sistema TRMM o EMA máximo foi de 352 kg ha⁻¹.

Prakash et al. (2016), utilizando dados de estações pluviométricas como parâmetro, compararam a eficiência dos sistemas de satélite TRMM (TMPA) e GPM (IMERG) em detectar chuvas intensas entre os meses de junho e setembro de 2014 na Índia, concluindo que o GPM é mais consistente com as observações terrestres. No entanto, o GPM apresentou um comportamento muito semelhante ao TRMM em relação ao volume de precipitação atingida, à taxa de erro e ao falso alarme.

No RS, Lemos et al. (2017) e Weymar Junior et al. (2017) avaliaram a acurácia dos dados de precipitação do sistema GPM em relação aos dados de estações meteorológicas convencionais, localizadas nos municípios de Pelotas/RS e Santa Vitória do Palmar/RS, respectivamente. Os autores encontraram resultados semelhantes entre si, sendo que o produto GPM *Final* acumulado quinzenalmente para Pelotas obteve um Erro Médio (EM) de 5,33 mm e índice de Nash-Sutcliffe (NS) de 0,41. Já em Santa Vitória do Palmar, o EM foi de 1,69 mm e o índice de NS de 0,75. Lemos et al. (2017) e Weymar Junior et al. (2017) concordam que o produto GPM *Final* apresenta elevada acurácia e que os produtos GPM *Early* e GPM *Late* demonstram acurácia inferior e semelhantes entre si.

4.6. Modelos de produtividade agrícola

Nenhum modelo matemático representa um fenômeno de forma tão exata quanto à observação do próprio fenômeno *in loco*. No entanto, nem sempre a observação do fenômeno em tempo real se demonstra como prática viável para a solução de problemas. Como exemplo, podem-se citar os modelos de probabilidade de precipitação, utilizados no dimensionamento de reservatórios de água. Pois não é possível esperar o rompimento de um reservatório, para só então descobrir as precipitações máximas que o limitam.

Em se tratando de modelos matemáticos de estimativa da produtividade agrícola, Doorenbos e Kassam (1979) desenvolveram uma metodologia em que é possível relacionar os fatores meteorológicos vigentes durante a safra, aos efeitos fisiológicos da planta que levam a produtividade agrícola.

O Modelo proposto por Doorenbos e Kassam (1979) se baseia principalmente na relação entre a produtividade da cultura e as penalizações causadas pelo déficit hídrico em cada estágio de desenvolvimento. Sendo que o estresse hídrico é representado pela Evapotranspiração relativa (ET_r/ET_m) e o estágio de desenvolvimento é representado pelo fator de resposta à produtividade (ky). O ky determina a potencialidade do impacto do estresse hídrico em cada estágio de desenvolvimento, de modo que, quanto maior este

fator, maior será o impacto que baixos valores de E_{Tr}/E_{Tm} causam sobre a produtividade. A combinação entre os fatores k_y e E_{Tr}/E_{Tm} , também é conhecida como Índice de Penalização (IP) (RUDORFF & BATISTA, 1990).

A produtividade de uma cultura também é limitada por um patamar máximo, a Produtividade Máxima (PM). Este fator também depende de variáveis meteorológicas, como a temperatura do ar e a Fração do dia em que o céu está encoberto, além de variáveis fisiológicas da planta. Desta maneira, a partir de uma PM estabelecida para uma cultura em um período específico, são aplicadas as penalizações à produtividade (IP), culminando na produtividade final, que é o resultado do somatório das produtividades parciais.

Modelos de estimativa da produtividade agrícola podem ser de grande importância estratégica para a diminuição de perdas causadas devido à épocas de semeadura incorreta. Cunha et al. (2001) desenvolveram o zoneamento agrícola para a cultura da soja no RS através de um modelo de produtividade baseado nas interações entre dados climáticos, datas de semeadura e ciclos da cultura, simulando assim, os períodos críticos que limitam o desenvolvimento ideal da cultura e, conseqüentemente, podendo evitá-los.

Entre os principais resultados alcançados pelo Programa de Zoneamento Agrícola do MAPA, destacam-se: redução de riscos climáticos para culturas, retorno de capitais aplicados em operações de crédito agrícola, redução das taxas de sinistralidade e, de modo geral, diminuição no número de indenizações pagas pelo PROAGRO (Programa de Garantia da Atividade Agropecuária) e por seguradoras privadas (Cunha & Assad, 2001). De acordo com Rizzi et al. (2006) o IP obtido a partir de modelos de estimativa da produtividade agrícola tem uma importante aplicação nas operações de seguro agrícola, onde a identificação dos períodos e das regiões de maior impacto das condições meteorológicas adversas fornecem subsídios objetivos para otimizar e tornar mais eficiente o processo de vistoria de campo das lavouras.

Modelos agrometeorológicos também podem ser utilizados para a estimativa de produtividades em cenários climáticos futuros. Este tipo de

aplicação propõe compreender como cultivares existentes se comportariam em possíveis cenários de mudanças climáticas. Ao simular a produtividade da soja em cenários climáticos até o ano de 2099, quando a temperatura e as concentrações de CO₂ prováveis seriam maiores que as atuais no RS, Cera et al. (2017) obtiveram aumentos de 1,5 a 2 t ha⁻¹ na produtividade, com maiores incrementos nas datas de semeadura de setembro e dezembro, principalmente nas regiões norte e nordeste do estado. Enquanto nas datas de semeadura janeiro e fevereiro os incrementos foram menores, como consequência do encurtamento do ciclo de desenvolvimento da cultura. No entanto, ao considerar a água no solo como fator limitante, a produtividade da cultura tende a diminuir.

Simulando a produtividade da cultura do milho para o município de Santa Maria/RS frente a cenários de mudanças climáticas nos próximos 100 anos, Streck & Alberto (2006) verificaram que a produtividade da cultura tende a aumentar quando há um aumento de CO₂ sem aumentar a temperatura do ar. No entanto, aumentos de temperatura de 2 e 3 °C tendem a anular o efeito positivo do aumento de CO₂ na produtividade de grãos, enquanto que aumentos de 4 °C ou mais causam redução na produtividade de grãos de milho.

Esse mesmo raciocínio pode ser aplicado para compreender o comportamento de uma determinada cultivar em diferentes regiões climáticas. Essas simulações podem ser empregadas por meio do ajuste do fator de resposta a produtividade (ky), ou através da introdução de outro fator de ajuste. Monteiro et al. (2017) aplicaram dois parâmetros ao modelo de estimativa da produtividade de Doorenbos & Kassam (1979) para a cultura do milho, um parâmetro representando a sensibilidade da cultivar ao déficit hídrico e outro o potencial tecnológico empregado em cada região produtora do Brasil. Ao comparar os dados modelados com os dados de produtividade do IBGE, fatiados em cinco classes de produtividade (dos municípios de mais baixa aos de mais alta produtividade), os autores obtiveram erros médios relativos que variaram de -0,9 a 2,4% e R² que variaram de 0,76 a 0,92, dependendo da classe de produtividade modelada.

Devido à importância apresentada na estimativa de produtividade, também foram desenvolvidos *softwares* que modelam a produtividade de algumas culturas específicas. Por exemplo, o modelo SimulArroz, que calcula a taxa de crescimento dos diferentes compartimentos da planta (raízes, caule, folhas e panículas) e de desenvolvimento (emissão de folhas e avanço na fenologia da cultura), usando variáveis meteorológicas como temperatura diária do ar e radiação solar para estimar a produtividade. Esse modelo foi utilizado por Rosa et al. (2015), que não obtiveram diferenças significativas entre os dados simulados e os observados em experimentos de campo realizados no RS. Silva et al. (2016) utilizaram dados de um modelo climático regional para alimentar o modelo SimulArroz, obtendo a raiz do quadrado médio do erro normalizado (RQME_n) que variaram entre 12,7 e 15,8% ao comparar os resultados simulados aos observados em área experimental no sul do RS.

Com a maior disponibilidade dos sensores a bordo de satélites, assim como a distribuição gratuita destes dados aos usuários, foi promovida a incorporação de informações orbitais aos modelos agrometeorológicos. Por exemplo, ao substituir dados de IAF tabelado por dados espectrais, se pretende detectar não somente os efeitos meteorológicos sobre a cultura, mas principalmente a integração entre os efeitos referentes à variabilidade dos solos e as variáveis bióticas, como pragas, doenças e plantas daninhas, além de práticas de manejo.

Segundo Rizzi & Rudorff (2007), ao utilizarem dados de IAF obtidos pelo sensor MODIS/TERRA em um modelo de estimativa da produtividade da soja, os resultados apresentaram maior detalhamento no que se refere à variação espacial da produtividade, em comparação aos dados de IAF tabelados. Esta variabilidade espacial também é observada por He et al. (2018), que modelaram a produtividade das sete principais culturas agrícolas do estado de Montana/EUA, a partir da produtividade primária bruta da vegetação, obtidos por dados NDVI multiplicados por um índice de conversão de produtividade. Estes autores obtiveram forte correspondência ao nível de município ($r \geq 0,85$, $p < 0,05$), demonstrando grande variabilidade espacial e

anual nas produtividades de culturas, além de consistência com os dados oficiais de produtividade.

Devido à grande influência que a temperatura tem sobre o controle da demanda evapotranspirativa da atmosfera, diversos autores têm utilizado dados termais obtidos via satélite para o monitoramento da produtividade agrícola. Gusso et al. (2014) avaliaram os desvios de produtividade da soja para o RS, correlacionando estes, aos desvios de temperatura do dossel em relação à média do mesmo período; para tal, os dados do LST/MODIS foram organizados em janelas de 32 dias ao longo da safra. Os autores concluíram que as produtividades mais altas se correlacionam às ocorrências abaixo da média do LST, assim como produtividades mais baixas se correlacionam a LST acima da média, obtendo R^2 de 0,82 para a janela que se inicia no estágio de enchimento dos grãos.

Também é importante lembrar que a precipitação apresenta alta variabilidade espacial (Camargo et al., 2005) e que dados obtidos por satélite podem melhor representar as variações da precipitação e, por consequência, de produtividade. Mota (2015), ao comparar dados quinzenais de precipitação estimados pelo sistema TRMM com estações do INMET, constatou uma superestimativa de, em média, 11% (7 mm), o que por consequência poderia superestimar o resultado de produtividade obtida por um modelo. No entanto, Silva-Fuzzo et al. (2015) encontraram uma melhora nas estimativas de produtividade da soja ao utilizar dados do TRMM em comparação aos dados de estações meteorológicas, atribuindo esse resultado principalmente a maior cobertura espacial dos dados adquiridos via satélite.

Outra abordagem bastante utilizada visa correlacionar mais de uma variável obtida por satélite às estimativas de produtividade. Johnson (2014), utilizou um algoritmo de árvore de decisão para relacionar a produtividade do milho e da soja com as variáveis LST e NDVI do MODIS, resultando em um modelo com erro absoluto médio no nível de condado de 1,26 t ha⁻¹ para milho e 0,42 t ha⁻¹ para soja, com um R^2 de 0,77 e 0,71, para as respectivas culturas.

Também é possível integrar dados através do método do retângulo (WDI - *Water Deficit Index*), abordado por El-Shirbeny et al. (2015), que

estimaram a produtividade da cultura do trigo no Egito, utilizando dados LST e NDVI obtidos pelo satélite Landsat para compor o índice WDI em substituição à relação $(1 - ETr/ETm)$ da equação de Doorenbos & Kassam (1979). Os autores obtiveram um R^2 de 0,76 entre os dados modelados e os observados, quando as estimativas foram realizadas durante o mês de março, estágio de formação da produtividade da cultura no delta do rio Nilo.

5. Metodologia

5.1. Processamento do Modelo

As operações que serão posteriormente mencionadas foram realizadas através do Sistema de Processamento de Informações Georeferenciadas – SPRING (Câmara et al., 1996), na versão 5.5.2, disponibilizado gratuitamente pelo INPE em www.dpi.inpe.br/spring/. O Spring também apresenta uma linguagem de programação própria (Linguagem Espacial para Geoprocessamento Algébrico - LEGAL), que possibilita operações algébricas e em lotes entre os mapas, sendo essa uma ferramenta fundamental para o processamento do modelo matemático de estimativa da produtividade.

5.2. Área em estudo

O RS foi utilizado como área de interesse do presente estudo. Devido ao Estado apresentar diferentes características climáticas e de solo, que por sua vez, implicam em diferentes características de cultivo, como época de semeadura, cultivares, tecnologia de manejo e potencial produtivo, neste trabalho, o RS foi dividido em duas regiões, denominadas de porções norte e sul (Figura 7), sendo que o modelo matemático de estimativa de produtividade proposto teve alguns parâmetros ajustados de forma independente entre as duas porções.

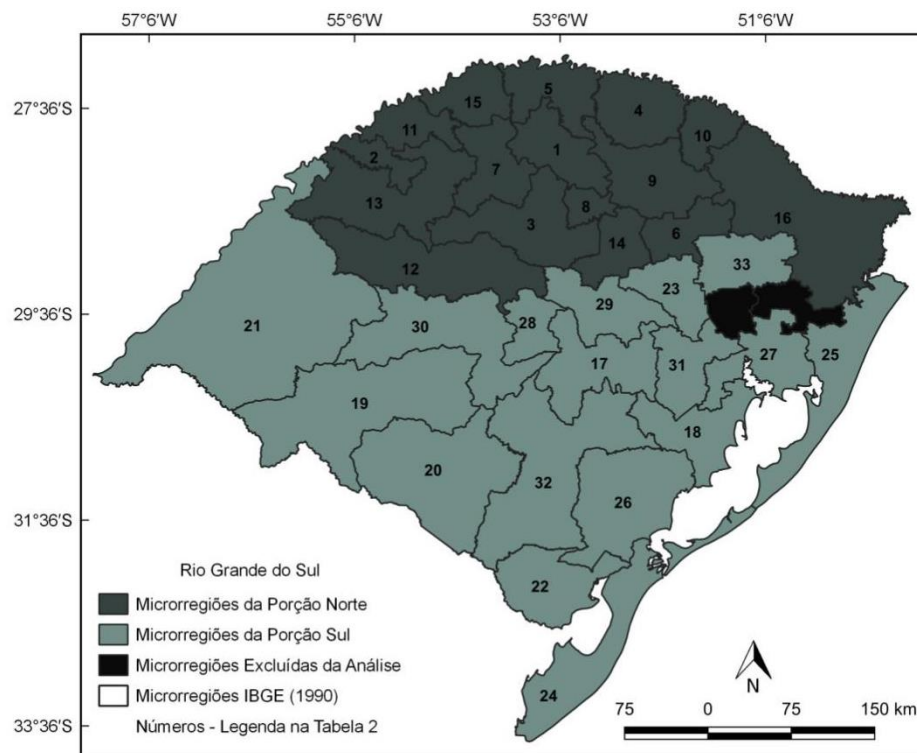


Figura 7: Subdivisão da área de estudo nas porções norte e sul do RS.

Dentro da área de estudo, foram adotadas as microrregiões por Unidade da Federação definidas pelo IBGE (IBGE, 1990). Também foram excluídas da análise as microrregiões de Montenegro e Gramado-Canela, principalmente por não possuírem áreas expressivas cultivadas com soja. As 33 microrregiões utilizadas no modelo são apresentadas na Figura 7 e na Tabela 2, sendo 16 da porção norte e 17 da porção sul.

Tabela 2: Microrregiões do IBGE utilizadas na análise do modelo e divididas entre as porções norte e sul do RS.

Legenda norte	Porção norte	Legenda sul	Porção sul
1	Carazinho	17	Cachoeira do Sul
2	Cerro Largo	18	Camaquã
3	Cruz Alta	19	Campanha Central
4	Erechim	20	Campanha Meridional
5	Frederico Westphalen	21	Campanha Ocidental
6	Guaporé	22	Jaguarão
7	Ijuí	23	Lajeado-Estrela
8	Não-Me-Toque	24	Litoral Lagunar
9	Passo Fundo	25	Osório
10	Sananduva	26	Pelotas
11	Santa Rosa	27	Porto Alegre
12	Santiago	28	Restinga Seca
13	Santo Ângelo	29	Santa Cruz do Sul
14	Soledade	30	Santa Maria
15	Três Passos	31	São Jerônimo
16	Vacaria	32	Serra do Sudeste
	-	33	Caxias do Sul

5.3. Mapeamento da cultura da soja na porção norte do RS

A divisão do RS em duas porções com características distintas teve também o intuito de testar o desempenho da componente espectral no modelo de estimativa de produtividade. Entretanto, para evitar que a resposta espectral de outros alvos interferisse na estimativa da produtividade da soja, foi necessária a produção de um mapa contendo as áreas cultivadas com soja, de modo que o modelo pudesse ser aplicado primordialmente sobre tais áreas. A porção norte do RS apresenta grande proporção de área cultivada com soja (comparativamente à porção sul). Nesta porção, os cultivos já estão estabelecidos por várias safras, pouco se alteram ao longo dos anos e geralmente são contíguos. Isto facilita o mapeamento aproximado das áreas de soja a partir de metodologias automáticas ou semi-automáticas em grandes regiões, a partir de imagens de sensores de moderada resolução espacial, (como o MODIS), de modo que essa região foi escolhida para o

mapeamento da soja e, conseqüentemente, para a utilização da componente espectral no modelo.

O mapa de cultivo da soja na porção norte do RS foi realizado via imagens do índice de vegetação *Enhanced Vegetation Index* (EVI), obtidos pelo sensor MODIS, produto MOD13Q1, principalmente devido à grande faixa de abrangência, capaz de imagear em totalidade a área de estudo, além de possuir resolução temporal quase diária.

A metodologia utilizada para o mapeamento das áreas de soja foi a CEI (*Crop Enhancement Index*) proposta por Rizzi et al. (2009) (Equação 2), que consiste em identificar as áreas agrícolas pela variação entre o mínimo e o máximo IV, referentes à fase inicial de cultivo (MinEVI) e ao pico vegetativo da cultura (MaxEVI). Desta forma, grandes diferenças positivas entre o MaxEVI e o MinEVI observados ao longo da safra da soja retornam altos valores de CEI e indicam grande probabilidade de um pixel representar a cultura e vice-versa (RIZZI et al., 2009). Aplicou-se um limiar de fatiamento de 0,38, acima do qual todos os valores de CEI são atribuídos à classe soja. Após a classificação, utilizou-se um filtro de limpeza de pixels, a fim de remover áreas isoladas de até 10 pixels (65 ha). Os dados de área plantada estimados a partir da metodologia CEI foram comparados aos oficiais disponibilizados pelo IBGE.

$$CEI = G * \left(\frac{MaxEVI - MinEVI}{MaxEVI + MinEVI + 2S} \right) \quad (2)$$

em que:

G= fator de ganho (10^2);

MaxEVI= valor máximo de EVI;

MinEVI= valor mínimo de EVI;

S= coeficiente de realce (10^2).

5.4.Dados meteorológicos obtidos por satélite

O baixo número de estações meteorológicas convencionais no território do RS incorre em uma cobertura espacial esparsa, principalmente em regiões

que se encontram mais distantes das estações. Devido a essa condição, no presente trabalho, as informações meteorológicas foram, sempre que possível, derivadas de informações obtidas por sensores a bordo de satélites.

Os dados de precipitação foram obtidos pela constelação de satélites do programa GPM. Os dados do GPM são disponibilizados ao usuário final em três versões: IMERG *Early* e IMERG *Late*, disponibilizados em quatro e 14 horas após a sua aquisição, respectivamente, e IMERG *Final*, cuja disponibilidade se dá 3,5 meses após a aquisição dos dados (NASA, 2021a). Os dados podem ser obtidos de forma gratuita em <https://giovanni.gsfc.nasa.gov/giovanni/>.

A bordo do satélite Aqua está o sensor AIRS (*Atmospheric Infrared Sounder*), cujo um dos objetivos é o monitoramento da umidade relativa do ar (UR) nas diferentes camadas da atmosfera. Estes dados foram utilizados para o cálculo da pressão atual de vapor (e_a). Embora o sensor apresente resolução temporal diária, com passagens diurnas e noturnas, apenas os dados de aquisição noturna apresentaram, em uma análise preliminar, precisão aceitável para utilização no presente trabalho. Outra questão, diz respeito à estratificação da atmosfera (porção vertical), em que os dados são obtidos, pois o RS apresenta uma grande amplitude altimétrica em seu relevo, sendo necessária a obtenção da UR nos estratos atmosféricos de 1.000 hPa (menor altitude) e 950 hPa (estrato de maior altitude). Apesar da resolução espacial deste sensor ser de 13,5 km no nadir, o produto de UR disponibilizado apresenta uma resolução espacial de aproximadamente 111 km. Os dados podem ser obtidos de forma gratuita em <https://giovanni.gsfc.nasa.gov/giovanni/>.

Os dados de temperatura foram adquiridos através dos sensores MODIS, a bordo dos satélites Terra e Aqua pertencentes à NASA (<https://search.earthdata.nasa.gov/search>). Ambos os satélites apresentam duas passagens diárias. Dessa forma, os horários de passagem noturnos foram considerados como período de aquisição das temperaturas mínimas e as passagens diurnas como período de aquisição das temperaturas máximas. Assim como muitos produtos MODIS, os melhores pixels são agrupados em composições, que nesse caso são de oito dias. No entanto, para que a escala

temporal dos dados seja compatível com a escala quinzenal utilizada no modelo, assim como uma eliminação mais eficiente da presença de nuvens, os dados de temperatura máxima e mínima foram agrupados em médias de 16 dias, ou seja, uma combinação de quatro imagens compostas Terra e quatro imagens compostas Aqua, sendo que destas, quatro têm passagem diurna (temperaturas máximas) e quatro noturna (temperaturas mínimas). A resolução espacial dos produtos de temperatura do MODIS é de 1 km.

Os dados de temperatura do MODIS são fornecidos pelos produtos MOD11 (Terra) e MYD11 (Aqua) e representam a temperatura adquirida na superfície do solo (LST). Devido ao modelo de estimativa da produtividade de culturas utilizar dados adquiridos a dois metros de altura do solo, foi necessário corrigir essa discrepância através de uma equação de regressão linear, para tanto, os dados LST foram correlacionados às estações meteorológicas convencionais em solo.

No entanto, mesmo que os produtos MODIS apresentem um algoritmo que selecione os pixels de melhor qualidade dentro desse período, ainda assim é possível que o pixel esteja inviabilizado, principalmente pela presença de nuvens, que interfere na obtenção de dados da superfície. Assim, utilizou-se a Linguagem LEGAL para desenvolver um algoritmo para produzir mapas de temperatura média de superfície para períodos de 16 dias, utilizando informações dos vários horários de passagem do sensor MODIS.

Para tanto, primeiramente foi necessário selecionar os valores considerados máximos e mínimos para tal período. Para os primeiros, utilizaram-se aqueles referentes à passagem diurna do MODIS, da seguinte forma: quando um pixel estivesse inviabilizado em uma passagem das 13h30 (Aqua), este foi substituído pelo da passagem das 10h30 (Terra). Mantendo-se tal situação, efetuou-se o mesmo procedimento para o período posterior de oito dias. De forma análoga, obtiveram-se os valores de temperatura mínima iniciando o processo pelos dados de aquisição noturna do satélite Aqua (01h30). Então, o valor da temperatura de superfície média foi obtido utilizando a média simples para os valores considerados máximos (diurnos) e mínimos (noturnos). Em caso de persistência de nuvens, mesmo após o processo de seleção de pixels, foi adotado um valor de preenchimento de 25

°C. Este valor foi adotado, principalmente por se aproximar da temperatura média do ar e devido aos valores de preenchimento corresponderem a um pequeno percentual de pixels em relação ao total, o que por consequência, causou pouco impactando no resultado.

O processo de seleção dos pixels é representado esquematicamente na Figura 8, demonstrando a composição do primeiro período de dados para o ano civil. Neste algoritmo (Apêndice A), os períodos de oito dias foram agrupados aos pares, de tal forma que o primeiro fosse pareado ao segundo e o terceiro ao quarto e assim sucessivamente. Sendo que o primeiro somente pudesse adquirir pixels do segundo e vice-versa.

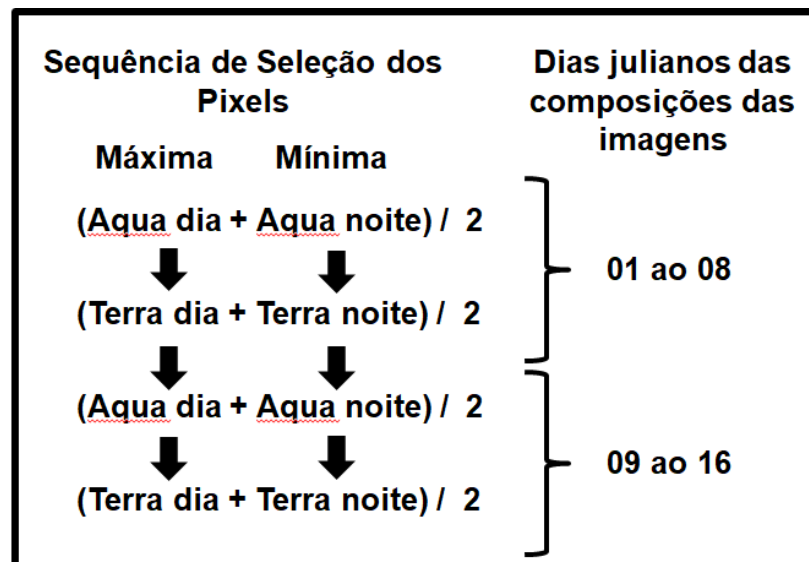


Figura 8: Esquema do Algoritmo de seleção de pixel, para o cálculo de temperatura média da superfície através dos satélites Terra e Aqua, de passagens diurnas e noturnas, visando à composição das imagens de LST do primeiro período do ano civil.

5.4.1. Acurácia dos sensores meteorológicos adquiridos por satélite

Devido ao modelo de estimativa de produtividade utilizar predominantemente dados meteorológicos provenientes de sensores a bordo de satélites, foram realizados testes estatísticos de acurácia de tais dados. Os dados de precipitação obtidos pelo sistema GPM, os dados de umidade relativa do ar obtido pelo sensor AIRS/Aqua e os dados de temperatura da superfície obtidos pelo sensor MODIS e os estimados de temperatura do ar

foram comparados aos adquiridos por estações meteorológicas convencionais (Figura 9).

A escolha por estações meteorológicas convencionais em detrimento das automáticas se deve em função dessas apresentarem menor precisão na medição de alguns parâmetros, como a umidade relativa do ar (Oliveira et al. 2010) e a precipitação (Sentelhas & Caramori, 2002). Estas discrepâncias podem ser atribuídas aos tipos de elemento sensível de cada instrumento, sendo mecânicos para as estações convencionais e eletrônicos para as estações automáticas.

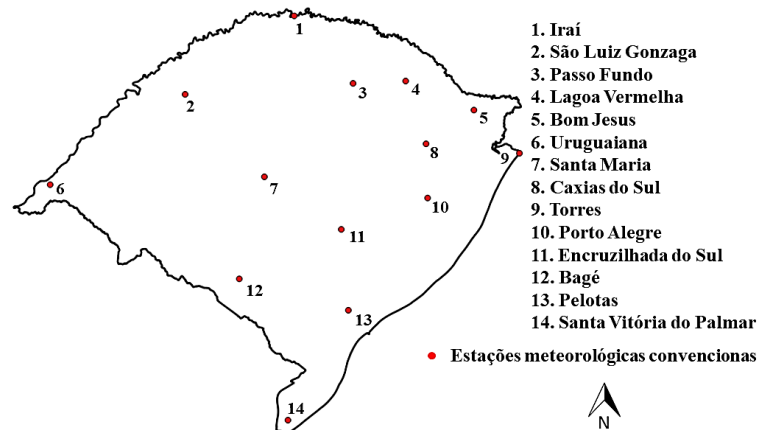


Figura 9: Localização das estações meteorológicas convencionais do INMET no RS utilizadas no presente estudo.

Com relação aos dados de precipitação estimados pelo sistema GPM, os dados de aquisição diária foram acumulados em quinzenas, sendo que, para os produtos *Early* e *Late* os dados foram avaliados para o ano de 2016 e o produto *Final* foi avaliado para o ano de 2015. Isso se deve a não disponibilidade do produto *Final* para o ano de 2016 na época da avaliação. Neste caso, a estação meteorológica do município de Pelotas foi escolhida como parâmetro de referência. Os testes de acurácia utilizados foram o Viés, a Raiz Quadrada do Erro Médio Quadrático (RMS) e o teste de Willmott (d) (Willmott et al., 1985), apresentados respectivamente nas equações 3, 4 e 5. Foi verificado o coeficiente de determinação entre ambos dados e de forma

complementar também se produziu um gráfico que representa o comportamento da variável ao longo do tempo.

$$Viés = \frac{\sum_{i=1}^n (Estimado - Observado)}{n} \quad (3)$$

$$RMS = \sqrt{\frac{\sum_{i=1}^n (Estimado - Observado)^2}{n}} \quad (4)$$

$$d = 1 - \left[\frac{\sum_{i=1}^n (Estimado - Observado)^2}{\sum_{i=1}^n (|Estimado - \overline{obs}| + |Observado - \overline{obs}|)^2} \right] \quad (5)$$

em que, *observado* são os valores referentes à estação meteorológica, *estimado* são os valores pertencentes aos dados obtidos pelo satélite, *n* é o número de quinzenas, \overline{obs} é a média dos valores observados.

Os mesmos testes foram aplicados para a umidade relativa do ar obtida pelo sensor AIRS, porém, diferentemente da precipitação, foram organizados em médias quinzenais. Para essa análise, apenas o período referente à safra de verão no RS foi avaliado (de 01/11/2015 a 28/04/2016). Devido ao sensor AIRS estratificar a atmosfera em diferentes altitudes, foi necessário analisar dados que englobassem a variabilidade de altitudes presente no RS. Logo, as estações meteorológicas de Bagé e Porto Alegre foram escolhidas, por representarem o estrato de menor altitude (1.000 hPa) e as estações de Passo Fundo e Bom Jesus por representarem o estrato imediatamente superior (925 hPa).

Os dados de temperatura adquiridos pelo sensor MODIS, dos produtos MOD11 (Terra) e MYD11 (Aqua), são referentes à temperatura de superfície LST, no entanto, o modelo de estimativa da produtividade utiliza dados de temperatura do ar adquiridos a dois metros de altura. Primeiramente, antes que a acurácia dos dados de temperatura do ar fosse testada, foi necessário estimá-la a partir dos dados LST. Para isso, realizou-se uma regressão linear entre os dados MODIS e os dados de estação, obtendo-se assim, uma estimativa da temperatura do ar através da equação de ajuste da reta. Foram utilizados os dados das 14 estações meteorológicas convencionais presentes

no RS (Figura 9), tais dados foram organizados em médias de oito dias ao longo de todo o ano de 2016, totalizando 592 pares de valores. A temperatura do ar foi calculada através equação 6.

$$Tar = 07966 * LST + 1,8289 \quad (6)$$

em que:

Tar= Temperatura do ar;

LST= *Land Surface Temperature*.

Em seguida, a equação foi aplicada aos dados LST do MODIS adquiridos em 2017, de modo a estimar a temperatura média do ar, a qual foi confrontada aos dados do INMET do referido ano.

Os testes de acurácia foram realizados através da Equação 3 e do teste de NS (Nash & Sutcliffe, 1970), Equação 7.

$$NS = \frac{\left(\frac{1}{n}\sum_{i=1}^n(\text{observado}-\overline{obs})\right)^2 - \left(\frac{1}{n}\sum_{i=1}^n(\text{observado}-\text{estimado})\right)^2}{\frac{1}{n}\sum_{i=1}^n(\text{observado}-\overline{obs})^2} \quad (7)$$

5.5.Dados meteorológicos obtidos por estações convencionais

Embora o intuito do trabalho seja o uso majoritário de dados obtidos por satélite, algumas informações como velocidade do vento e insolação tornam-se de difícil aquisição por sensores orbitais ou não estão disponíveis. Ambos os dados foram obtidos por estações meteorológicas convencionais em superfície, pertencentes ao INMET (Figura 9).

5.6.Resolução temporal do modelo

Conforme já mencionado, os dados meteorológicos diários foram organizados em médias quinzenais, com exceção da precipitação, em que os dados foram somados quinzenalmente. Supondo que a safra possua nove quinzenas, ou seja, 135 dias de ciclo da cultura, o modelo de produtividade foi

executado em cada uma destas, a fim de se obterem produtividades parciais. Posteriormente, realizou-se um somatório dos resultados parciais, obtendo a produtividade final da safra.

A quinzena inicial do modelo de estimativa de produtividade foi 17 de novembro e a final foi 31 de março. Este período foi verificado pelo comportamento espectro-temporal predominante para o cultivo da soja na porção norte do RS (RIZZI & RUDORFF, 2007).

5.7. Resolução espacial do modelo

Adotou-se uma grade regular de 250 x 250 m, principalmente por se adequar à resolução espacial dos dados de NDVI do sensor MODIS, utilizados como componente espectral na porção norte do RS. Dessa forma, as informações referentes à produtividade estarão representadas em cada um dos pixels desta grade. Estabelecer uma resolução espacial para o modelo torna-se necessário, devido às diversificadas resoluções espaciais dos diferentes dados utilizados. Logo, os dados cujas resoluções espaciais que não se enquadram, assim como os dados pontuais oriundos das estações meteorológicas convencionais, foram interpolados para o padrão do modelo pelo método da média ponderada das cotas do quadrante, disponível no programa Spring.

5.8. Modelagem da produtividade

A produtividade da soja e de outras culturas pode ser estimada com o emprego de modelos matemáticos, baseados em informações agrometeorológicas, associadas ou não, aos dados obtidos por sensoriamento remoto (Sugawara, 2001).

Nesse estudo, a produtividade foi estimada através do modelo proposto por Doorenbos e Kassam (1979), sendo essa uma metodologia recomendada pela FAO (Equação 8).

$$PR = PM \left[1 - ky \left(1 - \left(\frac{Etr}{Etm} \right) \right) \right] \quad (8)$$

em que:

PR= Produtividade real;

PM= Produtividade máxima;

ky= Fator de resposta à produtividade (Tabela 3);

ETr= Evapotranspiração real;

ETm= Evapotranspiração máxima.

A relação entre ETr e ETm estabelece uma quantificação do nível de estresse hídrico sofrido pela cultura em um determinado estágio de desenvolvimento (ky). Quando a ETr é igual a ETm, significa que não há restrição no fornecimento hídrico. No entanto, se ETr é menor do que ETm, dependendo do estágio de desenvolvimento em que ocorrer, poderá prejudicar seriamente a produtividade final da cultura. O parâmetro ky foi ajustado com acréscimo de 70% aos valores adotados por Rizzi & Rudorff (2007), visando aumentar a sensibilidade do modelo aos estresses meteorológicos característicos da região de estudo (Tabela 3).

Tabela 3: Fator de resposta à produtividade (ky), para a cultura da soja, utilizados no modelo de produtividade em cada quinzena.

	Quinzenas								
	1	2	3	4	5	6	7	8	9
ky	0,34	0,51	0,85	1,53	1,53	1,53	1,70	1,70	1,70

Fonte: Adaptado de Doorenbos & Kassam (1979).

5.8.1. Componente meteorológico do modelo

Os dados meteorológicos são de grande importância a modelagem da produtividade agrícola, esses dados são incluídos na equação através da relação ETr/ETm.

Inicialmente, é necessário obter a evapotranspiração potencial (ETo), para tal foi utilizado o método de Penman-Monteith, descrito por Allen et al. (1998), apresentada na Equação 9.

$$ET_0 = \frac{0,408\Delta(Rn-G) + \gamma \frac{(900)}{(T+273)} U_2 (es-ea)}{\Delta + \gamma(1+0,34U_2)} \quad (9)$$

em que:

Δ = Curva de saturação de vapor em kPa;

R_n = Radiação líquida total em $Mj m^{-2} dia^{-1}$;

G = Fluxo de calor no solo em $Mj m^{-2} dia^{-1}$, considerado zero para valores quinzenais;

γ = Constante psicrométrica (0,063 kPa);

T = Temperatura do ar a 2 metros de altura em °C;

es = Pressão de saturação do vapor em kPa;

ea = Pressão atual de vapor em kPa;

$es-ea$ = Déficit de pressão de vapor em kPa;

U_2 = Velocidade do vento a 2 metros de altura em $m s^{-1}$.

Os valores de R_n foram obtidos pela Equação 10, que por sua vez tem seus componentes calculados através das equações 11 e 12. Os valores de R_a e N para a latitude média do RS (30° sul) são apresentados na Tabela 4, sendo adotados para todo o RS.

$$R_n = (0,75R_{ocr}) - R_{nl} \quad (10)$$

$$R_{ocr} = \left(0,25 + 0,50 \left(\frac{n}{N} \right) \right) R_a \quad (11)$$

$$R_{nl} = f(t) * f\left(\frac{n}{N}\right) * f(ea) \quad (12)$$

em que:

R_{ocr} = Radiação de ondas curtas real em $mm dia^{-1}$;¹

R_{nl} = Radiação líquida de onda longa em $mm dia^{-1}$;

¹ A unidade $mm dia^{-1}$ é referente a evapotranspiração equivalente.

- n= Insolação em hora dia⁻¹;
 N= Fotoperíodo em hora dia⁻¹;
 Ra= Radiação extraterrestre em mm dia⁻¹;
 $f(t)$ = Efeito da temperatura em função Rnl em mm dia⁻¹;
 $f(n/N)$ = Taxa de insolação em função Rnl em mm dia⁻¹;
 $f(ea)$ = Pressão atual de vapor em função Rnl em mm dia⁻¹.

Tabela 4: Radiação extraterrestre- Ra (mm dia⁻¹) e fotoperíodo- N (hora dia⁻¹) para latitude 30° S.

Mês	Nov	Dez	Jan	Fev	Mar
Ra	17,3	18,1	17,8	16,4	14,0
N	13,6	14,0	13,9	13,2	12,4

Fonte: Adaptado de Doorenbos & Kassam (1979).

Os fatores que compõe a equação de radiação líquida de onda longa (Rnl) são apresentados nas equações 13, 14 e 15.

$$f(t) = 1,385 \times 10^{-12} * 1440 * (273 + T)^4 \quad (13)$$

$$f\left(\frac{n}{N}\right) = 0,1 + \left(0,9 \left(\frac{n}{N}\right)\right) \quad (14)$$

$$f(ea) = 0,34 - 0,044(\sqrt{ea}) \quad (15)$$

A determinação da pressão de saturação do vapor (es), pressão atual de vapor (ea) e curva de saturação de vapor (Δ) são apresentadas nas equações 16, 17 e 18, respectivamente.

$$es = 6,178 \exp\left(\frac{17,27 * T}{T + 237,15}\right) \quad (16)$$

$$ea = es \left(\frac{RH}{100}\right) \quad (17)$$

$$\Delta = \frac{(4098 * e_s)}{(T + 237,15)^2} \quad (18)$$

em que:

RH= Umidade relativa do ar (%);

A evapotranspiração máxima ou de cultura (ETm), foi calculada pela multiplicação da ETo pelo coeficiente de cultura (kc). Os valores quinzenais referentes ao kc para a cultura da soja são apresentados na Tabela 5.

Tabela 5: Coeficiente de cultura (kc) para a cultura da soja utilizados no modelo de produtividade em cada quinzena.

	Quinzenas								
	1	2	3	4	5	6	7	8	9
kc	0,62	0,90	1,14	1,32	1,44	1,44	1,38	1,20	1,08

Fonte: Adaptado de Doorenbos & Kassam (1979).

A evapotranspiração real (ETr) foi obtida através da metodologia do balanço hídrico de Thornthwait-Matter (1955), de forma que, quando a precipitação for maior ou igual à evapotranspiração máxima, a ETr será igual a ETm e quando a precipitação for menor que a evapotranspiração máxima, a ETr será igual à soma entre a precipitação e o módulo da alteração de água no solo (ALT).

Para o cálculo do balanço hídrico é necessária a informação referente à CAD, relacionada às classes de solo (Tabela 6). Esta informação foi derivada do mapa de levantamento de reconhecimento dos solos do estado do RS (BRASIL, 1973), na escala de 1:750.000.

Tabela 6: Capacidade de retenção de água no solo (CAD) para as diferentes Classes de Solo.

Classes de solo	CAD (mm)
Neossolo Quartzarênico, Neossolo Flúvico de textura arenosa, Planossolos.	50
Latossolo Vermelho-Amarelo, Latossolo Vermelho (menos de 35% de argila), Neossolo Litólico, Chernossolos.	70
Luvissolos, Argissolos, Nitossolos, Latossolos (exceto Latossolo Vermelho com menos de 35% de argila), Cambissolos e Neossolo Flúvico de textura média a argilosa.	100

Fonte: Farias et al. (2000).

O Índice de Área Foliar (IAF) é uma das variáveis da equação necessárias ao cálculo da PM, sendo esse um dos componentes do modelo. Os valores de IAF foram obtidos a partir de Fontana et al., (1992), sendo utilizado um valor por quinzena para toda a área de estudo (Tabela 7). Neste caso, o modelo foi denominado de *Agrometeorológico*.

Tabela 7: Índices de Área Foliar (IAF) estimados para a cultura da soja, utilizados no modelo de produtividade.

Quinzena	1	2	3	4	5	6	7	8	9
IAF	0,11	0,77	2,20	3,30	5,50	6,90	5,50	3,85	1,10

Fonte: Adaptado de Fontana et al. (1992).

A partir do estabelecimento de uma PM, é possível aplicar o IP a essa produtividade, tomando como base a resposta da cultura às variáveis meteorológicas (ETr/ETm) e ao fator de resposta à produtividade (ky), que varia conforme o estágio da cultura. Dessa forma, o IP representa a fração da produtividade agrícola que está sendo perdida em função de limitações do crescimento da cultura em um determinado ano safra (RIZZI et al., 2006). A PM é calculada a partir da Equação 19.

$$PM = Fcc * Fr * Fpa * ND * PMB \quad (19)$$

em que:

PM= Produtividade máxima (kg ha⁻¹);

Fcc= Fator de compensação do crescimento;

Fr= Fator de respiração;

Fpa= Fator de produtividade agrícola;

ND= Número de dias da quinzena;

PMB= Produção de matéria seca bruta do grupo da cultura.

O Fator de compensação do crescimento é função do IAF da quinzena, de acordo com a Equação 20.

$$Fcc = 0,515 - e^{(-0,664-0,515*IAF)} \quad (20)$$

em que:

Fcc= Fator de compensação do crescimento;

IAF= índice de Área Foliar.

O Fator de respiração (Fr) é dependente da temperatura média da quinzena, de modo que, se:

a temperatura média da quinzena < 20°C: Fr= 0,4;

a temperatura média da quinzena > 20°C: Fr= 0,5;

O Fator de produtividade agrícola (Fpa) corresponde ao quanto da massa seca total produzida pela planta é convertida em grãos. Nesse sentido, levando em consideração as distintas características presentes nas porções norte e sul do RS, adotaram-se dois diferentes valores de Fpa. Sendo, um para a porção norte (38,6%) e outro para a porção sul (32,0%) do RS.

A fim de calcular a PMB, Equações 21 e 22, para o grupo de culturas do qual pertence a soja (quente I), primeiramente foi necessário o cálculo da taxa de produção de matéria seca da cultura em função da temperatura do ar (ym). Para facilitar a inserção da informação de ym na linguagem de programação, os dados originalmente tabelados por Doorenbos e Kassam (1979) foram convertidos em equações de regressão que compreendem três faixas de temperatura, apresentadas nas Equações 23, 24 e 25.

Se $y_m > 20$ kg/ha/hora:

$$PMB = (F * (0,8 + (0,01 * y_m)) * y_o) + ((1 - F) * (0,5 + (0,025 * y_m)) * y_c). \quad (21)$$

Se $y_m < 20$ kg/ha/hora:

$$PMB = (F * (0,5 + (0,025 * y_m)) * y_o) + ((1 - F) * (0,05 * y_m) * y_c) \quad (22)$$

em que:

PMB= Produção de matéria seca bruta do grupo da cultura;

y_m = Taxa de produção de matéria seca da cultura em função da temperatura ($\text{kg ha}^{-1} \text{ hora}^{-1}$);

y_o = taxa bruta de produção de matéria seca de uma cultura padrão para um determinado local em um dia completamente nublado;

y_c = taxa bruta de produção de matéria seca de uma cultura padrão para um determinado local em um dia claro (sem nuvens);

F= Fração do dia em que o céu está encoberto.

De 10° a 19°C:

$$y_m = 0,0457 * T^2 + 1,8922 * T - 23,25 \quad (23)$$

De 20° a 35°C:

$$y_m = -0,0481 * T^2 + 2,6479 * T - 1,3235 \quad (24)$$

De 36° a 40°C:

$$y_m = -5,4991 * T + 224,96 \quad (25)$$

em que: T = temperatura média do ar.

Os valores de y_o e y_c para a latitude de 30° sul (latitude média para a área de estudo) e para os meses que compreendem o cultivo da soja são

apresentados na Tabela 8. A fração do dia em que o céu está encoberto (F) é apresentada pela Equação 26 e a radiação de onda curta (Roc) é apresentada na Tabela 9.

$$F = \frac{(Roc - (0,5 * Rocr))}{(0,8 * Roc)} \quad (26)$$

Em que:

F = fração do dia em que o céu está encoberto;

Roc = radiação de onda curta em cal cm⁻² dia⁻¹.

Tabela 8: Valores de taxa de produção de matéria seca da cultura em função da temperatura (yc) e taxa bruta de produção de matéria seca de uma cultura padrão para um dia completamente nublado (yo).

Mês/ 30° sul	Nov	Dez	Jan	Fev	Mar
yc	471	489	483	456	412
yo	251	261	258	243	216

Fonte: Adaptado de Doorenbos & Kassam (1979).

Tabela 9: Radiação de onda curta (cal cm⁻² dia⁻¹).

Mês/ 30° sul	Nov	Dez	Jan	Fev	Mar
Roc	400	417	411	384	333

Fonte: Adaptado de Doorenbos & Kassam (1979).

5.8.2. Componente espectral do modelo

Para a porção norte do RS, a fim de avaliar o desempenho de uma componente espectral no modelo de produtividade, o presente estudo utilizou também uma abordagem que fez uso de dados de NDVI (Equação 27) do sensor MODIS, em resolução espacial de 250 x 250 m (produto MOD13Q1), que foram convertidos em IAF através das Equações 28 e 29. Neste caso, ao invés de toda a região em estudo ser representada por um único valor de IAF para cada quinzena, tais valores são estimados em nível de pixel. As demais equações e parâmetros do modelo permaneceram inalterados, com exceção do Fpa, que foi estabelecido em 37,5%. O modelo foi, então, denominado de *Agrometeorológico espectral*.

$$NDVI = \frac{(NIR-R)}{(NIR+R)} \quad (27)$$

em que:

NDVI= *Normalized Difference Vegetation Index*;

NIR= reflectância no infravermelho próximo;

R= reflectância no vermelho.

$$Fc = 1 - \left[\frac{(NDVImax-NDVI)}{(NDVImax-NDVImin)} \right]^{0,9} \quad (28)$$

em que:

Fc= Fração do solo coberto pela cultura;

NDVImax= NDVI máximo;

NDVImin= NDVI mínimo.

$$IAF = -2\ln(1 - Fc) \quad (29)$$

5.9.Cálculo da produtividade média

Conforme já comentado, a utilização da componente espectral no modelo de produtividade é dependente da disponibilidade de um mapa contendo a localização das áreas de soja. Assim, quando aplicado para a porção sul do RS, o modelo agrometeorológico não utilizou o mapa de soja para calcular a produtividade média da microrregião, uma vez que não utilizou-se a componente espectral por não se possuir um mapa de soja confiável. Isto significa que o valor de produtividade correspondeu à média de todos os pixels, estando estes sobre áreas de soja ou não. Esta característica não constitui um problema para o modelo, pois o resultado é uma função da média dos dados meteorológicos, não sendo afetado pelas características espectrais da soja.

Já quando aplicado para a porção norte do RS, a disponibilidade do mapa de soja permitiu que o modelo pudesse fornecer como valor de

produtividade o resultado da média dos pixels somente para as áreas mapeadas como soja presentes em cada microrregião. Isto ocorreu tanto quando o valor do IAF foi oriundo da literatura (Tabela 7) (modelo Agrometeorológico), quanto quando foi estimado a partir da componente espectral (modelo Agrometeorológico Espectral). Isto permitiu que as características espectrais da cultura da soja possam ser incluídas no modelo a partir das imagens de NDVI do sensor MODIS. Neste processo, devido a aparente melhor qualidade do mapa gerado para a safra de 2015 e levando em consideração que as áreas de soja na porção norte do RS apresentam pouca alteração entre safras, o mapa de soja referente à safra 2015 foi utilizado em todas as safras. Salienta-se, que o modelo não foi aplicado para a safra 2015, apenas o mapa de soja desta safra foi utilizado.

5.10. Monitoramento espaço-temporal por meio do Índice de Penalização acumulado

O monitoramento do efeito conjunto das condições definidoras da produtividade consiste em gerar o índice de penalização acumulado (IP) (RIZZI et al. 2006). O monitoramento acumulado da penalização é obtido pelo somatório de uma quinzena com todas as anteriores, sendo possível acompanhar as condições de desenvolvimento da cultura ao longo da safra e identificar os períodos e as regiões com maior ou menor impacto dos fatores definidores da produtividade. Assim, podem-se fazer inferências sobre a produtividade antes mesmo do final da safra. O IP é apresentado na Equação 30.

$$IP = \frac{PRa}{PMa} \quad (30)$$

em que:

IP= Índice de penalização acumulado;

PRa= Produtividade real acumulada até a quinzena considerada (kg ha⁻¹);

P_{Ma}= Produtividade máxima acumulada até a quinzena considerada (kg ha⁻¹);

5.11. Parametrização e validação do modelo

A parametrização do modelo foi realizada a partir da média de produtividade da safra de 2017, em que foram utilizadas a média das porções norte e sul do RS, para o caso do modelo agrometeorológico, e a média da porção norte do estado para o caso do modelo agrometeorológico espectral. De modo que as médias de produtividade fornecidas pelo IBGE fossem confrontadas às médias dos respectivos modelos. A parametrização dos modelos foi feita através do ajuste do parâmetro F_{pa}, que foi modificado até que as produtividades modeladas se adequassem aos dados do IBGE. Após o ajuste, este parâmetro foi aplicado às demais safras em nível de microrregião.

A validação do modelo foi realizada através dos dados de produtividade estimada obtidos nas safras de 2016, 2017 e 2018, em comparação aos dados oficiais disponibilizados pelo IBGE ao nível de microrregião da Unidade da Federação.

O teste de normalidade dos dados modelados e do IBGE foi realizado pelo teste de Shapiro-Wilk a 5% de significância. A análise de similaridade entre os dados modelados e os do IBGE foi realizada através do teste pareado de Kolmogorov-Smirnov (KS) a 5% de significância. Estes testes estatísticos foram realizados através do *software* R, versão 4.0.3.

6. Resultados e discussões

6.1. Mapa de cultivo da soja para a porção norte do RS

O mapeamento da área cultivada com soja na safra 2015 para a porção norte do RS apresentou uma área de 3.720.619 ha. O mapa é apresentado na Figura 10.

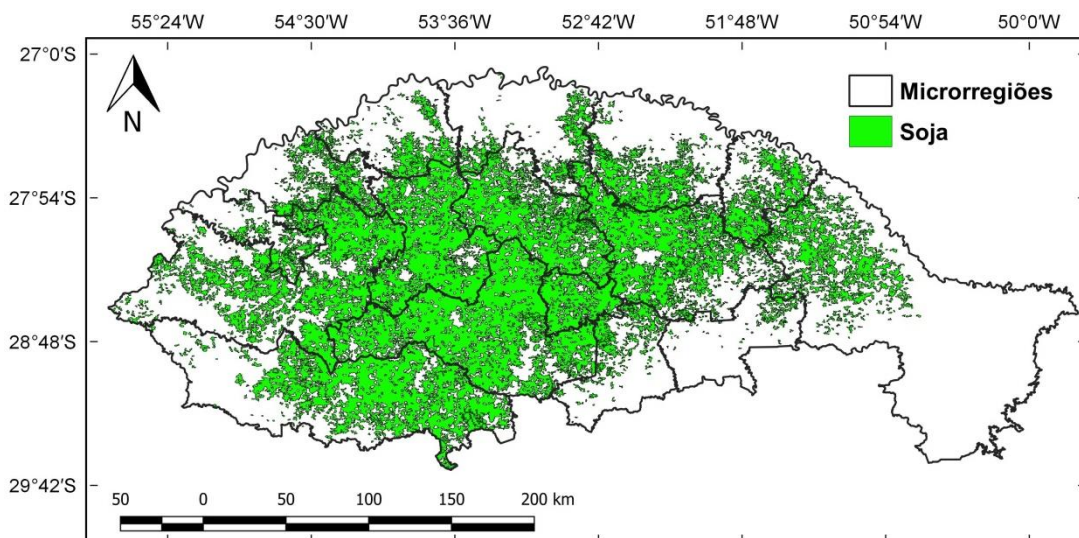


Figura 10: Mapa contendo as áreas de cultivo de soja para a porção norte do RS, na safra 2015.

A regressão linear (Figura 11) demonstrou um ajuste muito próximo entre a linha de tendência e os dados de área de soja mapeados através da metodologia CEI e os disponibilizados pelo IBGE, com um $R^2 = 0,969$.

A Tabela 10 apresenta a comparação entre a área de soja obtida através da metodologia CEI e os dados disponibilizados pelo IBGE, para a safra 2015 nas microrregiões da porção norte do RS. De forma que, a diferença total de área cultivada entre os dois métodos foi de 42.367 ha (1,15%).

De acordo com Rizzi et al. (2009), para o estado do Mato Grosso, as áreas corretamente classificadas pela metodologia CEI nos temas *soja* e *não soja* perfizeram 91% e os erros de omissão e inclusão foram de 6,1 e 2,9%, respectivamente.

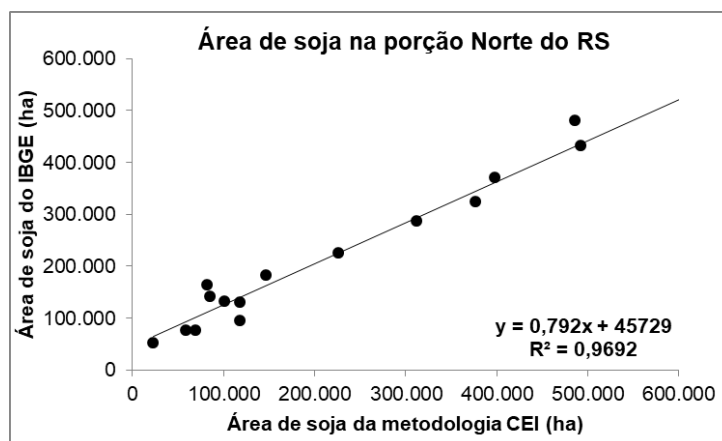


Figura 11: Regressão linear entre a área de soja obtida através da metodologia CEI e a disponibilizada pelo IBGE para a safra 2015 nas microrregiões da porção norte do RS.

Tabela 10: Comparação entre a área de soja obtida através da metodologia CEI e a disponibilizada pelo IBGE, para a safra 2015, nas microrregiões da porção norte do RS.

Microrregião	CEI (ha)	IBGE (ha)	Diferença (ha)	Diferença (%)
Santiago	492.214	432.200	60.014	13,89
Cruz Alta	623.639	512.785	110.854	21,62
Soledade	69.646	75.540	-5.894	-7,80
Guaporé	23.358	52.575	-29.217	-55,57
Vacaria	226.652	224.810	1.842	0,82
Passo Fundo	398.033	369.325	28.708	7,77
Sananduva	118.458	129.400	-10.942	-8,46
Erechim	146.408	182.430	-36.022	-19,75
Não-Me-Toque	118.139	95.340	22.799	23,91
Santo Ângelo	486.383	479.375	7.008	1,46
Ijuí	376.533	324.044	52.489	16,20
Cerro Largo	59.283	76.278	-16.995	-22,28
Carazinho	312.439	287.050	25.389	8,84
Santa Rosa	101.121	131.930	-30.809	-23,35
Frederico Westphalen	82.721	163.820	-81.099	-49,51
Três Passos	85.589	141.350	-55.761	-39,45
Total	3.720.619	3.678.252	42.367	1,15

6.2. Acurácia dos dados meteorológicos obtidos por satélites

6.2.1. Acurácia dos dados de precipitação GPM

As séries de dados de precipitação para os três produtos do sensor GPM (*Early*, *Late* e *Final*) são apresentadas na Figura 12. É possível verificar que os produtos *Early* e *Late* apresentam alguns picos que superestimam os valores de precipitação em relação aos dados da estação meteorológica convencional. No entanto, de forma geral, os dados GPM acompanham as variações dos valores de precipitação da estação meteorológica. Já para os dados do produto *Final*, embora não se possa estabelecer uma comparação direta com relação aos produtos *Early* e *Late*, devido a estes terem sido adquiridos em anos diferentes, nota-se um melhor acompanhamento dos valores em relação aos dados da estação meteorológica, assim como uma diminuição da superestimativa. Isso pode ser decorrente da remoção de interferências, dado o maior tempo de processamento da informação (NASA, 2021b). O modelo de regressão linear apresentou maior valor de R^2 para o produto *Final* (0,58) em relação aos produtos *Early* (0,52) e *Late* (0,54).

Nas avaliações de acurácia apresentadas na Tabela 11, os valores de diferença demonstram, em geral, uma superestimativa dos dados GPM, no entanto, para os dados do produto *Final*, há uma grande redução na diferença quando comparado aos produtos *Early* e *Late*. A mesma tendência é observada com relação ao RMS, em que o produto *Final* apresenta uma melhora na representação dos dados da estação meteorológica. Ao contrário dos outros produtos, que são submetidos a um menor tempo de processamento da informação.

O teste de Willmott (d) confirma a melhora na estimativa dos valores de precipitação para os dados do produto *Final*, alcançando valores de 0,86, sendo que os produtos *Early* e *Late* apresentaram valores de 0,65 e 0,67, respectivamente.

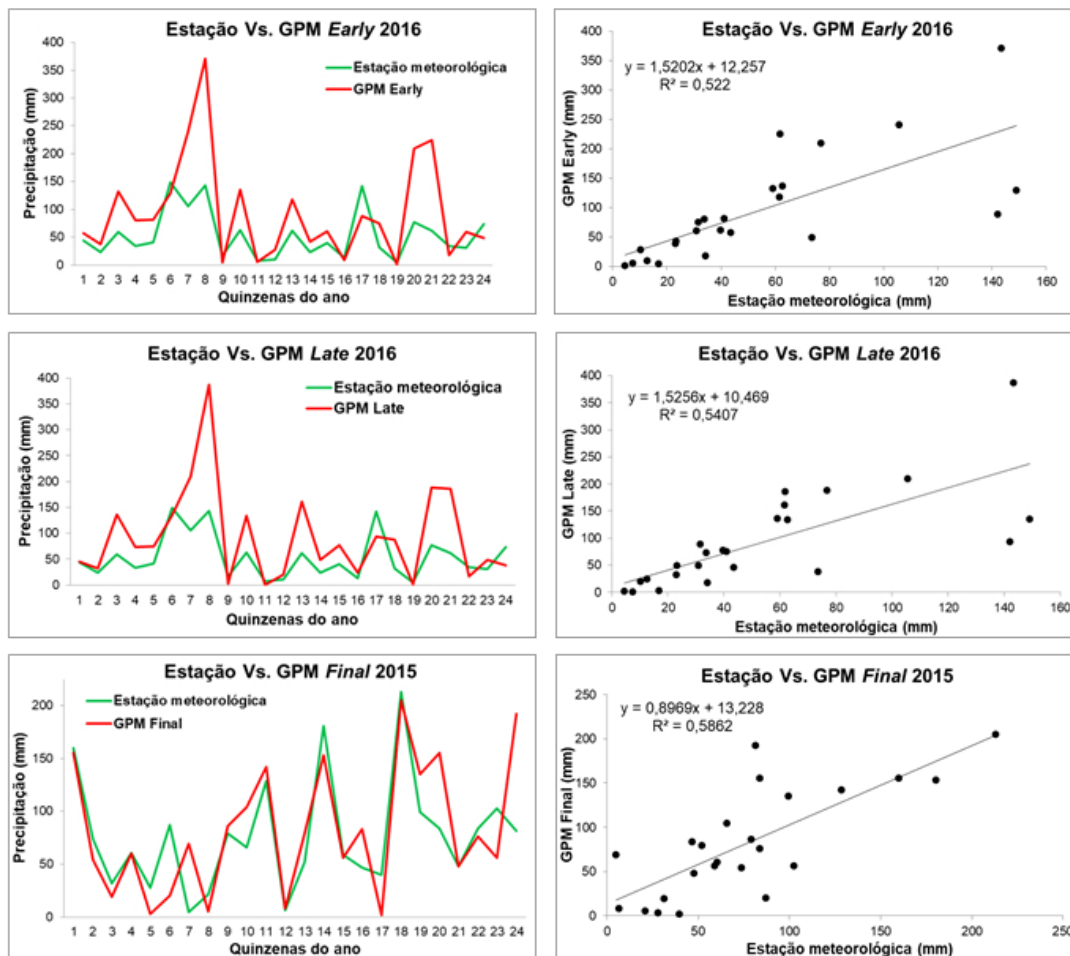


Figura 12: Séries quinzenais ao longo de um ano e regressão linear entre os dados do sistema de satélites GPM e a estação meteorológica de Pelotas/RS, para os produtos *Early* e *Late* no ano de 2016 e *Final* no ano de 2015.

Tabela 11: Acurácia dos dados obtidos pelo sistema de satélites GPM em relação aos observados pela estação meteorológica de Pelotas, sendo obtidos no ano de 2016 para os dados *Early* e *Late* e 2015 para o *Final*.

	GPM <i>Early</i>	GPM <i>Late</i>	GPM <i>Final</i>
Viés (mm)	40,23	21,75	5,33
RMS (mm)	76,39	74,02	39,16
d	0,65	0,67	0,86

6.2.2. Acurácia dos dados AIRS de Umidade Relativa do ar

A Figura 13 apresenta os dados de UR adquiridos pelo sensor AIRS a bordo do satélite Aqua, comparando-os a quatro estações meteorológicas convencionais no RS, para a safra 2015/16. Apenas os dados de aquisição noturna foram utilizados nessa análise, isso se deve ao fato de os dados diurnos subestimarem os valores em comparação às estações.

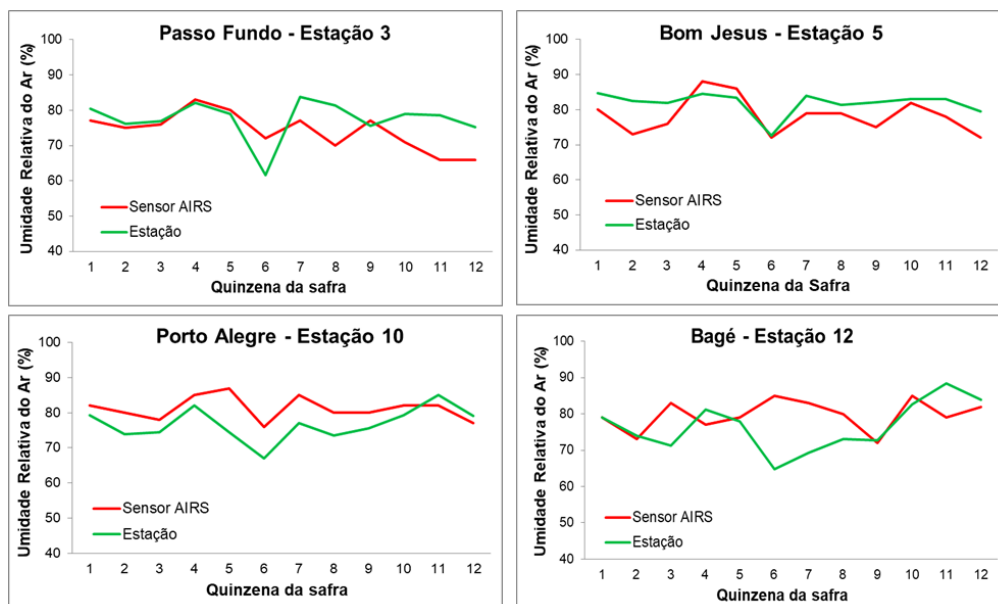


Figura 13: Séries temporais quinzenais dos dados de umidade relativa do ar adquiridos pelo sensor AIRS/Aqua e estações meteorológicas convencionais ao longo da safra 2015/16.

De forma geral, os dados noturnos do AIRS apresentaram valores muito próximos dos adquiridos pelas estações meteorológicas em todos os municípios. A Tabela 12 apresenta uma análise de acurácia de tais dados. Com relação ao Viés, é possível notar uma oscilação entre sub e superestimativas, com variações entre -4 a 4,43% de UR, dependendo do município. Já o RMS está em torno de 16% de UR, salvo no município de Porto Alegre, que apresentou RMS de 4,33%. Esse bom resultado é corroborado pelo teste de Wilmott, que apresentou um coeficiente de 0,67 para Porto Alegre, ao contrário dos demais municípios que apresentaram coeficientes que variaram de 0,25 a 0,41.

Esses resultados demonstram uma acurácia aceitável para os dados de UR obtidos pelo AIRS, podendo assim ser utilizado no modelo de estimativa de produtividade. A utilização de pixels adquiridos em diferentes estratos de altitude não alterou a qualidade dos dados, de forma que uma combinação dos dados em um mesmo modelo de produtividade não causaria discrepâncias entre as diferentes altitudes presentes na área de estudo.

Tabela 12: Análise de acurácia dos dados AIRS de aquisição noturna, em comparação aos dados observados por estações meteorológicas convencionais.

	Bagé	Passo Fundo	Porto Alegre	Bom Jesus
Viés (%)	3,00	-3,30	4,43	-4,00
RMS (%)	15,86	15,48	4,33	17,04
d	0,41	0,36	0,67	0,25

6.2.3. Estimativa e acurácia da temperatura do ar através do sensor MODIS

A temperatura do ar estimada através dos dados LST/MODIS foi obtida pela equação de ajuste da reta que é apresentada na Figura 14, juntamente com o gráfico de dispersão. É possível notar um bom agrupamento dos pontos ao redor da linha de ajuste, além de um R^2 de 0,86, demonstrando uma boa relação entre as duas fontes de dados.

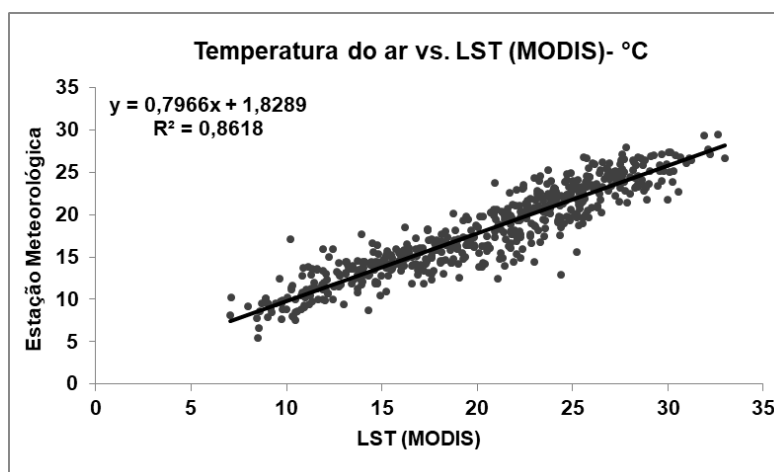


Figura 14: Diagrama de dispersão entre os dados de temperatura média LST do MODIS e de temperatura média do ar das estações meteorológicas convencionais para o RS para o ano de 2016.

A Figura 15 apresenta as séries temporais dos dados LST/MODIS, de temperatura do ar estimada pela equação de regressão e os dados observados para o ano de 2017, em quatro estações meteorológicas localizadas no RS. De acordo com Fu et al. (2011), as temperaturas diárias máximas e mínimas e as temperaturas médias diurnas e noturnas do ar podem ser mais bem explicadas pelos dados de LST do Terra (MOD11) do que pelo do Aqua (MYD11). Porém, no presente estudo, o algoritmo utilizado

para substituir os pixels contaminados por nuvens demonstrou-se de grande eficiência para representar os valores de temperatura observados, pois o uso combinado dos quatro momentos de passagem de ambos os satélites permite uma ampla representação espacial dos dados, diminuindo a probabilidade de ocorrerem falhas.

Nota-se que os dados de LST/MODIS acompanharam a variabilidade temporal dos dados de temperatura observados, embora estes sejam referentes à temperatura do ar a dois metros de altura, ao contrário das do sensor MODIS que fazem menção à temperatura da superfície. Este comportamento observou-se em todas as estações, demonstrando boa acurácia dos dados nas diferentes regiões do RS. Ademais, os dados derivados do MODIS possuem uma resolução espacial que originalmente é de 1 km, cobrindo toda a superfície do RS e os dados obtidos pelas estações são pontuais e esparsos.




Figura 15: Séries temporais de oito dias da temperatura média LST/MODIS e do ar estimada pela equação de regressão em comparação à observada pelas estações meteorológicas convencionais para o ano de 2017.

Os dados de LST/MODIS para 2017 apresentaram um Viés de 2,15 °C, indicando uma superestimativa em relação aos dados observados pelas estações do INMET. Já o teste de NS demonstrou um resultado de 0,33, sendo considerado *inaceitável*, de acordo com Silva et al. (2008). Tal

diferença já era esperada, pois o sensor MODIS adquire dados relativos à superfície, sendo estes ligeiramente superiores em relação à temperatura do ar a dois metros de altura, considerando que o ar se aquece e se eleva por convecção a partir do contato com o solo. Ao aplicar-se a equação de regressão para estimar a temperatura do ar a partir dos dados LST do MODIS para o ano de 2017, observou-se um melhor ajuste entre os dados, com um Viés de $-0,3$ °C e um coeficiente de NS 0,76, considerado *bom*, de acordo com Silva et al. (2008). Vale ressaltar que o teste de NS é muito rigoroso e tal resultado demonstra uma grande confiabilidade na informação. Kloog et al. (2014) também observaram uma melhora nas estimativas de temperatura do ar obtidas através da temperatura da superfície do sensor MODIS, quando esses dados são corrigidos através de um modelo matemático.

Os resultados apresentados na Figura 15 confirmam visualmente o que os testes de acurácia demonstram, visto que há um melhor ajuste da linha que representa a temperatura do ar estimada pela equação em relação aos dados observados pelas estações do INMET, quando em comparação aos dados LST do MODIS. Camparotto et al. (2013) corrigiram as discrepâncias entre os dados LST do sensor MODIS/Aqua e de temperatura do ar por meio de uma regressão linear entre os dados orbitais e de estações meteorológicas do estado de São Paulo. Segundo os autores, após a aplicação desta correção, foram observados melhores ajustes entre as séries temporais anuais de ambos os dados, obtendo erro médio absoluto de no máximo $1,3$ °C, no mês de novembro.

6.3. Validação do modelo de produtividade

Os resultados da análise de normalidade pelo teste de Shapiro-Wilk a 5% de significância para os modelos agrometeorológico e agrometeorológico-espectral e para os dados do IBGE, nas safras de 2016, 2017 e 2018, são apresentados na Tabela 13.

Tabela 13: Teste de normalidade de Shapiro-Wilk para os dados de produtividade do IBGE, modelo agrometeorológico e modelo agrometeorológico espectral, para as safras de 2016, 2017 e 2018.

	Safra	2016	2017	2018
IBGE RS	SW	0,871 ^{NN}	0,923 ^{NN}	0,944 ^N
	p-valor	0,001 ^{NN}	0,023 ^{NN}	0,088 ^N
IBGE norte	SW	0,905 ^N	0,895 ^N	0,936 ^N
	p-valor	0,096 ^N	0,068 ^N	0,303 ^N
Modelo agrometeorológico RS	SW	0,922 ^{NN}	0,908 ^{NN}	0,910 ^{NN}
	p-valor	0,021 ^{NN}	0,009 ^{NN}	0,010 ^{NN}
Modelo agrometeorológico norte	SW	0,907 ^N	0,886 ^{NN}	0,941 ^N
	p-valor	0,104 ^N	0,048 ^{NN}	0,365 ^N
Modelo agrometeorológico espectral norte	SW	0,890 ^N	0,878 ^{NN}	0,922 ^N
	p-valor	0,056 ^N	0,036 ^{NN}	0,183 ^N

N= normal a 5% de significância pelo teste de Shapiro-Wilk; NN= não normal a 5% de significância pelo teste de Shapiro-Wilk.

Levando em consideração que o valor da estatística tabelada para o teste de Shapiro-Wilk a 5% de significância, com número de 33 dados (microrregiões de todo o RS) é 0,931 e que para 16 dados (microrregiões da porção norte do RS) é 0,887, é possível avaliar a normalidade quando a estatística calculada destes supera o valor tabelado, aceitando a hipóteses H_0 . Também é possível analisar a normalidade dos dados através do p-valor, de modo que, quando este for maior que 0,05 de significância, os dados apresentam distribuição normal.

Desta forma, é possível concluir que os dados do IBGE para a porção norte do RS apresentaram normalidade em todas as safras analisadas, enquanto que na análise dos dados do IBGE em todo o RS, apenas a safra de 2018 apresentou normalidade. Já com relação aos resultados do modelo de produtividade, quando analisada a porção norte do RS, tanto para o modelo agrometeorológico, quanto para o agrometeorológico-espectral, somente a safra de 2017 não apresentou normalidade. Quando analisado

todo o RS, com os dados do modelo agrometeorológico, nenhuma das safras apresentou normalidade.

Na Figura 16 e 17 são apresentados os histogramas com a distribuição de frequência das produtividades do IBGE e modeladas, respectivamente. Também é apresentada em sobreposição a curva que representa uma distribuição normal para a mesma média e mesmo desvio padrão de cada um dos conjuntos de dados.

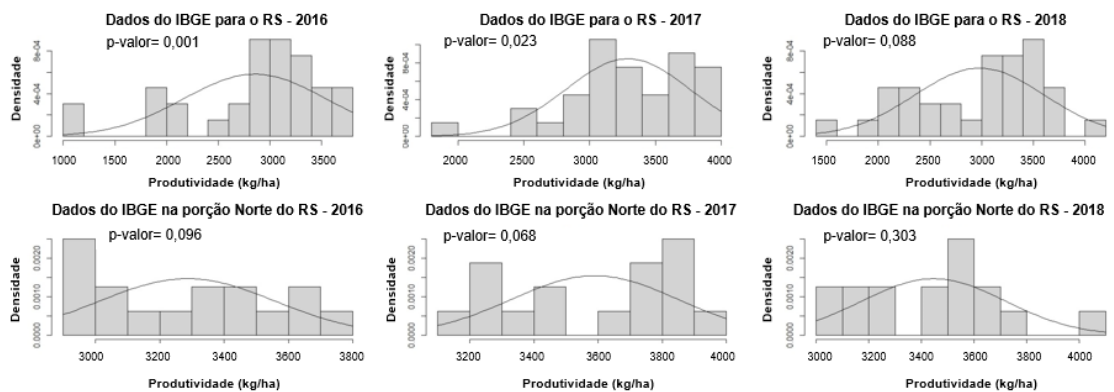


Figura 16: Histograma e curva normal para os dados de produtividade da soja obtidos pelo IBGE para o estado do RS e para a porção norte do RS, nas safras 2016, 2017 e 2018.

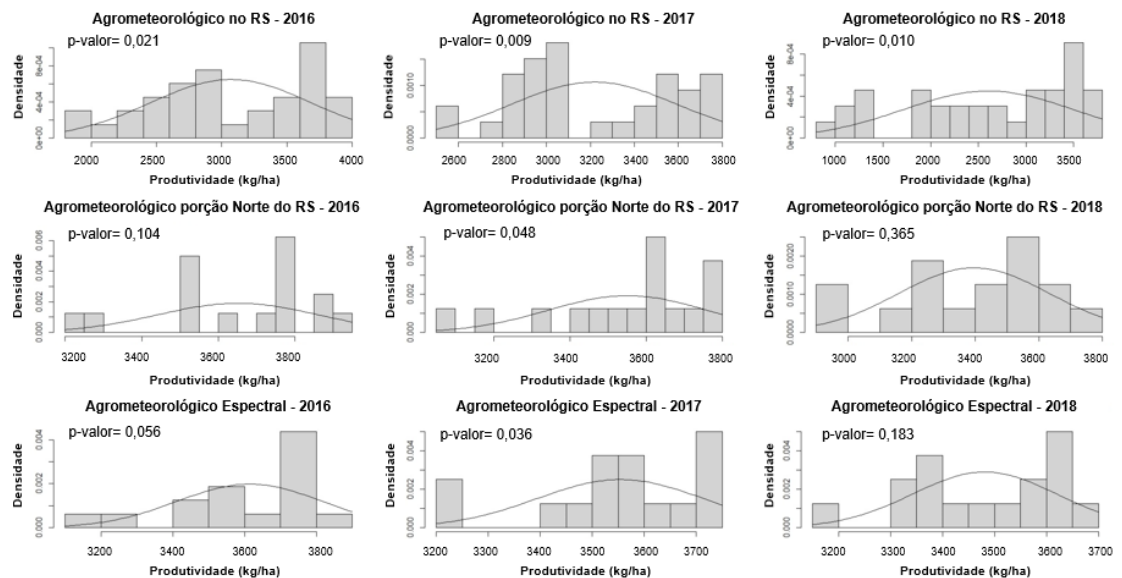


Figura 17: Histograma e curva normal para as produtividades da soja obtidas pelos modelos agrometeorológico para o RS, agrometeorológico para a porção norte do RS e modelo agrometeorológico espectral para a porção norte do RS, nas safras 2016, 2017 e 2018.

As distribuições normais para os dados do IBGE e para os dados modelados têm as interpretações reforçadas pelos seus respectivos histogramas. No caso dos dados do IBGE para a porção norte do RS, na safra de 2016, os dados se concentraram principalmente entre 3.000 e 3.400 kg ha⁻¹, na safra de 2017, entre 3.600 e 4.000 kg ha⁻¹ e na safra de 2018, entre 3.000 e 3.600 kg ha⁻¹. Para os dados do IBGE no RS, onde os dados foram normais somente para a safra 2018, as produtividades se concentraram principalmente entre 3.000 e 3.500 kg ha⁻¹. Da mesma forma, para o modelo agrometeorológico da porção norte do RS e agrometeorológico espectral, ambos para as safras de 2016 e 2018, houve concentrações das produtividades ao redor dos 3.800 kg ha⁻¹ e 3.600 kg ha⁻¹, respectivamente para as safras e em ambos os modelos.

De forma oposta, nas distribuições não normais, como no caso das produtividades obtidas em todas as safras pelo modelo agrometeorológico no RS, é possível notar que os dados se concentram em dois picos, o primeiro ao redor dos 3.000 kg ha⁻¹ e o segundo ao redor dos 3.800 kg ha⁻¹, tanto para a safra de 2016, quanto para a de 2017. Já para a safra de 2018, os dados se distribuem quase igualmente em todos os estratos, apenas com um pico em 3.500 kg ha⁻¹. Com relação aos modelos agrometeorológico e agrometeorológico espectral na porção norte, para o ano de 2017, notam-se concentrações mais deslocadas para a direita do histograma, ao redor dos 3.800 kg ha⁻¹. O mesmo caso também pode ser observado para os dados do IBGE de todo o RS.

Como grande parte dos dados não apresentou normalidade, optou-se por uma análise não paramétrica de similaridade, utilizando-se o teste de KS. Os resultados do teste de KS são apresentados na Tabela 14. De forma que, para que ambos os conjuntos de dados apresentem similaridade e a hipótese H_0 seja aceita, é necessário que o valor crítico seja maior que a estatística calculada do teste de KS. Sendo o valor crítico de 0,5 para os conjuntos de 16 dados (porção norte) e de 0,333 para os conjuntos de 33 dados (todo o RS). Também é possível analisar a similaridade dos dados através do p-valor, de modo que, quando este for maior que 0,05 de significância, não há indícios

suficientes para afirmar que existe diferença entre ambos os conjuntos de dados.

Tabela 14: Teste de Kolmogorov-Smirnov entre os dados de produtividade modelados e do IBGE.

Safr	Agro norte vs. IBGE norte		Espectral norte vs. IBGE norte		Agro RS vs. IBGE RS	
	KS	p-valor	KS	p-valor	KS	p-valor
2016	0,625*	0,003*	0,562*	0,011*	0,272 ^{NS}	0,172 ^{NS}
2017	0,375 ^{NS}	0,214 ^{NS}	0,437 ^{NS}	0,093 ^{NS}	0,303 ^{NS}	0,096 ^{NS}
2018	0,187 ^{NS}	0,952 ^{NS}	0,312 ^{NS}	0,426 ^{NS}	0,272 ^{NS}	0,172 ^{NS}

NS= Não difere significativamente; *Difere Significativamente a 5% de probabilidade pelo teste de Kolmogorov-Smirnov.

Os dados de produtividade estimados pelo modelo agrometeorológico e os dados do IBGE para as 33 microrregiões do RS foram estatisticamente iguais entre si a 5% de significância pelo teste de KS, para as três safras analisadas. Quando analisadas as 16 microrregiões pertencentes a porção norte do estado do RS, tanto para o modelo agrometeorológico, quanto para o agrometeorológico espectral, foram observadas similaridades com os dados do IBGE a 5% de significância pelo teste de KS, nas safras 2017 e 2018. Apenas a safra de 2016 apresentou diferença significativa entre os dados do IBGE e ambos os modelos. Rizzi & Rudorff (2007) também utilizaram um modelo de estimativa da produtividade para a cultura da soja no estado do RS, com base em dados de IAF tabelados e obtidos pelas imagens NDVI do sensor MODIS/TERRA, não encontrando diferença significativa entre as duas abordagens e os dados oficiais do IBGE, em duas das três safras analisadas.

6.4. Estimativa de produtividade pelos modelos agrometeorológico e agrometeorológico espectral

A Tabela 15 apresenta os dados de produtividade para a porção norte do RS, comparando os dados do IBGE com os modelos agrometeorológico e agrometeorológico espectral, nas safras de 2016, 2017 e 2018. A Tabela 16 demonstra a diferença entre estes modelos e os dados do IBGE, nas respectivas safras.

Tabela 15: Produtividade estimada pelos modelos agrometeorológico e agrometeorológico espectral (kg ha^{-1}) para a porção norte do RS, e disponibilizada pelo IBGE nas safras de 2016, 2017 e 2018.

Safras	2016			2017			2018		
	IBGE	Agro	Espec	IBGE	Agro	Espec	IBGE	Agro	Espec
Santiago	2.952	3.538	3.444	3.442	3.656	3.650	3.218	3.245	3.347
Cruz Alta	3.324	3.778	3.738	3.701	3.720	3.704	3.651	3.445	3.534
Soledade	2.977	3.522	3.555	3.481	3.490	3.527	3.419	3.231	3.432
Guaporé	3.494	3.253	3.260	3.822	3.095	3.206	3.621	2.994	3.326
Vacaria	3.614	3.234	3.158	3.823	3.158	3.227	3.500	2.967	3.196
Passo Fundo	3.509	3.508	3.529	3.820	3.340	3.427	3.551	3.241	3.393
Sananduva	3.635	3.509	3.458	3.809	3.414	3.547	3.712	3.180	3.370
Erechim	3.399	3.608	3.590	3.693	3.532	3.598	3.591	3.322	3.369
Não-Me-Toque	3.741	3.754	3.754	3.959	3.628	3.583	4.035	3.420	3.461
Santo Ângelo	3.035	3.859	3.674	3.282	3.776	3.734	3.230	3.587	3.558
Ijuí	3.466	3.865	3.866	3.784	3.773	3.723	3.567	3.596	3.634
Cerro Largo	2.992	3.930	3.774	3.238	3.780	3.705	3.092	3.536	3.556
Carazinho	3.270	3.710	3.756	3.746	3.577	3.583	3.584	3.547	3.625
Santa Rosa	3.130	3.796	3.781	3.279	3.636	3.547	3.038	3.651	3.606
Frederico Westphalen	3.049	3.762	3.776	3.392	3.607	3.642	3.160	3.641	3.650
Três Passos	2.982	3.798	3.714	3.163	3.638	3.457	3.166	3.739	3.634
Média	3.286	3.652	3.614	3.590	3.551	3.554	3.446	3.396	3.481
Desvio Padrão	271	209	202	258	208	160	272	236	138

Tabela 16: Diferença entre a produtividade estimada pelos modelos agrometeorológico e agrometeorológico espectral (kg ha^{-1}) para a porção norte do RS e a informada pelo IBGE, nas safras de 2016, 2017 e 2018.

Safras	2016		2017		2018	
	Agro - IBGE	Espec - IBGE	Agro - IBGE	Espec - IBGE	Agro - IBGE	Espec - IBGE
Santiago	586	492	214	208	27	129
Cruz Alta	454	414	19	3	-206	-117
Soledade	545	578	9	46	-188	13
Guaporé	-241	-234	-727	-616	-627	-295
Vacaria	-380	-456	-665	-596	-533	-304
Passo Fundo	-1	20	-480	-393	-310	-158
Sananduva	-126	-177	-395	-262	-532	-342
Erechim	209	191	-161	-95	-269	-222
Não-Me-Toque	13	13	-331	-376	-615	-574
Santo Ângelo	824	639	494	452	357	328
Ijuí	399	400	-11	-61	29	67
Cerro Largo	938	782	542	467	444	464
Carazinho	440	486	-169	-163	-37	41
Santa Rosa	666	651	357	268	613	568
Frederico Westphalen	713	727	215	250	481	490
Três Passos	816	732	475	294	573	468
Viés	366	329	-38	-36	-49	35

Com relação as médias de produtividade da porção norte do RS, de forma geral, ambos os modelos apresentaram boa capacidade de estimar os dados do IBGE de produtividade da soja. Entretanto, na safra de 2016, ambos os modelos superestimaram a média do IBGE, com diferenças de 366 kg ha^{-1} no agrometeorológico e 329 kg ha^{-1} no agrometeorológico espectral, sendo estas as maiores diferenças dentre as três safras analisadas. Em 2017, ambos os modelos subestimaram a média do IBGE, com diferenças de -38 kg ha^{-1} no agrometeorológico e -36 kg ha^{-1} no agrometeorológico espectral. Em 2018, houve subestimativa do modelo agrometeorológico (-49 kg ha^{-1}) e superestimativa do modelo agrometeorológico espectral (35 kg ha^{-1}). Ambos os modelos demonstraram sensibilidade com relação as variações interanuais de produtividade, acompanhando os dados do IBGE, com maiores

produtividades na safra de 2017 e menores em 2018. Esta sensibilidade também foi observada por Rizzi & Rudorff (2007), que aplicaram o modelo agrometeorológico espectral para a principal região produtora de soja do RS, detectando a queda de produtividade ocorrida na safra 2001/02.

Comparando os dois modelos, nota-se que o agrometeorológico espectral apresentou as maiores médias de produtividade, com exceção da safra de 2016, embora a diferença entre os modelos, nesta safra, tenha sido de apenas 38 kg ha⁻¹. A safra de 2018 apresentou as maiores diferenças entre as médias de produtividade dos modelos, 85 kg ha⁻¹, e a safra de 2017 a menor diferença 3 kg ha⁻¹.

A microrregião de Vacaria apresentou as menores produtividades para o modelo agrometeorológico, para as três safras analisadas, com menor produtividade em 2018 (2.967 kg ha⁻¹). No modelo agrometeorológico espectral, essa tendência também foi observada para as safras de 2016 e 2018, sendo que em 2017, a microrregião de Guaporé apresentou a menor produtividade (3.206 kg ha⁻¹), seguido de Vacaria (3.227kg ha⁻¹) como a segunda menor produtividade desta safra.

As microrregiões que apresentaram as maiores produtividades no modelo agrometeorológico são, Cerro Largo, em 2016 e em 2017, e Três Passos, em 2018. Já no modelo agrometeorológico espectral, as maiores produtividades para as safras 2016 e 2018 foram observadas em Ijuí e, na safra de 2017, em Santo Ângelo. No entanto, quando a área de cultivo de soja (Tabela 10) é analisada conjuntamente, nota-se que, dentre as microrregiões que apresentam as maiores produtividades, as que também apresentam as maiores áreas de cultivo de soja são, Cruz Alta (623.639 ha), Ijuí (376.533 ha) e Santo Ângelo (486.383 ha).

A Tabela 17 apresenta os dados de produtividade para a porção sul do RS, comparando os dados do IBGE com o modelo agrometeorológico, nas safras de 2016, 2017 e 2018. A Tabela 18 demonstra a diferença entre o modelo agrometeorológico e os dados do IBGE, nas respectivas safras.

Tabela 17: Produtividade estimada pelo modelo agrometeorológico para a porção sul do RS e disponibilizada pelo IBGE nas safras de 2016, 2017 e 2018.

Safra	2016		2017		2018	
	IBGE	Agro	IBGE	Agro	IBGE	Agro
Litoral Lagunar	1.819	1.981	1.824	2.566	2.444	919
Pelotas	1.149	2.458	3.095	2.961	1.840	1.363
Camaquã	1.958	2.561	2.879	3.027	2.145	1.943
Osório	3.049	2.579	3.247	2.895	3.135	2.524
São Jerônimo	2.970	2.762	2.949	2.973	2.400	2.311
Porto Alegre	2.685	2.819	2.952	3.041	2.581	2.603
Santa Cruz do Sul	3.211	2.837	3.670	2.997	3.356	2.385
Lajeado-Estrela	3.076	2.804	3.469	2.839	3.278	2.604
Jaguarão	1.009	1.923	3.049	2.850	1.551	1.013
Campanha Meridional	1.820	2.018	2.555	2.850	2.100	1.079
Serras de Sudeste	2.099	2.328	2.557	2.970	2.063	1.360
Campanha Central	2.146	2.393	2.634	2.933	2.287	1.258
Cachoeira do Sul	3.023	2.818	3.085	3.071	2.324	1.910
Santa Maria	2.766	2.788	3.170	3.008	2.739	2.034
Restinga Seca	2.961	2.812	3.173	3.056	2.892	2.052
Campanha Ocidental	2.544	2.724	3.088	2.766	2.673	1.923
Caxias do Sul	3.334	2.669	3.767	2.537	3.381	2.557
Média	2.448	2.545	3.010	2.902	2.541	1.873
Desvio Padrão	714	315	456	157	538	595

Tabela 18: Diferença entre a produtividade estimada pelo modelo agrometeorológico para a porção sul do RS e a informada pelo IBGE, nas safras de 2016, 2017 e 2018.

Safra	2016	2017	2018
Microrregiões	Agro - IBGE	Agro - IBGE	Agro - IBGE
Litoral Lagunar	162	742	-1.525
Pelotas	1.309	-134	-477
Camaquã	603	148	-202
Osório	-470	-352	-611
São Jerônimo	-208	24	-89
Porto Alegre	134	89	22
Santa Cruz do Sul	-374	-673	-971
Lajeado-Estrela	-272	-630	-674
Jaguarão	914	-199	-538
Campanha Meridional	198	295	-1.021
Serras de Sudeste	229	413	-703
Campanha Central	247	299	-1.029
Cachoeira do Sul	-205	-14	-414
Santa Maria	22	-162	-705
Restinga Seca	-149	-117	-840
Campanha Ocidental	180	-322	-750
Caxias do Sul	-665	-1.230	-824
Viés	97	-107	-668

Na porção sul do RS, o modelo agrometeorológico também apresentou boa capacidade de estimar as produtividades do IBGE. Embora, para a safra de 2018, tenha ocorrido uma subestimativa de 668 kg ha⁻¹, nas demais safras essa diferença foi menor, com superestimativa de 97 kg ha⁻¹ em 2016 e subestimativa de 107 kg ha⁻¹ em 2017.

O modelo apresentou sensibilidade em detectar as variações interanuais de produtividade, acompanhando tanto as elevações de produtividade de 2017, quanto às quedas de produtividade observadas nas safras de 2016 e 2018.

Com relação à safra de 2018, destaca-se que esse foi um ano de La Niña e que a porção sul do RS sofreu grandes perdas de produtividade para a cultura da soja. Neste sentido, o modelo agrometeorológico foi capaz de

detectar as grandes diferenças de produtividade existentes entre as porções norte e sul do RS.

As microrregiões da porção sul que apresentaram as menores produtividades modeladas foram: Jaguarão (1.923 kg ha^{-1}), Caxias do Sul (2.537 kg ha^{-1}) e Litoral Lagunar (919 kg ha^{-1}), respectivamente para as safras 2016, 2017 e 2018. Destaque pode ser dado ao Litoral Lagunar, por apresentar baixa produtividade nas três safras analisadas, assim como a microrregião de Jaguarão, que apresentou baixa produtividade nas safras 2016 e 2018. As microrregiões que apresentaram as maiores produtividades modeladas na porção sul do RS foram, Porto Alegre (2.819 kg ha^{-1}), Cachoeira do Sul (3.071 kg ha^{-1}) e Lajeado-Estrela (2.604 kg ha^{-1}), respectivamente para as safras 2016, 2017 e 2018.

A Tabela 19 apresenta a média e desvio padrão do modelo agrometeorológico para o estado do RS e para os dados do IBGE, nas safras de 2016, 2017 e 2018.

Tabela 19: Média e desvio padrão para o Modelo agrometeorológico no estado do RS e dados do IBGE, nas safras de 2016, 2017 e 2018.

	2016		2017		2018	
	Média	D. padrão	Média	D. padrão	Média	D. padrão
RS Agro	3.070	613	3.217	374	2.605	890
RS IBGE	2.854	686	3.291	471	2.980	625

Quando o modelo agrometeorológico é considerado para todo o estado do RS, as diferenças entre as produtividades modeladas e os dados do IBGE são de 216, -74 e -375 kg ha^{-1} , respectivamente para as safras 2016, 2017 e 2018. Assim como nas porções norte e sul, o modelo agrometeorológico continua apresentando a capacidade de acompanhar as variações interanuais de produtividade, pois detecta as menores produtividades observadas nas safras de 2016 e 2018, assim como o aumento da produtividade em 2017. Estes resultados reforçam a afirmativa de que o modelo detecta as variabilidades de produtividade, tanto em nível de porções norte e sul, quanto em nível estadual. De acordo com Monteiro et al. (2017), os erros sistemáticos em modelos de produtividade podem ser corrigidos por meio de calibração,

sendo importante observar a capacidade deste em quantificar a variabilidade da produtividade interanual. Assim, mais atenção é dada aos casos em que as produtividades observadas exibem tendência crescente ou decrescente, e os rendimentos estimados apresentam comportamento oposto, cujo qual é explicado por mudanças nas práticas de manejo da cultura, como cultivar utilizada, manejo do solo, adubação, etc.

Os mapas de produtividade para as safras 2016, 2017 e 2018, obtidos através do modelo agrometeorológico para a porção norte do RS, são apresentados nas Figuras 18, 19 e 20, respectivamente.

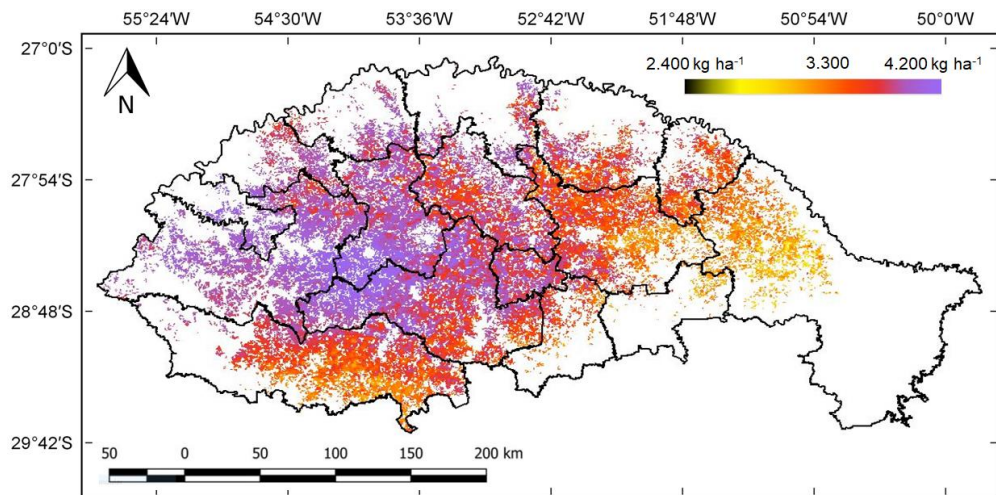


Figura 18: Mapa de produtividade obtido pelo modelo agrometeorológico para as áreas de cultivo de soja da porção norte do RS na safra 2016.

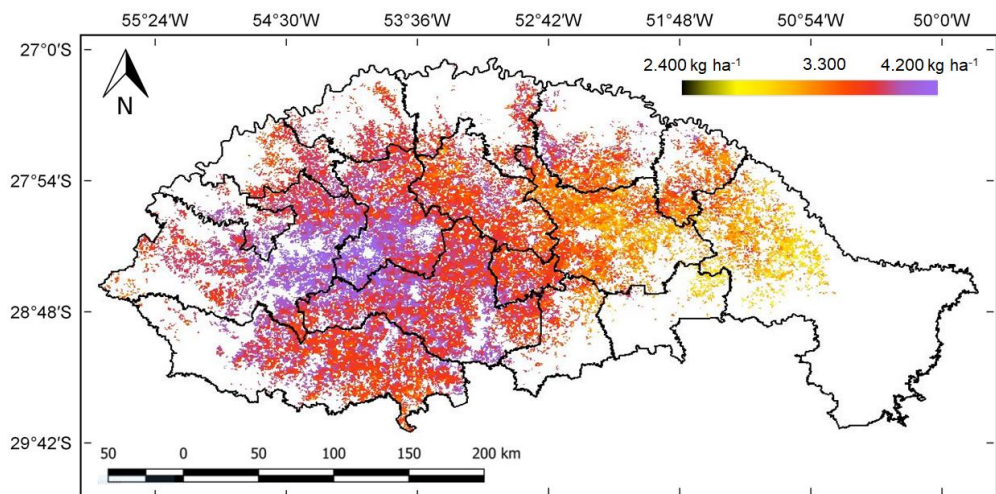


Figura 19: Mapa de produtividade obtido pelo modelo agrometeorológico para as áreas de cultivo de soja da porção norte do RS na safra 2017.

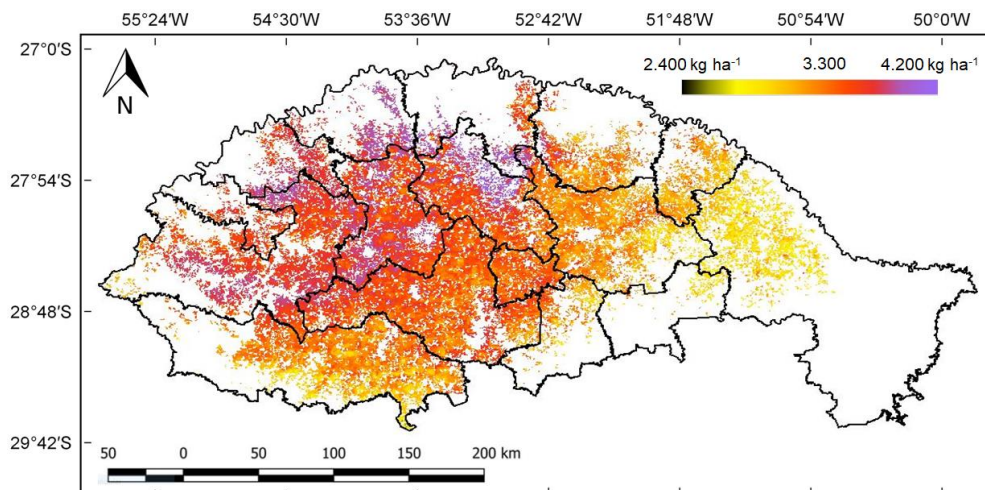


Figura 20: Mapa de produtividade obtido pelo modelo agrometeorológico para as áreas de cultivo de soja da porção norte do RS na safra 2018.

Os mapas de produtividade para as safras 2016, 2017 e 2018, obtidos através do modelo agrometeorológico espectral para a porção norte do RS, são apresentados nas Figuras 21, 22 e 23.

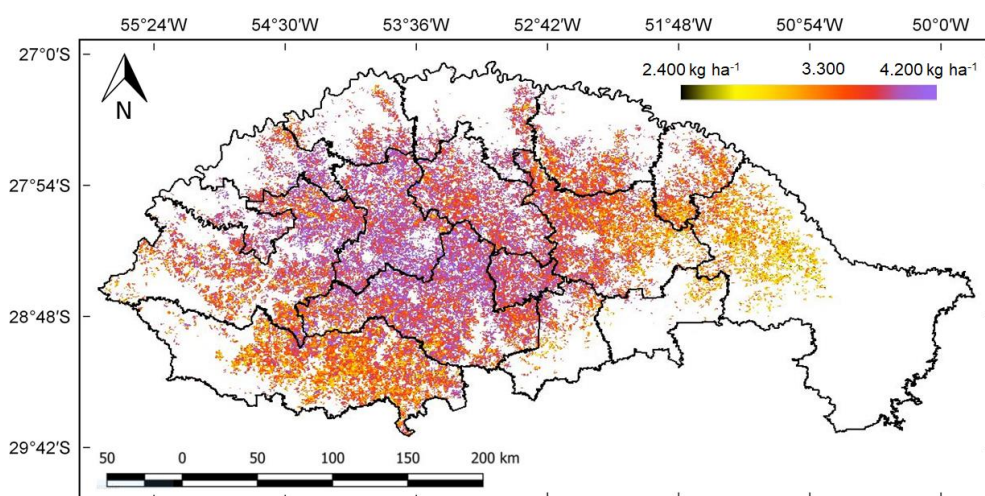


Figura 21: Mapa de produtividade obtido pelo modelo agrometeorológico espectral para as áreas de cultivo de soja da porção norte do RS na safra 2016.

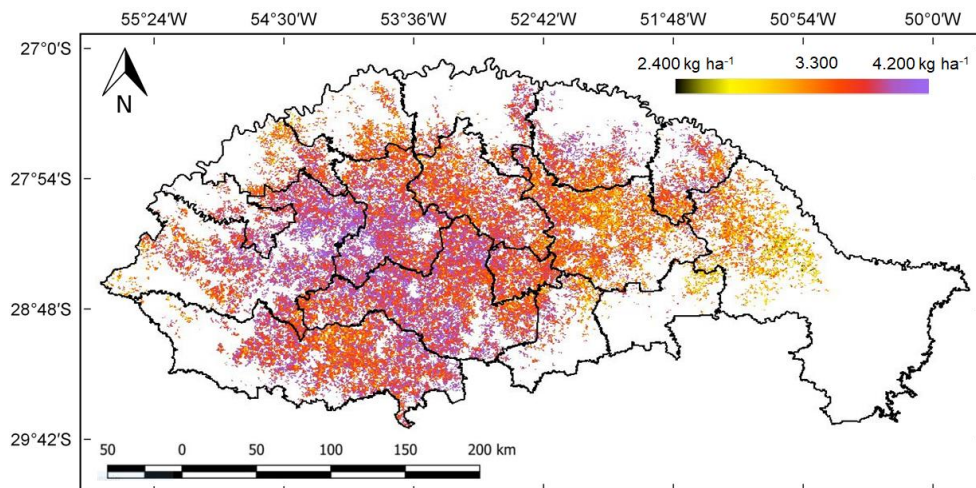


Figura 22: Mapa de produtividade obtido pelo modelo agrometeorológico espectral para as áreas de cultivo de soja da porção norte do RS na safra 2017.

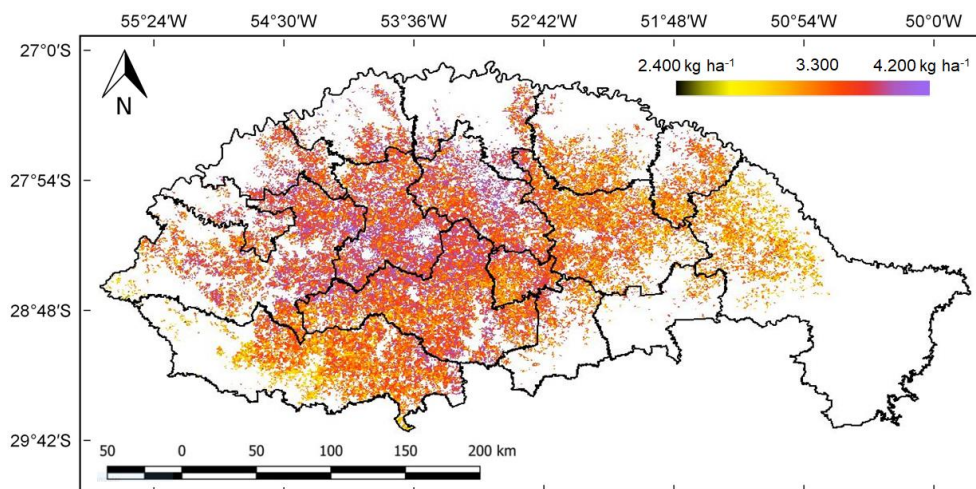


Figura 23: Mapa de produtividade obtido pelo modelo agrometeorológico espectral para as áreas de cultivo de soja da porção norte do RS na safra 2018.

Ao analisar os mapas de produtividade para o modelo agrometeorológico na porção norte do RS, nas áreas de cultivo de soja, observa-se que, para a safra de 2016, as maiores produtividades se localizaram na região centro e noroeste do estado, abrangendo principalmente as microrregiões de Cruz Alta, Santo Ângelo e Ijuí.

Em comparação a safra anterior, na safra de 2017, houve uma diminuição das áreas que apresentaram produtividades acima de 3.700 kg ha^{-1} , sendo que as produtividades mais altas concentraram-se nas microrregiões de Santo Ângelo e Ijuí. Embora a média de produtividade de 2016 seja maior do que a de 2017, o desvio padrão entre as safras de 2016 (209 kg ha^{-1}) e de

2017 (208 kg ha⁻¹) foi muito próximo, demonstrando que a variabilidade das produtividades entre as microrregiões, está próxima à média em ambas as safras.

Em 2018, uma safra de ocorrência de La Niña, as áreas de maiores produtividades se deslocaram para as regiões norte e noroeste do estado, principalmente para as microrregiões de Frederico Westphalen e Três Passos, embora Ijuí ainda apresente produtividades acima da média. O desvio padrão de 236 kg ha⁻¹ também reforça a maior variabilidade das produtividades entre as microrregiões.

Em todas as safras analisadas, as menores produtividades foram observadas na região nordeste do estado, principalmente na região de Vacaria, mas também na porção Leste das microrregiões de Passo Fundo e Guaporé. Esse resultado demonstra que existiu um gradiente de produtividade que se desloca e aumenta de nordeste para o centro e noroeste do estado.

O mapa referente ao modelo agrometeorológico espectral apresentou as mesmas tendências de distribuição espacial que o referente ao modelo agrometeorológico. Porém, o modelo agrometeorológico espectral demonstra maior variabilidade entre as áreas, como, na safra 2016, em que as regiões centro e noroeste do estado apresentaram, tanto áreas com produtividades próximas à média, quanto áreas com produtividades mais elevadas. Comparativamente, o modelo agrometeorológico apresentou para estas mesmas regiões, áreas com menor variabilidade e ao redor das elevadas produtividades.

A característica de maior variabilidade espacial das produtividades apresentada pelo modelo agrometeorológico espectral é causada pela variabilidade do IV, que representa a resposta da planta, não somente aos fatores meteorológicos, mas também aos fatores de solo e manejo da cultura. Por utilizar IAF tabelado, o modelo agrometeorológico não apresenta essas características, tendo apenas os fatores meteorológicos e de CAD como fonte de sua variabilidade espacial. Picoli et al. (2009) substituíram os dados de IAF espectral, por valores médios de IAF na cultura da cana-de-açúcar,

concluindo que, nestas condições o modelo não explica a variabilidade espacial da produtividade.

Uma análise conjunta entre os dois modelos pode constituir uma ferramenta importante ao monitoramento agrícola, visto que o modelo agrometeorológico pode indicar de forma mais generalizada as influências meteorológicas entre microrregiões, enquanto que o modelo agrometeorológico espectral pode apontar variabilidades dentro de cada microrregião. Esse tipo de ferramenta de análise pode guiar a atuação de técnicos e engenheiros agrônomos, que podem identificar falhas decorrentes de manejo em regiões específicas.

Ao analisar as falhas que impedem o alcance de altas produtividades, para a cultura da soja no Brasil, Sentelhas et al. (2015) concluíram que, para uma mesma faixa de evapotranspiração relativa durante a fase reprodutiva (0,65 a 0,70 mm), é possível observar uma grande variação de produtividades (de 2.900 a 5.000 kg ha⁻¹), demonstrando que as falhas de manejo (variabilidade do IAF) podem causar variabilidades de produtividade, mesmo que os fatores meteorológicos não variem.

Os mapas de produtividade obtidos pelo modelo agrometeorológico nas porções sul do RS, para as safras 2016, 2017 e 2018, são apresentados nas Figuras 24, 25, e 26, respectivamente.

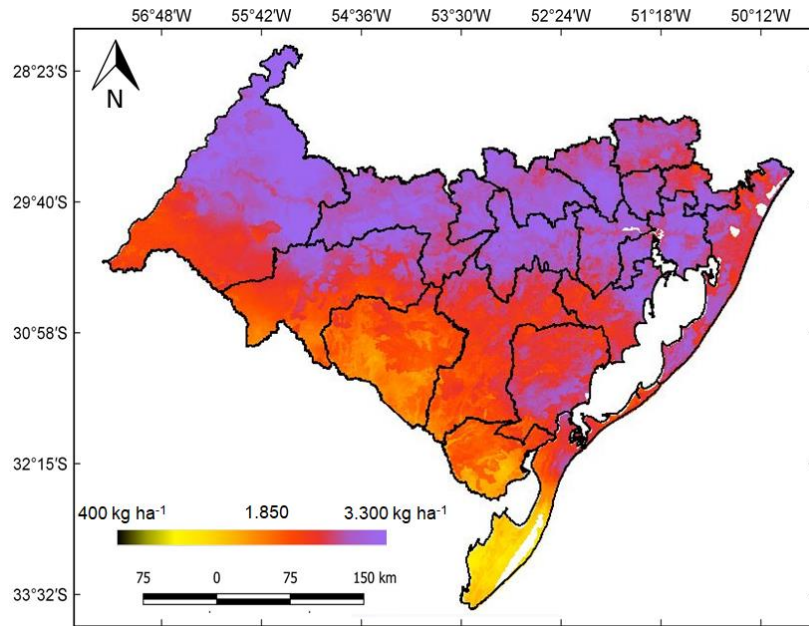


Figura 24: Mapa de produtividade obtido pelo modelo agrometeorológico para a porção sul do RS na safra 2016.

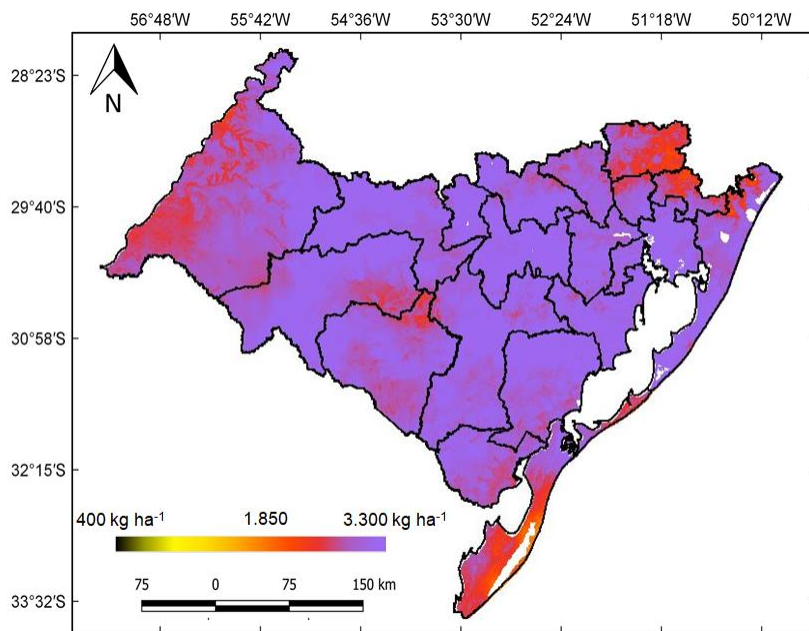


Figura 25: Mapa de produtividade obtido pelo modelo agrometeorológico para a porção sul do RS na safra 2017.

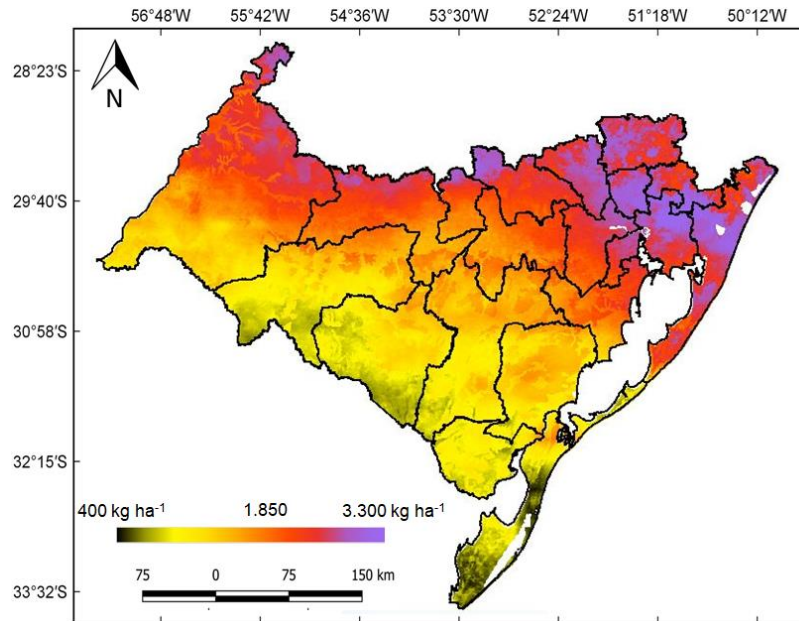


Figura 26: Mapa de produtividade obtido pelo modelo agrometeorológico para a porção sul do RS na safra 2018.

É necessário ressaltar que os modelos agrometeorológicos foram aplicados com fatores F_{pa} diferenciados entre as porções norte e sul do estado. Isto demonstrou eficiência em distinguir as características peculiares de cada porção do estado. Krüger et al. (2007) obtiveram bons resultados para o modelo de estimativa da produtividade da soja, ao dividir a porção norte do RS em três sub-regiões, caracterizadas por suas diferentes médias de produtividade, de forma que, foi possível ajustar o modelo independentemente para cada sub-região, representando adequadamente as diferenças de solo, clima e manejo da cultura dentro da grande região de produção de soja.

Ao comparar os mapas obtidos pelo modelo agrometeorológico, para as porções norte e sul do RS, é possível observar as grandes diferenças de produtividade entre as duas porções. A porção sul também apresenta maior variabilidade nos valores de produtividade, visto que o desvio padrão pode chegar a 595 kg ha^{-1} na safra de 2018, em comparação a porção norte que obteve um desvio padrão de 236 kg ha^{-1} , para a mesma safra, demonstrando maior estabilidade das produtividades ao redor das médias.

De modo geral, para a porção sul, as menores produtividades tendem a se concentrar na fronteira sul e Sudoeste, principalmente nas microrregiões

da Campanha central, Campanha Meridional, Serra do Sudeste, Jaguarão e Litoral Lagunar. Esta região se caracteriza por solos hidromórficos e pouco profundos, com baixa CAD. Ao avaliar o desempenho da cultura da soja em solos hidromórficos (município de Cachoeirinha) e não-hidromórficos (município de Santa Maria), com e sem irrigação, Rocha et al. (2017) observaram valores mais baixos da taxa fotossintética e condutância estomática em Cachoeirinha, indicando que as plantas são mais vulneráveis ao estresse hídrico do solo em ambientes hidromórficos, mesmo em anos com chuvas regulares e bem distribuídas.

De forma oposta, as maiores produtividades concentram-se no Centro e Leste do estado, tornando evidente um gradiente de produtividade que se desloca de Leste para Sul e Sudoeste, em direção as menores produtividades. Esse gradiente de produtividade também é encontrado por Cunha et al. (2001) no zoneamento climático para a cultura da soja no RS.

No entanto, a safra de 2017 para a porção sul apresentou uma distribuição mais homogênea das produtividades em toda a área, com médias mais altas e com uma atenuação do gradiente de produtividade. Em comparação à porção norte, também é possível observar uma diminuição das variabilidades, assim como uma média de produtividade mais elevada.

A safra de 2018, ano de La Niña, apresentou a maior discrepância entre as duas porções do estado, uma diferença de 1.523 kg ha⁻¹ entre as médias de produtividade das duas regiões. Pelo mapa da porção sul nesta safra, é possível verificar o agravamento das quedas de produtividade na fronteira Sul e Sudoeste, com produtividades mais elevadas concentrando-se no Leste do estado.

6.5. Monitoramento espacial e temporal por meio do Índice de Penalização

As Figuras 27, 28 e 29 apresentam os mapas com a distribuição do IP acumulado, na porção norte do RS, para as safras 2016, 2017 e 2018, respectivamente.

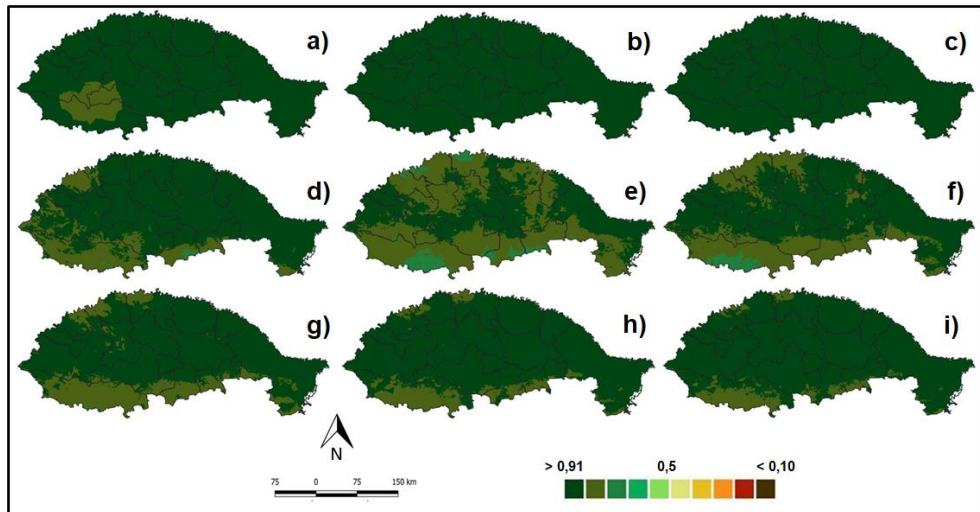


Figura 27: Índice de penalização acumulado para a porção norte do RS na safra 2016. a) quinzena 1, b) quinzena 2, c) quinzena 3, d) quinzena 4, e) quinzena 5, f) quinzena 6, g) quinzena 7, h) quinzena 8, i) quinzena 9.

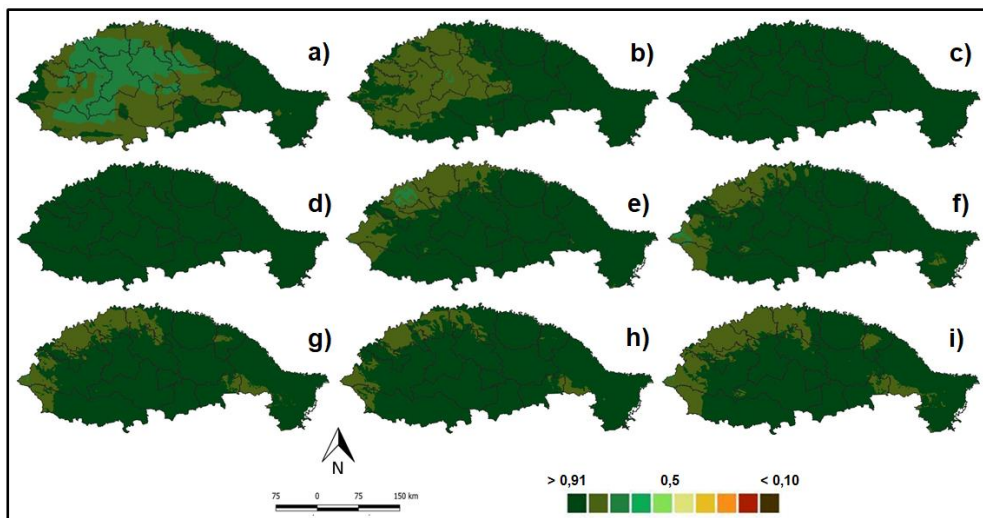


Figura 28: Índice de penalização acumulado para a porção norte do RS na safra 2017. a) quinzena 1, b) quinzena 2, c) quinzena 3, d) quinzena 4, e) quinzena 5, f) quinzena 6, g) quinzena 7, h) quinzena 8, i) quinzena 9.

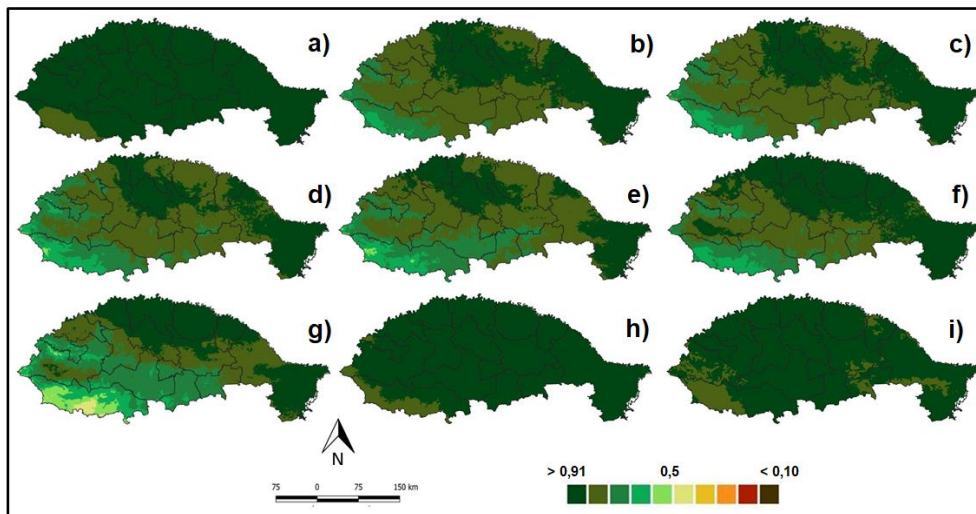


Figura 29: Índice de penalização acumulado para a porção norte do RS na safra 2018. a) quinzena 1, b) quinzena 2, c) quinzena 3, d) quinzena 4, e) quinzena 5, f) quinzena 6, g) quinzena 7, h) quinzena 8, i) quinzena 9.

As Figuras 30, 31 e 32 apresentam os mapas com a distribuição do IP acumulado, na porção sul do RS, para as safras 2016, 2017 e 2018, respectivamente.

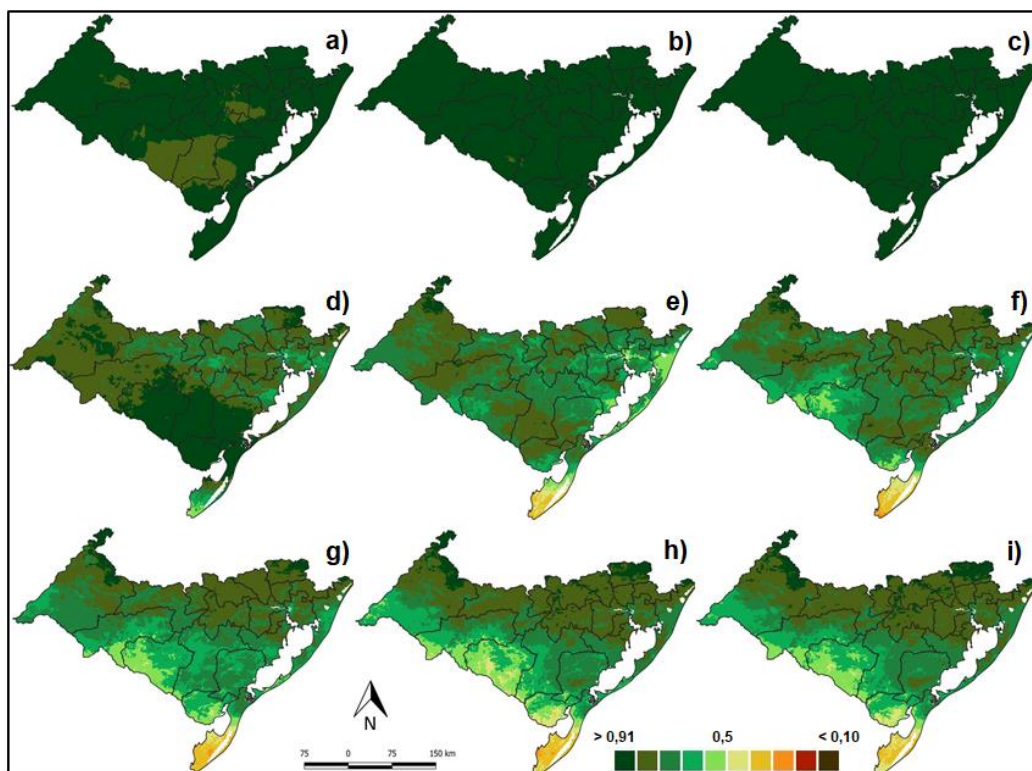


Figura 30: Índice de penalização acumulado para a porção sul do RS na safra 2016. a) quinzena 1, b) quinzena 2, c) quinzena 3, d) quinzena 4, e) quinzena 5, f) quinzena 6, g) quinzena 7, h) quinzena 8, i) quinzena 9.

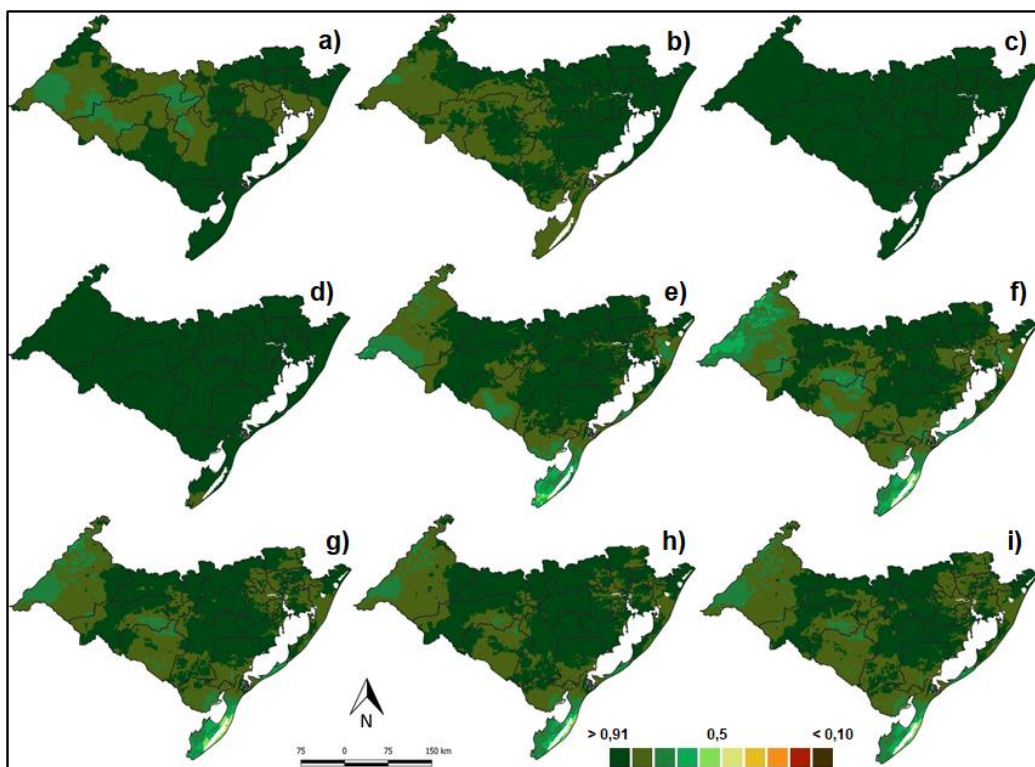


Figura 31: Índice de penalização acumulado para a porção sul do RS na safra 2017. a) quinzena 1, b) quinzena 2, c) quinzena 3, d) quinzena 4, e) quinzena 5, f) quinzena 6, g) quinzena 7, h) quinzena 8, i) quinzena 9.

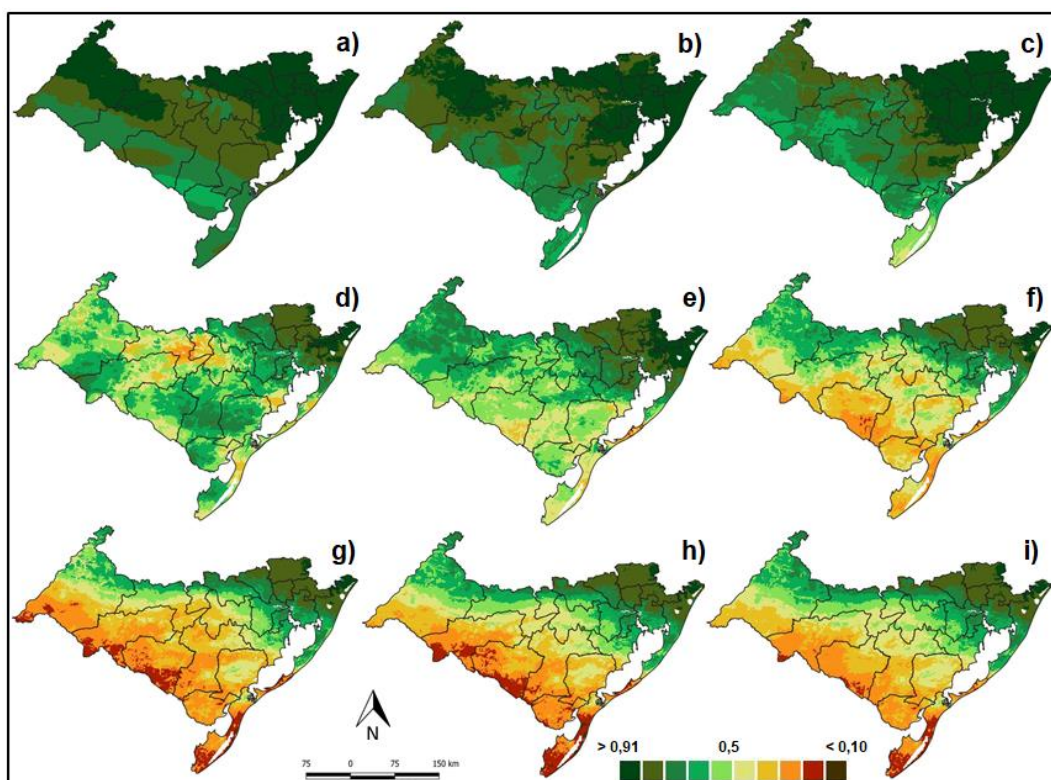


Figura 32: Índice de penalização acumulado para a porção sul do RS na safra 2018. a) quinzena 1, b) quinzena 2, c) quinzena 3, d) quinzena 4, e) quinzena 5, f) quinzena 6, g) quinzena 7, h) quinzena 8, i) quinzena 9.

Para o IP acumulado na porção norte do RS, para a safra de 2016, houve pouca penalização nas três primeiras quinzenas. Os danos meteorológicos que ocorreram a partir da quinzena 4, nas regiões Noroeste e Centro do estado, tenderam a se expandir na quinzena 5 e 6, alcançando, em algumas regiões, IPs de 0,7 (30% de perda no potencial produtivo). A partir deste ponto, iniciou-se uma recuperação em toda porção norte do estado, de modo que, na quinzena 9, os menores IPs acumulados se concentraram nas regiões mais centrais do estado.

A safra de 2017 para a porção norte demonstrou danos meteorológicos já nas quinzenas 1 e 2, com IPs de 0,7 a 0,8 (30 a 20%, respectivamente, de perda no potencial produtivo) nas regiões norte e Noroeste do estado. Os danos apresentaram retração de área nas quinzenas seguintes, concentrando-se na região Noroeste do estado, com IP de 0,8.

Na safra de 2018 para a porção norte do estado, os danos climáticos se prolongaram da quinzena 2 até a 7, que por consequência, acumulou os maiores danos, com IPs de 0,4 a 0,5 (60 a 50%, respectivamente, de perda no potencial produtivo) na região Oeste do estado.

Ao comparar o IP aos mapas de produtividade, nota-se que a microrregião de Vacaria apresentou as menores produtividades em todas as safras. Porém, os IPs alcançaram valores de 0,9 a 1,0, portanto, sem grades restrições climáticas. Embora, estas informações pareçam contraditórias, isto significa que o potencial produtivo desta microrregião é baixo, ou seja, baixa PM. Ainda que as restrições climáticas desta região não sejam elevadas, como também demonstrado por Cunha et al. (2001), com baixa PM, a microrregião produz tanto o quanto é possível.

Essa resposta pode ser explicada por temperaturas médias mais baixas e, por consequência, menores valores de Taxa de produção de matéria seca para a cultura em função da temperatura (y_m) (Equações 23, 24 e 25). Para a microrregião de Vacaria, comparativamente as demais microrregiões, estes fatores foram baixos em todas as quinzenas e consequentemente, reduziram a PM.

A porção sul do RS sofreu as maiores penalizações, principalmente nas regiões da fronteira sul e Sudoeste do estado. Essas penalizações ocorreram em todas as safras analisadas, tendo menor impacto para a safra de 2017 e maior intensidade na safra de 2018.

Para a safra de 2016, IPs de 0,6 a 0,7 começaram a ocorrer a partir da quinzena 4, tornando-se mais graves nas quinzenas seguintes, de modo que a quinzena 9 apresentou IPs de 0,2 a 0,4 (80 a 60% de perda no potencial produtivo) nas regiões mais ao sul do estado e de 0,5 a 0,6 no Sudoeste.

Na safra de 2018, os efeitos da La Niña causaram grandes penalizações para a cultura da soja, começando na quinzena 1, apresentando um agravamento a partir da quinzena 4 e se prolongando até a quinzena 9. As quinzenas 7, 8 e 9 apresentaram IPs de 0,2 a 0,5, predominando em mais da metade da área do estado e se concentrando na região central da porção sul. Algumas regiões das fronteiras sul e sudoeste apresentaram IPs de 0,1 a 0,2 (90 a 80% de perda no potencial produtivo).

De acordo com Anderson et al. (2016), ao acumular os índices de estresse à seca em janelas de tempo, quanto maior o intervalo das janelas (semanas acumuladas), maior a sua correlação com a produtividade, podendo assim, predizer melhor os eventos de seca, embora, quanto maior o número de semanas acumuladas, maior é o atraso para a detecção desses eventos.

7. Conclusões

O mapa de soja para a porção norte do RS apresentou uma área de 3.720.619 ha no ano de 2015. Uma diferença de 42.367 ha (1,15%) em relação aos dados oficiais disponibilizados pelo IBGE.

Os dados de precipitação estimados pelo sistema GPM EMERG *Final* apresentaram o menor Viés (5,33 mm) e maior coeficiente d (0,86), em relação aos produtos EMERG *Early* e EMERG *Late*, quando comparados aos observados por uma estação meteorológica convencional, sendo portanto, escolhidos para compor o modelo.

Os dados de UR estimados a partir do sensor AIRS de passagem noturna apresentaram Viés variando de -4,00 a 4,43%, em relação aos observados por estações meteorológicas convencionais, sendo considerados aceitáveis para sua utilização no modelo.

Os dados de temperatura de superfície do MODIS estimaram os dados de temperatura do ar observados pelas estações meteorológicas convencionais com exatidão satisfatória para utilização no modelo, apresentando um $R^2 = 0,86$, Viés de $-0,3 \text{ }^\circ\text{C}$ e coeficiente de NS de 0,76.

O modelo agrometeorológico, quando aplicado para todo o RS, demonstrou similaridade aos dados do IBGE pelo teste de KS, para $\alpha=0,05$. Quando analisado apenas a porção norte do RS, tanto para o modelo agrometeorológico, quanto para o agrometeorológico espectral, foram observadas similaridades com os dados do IBGE pelo teste de KS, nas safras 2017 e 2018; apenas a safra de 2016 apresentou diferença significativa entre os dados modelados e os do IBGE, em ambos os modelos.

Com relação ao IP, a porção norte foi pouco penalizada, com IPs de 0,7 a 0,8 na região Oeste. A porção sul obteve as maiores quedas de potencial produtivo na safra de 2018 (90 a 80%), sendo as fronteiras sul e Sudoeste as regiões mais prejudicadas.

O modelo proposto, que utiliza majoritariamente dados meteorológicos e espectrais oriundo de sensores orbitais, mostrou ser uma eficiente ferramenta de auxílio para monitorar e estimar a produtividade da soja no RS.

Referências

ANDERSON, Martha C. *et al.* Comparison of satellite-derived LAI and precipitation anomalies over Brazil with a thermal infrared-based Evaporative Stress Index for 2003–2013. **Journal of Hydrology**, v. 526, p. 287-302, 2015.

ANDERSON, Martha C. *et al.* The Evaporative Stress Index as an indicator of agricultural drought in Brazil: An assessment based on crop yield impacts. **Remote Sensing of Environment**, v. 174, p. 82-99, 2016.

AGROLINK. **Cotações históricas da soja (saco de 60 Kg) para o Rio grande do Sul.** Disponível em: <https://www.agrolink.com.br/cotacoes/historico/rs/soja-em-grao-sc-60kg>. Acesso: 10 novembro 2020.

ARAUJO, Marla Alessandra; SOUZA, Jorge Luiz Moretti de; TSUKAHARA, Rodrigo Yoití. Modelos agro-meteorológicos na estimativa da produtividade da cultura da soja na região de Ponta Grossa, Estado do Paraná. **Acta Scientiarum. Agronomy**, Maringá, v. 33, n. 1, p. 23-31, 2011.

ALLEN, Richard G.; PEREIRA, Luis S.; RAES, Dirk; SMITH, Martin. **Crop evapotranspiration** - Guidelines for computing crop water requirements. Food and Agriculture Organization of the United Nations, Rome, 1998. 300 p. (FAO Irrigation and drainage paper 56).

ALLIPRANDINI, Luís Fernando *et al.* Understanding soybean maturity groups in Brazil: environment, cultivar classification, and stability. **Crop Science**, Madison, v. 49, n. 3, p. 801-808, 2009.

ÁVILA, Ana Maria Heuminski de; BERLATO, Moacir Antônio; SILVA, João Baptista da; FONTANA, Denise Cybis. Probabilidade de ocorrência de precipitação pluvial mensal igual ou maior que a evapotranspiração potencial para a estação de crescimento das culturas de primavera-verão no estado do Rio Grande do Sul. **Pesquisa Agropecuária Gaúcha**, v. 2, n. 2, p. 149-154, 1996.

BERGAMASCHI, Homero *et al.* Estimating maize water requirements using agrometeorological data. **Revista Argentina de Agrometeorologia**, v.1, p. 23-27, 2001.

BERLATO, Moacir Antônio; MATZENAUER, Ronaldo; Bergamaschi, Homero. Evapotranspiração máxima da soja e relações com a evapotranspiração calculada pela equação de Penman, evaporação do tanque “classe A” e radiação solar global. **Agronomia Sulriograndese**, Porto Alegre, v. 22, n. 2, p. 243-256. 1986.

BERLATO, Moacir Antônio; FONTANA, Denise Cybis; GONÇALVES, Hélio M. Relação entre o rendimento de grãos de soja e variáveis meteorológicas. **Pesquisa Agropecuária Brasileira**, Brasília, v. 27, n. 5, p. 695-702, 1992.

BERLATO, Moacir Antônio; FONTANA, Denise Cybis. Variabilidade interanual da precipitação pluvial e rendimento da soja no estado do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 7, n. 1, p. 119-125, 1999.

BELWARD, Alan S.; SKOEN, Jon O. Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. **ISPRS Journal of Photogrammetry and Remote Sensing**, n. 103, p. 115-128, 2014.

BRASIL - Ministério da Agricultura. Departamento Nacional de Pesquisa Agropecuária. Divisão de Pesquisa Pedológica. **Levantamento de reconhecimento dos solos do Estado do Rio Grande do Sul**. Recife, 1973, 431 p. (DNPEA. Boletim técnico n. 30). Escala 1:750.000.

CÂMARA, Gilberto; SOUZA, Ricardo Cartoxo Modesto; FREITAS, Ubirajara Moura; GARRIDO, Juan. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v.20, n.3, p.395-403, 1996.

CAMARGO, Ângelo Paes de. Contribuição para a determinação da evapotranspiração potencial no Estado de São Paulo. **Bragantia**, Campinas, v.21, p.163-213, 1962.

CAMARGO, Marcelo Bento Paes de; BRUNINI, Orivaldo; JUNIOR, Mário José Pedro; BARDIN, Ludmila. Variabilidade espacial e temporal de dados termoplúviométricos diários da rede de estações agrometeorológicas do instituto agrônomo (IAC). **Bragantia**, Campinas, v. 64, n. 3, p. 473-483, 2005.

CAMPAROTTO, Ludmila Bardin *et al.* Validação de dados termoplúviométricos obtidos via sensoriamento remoto para o Estado de São Paulo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 6, p. 665–671, 2013.

CERA, Jossana Ceolin. *et al.* Soybean yield in future climate scenarios for the state of Rio Grande do Sul, Brazil. **Pesquisa Agropecuária Brasileira**, Brasília, v. 52, n. 6, p. 380-392, 2017.

COLLISCHONN, Bruno; ALLASIA, Daniel; COLLISCHONN, Walter; TUCCI, Carlos Eduardo Morelli. Desempenho do satélite TRMM na estimativa de

precipitação sobre a bacia do Paraguai superior. **Revista Brasileira de Cartografia**, Porto Alegre, v. 59, n. 01, p. 93-99, 2007.

CONAB - Companhia Nacional de Abastecimento. **Séries históricas**. Disponível em: <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras?start=30>. Acesso: 10 novembro 2020.

CONAB - Companhia Nacional de Abastecimento. **Calendário de Plantio e Colheita de Grãos no Brasil 2019**. Brasil, 2019, 73 p.

CUNHA, Gilberto Rocca da; ASSAD, Eduardo Delgado. Uma visão geral do número especial da RBA sobre zoneamento agrícola no Brasil. **Revista Brasileira de Agrometeorologia**, Passo Fundo, v. 9, n. 3, p. 377-385, 2001.

CUNHA, Gilberto Rocca da *et al.* Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, Passo Fundo, v. 9, n. 3, p. 446-459, 2001.

DOOREMBOS, J.; KASSAM, A. H. **Yield response to water**. Food and Agriculture Organization of the United Nations. Rome, 1979, 193 p. (FAO-Irrigation and Drainage Paper n. 33).

D'OLIVEIRA, Augusto Brandão; ANGELIS, Carlos Frederico de; ARAI, Nelson; MACHADO, Luiz Augusto Toledo. Estimativas de precipitação por microondas passivas com ênfase na participação brasileira no GPM. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 16., 2010, Belém. **Anais [...]**. Belém: 2010. p.1 - 5.

EL-SHIRBENY, Mohammed A.; ALI, A. M.; RASHASH, A; BADR, M. A. Wheat Yield Response to Water Deficit under Central Pivot Irrigation System Using Remote Sensing Techniques. **World Journal of Engineering and Technology**. v. 3, p. 65-72, 2015.

FARIAS, José Renato Bouças; NEPOMUCENO, Alexandre Lima.; NEUMAIER, Norman; OYA, Tetsuji. Ecofisiologia. In: Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). **A cultura da soja no Brasil**. Londrina: Embrapa Soja, 2000.

FARIAS, José Renato Bouças; NEPOMUCENO, Alexandre Lima.; NEUMAIER, Norman. **Ecofisiologia da Soja**. Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Londrina: Embrapa Soja, 2007.

FONTANA, Denise Cybis; BERLATO, Moacir Antônio; BERGAMASCHI, Homero. Alterações micrometeorológicas na cultura da soja submetida a

diferentes regimes hídricos. **Pesquisa Agropecuária Brasileira**, Brasília, v. 27, n. 5, p. 661-669. 1992.

FONTANA, Denise Cybis; BERLATO, Moacir Antônio; LAUSCHNER, Marcio Henrique; MELLO, Ricardo Wanke de. Modelo de estimativa de rendimento de soja no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, Brasília, v. 36, n. 3, p. 399-403, 2001.

FU, Gang *et al.* Estimating air temperature of an alpine meadow on the Northern Tibetan Plateau using MODIS land surface temperature. **Acta Ecologica Sinica**, v. 31, p. 8-13, 2011.

GUSSO, Aníbal; DUCATI, Jorge Ricardo; VERONEZ, Mauricio Roberto; INOCÊNCIO, Leonardo Campos. Avaliação do Impacto de Ondas de Calor em Safras de Verão por Integração de Dados dos Satélites Aqua e Terra/MODIS. **Revista Brasileira de Geografia Física**. v. 7, n. 1, p. 01-16, 2014.

HE, Mingzhu *et al.* Regional Crop Gross Primary Productivity and Yield Estimation Using Fused Landsat-MODIS Data. **Remote Sensing**. v. 10, n. 372, 2018.

HIRAKURI, Marcelo Hiroshi; LAZZAROTO, Joelsio José. **O agronegócio da soja nos contextos mundial e brasileiro**. Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Londrina: Embrapa Soja, 2014. 70 p.

HOU, A. Y. *et al.* The global precipitation measurement mission: an international satellite mission to unify and advance precipitation measurements from space for scientific research and societal applications is described. **Bulletin of the American Meteorological Society**. v. 95, n. 5, p. 701-722, 2014.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Divisão Regional do Brasil - Microrregiões Geográficas - 1989**. Rio de Janeiro, 1990. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/divisao-regional/15778-divisoes-regionais-do-brasil.html?edicao=16163&t=downloads>. Acesso: 01 de agosto de 2020.

IBGE - Instituto Brasileiro de Geografia e Estatística. Disponível em: <https://sidra.ibge.gov.br/tabela/1612>. Produção Agrícola Municipal. Acesso em: 10 de outubro 2020.

INMET - Instituto Nacional de Meteorologia. Disponível em: <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>. Acesso: 20 de novembro 2018.

JACKSON, Ray D. Remote Sensing of Vegetation Characteristics for Farm Management. **Remote Sensing**. v. 475, 1984.

JENSEN, John R. **Sensoriamento Remoto do Ambiente**: Uma perspectiva em recursos terrestres. 2011, 2 ed. Tradução Epiphany J.C.N et al. São José dos Campos, SP: Parêntese, 2009, p. 598.

JOHNSON David M. An assessment of pre- and within-season remotely sensed variables for forecasting corn and soybean yields in the United States. **Remote Sensing of Environment**. v. 141, p. 116-128, 2014.

KHAN, Amir Zaman *et al.* Seed quality and vigor of soybean cultivars as influenced by canopy temperature. **Pakistan Journal of Botany**. v. 43, n. 1, p. 643-648, 2011.

KLOOG, Itai; NORDIO, Francesco; COULL, Brent A.; SCHWARTZ, Joel. Predicting spatiotemporal mean air temperature using MODIS satellite surface temperature measurements across the Northeastern USA. **Remote Sensing of Environment**, v. 150, p. 132-139, 2014.

KRÜGER, Cleusa Adriane Menegassi Bianchi; FONTANA, Denise Cybis; MELO, Ricardo Wanke de. Estimativa do rendimento de grãos da soja no Rio Grande do Sul usando um modelo agrometeorológico-espectral regionalizado. **Revista Brasileira de Agrometeorologia**, Piracicaba, v. 15, n. 3, p. 210-219, 2007.

LEMOS, Gabriel da Silva *et al.* Acurácia do sistema GPM na estimativa da precipitação pluvial em Pelotas/RS. *In*: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 22., 2017, Florianópolis. **Anais [...]**. Florianópolis: ABRH, 2017. Disponível em: <http://anais.abrh.org.br/works/2358>. Acesso: 25 de novembro 2020.

LI, Ainong; LIANG, Shunlin; WANG, Angsheng; QIN, Jun. Estimating Crop Yield from Multi-temporal Satellite Data Using Multivariate Regression and Neural Network Techniques. **Photogrammetric Engineering & Remote Sensing**, v. 73, n. 10, p. 1149-1157, 2007.

MACHADO JÚNIOR, Carlos Sebastião; DA SILVA, Cláudio Ricardo; SANCHES, Maria Cristina; HAMAWAKI, Osvaldo Toshiyuki; SOUSA, Larissa Barbosa de. Physiologic parameters of soybean of determinate and indeterminate growth habit subjected to levels of soil moisture. **Pesquisa Agropecuária Brasileira**, v.52, n.6, p. 419-425, 2017.

MAGALHÃES JÚNIOR, Ariano Martins de; GOMES, Algenor da Silva; SANTOS, Alberto Baêta dos. **Sistema de Cultivo de Arroz Irrigado no Brasil**. Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Pelotas: Embrapa Clima Temperado, 2004. 270 p.

MAPA - Ministério da Agricultura, Pecuária e Abastecimento. **Zoneamento Agrícola de Risco Climático para a cultura de soja no Estado do Rio Grande do Sul, ano-safra 2020/2021**. Portaria nº 159, de 28 de maio de 2020.

MATZENAUER, Ronaldo. *et al.* **Consumo de água e disponibilidade hídrica para milho e soja, no Rio Grande do Sul**. Porto Alegre: FEPAGRO, 2002. 104 p. (Boletim FEPAGRO, 10).

MATZENAUER, Ronaldo; BARNI, Nídio Antonio; MALUF, Jaime Ricardo Tavares. Estimativa do consumo relativo de água para a cultura da soja no Estado do Rio Grande do Sul. **Ciência Rural**, v. 33, n. 6, p. 1013-1019, 2003.

MATZENAUER, Ronaldo; RADIN, Bernadete; MALUF, Jaime Ricardo Tavares. O fenômeno ENOS e o regime de chuvas no Rio Grande do Sul. **Agrometeoros**, Passo Fundo, v. 25, n. 2, p. 323-331, 2017.

MELO, Ricardo Wanke de; FONTANA, Denise Cybis; BERLATO, Moacir Antônio. Modelo agrometeorológico-espectral de estimativa de rendimento da soja para o estado do Rio Grande do Sul. *In*: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. **Anais [...]**. Belo Horizonte: INPE, 2003. p. 173-179.

MONTEIRO, José Eduardo Boffino de Almeida; ASSAD, Eduardo Delgado; SENTELHAS, Paulo Cesar; AZEVEDO, Letícia da Costa. Modeling of corn yield in Brazil as a function of meteorological conditions and technological level. **Pesquisa agropecuária brasileira**, Brasília, v. 52, n. 3, p. 137-148, 2017.

MOTA, Marcelo Crestani. **Comparação entre dados meteorológicos estimados e observados para utilização em modelos de estimativa de produtividade agrícola**. Dissertação de Mestrado (manejo e conservação de solo e da água). UFPel. 2015. 100 p.

MDIC - Ministério da Indústria, Comércio Exterior e Serviços. Disponível em: <http://comexstat.mdic.gov.br/pt/comex-vis>. Acesso: 10 de outubro 2020.

NASA (a) - National Aeronautics and Space Administration. Disponível em: <https://web.archive.org/web/20170515022022/https://landsat.gsfc.nasa.gov/wp-content/uploads/2015/06/Landsat.v.Sentinel-2.png>. Acesso em: 07 de outubro 2020.

NASA (b) - National Aeronautics and Space Administration. The Television Infrared Observation Satellite Program (TIROS). Disponível em: <https://science.nasa.gov/missions/tiros>. Acesso em: 26 de setembro de 2020.

NASA (a) - National Aeronautics and Space Administration. Disponível em: https://docserver.gesdisc.eosdis.nasa.gov/public/project/GPM/IMERG_ATBD_V06.pdf. Acesso em: 12 de outubro de 2021.

NASA (b) - National Aeronautics and Space Administration. Disponível em: <https://gpm.nasa.gov/data/directory>. Acesso em: 17 de junho de 2021.

NASA (c) - National Aeronautics and Space Administration. Disponível em: <https://lpdaac.usgs.gov/products/myd11a2v006/>. Acesso em: 12 de outubro de 2021.

NASH, J. E.; SUTCLIFFE, J. E. River flow forecasting through conceptual models: Part I. A discussion of principles. **Jornal of Hydrology**, Amsterdã, v. 10, n. 3, p. 282-290, 1970.

NEUMAIER, Norman *et al.* Ecofisiologia da soja. In: **Tecnologias de produção de soja**. Embrapa Soja. Londrina: Embrapa Soja, 2020. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1123928/1/SP-17-2020-online.pdf>. Acesso em: 25 de novembro de 2020.

OLIVEIRA, Gilvan Sampaio de. **O El Niño e Você** - o fenômeno climático. 2001. São José dos Campos, SP: Transtec, 2001, 116 p.

OLIVEIRA, Alexsandra Duarte de *et al.* Comparação de dados meteorológicos obtidos por estação convencional e automática em Jaboticabal-SP. **Revista Caatinga**, Mossoró, v. 23, n. 4, p. 108-114, 2010.

PEREIRA, Antonio Roberto; ANGELOCCI, Luiz Roberto; SENTELHAS, Paulo Cesar. **Meteorologia Agrícola**. Piracicaba, SP: Escola Superior de Agricultura Luiz de Queiroz, 2007, 192 p.

PENMAN, Howard Latimer. Natural evaporation from open water, bare soil and grass. **Proceedings of Royal Society**. London, v. 193, p. 120-145, 1948.

PICOLI, Michelle Cristina Araujo; RUDORFF, Bernardo Friedrich Theodor; RIZZI, Rodrigo; GIAROLLA, Angélica. Índice de vegetação do sensor MODIS na estimativa da produtividade agrícola da cana-de-açúcar. **Bragantia**, Campinas, v. 68, n. 3, p. 789-795, 2009.

PRAKASH, Satya; MITRA, Ashis Kumar; PAI, D. S.; AGHAKOUCHAK, Amir. From TRMM to GPM: How well can heavy rainfall be detected from space? **Advances in Water Resources**, v. 88, p.1–7, 2016.

QUIRINO, Dayanna Teodoro *et al.* Avaliação das estimativas de precipitação do satélite TRMM (algoritmo 3B42 Versão 7 e Real Time) utilizadas no balanço hídrico climatológico no Estado de Goiás. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 17., 2015, **Anais [...]**. João Pessoa: INPE, 2015, p. 5094-5101.

REICHARDT, Klaus. & TIMM, Luís Carlos. **Solo, planta e atmosfera: conceitos, processos e aplicações**. 2012. 2ªed. São Paulo: Manole, 2012. 497p.

RIZZI, Rodrigo; RUDORFF, Bernardo Friedrich Theodor; FREITAS, Ramon Morais; FONTANA, Denise Cybis. Monitoramento e estimativa da produtividade de soja auxiliados pelo modelo regional de previsão de tempo ETA. **Ambiente e Água**, v. 1, n. 2, p. 28-38, 2006.

RIZZI, Rodrigo e RUDORFF, Bernardo Friedrich Theodor. Imagens do sensor MODIS associadas a um modelo agrônômico para estimar a produtividade de soja. **Pesquisa Agropecuária Brasileira**, Brasília, v. 42, n. 1, p. 73-80, 2007.

RIZZI, Rodrigo *et al.* Estimativa da área de soja no Mato Grosso por meio de imagens MODIS. **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, 14., 2009, Natal. **Anais [...]**. Natal: INPE, 2009. p. 387-394.

RUDORFF, Bernardo Friedrich Theodor e BATISTA Getulio Teixeira. Yield estimation of sugarcane based on agrometeorological - spectral models. **Remote Sensing of Environment**, New York, v. 33, p. 183-192, 1990.

ROCHA, Thiago Schmitz Marques da *et al.* Performance of soybean in hydromorphic and nonhydromorphic soil under irrigated or rainfed conditions. **Pesquisa agropecuária brasileira**, Brasília, v. 52, n. 5, p. 293-302, 2017.

ROSA, Hamilton T. *et al.* Simulação do crescimento e produtividade de arroz no Rio Grande do Sul pelo modelo SimulArroz. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 19, n. 12, p. 1159-1165, 2015.

SENTELHAS, Paulo Cesar; CARAMORI, Paulo Henrique. Inconsistências na medida da chuva com pluviômetros de balança, utilizados em estações meteorológicas automáticas. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 10, n. 2, p. 301-304, 2002.

SENTELHAS, Paulo Cesar *et al.* The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **Journal of Agricultural Science**, v. 153, p. 1394-1411, 2015.

SILVA-FUZZO, Daniela Fernanda; PRELA-PANTANO, Angélica; CAMARGO, Marcelo Bento Paes de. Análise de dados de precipitação estimados pelo satélite TRMM para o vale do médio Parapanema – SP. **Engenharia na agricultura**, v. 21, n. 2, p. 138-147. 2013.

SILVA-FUZZO, Daniela Fernanda; PRELA-PANTANO, Angélica; Camargo, Marcelo Bento Paes de. Modelagem agrometeorológica para estimativa de produtividade de soja para o vale do médio Parapanema-SP. **Irriga, Botucatu**, v. 20, n. 3, p. 490-501, 2015.

SILVA-FUZZO, D. F.; ROCHA, Jansle Vieira. Validação dos dados de precipitação estimados pelo TRMM, para o estado do Paraná, e sua contribuição ao monitoramento Agrometeorológico. **Revista Formação**. v. 3, n. 23, p. 301- 316, 2016.

SILVA, Michel Rocha da *et al.* Modelagem numérica para previsão de safra de arroz irrigado no Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**. v.51, n.7, p.791-800. 2016.

SILVA, Polyanna M. de O; MELLO, Carlos R. de; SILVA, Antônio M. da; COELHO, Gilberto. Modelagem da hidrógrafa de cheia em uma bacia hidrográfica da região Alto Rio Grande. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, n. 3, p. 258-265, 2008.

SILVEIRA, Celestino Pires Silveira; GONZÁLEZ, José Antonio; FONSECA, Eliana Lima da. Land use changes after the period commodities rising price in the Rio Grande do Sul State, Brazil. **Ciência Rural**, v. 47, n. 4, p. 1-7, 2017.

STRECK, Nereu Augusto; ALBERTO, Cleber Maus. Estudo numérico do impacto da mudança climática sobre o rendimento de trigo, soja e milho. **Pesquisa agropecuária brasileira**, Brasília, v. 41, n. 9, p. 1351-1359, 2006.

SUGAWARA, Luciana Miura. **Avaliação de modelo agrometeorológico e imagens NOAA/AVHRR no acompanhamento e estimativa de produtividade da soja no estado do Paraná**. Dissertação de Mestrado (Sensoriamento Remoto). INPE. 2001. 181 p.

TAPIADOR, Francisco J. *et al.* Global precipitation measurement: Methods, datasets and applications. **Atmospheric Research**, v. 104, p. 70-97, 2012.

THEISEN, Giovani; VERNETTI Jr. Francisco; ANDRES, André; SILVA; Júlio J. Centeno da. **Manejo da Cultura da Soja em Terras Baixas em Safras com El-Niño**. Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Pelotas: dezembro, 2009.

TORRION, Jessica; SETIYONO, Tri Deri; CASSMAN, Kenneth; SPECHT, James. Soybean Phenology Simulation in the North-Central United States. **Agronomy Journal**, v. 103, p. 1661-1667, 2011.

THORNTHWAITE, C.W. An approach toward a rational classification of climate. **Geographical Review**, v. 38, p. 55-94, 1948.

THORNTHWAITE, C.W. e MATHER, J.R. **The water balance**. Drexel Institute of Technology, New Jersey, v. 8, n. 1, 1955, 104 p.

THORNTHWAITE, C.W. e MATHER, J.R. Instructions and tables for computing potential evapotranspiration and the water balance. **Publications in Climatology**, v. 10, n. 3, New Jersey, p. 185-310, 1957.

USDA (a) - United States Department of Agriculture. **World Agricultural Supply and Demand Estimates**. Dezembro, 2020.

USDA (b) - United States Department of Agriculture. Disponível em: <https://www.fas.usda.gov/soybeans-2019-export-highlights>. Acesso: 10 de outubro 2020.

WEYMAR JUNIOR, Luis Carlos Nunes. *et al.* Comparação entre a precipitação estimada pelo sistema GPM e a observada em superfície em Santa Vitória do Palmar/RS. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 22., 2017, Florianópolis. **Anais [...]**. Florianópolis: ABRH, 2017. Disponível em: <http://anais.abrh.org.br/works/2844>. Acesso: 25 de novembro 2020.

ZANON, Alencar Junior. *et al.* Desenvolvimento de cultivares de soja em função do grupo de maturação e tipo de crescimento em terras altas e terras baixas. **Bragantia**, Campinas, v. 74, n. 4, p. 400-411, 2015.

Apêndices

Apêndice A - Algoritmo de seleção de pixel, para o cálculo de temperatura média da superfície através dos satélites Terra e Aqua.

```
{  
  
// Comentários:  
  
// Booleana em Lote, Safra 2017/18, substitui os pixels com nuvens pelos  
valores dos pixels referentes às passagens subsequentes dos satélites terra e  
aqua.  
  
// Os dados de temperatura de 321 até 361 são de 2017 (quinzenas de 1 a 3),  
já os de 001 até 105 são de 2018 (quinzenas de 4 a 10).  
  
// Os MNTs de temperatura em Kelvin estarão na categoria  
CAT_medias_quinzenas e os resultados serão enviados para a categoria  
CAT_MNT em Celsius.  
  
// 0.02 é um fator de conversão fornecido pela NASA para os dados LST.  
  
//O valor de 14907.5 (ou 25°C) corresponde ao valor de preenchimento caso  
ocorra nuvem nos pixels de todas as datas, sendo assim, a temperatura de  
25°C é adotada, convertida para Kelvin, e dividida pelo fator de conversão da  
NASA, resultando em 14907.5.  
  
//Somente as quinzenas de 2 a 10 foram utilizadas para a modelagem de  
produtividade da soja, ou seja, 9 quinzenas.  
  
  
// Declaração das variáveis  
  
  
//Dados de entrada  
  
MNT Td321, Tn321, Td329, Tn329, Ad321, An321, Ad329, An329  
("CAT_medias_quinzenas");  
  
MNT Td337, Tn337, Td345, Tn345, Ad337, An337, Ad345, An345  
("CAT_medias_quinzenas");
```

MNT Td353, Tn353, Td361, Tn361, Ad353, An353, Ad361, An361
("CAT_medias_quinzenas");

MNT Td001, Tn001, Td009, Tn009, Ad001, An001, Ad009, An009
("CAT_medias_quinzenas");

MNT Td017, Tn017, Td025, Tn025, Ad017, An017, Ad025, An025
("CAT_medias_quinzenas");

MNT Td033, Tn033, Td041, Tn041, Ad033, An033, Ad041, An041
("CAT_medias_quinzenas");

MNT Td049, Tn049, Td057, Tn057, Ad049, An049, Ad057, An057
("CAT_medias_quinzenas");

MNT Td065, Tn065, Td073, Tn073, Ad065, An065, Ad073, An073
("CAT_medias_quinzenas");

MNT Td081, Tn081, Td089, Tn089, Ad081, An081, Ad089, An089
("CAT_medias_quinzenas");

MNT Td097, Tn097, Td105, Tn105, Ad097, An097, Ad105, An105
("CAT_medias_quinzenas");

//Resultados

MNT quin01, quin02, quin03, quin04, quin05, quin06, quin07, quin08, quin09,
quin10 ("CAT_MNT");

// Instanciação das variáveis

//lote quin01

Td321 = Recupere(Nome = "Terra_2017_321_LSTD");

Td329 = Recupere(Nome = "Terra_2017_329_LSTD");

Tn321 = Recupere(Nome = "Terra_2017_321_LSTN");

Tn329 = Recuperare(Nome = "Terra_2017_329_LSTN");

Ad321 = Recuperare(Nome = "Aqua_2017_321_LSTD");

Ad329 = Recuperare(Nome = "Aqua_2017_329_LSTD");

An321 = Recuperare(Nome = "Aqua_2017_321_LSTN");

An329 = Recuperare(Nome = "Aqua_2017_329_LSTN");

quin01 = Novo(Nome = "Quinz_01_2017" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

//lote quin02

Td337 = Recuperare(Nome = "Terra_2017_337_LSTD");

Td345 = Recuperare(Nome = "Terra_2017_345_LSTD");

Tn337 = Recuperare(Nome = "Terra_2017_337_LSTN");

Tn345 = Recuperare(Nome = "Terra_2017_345_LSTN");

Ad337 = Recuperare(Nome = "Aqua_2017_337_LSTD");

Ad345 = Recuperare(Nome = "Aqua_2017_345_LSTD");

An337 = Recuperare(Nome = "Aqua_2017_337_LSTN");

An345 = Recuperare(Nome = "Aqua_2017_345_LSTN");

quin02 = Novo(Nome = "Quinz_02_2017" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

//lote quin03

Td353 = Recuperare(Nome = "Terra_2017_353_LSTD");

Td361 = Recuperare(Nome = "Terra_2017_361_LSTD");

Tn353 = Recuperare(Nome = "Terra_2017_353_LSTN");

Tn361 = Recuperare(Nome = "Terra_2017_361_LSTN");

Ad353 = Recuperare(Nome = "Aqua_2017_353_LSTD");

Ad361 = Recuperare(Nome = "Aqua_2017_361_LSTD");

An353 = Recuperare(Nome = "Aqua_2017_353_LSTN");

An361 = Recuperare(Nome = "Aqua_2017_361_LSTN");

quin03 = Novo(Nome = "Quinz_03_2017" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

// lote quin04

Td001 = Recuperare(Nome = "Terra_2018_001_LSTD");

Td009 = Recuperare(Nome = "Terra_2018_009_LSTD");

Tn001 = Recuperare(Nome = "Terra_2018_001_LSTN");

Tn009 = Recuperare(Nome = "Terra_2018_009_LSTN");

Ad001 = Recuperare(Nome = "Aqua_2018_001_LSTD");

Ad009 = Recuperare(Nome = "Aqua_2018_009_LSTD");

An001 = Recuperare(Nome = "Aqua_2018_001_LSTN");

An009 = Recuperare(Nome = "Aqua_2018_009_LSTN");

quin04 = Novo(Nome = "Quinz_04_2018" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

//lote quin05

Td017 = Recuperere(Nome = "Terra_2018_017_LSTD");

Td025 = Recuperere(Nome = "Terra_2018_025_LSTD");

Tn017 = Recuperere(Nome = "Terra_2018_017_LSTN");

Tn025 = Recuperere(Nome = "Terra_2018_025_LSTN");

Ad017 = Recuperere(Nome = "Aqua_2018_017_LSTD");

Ad025 = Recuperere(Nome = "Aqua_2018_025_LSTD");

An017 = Recuperere(Nome = "Aqua_2018_017_LSTN");

An025 = Recuperere(Nome = "Aqua_2018_025_LSTN");

quin05 = Novo(Nome = "Quinz_05_2018" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

//lote quin06

Td033 = Recuperere(Nome = "Terra_2018_033_LSTD");

Td041 = Recuperere(Nome = "Terra_2018_041_LSTD");

Tn033 = Recuperere(Nome = "Terra_2018_033_LSTN");

Tn041 = Recuperere(Nome = "Terra_2018_041_LSTN");

Ad033 = Recuperere(Nome = "Aqua_2018_033_LSTD");

Ad041 = Recuperere(Nome = "Aqua_2018_041_LSTD");

An033 = Recuperare(Nome = "Aqua_2018_033_LSTN");

An041 = Recuperare(Nome = "Aqua_2018_041_LSTN");

quin06 = Novo(Nome = "Quinz_06_2018" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

//lote quin07

Td049 = Recuperare(Nome = "Terra_2018_049_LSTD");

Td057 = Recuperare(Nome = "Terra_2018_057_LSTD");

Tn049 = Recuperare(Nome = "Terra_2018_049_LSTN");

Tn057 = Recuperare(Nome = "Terra_2018_057_LSTN");

Ad049 = Recuperare(Nome = "Aqua_2018_049_LSTD");

Ad057 = Recuperare(Nome = "Aqua_2018_057_LSTD");

An049 = Recuperare(Nome = "Aqua_2018_049_LSTN");

An057 = Recuperare(Nome = "Aqua_2018_057_LSTN");

quin07 = Novo(Nome = "Quinz_07_2018" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

//lote quin08

Td065 = Recuperare(Nome = "Terra_2018_065_LSTD");

Td073 = Recuperare(Nome = "Terra_2018_073_LSTD");

Tn065 = Recuperare(Nome = "Terra_2018_065_LSTN");

Tn073 = Recuperare(Nome = "Terra_2018_073_LSTN");

Ad065 = Recuperare(Nome = "Aqua_2018_065_LSTD");

Ad073 = Recuperare(Nome = "Aqua_2018_073_LSTD");

An065 = Recuperare(Nome = "Aqua_2018_065_LSTN");

An073 = Recuperare(Nome = "Aqua_2018_073_LSTN");

quin08 = Novo(Nome = "Quinz_08_2018" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

//lote quin09

Td081 = Recuperare(Nome = "Terra_2018_081_LSTD");

Td089 = Recuperare(Nome = "Terra_2018_089_LSTD");

Tn081 = Recuperare(Nome = "Terra_2018_081_LSTN");

Tn089 = Recuperare(Nome = "Terra_2018_089_LSTN");

Ad081 = Recuperare(Nome = "Aqua_2018_081_LSTD");

Ad089 = Recuperare(Nome = "Aqua_2018_089_LSTD");

An081 = Recuperare(Nome = "Aqua_2018_081_LSTN");

An089 = Recuperare(Nome = "Aqua_2018_089_LSTN");

quin09 = Novo(Nome = "Quinz_09_2018" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

//lote quin10

Td097 = Recuperare(Nome = "Terra_2018_097_LSTD");

Td105 = Recuperare(Nome = "Terra_2018_105_LSTD");

Tn097 = Recuperar(Nome = "Terra_2018_097_LSTN");

Tn105 = Recuperar(Nome = "Terra_2018_105_LSTN");

Ad097 = Recuperar(Nome = "Aqua_2018_097_LSTD");

Ad105 = Recuperar(Nome = "Aqua_2018_105_LSTD");

An097 = Recuperar(Nome = "Aqua_2018_097_LSTN");

An105 = Recuperar(Nome = "Aqua_2018_105_LSTN");

quin10 = Novo(Nome = "Quinz_10_2018" , ResX = 1000 , ResY = 1000 ,
Escala = 100000);

// Operação

quin01 = ((((Ad321 != 0 ? Ad321 : (Td321 != 0 ? Td321 : (Ad329 != 0 ?
Ad329 : Td329))) * (An321 != 0 ? An321 : (Tn321 != 0 ? Tn321 : (An329 !=
0 ? An329 : Tn329)))) == 0 ? 14907.5 : ((((Ad321 != 0 ? Ad321 : (Td321
!= 0 ? Td321 : (Ad329 != 0 ? Ad329 : Td329))) + (An321 != 0 ? An321 : (Tn321
!= 0 ? Tn321 : (An329 != 0 ? An329 : Tn329)))) / 2) + (((Ad329 !=
0 ? Ad329 : (Td329 != 0 ? Td329 : (Ad321 != 0 ? Ad321 : Td321))) + (An329 != 0 ? An329 : (Tn329 != 0 ? Tn329 : (An321 != 0 ? An321 : Tn321)))) / 2)) / 2) * 0.02) - 273.15 ;

quin02 = ((((Ad337 != 0 ? Ad337 : (Td337 != 0 ? Td337 : (Ad345 != 0 ?
Ad345 : Td345))) * (An337 != 0 ? An337 : (Tn337 != 0 ? Tn337 : (An345 !=
0 ? An345 : Tn345)))) == 0 ? 14907.5 : ((((Ad337 != 0 ? Ad337 : (Td337
!= 0 ? Td337 : (Ad345 != 0 ? Ad345 : Td345))) + (An337 != 0 ? An337 : (Tn337
!= 0 ? Tn337 : (An345 != 0 ? An345 : Tn345)))) / 2) + (((Ad345 !=
0 ? Ad345 : (Td345 != 0 ? Td345 : (Ad337 != 0 ? Ad337 : Td337))) + (

An345 != 0 ? An345 : (Tn345 != 0 ? Tn345 : (An337 != 0 ? An337 : Tn337))) / 2) / 2) * 0.02) - 273.15 ;

quin03 = ((((Ad353 != 0 ? Ad353 : (Td353 != 0 ? Td353 : (Ad361 != 0 ? Ad361 : Td361))) * (An353 != 0 ? An353 : (Tn353 != 0 ? Tn353 : (An361 != 0 ? An361 : Tn361)))) == 0 ? 14907.5 : ((((Ad353 != 0 ? Ad353 : (Td353 != 0 ? Td353 : (Ad361 != 0 ? Ad361 : Td361))) + (An353 != 0 ? An353 : (Tn353 != 0 ? Tn353 : (An361 != 0 ? An361 : Tn361)))) / 2) + (((Ad361 != 0 ? Ad361 : (Td361 != 0 ? Td361 : (Ad353 != 0 ? Ad353 : Td353))) + (An361 != 0 ? An361 : (Tn361 != 0 ? Tn361 : (An353 != 0 ? An353 : Tn353)))) / 2)) / 2) * 0.02) - 273.15 ;

quin04 = ((((Ad001 != 0 ? Ad001 : (Td001 != 0 ? Td001 : (Ad009 != 0 ? Ad009 : Td009))) * (An001 != 0 ? An001 : (Tn001 != 0 ? Tn001 : (An009 != 0 ? An009 : Tn009)))) == 0 ? 14907.5 : ((((Ad001 != 0 ? Ad001 : (Td001 != 0 ? Td001 : (Ad009 != 0 ? Ad009 : Td009))) + (An001 != 0 ? An001 : (Tn001 != 0 ? Tn001 : (An009 != 0 ? An009 : Tn009)))) / 2) + (((Ad009 != 0 ? Ad009 : (Td009 != 0 ? Td009 : (Ad001 != 0 ? Ad001 : Td001))) + (An009 != 0 ? An009 : (Tn009 != 0 ? Tn009 : (An001 != 0 ? An001 : Tn001)))) / 2)) / 2) * 0.02) - 273.15 ;

quin05 = ((((Ad017 != 0 ? Ad017 : (Td017 != 0 ? Td017 : (Ad025 != 0 ? Ad025 : Td025))) * (An017 != 0 ? An017 : (Tn017 != 0 ? Tn017 : (An025 != 0 ? An025 : Tn025)))) == 0 ? 14907.5 : ((((Ad017 != 0 ? Ad017 : (Td017 != 0 ? Td017 : (Ad025 != 0 ? Ad025 : Td025))) + (An017 != 0 ? An017 : (Tn017 != 0 ? Tn017 : (An025 != 0 ? An025 : Tn025)))) / 2) + (((Ad025 != 0 ? Ad025 : (Td025 != 0 ? Td025 : (Ad017 != 0 ? Ad017 : Td017))) + (An025 != 0 ? An025 : (Tn025 != 0 ? Tn025 : (An017 != 0 ? An017 : Tn017)))) / 2)) / 2) * 0.02) - 273.15 ;

$$\text{quin06} = ((((\text{Ad033} \neq 0 ? \text{Ad033} : (\text{Td033} \neq 0 ? \text{Td033} : (\text{Ad041} \neq 0 ? \text{Ad041} : \text{Td041}))) * (\text{An033} \neq 0 ? \text{An033} : (\text{Tn033} \neq 0 ? \text{Tn033} : (\text{An041} \neq 0 ? \text{An041} : \text{Tn041})))) == 0 ? 14907.5 : (((((\text{Ad033} \neq 0 ? \text{Ad033} : (\text{Td033} \neq 0 ? \text{Td033} : (\text{Ad041} \neq 0 ? \text{Ad041} : \text{Td041}))) + (\text{An033} \neq 0 ? \text{An033} : (\text{Tn033} \neq 0 ? \text{Tn033} : (\text{An041} \neq 0 ? \text{An041} : \text{Tn041})))) / 2) + (((\text{Ad041} \neq 0 ? \text{Ad041} : (\text{Td041} \neq 0 ? \text{Td041} : (\text{Ad033} \neq 0 ? \text{Ad033} : \text{Td033}))) + (\text{An041} \neq 0 ? \text{An041} : (\text{Tn041} \neq 0 ? \text{Tn041} : (\text{An033} \neq 0 ? \text{An033} : \text{Tn033}))) / 2)) / 2)) * 0.02) - 273.15 ;$$

$$\text{quin07} = ((((\text{Ad049} \neq 0 ? \text{Ad049} : (\text{Td049} \neq 0 ? \text{Td049} : (\text{Ad057} \neq 0 ? \text{Ad057} : \text{Td057}))) * (\text{An049} \neq 0 ? \text{An049} : (\text{Tn049} \neq 0 ? \text{Tn049} : (\text{An057} \neq 0 ? \text{An057} : \text{Tn057})))) == 0 ? 14907.5 : (((((\text{Ad049} \neq 0 ? \text{Ad049} : (\text{Td049} \neq 0 ? \text{Td049} : (\text{Ad057} \neq 0 ? \text{Ad057} : \text{Td057}))) + (\text{An049} \neq 0 ? \text{An049} : (\text{Tn049} \neq 0 ? \text{Tn049} : (\text{An057} \neq 0 ? \text{An057} : \text{Tn057})))) / 2) + (((\text{Ad057} \neq 0 ? \text{Ad057} : (\text{Td057} \neq 0 ? \text{Td057} : (\text{Ad049} \neq 0 ? \text{Ad049} : \text{Td049}))) + (\text{An057} \neq 0 ? \text{An057} : (\text{Tn057} \neq 0 ? \text{Tn057} : (\text{An049} \neq 0 ? \text{An049} : \text{Tn049})))) / 2)) / 2)) * 0.02) - 273.15 ;$$

$$\text{quin08} = ((((\text{Ad065} \neq 0 ? \text{Ad065} : (\text{Td065} \neq 0 ? \text{Td065} : (\text{Ad073} \neq 0 ? \text{Ad073} : \text{Td073}))) * (\text{An065} \neq 0 ? \text{An065} : (\text{Tn065} \neq 0 ? \text{Tn065} : (\text{An073} \neq 0 ? \text{An073} : \text{Tn073})))) == 0 ? 14907.5 : (((((\text{Ad065} \neq 0 ? \text{Ad065} : (\text{Td065} \neq 0 ? \text{Td065} : (\text{Ad073} \neq 0 ? \text{Ad073} : \text{Td073}))) + (\text{An065} \neq 0 ? \text{An065} : (\text{Tn065} \neq 0 ? \text{Tn065} : (\text{An073} \neq 0 ? \text{An073} : \text{Tn073})))) / 2) + (((\text{Ad073} \neq 0 ? \text{Ad073} : (\text{Td073} \neq 0 ? \text{Td073} : (\text{Ad065} \neq 0 ? \text{Ad065} : \text{Td065}))) + (\text{An073} \neq 0 ? \text{An073} : (\text{Tn073} \neq 0 ? \text{Tn073} : (\text{An065} \neq 0 ? \text{An065} : \text{Tn065})))) / 2)) / 2)) * 0.02) - 273.15 ;$$

$$\text{quin09} = ((((\text{Ad081} \neq 0 ? \text{Ad081} : (\text{Td081} \neq 0 ? \text{Td081} : (\text{Ad089} \neq 0 ? \text{Ad089} : \text{Td089}))) * (\text{An081} \neq 0 ? \text{An081} : (\text{Tn081} \neq 0 ? \text{Tn081} : (\text{An089} \neq 0 ? \text{An089} : \text{Tn089})))) == 0 ? 14907.5 : (((((\text{Ad081} \neq 0 ? \text{Ad081} : (\text{Td081} \neq 0 ? \text{Td081} : (\text{Ad089} \neq 0 ? \text{Ad089} : \text{Td089}))) + (\text{An081} \neq 0 ? \text{An081} : ($$

Tn081 != 0 ? Tn081 : (An089 != 0 ? An089 : Tn089))) / 2) + (((Ad089 != 0 ? Ad089 : (Td089 != 0 ? Td089 : (Ad081 != 0 ? Ad081 : Td081))) + (An089 != 0 ? An089 : (Tn089 != 0 ? Tn089 : (An081 != 0 ? An081 : Tn081))) / 2)) / 2) * 0.02) - 273.15 ;

quin10 = ((((Ad097 != 0 ? Ad097 : (Td097 != 0 ? Td097 : (Ad105 != 0 ? Ad105 : Td105))) * (An097 != 0 ? An097 : (Tn097 != 0 ? Tn097 : (An105 != 0 ? An105 : Tn105)))) == 0 ? 14907.5 : ((((Ad097 != 0 ? Ad097 : (Td097 != 0 ? Td097 : (Ad105 != 0 ? Ad105 : Td105))) + (An097 != 0 ? An097 : (Tn097 != 0 ? Tn097 : (An105 != 0 ? An105 : Tn105)))) / 2) + (((Ad105 != 0 ? Ad105 : (Td105 != 0 ? Td105 : (Ad097 != 0 ? Ad097 : Td097))) + (An105 != 0 ? An105 : (Tn105 != 0 ? Tn105 : (An097 != 0 ? An097 : Tn097))) / 2)) / 2) * 0.02) - 273.15 ;

}