**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Análise agrometeorológica-espectral de lavouras de soja conduzidas com
Agricultura de Precisão, em Cruz Alta – RS**

Luiza Ferreira de Carvalho

Dissertação apresentada para obtenção do título de Mestra
em Ciências. Área de concentração: Engenharia de
Sistemas Agrícolas

**Piracicaba
2021**

Luiza Ferreira de Carvalho
Bacharela em Engenharia Agrícola

**Análise agrometeorológica-espectral de lavouras de soja conduzidas com
Agricultura de Precisão, em Cruz Alta – RS**

versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **FELIPE GUSTAVO PILAU**

Dissertação apresentada para obtenção do título de Mestra
em Ciências. Área de concentração: Engenharia de
Sistemas Agrícolas

Piracicaba
2021

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Carvalho, Luiza Ferreira de

Análise agrometeorológica-espectral de lavouras de soja conduzidas com Agricultura de Precisão, em Cruz Alta – RS / Luiza Ferreira de Carvalho
- - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - -
Piracicaba, 2021.

88 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. *Glycine max* L. 2. Balanço hídrico 3. NDVI 4. Modelagem 5. Agricultura de Precisão I. Título

DEDICATÓRIA

Aos meus pais.

AGRADECIMENTOS

À Deus por tudo.

Aos meus pais, Katia e Eduardo, por me proporcionarem a oportunidade de estudar, por serem apoio para todos os momentos nessa jornada e, principalmente, serem exemplo de honestidade, amor e respeito.

Aos meus irmãos, Pedro e Vinicius, pelos conselhos, amor e carinho.

Ao meu companheiro Rafael, por me incentivar a encarar novos desafios e me acompanhar nessa jornada.

Aos meus colegas do GEPEMA-AGRIMET por me ajudarem na adaptação e por confiarem em mim na execução dos projetos. Agradeço em especial a Brena e o Karlmer pelas orientações e companheirismo.

Aos queridos amigos que fiz durante a minha trajetória na Esalq: Cleverson, Deborah, Thais Charles, Jessica, Nina, Rodolfo e, principalmente, a Thais, que se tornou uma amiga para a vida.

Aos professores que contribuíram para a minha formação e, em especial, ao meu orientador, Felipe Pilau, pelos ensinamentos, oportunidades e contribuições durante todo o mestrado.

Aos funcionários da ESALQ pelos serviços e apoio prestados.

O presente trabalho foi realizado com apoio do CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico – Brasil.

Luiza Ferreira de Carvalho

SUMÁRIO

RESUMO	6
ABSTRACT	7
1. INTRODUÇÃO GERAL	9
2. OBJETIVOS	12
2.1. OBJETIVO GERAL	12
2.2. OBJETIVOS ESPECÍFICOS	12
REFERÊNCIAS	13
3. ANÁLISE DE LAVOURAS DE SOJA COM BASE EM ÍNDICES AGROMETEOROLÓGICOS E IMAGENS DE SATÉLITE	16
3.1. INTRODUÇÃO	17
3.2. MATERIAL E MÉTODOS.....	19
3.3. RESULTADOS E DISCUSSÃO	24
3.4. CONCLUSÃO	40
REFERÊNCIAS	40
4. ANÁLISE DA INTEGRAÇÃO DE UM MODELO AGROMETEOROLÓGICO AO NDVI PARA A ESTIMATIVA DE PRODUTIVIDADE DA SOJA EM CRUZ ALTA – RS.	48
4.1. INTRODUÇÃO	49
4.2. MATERIAL E MÉTODOS.....	51
4.3. RESULTADOS E DISCUSSÃO	63
4.4. CONCLUSÃO	79
REFERÊNCIAS	80

RESUMO

Análise agrometeorológica-espectral de lavouras de soja conduzidas com Agricultura de Precisão, em Cruz Alta – RS.

A soja é uma importante *commodity* mundial e representa grande parte das exportações brasileiras. As variações climáticas causam variabilidade de produtividade e o acompanhamento da safra é fundamental para a diminuição do impacto climático e para a garantia de preços aos produtores. Os modelos agrometeorológicos são ferramentas eficazes na identificação da influência meteorológica sobre a produtividade e estimam a produtividade potencial de dada região, de acordo com suas características climáticas e de solo, indicando a quebra de produtividade devido ao manejo inadequado. Essas estimativas, em geral, são feitas de forma pontual, considerando a área estudada como homogênea. No entanto, deve-se considerar que as áreas agrícolas, no nível de talhão, apresentam lacunas de rendimento decorrentes da variabilidade espaço-temporal de características de solo e clima. Dessa forma, a possibilidade de simular a produtividade em maior resolução espacial permite analisar a variabilidade dentro da área. As imagens de satélite, por meio dos índices de vegetação, auxiliam na identificação da variabilidade espacial de atributos de solo e da cultura e, indiretamente, fornecem informações da ação dos elementos meteorológicos de forma espacializada. O objetivo do estudo foi avaliar o potencial do NDVI (Índice de Vegetação por Diferença Normalizada) em conjunto com variáveis climáticas para acompanhar o crescimento e desenvolvimento da soja, bem como estimar sua produtividade por meio de um modelo gerado por regressão linear múltipla. O estudo foi realizado na Cooperativa Central Gaúcha LTDA (CCGL), no município de Cruz Alta-RS, nas safras de 2017 a 2019. Para isso, foram utilizados dados climáticos de temperatura e precipitação, dados de produtividade de sensores acoplados às colhedoras em áreas de agricultura de precisão, dados do NDVI e dados de produtividade potencial e atingível, estimados pelo modelo de Doreenbos & Kassam (1979). Os resultados mostraram que o NDVI foi capaz de descrever o comportamento da soja, mostrando sua relação com o IAF (Índice de Área Foliar). O NDVI apresentou correlação positiva com a precipitação acumulada. O modelo gerado foi capaz de explicar de 47 a 67% das estimativas de produtividade de soja para a safra 2017/18, sem melhoria significativa das estimativas quando adicionados os dados do modelo agrometeorológico. Os resultados foram promissores, indicando a necessidade de novas análises, em diferentes safras, para que maior variabilidade de clima seja computada no modelo.

Palavras-chave: *Glycine max* L.; Balanço hídrico; NDVI; Modelagem; Agricultura de Precisão

ABSTRACT

Agrometeorological and spectral analysis of soybean crops conducted with Precision Agriculture, in Cruz Alta – RS.

Soybean is an important global commodity and represents a large part of Brazilian exports. Climatic variations cause yield variability, and the monitoring of the harvest is essential to reduce climatic impact and to ensure good prices. Agrometeorological models are effective tools for identifying the meteorological influence on productivity and estimate the potential yield of a given region, according to its climatic and soil characteristics, indicating the yield gap due to inadequate management. These estimates, in general, are made considering a homogeneous region. However, it should be considered that agricultural areas have yield gaps resulting from the spatio-temporal variability of soil and climate characteristics within a plot. Thus, the possibility of simulating in greater spatial resolution allows to analyze the yield variability. Satellite images, by means of vegetation indices, help to identify the spatial variability of soil and plant attributes and, indirectly, provide information on the action of meteorological elements in a specialized way. The objective of the study was to evaluate the behavior of NDVI (Normalized Difference Vegetation Index) in conjunction with climatic variables to monitor the growth and development of soybeans, as well as to estimate its productivity through a model generated by multiple linear regression. The study was carried out at Cooperativa Central Gaúcha LTDA (CCGL), in the municipality of Cruz Alta-RS, in the harvests from 2017 to 2019. For this, climatic data of temperature and precipitation, productivity data from sensors coupled to the harvesters in areas of precision agriculture, data from NDVI and data of potential and attainable productivity, estimated by the model of Doreenbos & Kassam (1979) were used. The results showed that NDVI was able to describe the behavior of soybean, showing its relationship with LAI (Leaf Area Index). NDVI showed a positive correlation with accumulated precipitation. The generated model was able to explain 47 to 67% of the soybean yield estimates for the 2017/18 crop, without significant improvement of the estimates when adding the data from the agrometeorological model. The results were promising, indicating the need for new analyzes, in different harvests, so that climate variability is computed in the model.

Keywords: *Glycine max* L.; Water balance; NDVI; Modeling; Precision Agriculture

1. INTRODUÇÃO GERAL

A soja (*Glycine max* L.) é uma cultura produzida mundialmente e tem papel importante no contexto da segurança alimentar, pois é rica em proteína, óleo e fibras. A cultura ocupa uma área de 125,7 milhões de hectares no mundo, com produção de 362 milhões de toneladas (EMBRAPA, 2019). O Brasil tem grande representatividade na produção de soja no cenário mundial. O país é o segundo maior produtor, com estimativa de produção para a safra 2020/21 de 134,9 milhões de toneladas do grão, ocupando 38,2 milhões de hectares de área plantada (CONAB, 2020).

O estado do Rio Grande do Sul é o terceiro maior produtor de soja no Brasil, com área plantada de 5,9 milhões de ha (CONAB, 2020). Na safra de 2019/20, devido aos baixos índices pluviométricos dos meses de janeiro e fevereiro de 2020, a produtividade média das lavouras do estado foi de 1.937 kg/ha, representando uma queda de 41,7% em relação à safra anterior (CONAB, 2020).

Dada a importância da soja no estado do RS e a acentuada influência das variações meteorológicas sobre a produção (CUNHA et al., 2001; KRÜGER; FONTANA; MELO, 2007), a previsão e acompanhamento da safra, bem como das variáveis meteorológicas que interferem na produção, são fundamentais para o planejamento da economia, definição de políticas de preços e gerenciamento de logística e armazenamento da produção e, consequentemente, na segurança alimentar (ASSAD et al., 2007; FIGUEIREDO, 2005; FONTANA et al., 2001; RICHETTI, 2018).

O crescimento e desenvolvimento da cultura da soja são influenciados, principalmente, pela radiação solar, fotoperíodo, temperatura do ar e umidade do solo (FARIAS, NEUMAIER, NEPOMUCENO, 2009). A água é um dos fatores que mais afetam a produtividade da soja (ARAÚJO; ROCHA; LAMPARELLI, 2011; DE MELO; FONTANA; BERLATO, 2004; FARIAS; NEPOMUCENO; NEUMAIER, 2007). Proveniente da precipitação ou irrigação, a água é fundamental para que ocorram as trocas gasosas entre planta e atmosfera. Além disso, atua como reguladora térmica e carreadora de nutrientes. Os períodos mais críticos do desenvolvimento da soja, que sofrem maior influência da água, são germinação e emergência das plantas, e o florescimento e enchimento dos grãos (FARIAS, NEUMAIER, NEPOMUCENO, 2009; FARIAS et al., 2001).

Os modelos agrometeorológicos são ferramentas eficazes na identificação da influência meteorológica sobre a produtividade. Os dados requeridos por tais modelos, normalmente, incluem variáveis meteorológicas, como precipitação, temperatura e umidade do ar e radiação solar, e características de solo, como capacidade máxima de armazenamento de água (CAD) para, via processos empíricos ou mecanísticos, estimar a produtividade da cultura, por exemplo, em função da disponibilidade hídrica (ASSAD et al., 2007; PEREIRA; ANGELOCCI; SENTELHAS, 2007). Esses modelos podem estimar a Produtividade Potencial (Y_p) – sem limitações hídricas e nutricionais, e a Produtividade Atingível (Y_a) – em condições de sequeiro, dadas as condições meteorológicas, de solo e planta.

Essas estimativas representam a máxima produtividade possível para tais condições de cultivo e a diferença entre a produtividade real e produtividade potencial (Y_p) ou atingível (Y_a) é descrita pela lacuna de rendimento (do inglês: *yield gap*) (MARIN, 2014; PEREIRA; ANGELOCCI; SENTELHAS, 2007; VAN ITTERSUM et al., 2013).

A estimativa da produtividade por meio de modelos, em função das variáveis de entrada exigidas, é tradicionalmente feita de forma pontual, desconsiderando a heterogeneidade de caracteres de solo, clima e manejo nas unidades de produção, impossibilitando a análise da variabilidade no nível de talhão (HANSEN; JONES, 2000; HEINEMANN; STONE; SILVA, 2010). Para simular em maior resolução espacial são necessários dados de entrada coletados em grandes quantidades de pontos amostrais. Surge, nesse sentido, a possibilidade de obtenção desses dados a partir de sensoriamento remoto (SR).

As imagens de satélites são fontes de informações disponíveis à análise das áreas de produção, capazes de auxiliar na identificação da variabilidade espacial de atributos de solo e planta e, indiretamente, fornecer informações da ação dos elementos meteorológicos sobre a cultura (CLEVERS et al., 2017; JIANG et al., 2014; LI et al., 2019; LOBELL; ORTIZ-MONASTERIO, 2006). Por meio da resposta espectral do dossel, expressa por índices de vegetação, como o Índice de Vegetação por Diferença Normalizada (NDVI) (TUCKER, 1979), é possível obter informações a respeito das características da cultura, como o índice de área foliar (IAF) e biomassa, que têm relação com a produtividade (FENG et al., 2014; LOBELL, 2013; MENG; DU; WU, 2013).

Diversas abordagens de aplicação do SR junto a modelos de crescimento de culturas têm sido estudadas, como o desenvolvimento de modelos agrometeorológicos-espectrais (KRÜGER; FONTANA; MELO, 2007; RICHETTI, 2018). Essas abordagens são feitas para grandes áreas, a níveis municipais e estaduais, com dados de estimativas de produtividade governamentais, que podem conter falhas, dada a subjetividade das estimativas. Dessa forma, busca-se uma metodologia que avalie a produtividade em menores escalas, para que se possa identificar a variabilidade produtiva em talhões de produção agrícola.

A importância em se estudar a influência dos fatores abióticos e bióticos sobre a produção, espaço e temporalmente, de forma mais detalhada, está inserida no contexto da Agricultura de Precisão (AP), que busca identificar em alta resolução espacial esses fatores e sua correlação com a variabilidade de produtividade em talhões de produção (MOLIN; AMARAL; COLAÇO, 2015). Os mapas de colheita são simples representações gráficas da variabilidade produtiva da unidade de produção, porém não tratam de informações explicativas. Portanto, para entender as causas das variações é preciso associá-los a outras informações (COELHO, 2005). No âmbito da AP as pesquisas abordaram a variabilidade produtiva em função das características físicas (DALCHIAVON et al., 2011; ROSA FILHO et al., 2009) e químicas do solo (CORASSA et al., 2018; SANTI et al., 2012), contudo com pouca abordagem agrometeorológica.

O fator meteorológico, ausente nos exploratórios dos mapas de AP, pode ser abordado por meio dos modelos agrometeorológicos e de índices de vegetação. Com os novos produtos de satélites, que fornecem imagens em alta resolução, é possível obter essas informações para o talhão, ao longo de todo o ciclo da cultura, e associá-las aos dados de colheita para, por exemplo, analisar as relações entre os índices de vegetação e a produtividade (PERALTA et al., 2016). Essa abordagem, além de fornecer dados para o gerenciamento da plantação pós-temporada, possibilita o acompanhamento da cultura durante a estação de crescimento, sendo possível o manejo de estresse hídrico, nutricional e ataque de pragas e doenças (YANG et al., 2013).

Frente a lacuna de exploratórios do fator climático em análises de agricultura de precisão, o objetivo do trabalho foi avaliar a resposta espectral da cultura da soja às variáveis climáticas e adaptar um modelo agrometeorológico-espectral para a estimativa de produtividade da soja em Cruz Alta - RS, ao nível de talhão.

2. OBJETIVOS

2.1. Objetivo geral

Avaliar a influência meteorológica na variabilidade produtiva da soja por meio de modelagem agrometeorológica e imagens de sensoriamento remoto em uma análise a nível de talhão.

2.2. Objetivos específicos

Analisar a influência das condições meteorológicas na cultura da soja e como o índice espectral NDVI pode caracterizar o desenvolvimento da soja ao longo da safra e em resposta a influência meteorológica, em uma análise temporal;

Associar a modelagem agrometeorológica ao NDVI para estimar a produtividade espacial da soja a nível de talhão, utilizando imagens de satélite de resolução espacial de 10 metros.

REFERÊNCIAS

- ARAÚJO, G. K. D.; ROCHA, J. V.; LAMPARELLI, R. A. C. **Relação entre NDVI da cultura da soja e dados de precipitação de estações meteorológicas e do modelo ECMWF, no estado do Paraná.**, 2011.
- ASSAD, E. D. et al. Sistema de previsão da safra de soja para o Brasil. **Pesquisa Agropecuária Brasileira**, v. 42, n. 5, p. 615–625, 2007.
- CLEVERS, J. et al. Using Sentinel-2 Data for Retrieving LAI and Leaf and Canopy Chlorophyll Content of a Potato Crop. **Remote Sensing**, v. 9, n. 5, p. 405, 25 abr. 2017.
- COELHO, A. M. Agricultura de Precisão: manejo da variabilidade espacial e temporal dos solos e culturas. In: **Emprapa Milho e Sorgo**. [s.l: s.n.]. p. 60.
- CONAB. Acompanhamento da Safra Brasileira. **Companhia Nacional de Abastecimento**, v. 5, n. 4, p. 1–113, 2019.
- CONAB. Acompanhamento da safra brasileira 2019/2020. **Acompanhamento da Safra Brasileira de Grãos 2019/2020**, v. 8, p. 1–29, 2020.
- CORASSA, G. M. et al. Soil chemical attributes restricting grain yield in Oxisols under no-tillage system. **Pesquisa Agropecuaria Brasileira**, v. 53, n. 11, p. 1203–1212, 2018.
- CUNHA, G. R. DA et al. Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v. 9, n. 3, p. 446–459, 2001.
- DALCHIAVON, F. C. et al. Soybean yield and mechanical resistance to soil penetration under no-tillage in the Brazilian savannah. **Pesquisa Agropecuaria Tropical**, v. 41, n. 1, p. 8–19, 2011.
- DE MELO, R. W.; FONTANA, D. C.; BERLATO, M. A. Indicadores de produção de soja no Rio Grande do Sul comparados ao zoneamento agrícola. **Pesquisa Agropecuaria Brasileira**, v. 39, n. 12, p. 1167–1175, 2004.
- EMBRAPA. **Agência de Informação Embrapa**. [Home page]. Disponível em: <<https://www.embrapa.br/soja/cultivos/soja1/dados-economicos>>. Acesso em: 21 mai. 2020.
- FARIAS, J. R. B. et al. Caracterização de risco de déficit hídrico nas regiões produtoras de soja no Brasil. **Revista Brasileira de Agrometeorologia**, v. 9, n. 3, p. 415–421, 2001.
- FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. Ecofisiologia da Soja. **Circular Técnica - Embrapa Soja**, v. 48, 2007.
- FARIAS, J.R.B.; NEUMAIER, N.; NEPOMUCENO, A.L. Soja. In: MONTEIRO, J.E.B.A. **Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola**. Brasília: INMET, 2009. cap. 15, p. 261-278.

- FENG, W. et al. Measuring leaf nitrogen concentration in winter wheat using double-peak spectral reflection remote sensing data. **Field Crops Research**, v. 159, p. 43–52, 2014.
- FIGUEIREDO, D.C. Projeto GeoSafras - aperfeiçoamento do sistema de previsão de safras da CONAB. **Revista de Política Agrícola**, v.14, p.110-120, 2005.
- FONTANA, D. C. et al. Modelo de estimativa de rendimento de soja no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, v. 36, n. 3, p. 399–403, 2001.
- HANSEN, J. W.; JONES, J. W. Scaling-up crop models for climate variability applications. **Agricultural Systems**, v. 65, n. 1, p. 43–72, 1 jul. 2000.
- HEINEMANN, A. B.; STONE, L. F.; SILVA, S. C. Modelos de simulação do crescimento, desenvolvimento e produtividade na pesquisa agrônômica. **Embrapa Arroz e Feijão**, p. 26, 2010.
- JIANG, Z. et al. Application of crop model data assimilation with a particle filter for estimating regional winter wheat yields. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 11, p. 4422–4431, 2014.
- KRÜGER, C. A. M. B.; FONTANA, D. C.; MELO, R. W. DE. Estimativa do rendimento de grãos da soja no Rio Grande do Sul usando um modelo agrometeorológico-espectral regionalizado. **Revista Brasileira de Agrometeorologia**, v. 15, n. 3, p. 210–219, 2007.
- LI, C. et al. Using NDVI percentiles to monitor real-time crop growth. **Computers and Electronics in Agriculture**, v. 162, n. April, p. 357–363, 2019.
- LOBELL, D. B. The use of satellite data for crop yield gap analysis. **Field Crops Research**, v. 143, p. 56–64, 1 mar. 2013.
- LOBELL, D. B.; ORTIZ-MONASTERIO, J. I. Regional importance of crop yield constraints: Linking simulation models and geostatistics to interpret spatial patterns. **Ecological Modelling**, v. 196, n. 1–2, p. 173–182, 10 jul. 2006.
- MARIN, F. R. Eficiência de produção da cana-de-açúcar brasileira: estado atual e cenários futuros baseados em simulações multimodelos. **Escola Superior de Agricultura “Luiz de Quieroz” - Tese de Livre Docência**, n. May, p. 262, 2014.
- MENG, J.; DU, X.; WU, B. Generation of high spatial and temporal resolution NDVI and its application in crop biomass estimation. **International Journal of Digital Earth**, v. 6, n. 3, p. 203–218, 2013.
- MOLIN, J. P.; DO AMARAL, L. R.; COLAÇO, A. F. **Agricultura de Precisão**. 1. ed. São Paulo: Oficina de Textos, 2015.

- PERALTA, N. R. et al. Mid-season high-resolution satellite imagery for forecasting site-specific corn yield. **Remote Sensing**, v. 8, n. 10, 2016.
- PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. Meteorologia Agrícola. **Ed. Ver. e Ampl. Universidade de São Paulo, Escola Superior de Agricultura “Luiz de Queiroz”, Departamento de Ciências Exatas**, n. Piracicaba, 2007.
- RICHETTI, Jonathan. **MODELOS AGROMETEOROLÓGICOS, ESPECTRAIS E DE INTELIGÊNCIA ARTIFICIAL PARA ESTIMAÇÃO DE PRODUTIVIDADE DE SOJA**. 2018. 81 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel, 2018.
- ROSA FILHO, G. et al. Variabilidade da produtividade da soja em função de atributos físicos de um Latossolo Vermelho Distroférico sob plantio direto. **Revista Brasileira de Ciência do Solo**, v. 33, n. 2, p. 283–293, 2009.
- SANTI, A. L. et al. Análise de componentes principais de atributos químicos e físicos do solo limitantes à produtividade de grãos. **Pesq. agropec. bras., Brasília**, v. 47, n. 9, p. 1346–1357, 2012.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.
- VAN ITTERSUM, M. K. et al. Yield gap analysis with local to global relevance-A review. **Field Crops Research**, v. 143, p. 4–17, 2013.
- YANG, C. et al. Using high-resolution airborne and satellite imagery to assess crop growth and yield variability for precision agriculture. **Proceedings of the IEEE**, v. 101, n. 3, p. 582–592, 2013.

3. ANÁLISE DE LAVOURAS DE SOJA COM BASE EM ÍNDICES AGROMETEOROLÓGICOS E IMAGENS DE SATÉLITE

Resumo

As condições climáticas são uma das principais causas da variabilidade da produtividade da soja. Portanto, é de suma importância elucidar a relação entre produtividade da soja e clima, para diminuir os riscos climáticos da produção. O acompanhamento da safra auxilia o produtor no manejo da lavoura e, quando feito de forma remota, facilita as operações e possibilita que o produtor acompanhe toda a área quase em tempo real. O objetivo deste estudo foi avaliar as características climáticas de três safras de soja no município de Cruz Alta-RS e analisar a resposta espectral da cultura, por meio do Índice de Vegetação por Diferença Normalizada (NDVI) e como as variáveis climáticas, especialmente a precipitação, têm relação com o crescimento e desenvolvimento da soja, traduzido pelo NDVI. O estudo avaliou o clima da região de dois talhões de soja da Cooperativa Central Gaúcha LTDA (CCGL), no município de Cruz Alta-RS, nas safras de 2017/18, 2018/19 e 2019/20 e a resposta da cultura à disponibilidade hídrica, por meio do balanço hídrico sequencial de Thornthwaite e Matter (1955) adaptado, bem como o NDVI da cultura ao longo de cada safra. Foram feitas análises de regressão entre precipitação acumulada e NDVI para avaliar a influência da precipitação no crescimento da cultura e como o índice responde a esse crescimento. As safras 2017/18 e 2018/19 apresentaram bom desenvolvimento da soja em razão da boa disponibilidade hídrica, enquanto a safra 2019/20 apresentou déficit hídrico de mais de 400 mm acumulados, o que resultou em menor desenvolvimento da cultura. O NDVI foi capaz de descrever o comportamento da soja, mostrando sua relação com o IAF. O NDVI apresentou correlações positivas tanto precipitação quanto deficiência hídrica acumuladas nos ciclos de produção da soja. Os resultados evidenciaram e reafirmam a capacidade de identificar o efeito meteorológico a partir da observação do NDVI.

Palavras-chave: *Glycine max* L; NDVI; precipitação; balanço hídrico

Abstract

Climatic conditions are one of the main causes of the variability of soybean productivity. Therefore, it is extremely important to clarify the relationship between soybean productivity and climate, to reduce the climatic risks of production. Monitoring the harvest helps the producer to manage the crop and, when done remotely, optimizes operations and allows the producer to monitor the entire area almost in real time. The objective of the study was to evaluate the climatic characteristics of three soybean crops in the municipality of Cruz Alta-RS and to analyze the spectral response of the crop, using the Normalized Difference Vegetation Index (NDVI) to understand how the climatic variables, especially rainfall, are related to soybean growth and development, translated by NDVI. The study evaluated the climate of two soybean plots at Cooperativa Central Gaúcha LTDA (CCGL), in the municipality of Cruz Alta-RS, in the harvest seasons 2017/18, 2018/19 and 2019/20 and the crop's response to water availability, through the Thornthwaite and Matter (1955) water balance methodology, as well as the NDVI of the crop throughout each season. Regression analyzes between

accumulated precipitation and NDVI were performed to assess the influence of precipitation on the growth of the crop and how the index responds to this growth. The 2017/18 and 2018/19 harvest seasons showed good plant development due to good water availability, while the 2019/20 season showed a water deficit of more than 400 mm accumulated, which resulted in less plant development. NDVI was able to describe the behavior of soybean crop, showing its relationship with the LAI. NDVI showed positive correlations for both precipitation and water deficiency accumulated in soybean production cycles. The results showed and reaffirmed the ability to identify the meteorological effect from the observation of NDVI.

Keywords: *Glycine max* L; NDVI; precipitation; water balance

3.1. Introdução

A soja é uma importante *commodity* mundial, responsável por 39% das exportações brasileiras (EMBRAPA, 2019). A cultura ocupa uma área de 36,8 milhões de hectares, com produção de 120,3 milhões de toneladas no Brasil (CONAB, 2020). As principais regiões produtoras são Centro-Oeste e Sul do Brasil, responsáveis por mais de 78% da produção nacional. O Rio Grande do Sul (RS) é o segundo maior estado produtor da região Sul, atrás do Paraná. Na safra 2018/19 o RS produziu 19,2 milhões de toneladas, a maior produção já obtida, superando em 11,9% à safra anterior (CONAB, 2019).

No Rio Grande do Sul, o município de Cruz Alta é o quinto maior produtor de soja do estado, com uma área plantada de 93.000 hectares e produção de 326.160 toneladas (IBGE, 2020). Nessa região, a cultura é produzida entre os meses de novembro a abril, majoritariamente cultivada em condições de sequeiro.

Os elementos climáticos que mais influenciam no crescimento e desenvolvimento da cultura da soja são o fotoperíodo, a radiação solar, a temperatura do ar e a precipitação. Como planta de dia curto, o fotoperíodo para a soja é determinante no período de florescimento, para que a planta atinja a fase reprodutiva. Para florescer, a soja necessita de noites longas, dessa forma, o fotoperíodo máximo suportado pela planta é de 14 horas (FARIAS; NEUMAIER; NEPOMUCENO, 2009).

A temperatura do ar atua como fator moderador no desenvolvimento da cultura da soja. A temperatura máxima suportada pela soja é de 40°C, e está associada ao máximo conteúdo de CO₂ que a planta é capaz acumular no processo de fotossíntese (BATTISTI, 2013; FARIAS; NEUMAIER; NEPOMUCENO, 2009; PEREIRA et al., 2002).

A água, além de atuar como reguladora térmica e carreadora de nutrientes interfere nas trocas de CO₂ entre a planta e a atmosfera, já que esse processo é predominantemente realizado via estômatos. Os estádios de desenvolvimento mais sensíveis à deficiência hídrica são os relativos à germinação e emergência das plantas, e o florescimento e enchimento dos grãos. Para tais estádios de desenvolvimento da soja tem-se os maiores valores de coeficiente de cultura (Kc) do ciclo, entre 0,56 e 1,5 (FARIAS et al., 2001).

Nos estádios entre floração (R3-R4) e enchimento de grãos (R5-R6) a planta apresenta as taxas máximas de evapotranspiração, devido à maior área foliar, ou seja, há maior superfície para trocas gasosas (FARIAS; NEPOMUCENO; NEUMAIER, 2007). Nessas etapas do desenvolvimento vegetal o déficit hídrico pode causar a queda prematura das folhas e o abortamento das flores e vagens, causando queda na produtividade (FARIAS; NEUMAIER; NEPOMUCENO, 2009).

Visto que as condições climáticas são uma das principais causas da variabilidade da produtividade da soja, especialmente no Rio Grande do Sul (BATTISTI; SENTELHAS, 2019; BERGAMASCHI et al., 2004; FONTANA; BERLATO, 1996; NÓIA JÚNIOR; SENTELHAS, 2019), vislumbra-se o quão importante é elucidar a relação produtividade-clima, para definir as áreas aptas e os períodos de semeadura de menor risco climático (CUNHA et al., 2001; DE MELO; FONTANA; BERLATO, 2004).

Para auxiliar no acompanhamento do crescimento e desenvolvimento de uma lavoura, atividade indispensável ao estudo ecofisiológico, imagens de satélites são fonte de informação importante, capazes de auxiliar na identificação da variabilidade espacial de atributos de solo e planta e, indiretamente, fornecer informações da ação dos elementos meteorológicos sobre a cultura (CLEVERS et al., 2017; JIANG et al., 2014; LI et al., 2019; LOBELL; ORTIZ-MONASTERIO, 2006).

Por meio da resposta espectral de um dossel vegetal, expressa por índices de vegetação, como o Índice de Vegetação por Diferença Normalizada (NDVI) (TUCKER, 1979), é possível inferir sobre características da cultura como o índice de área foliar (IAF) e biomassa, que podem ter relação muito clara com a produtividade final (FENG et al., 2014; LOBELL, 2013; MENG; DU; WU, 2013) e com a precipitação (BARBOSA; LAKSHMI KUMAR, 2016; NICHOLSON; FARRAR, 1994; WANG; RICH; PRICE, 2003).

O NDVI é calculado pela razão entre a quantidade refletida na banda do espectro eletromagnético do vermelho e a quantidade refletida da banda do infravermelho próximo. Os comprimentos de onda da banda do vermelho estão associados à radiação fotossinteticamente ativa, enquanto os comprimentos de onda do infravermelho próximo estão associados ao conteúdo de água na folha (CRUSIOL et al., 2018; MÉNDEZ-BARROSO et al., 2009). Ou seja, quanto maior o conteúdo de água nas folhas, maior é a absorção nesse comprimento de onda, influenciando na resposta espectral da planta e no NDVI.

Baseando-se na hipótese de que o fator meteorológico pode ser abordado por meio de índices de vegetação obtidos por imagens de satélite, o objetivo do trabalho foi o de explorar o NDVI, como expressão das respostas da cultura da soja às condições meteorológicas, e sua relação com a precipitação.

3.2. Material e Métodos

3.2.1. Local de estudo

O local de estudo compreende dois talhões de produção de soja, cultivada em sequeiro, com área total de 56,6 ha, pertencente à Cooperativa Central Gaúcha LTDA (CCGL). A área está localizada no município de Cruz Alta (RS), na região norte do estado do Rio Grande do Sul (Latitude 28° 38 '19" Sul, Longitude 53° 36' 23" Oeste e Altitude 452 metros) (Figura 1). O período de coleta dos dados compreendeu as safras 2017/18, 2018/19 e 2019/20. Na safra 2017/18 os dois talhões foram cultivados com soja. Na safra 2018/19 apenas no talhão 2 foi semeado a soja e na safra 2019/20 somente no talhão 1 (Figura 1). Portanto foram utilizados os dados oriundos das safras 2017/18 e 2019/20 para o talhão 1, e dados da safra 2018/19 para o talhão 2.

A região de Cruz Alta (RS) tem temperatura média anual de 18,5°C e precipitação média anual de 1630 mm (INMET, 2019). O clima é o subtropical com verão quente (Cfa) conforme classificação climática de Köppen (ALVARES et al., 2013).

Figura 1 - Área de produção da Cooperativa Central Gaúcha LTDA (CCGL), no município de Cruz Alta, estado do Rio Grande do Sul.

3.2.2. A cultura da soja

As cultivares de soja utilizadas foram a Monsoy 6410 na safra 2017/18; a DM5958 IPRO na safra 2018/19 e BMX Zeus e NA 5909 na safra 2019/20. As datas de plantio foram 14/11/2017; 10/11/2018 e 22/11/2019 e as datas de colheita foram 20/04/2018; 28/03/2019 e 22/02/2020. A Tabela 1 reúne os dados referentes ao plantio da cultura da soja em cada safra.

Tabela 1 - Datas de semeadura e colheita, ciclo da cultura, cultivares de grupo de maturação para as safras 2017/18, 2018/19 e 2019/20.

	Safra		
	2017/18	2018/18	2019/20
Talhão	1	2	1
Data de semeadura	14/11/2017	10/11/2018	22/11/2019
Data de colheita	20/04/2018	28/03/2019	22/02/2020
Ciclo (dias)	158	139	93
Cultivar	Monsoy 6410	DM5958 IPRO	BMX Zeus / NA 5909
Grupo de Maturação	6.4	5.8	5.5 / 6.2

A adubação de base utilizada em cada talhão foi de 250 kg ha⁻¹, nas proporções 07-34-11, seguindo recomendação de soja para o estado do Rio Grande do Sul (SALVADORI et al., 2016). Os tratamentos fitossanitários foram, sempre que necessário, realizados para o controle de plantas daninhas, pragas e doenças, mantendo as áreas de produção sem interferência

desses fatores bióticos. Os dados de produtividade média de cada talhão foram fornecidos pela CCGL.

3.2.3. Dados meteorológicos

Os dados meteorológicos foram coletados na estação meteorológica automática do Instituto Nacional de Meteorologia (INMET), instalada no município de Cruz Alta - RS (28° 36 '12" Sul, 53° 40' 24" Oeste), interno a área da CCGL. Os dados foram obtidos na escala horária, e convertidos para a escala diária. Foram utilizados os dados diários de precipitação pluvial, temperaturas máxima e mínima do ar, umidade relativa do ar, velocidade do vento e radiação solar global, coletados nos anos de 2017 a 2020, sempre coincidindo com os períodos de produção da soja.

3.2.4. Cálculo do índice de vegetação

As imagens utilizadas para o cálculo do NDVI foram obtidas por meio de sensores a bordo do satélite Sentinel-2, lançados na missão da Agência Espacial Europeia (ESA), pertencente ao programa Copérnico de observação da Terra, grido pela Comissão Europeia (<http://www.copernicus.eu/main/overview>). A coleção de imagens ópticas do Sentinel-2 contém um sensor óptico (Multi-Spectral Instrument-MSI) que capta imagens com 13 bandas espectrais, desde o visível e o infravermelho próximo ao infravermelho de onda curta e bandas com correção atmosférica e reflectância de superfície (refletância TOA – Top of Atmosphere) (JIN et al., 2019). As observações por satélites são fornecidas numa escala temporal de 5 dias e em escala espacial de 10 metros (JIN et al., 2019; VELOSO et al., 2017).

Os processamentos destinados à coleta das imagens e cálculos dos índices de vegetação foram realizados na plataforma Google Earth Engine (GEE) (<http://earthengine.google.com>). Foram selecionadas imagens dos meses de novembro a abril, equivalente ao período normal de produção da soja na região, para as safras de 2017/18, 2018/19 e 2019/20. Foi aplicado um filtro de nuvens de 2%, resultando em um total de 16 imagens para a safra 2017/18, 15 imagens para a safra 2018/19 e 22 imagens para a safra 2019/20, que foram utilizadas para a análise temporal do NDVI da soja em cada uma das safras. O cálculo do NDVI (Eq. 1) para cada imagem foi feito na própria plataforma GEE.

$$NDVI = \frac{NIR-R}{NIR+R} \quad (\text{Eq. 1})$$

Em que NIR é a banda do infravermelho próximo e R é a banda do vermelho do espectro eletromagnético.

A fim de avaliar a relação do NDVI e disponibilidade hídrica, foram correlacionados os dados de NDVI acumulado com precipitação acumulada e déficit hídrico acumulado em cada talhão e safra, para todo o período de cultivo. Como o número de imagens da safra 2019/20 era maior do que para as safras anteriores, foram contabilizados na soma, dados relativos aos mesmos períodos fenológicos, caracterizados pelo número de dias após a semeadura, para que a escala temporal dos dados fosse a mesma. Assim, foi utilizado um total de oito imagens para cada uma das três safras. As avaliações de correlação entre as variáveis foram realizadas a partir das equações ajustadas por análises de regressão simples e respectivo coeficiente de determinação (R^2).

3.2.5. Balanço hídrico da cultura da soja

Para o cálculo do balanço hídrico (BH) da cultura foi usado modelo de Thornthwaite e Matter (1955) adaptado. Os cálculos foram feitos em escala diária, iniciados no mês de janeiro de 2017, portanto dez meses antes do primeiro ciclo de produção de soja, safra 2017/18, nos dois talhões (Figura 1). O cálculo prévio foi fundamental para determinar o valor de armazenamento de água no solo para a data de primeira semeadura. Após a primeira safra de soja (2017/18), prosseguiu-se com o cálculo do BH, utilizando para a entressafra de soja um valor de K_c fixo igual a 1. Para a contabilidade foram utilizados os dados coletados na estação meteorológica automática do Instituto Nacional de Meteorologia (INMET), instalada no município de Cruz Alta – RS.

O solo dos talhões (Figura 1) é classificado como Latossolo roxo distrófico (SANTOS et al., 2018), com porcentagens média de argila de 53%, de silte de 19% e de areia de 28% para o talhão 1 e 52% de argila, 19% de silte e 29% de areia para o talhão 2. Os dados de textura do solo foram obtidos a partir de coletas e análises físicas de amostras deformadas de solo, coletadas nas áreas em maio de 2020.

A partir das informações de textura média do solo das duas áreas (Figura 1), e da função de pedotransferência proposta por Reichardt et al. (2009), foram calculados os valores de umidade do solo em capacidade de campo (θ_{cc}) e em ponto de murcha permanente (θ_{pmp})

(equações 2 e 3), à profundidade do solo (Z) de 0,5m, considerado limite de profundidade do sistema radicular.

$$\theta_{cc}(10kPa) = 0,506 \text{ Argila}^{0,31} \quad (\text{Eq. 2})$$

$$\theta_{pmp}(1500kPa) = 0,39 \text{ Argila}^{0,51} \quad (\text{Eq. 3})$$

A capacidade de armazenamento de água do solo (CAD) foi então calculada (Eq. 4).

$$CAD = (\theta_{cc} - \theta_{pmp})Z \quad (\text{Eq. 4})$$

A unidade da umidade do solo em capacidade de campo (θ_{cc}) e ponto de murcha permanente (θ_{pmp}) é dada em $\text{cm}^3 \text{ cm}^{-3}$ e a CAD em mm.

Para a estimativa da evapotranspiração de referência (ETo) foi utilizada a equação de Penman-Monteith (ALLEN et al., 1998) (Eq. 5).

$$ET_o = \frac{0,408 \Delta (R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34u_2)} \quad (\text{Eq. 5})$$

Sendo: ETo a evapotranspiração de referência (mm dia^{-1}); Δ a inclinação da curva de pressão de vapor ($\text{kPa } ^\circ\text{C}^{-1}$); R_n ($\text{MJ m}^{-2} \text{ dia}^{-1}$) o saldo de radiação, G o fluxo de calor no solo ($\text{MJ m}^{-2} \text{ dia}^{-1}$); γ a constante psicrométrica ($\text{kPa } ^\circ\text{C}^{-1}$); T a temperatura média do ar ($^\circ\text{C}$); e_s a pressão de saturação de vapor (kPa); e_a a pressão de vapor real (kPa) e u_2 a velocidade do vento a 2 metros de altura (m s^{-1}).

Para o cálculo da ETo assumiu-se fluxo de calor no solo (G) igual a zero e o saldo de radiação (R_n) estimado pela equação (6) (ALLEN et al., 1998):

$$R_n = Q_g (1 - 0,23) + [(-4,903 \cdot 10^{-9} \left(\frac{T_{max}^4 + T_{min}^4}{2} \right) - 0,34 - 0,14\sqrt{e_a} \left(1,35 \frac{Q_g}{Q_{cs}} - 0,35 \right)] \quad (\text{Eq. 6})$$

Onde: Q_g é a radiação solar global ($\text{MJ m}^{-2} \text{ d}^{-1}$) medida na estação; T_{max} e T_{min} respectivamente a temperatura máxima e mínima do dia ($^\circ\text{C}$); e_a a pressão parcial de vapor (kPa) e Q_{cs} a radiação solar global estimada para céu claro ($\text{MJ m}^{-2} \text{ d}^{-1}$) (Eq. 7).

$$Q_{cs} = Q_o(0,75 + 2 \cdot 10^{-5} alt) \quad (\text{Eq. 7})$$

$$e_s = 0,6108 \cdot 10^{\frac{7,5 T_{med}}{237,3 + T_{med}}} \quad (\text{Eq. 8})$$

$$ea = es \frac{UR}{100} \quad (\text{Eq. 9})$$

Em que *alt* é a altitude (m) e UR é a umidade relativa do ar (%).

A evapotranspiração da cultura da soja (ET_c) foi calculada (Eq. 10) a partir dos dados de evapotranspiração de referência e do coeficiente de cultura (K_c) para soja (Eq. 11) (MARTORANO, 2007). Nessa equação, DAS significa dias após a semeadura da soja.

$$ET_c = K_c ET_o \quad (\text{Eq. 10})$$

$$K_c = -0,0001DAS^2 + 0,0168DAS + 0,4268 \quad (\text{Eq. 11})$$

O balanço hídrico considerou a água facilmente disponível (AFD) (Eq. 13). Esse ponto representa uma fração (percentual *p*) (Eq. 12) da CAD, aquela que pode ser extraída do solo a partir do armazenamento máximo, sem que ocorra déficit hídrico na cultura.

O valor do percentual *p* depende da cultura, cultivar e ET_c (ALLEN et al., 1998). Esse conceito está relacionado à dinâmica do processo de distribuição da água no solo, que considera a absorção da água pelas raízes das plantas não dependente apenas da capacidade do solo em armazenar água, mas também das características da planta e da demanda atmosférica (DE JONG VAN LIER, 2017; ROMANO et al. 2011).

$$p = 0,5 + [0,04(5 - ET_c)] \quad (\text{Eq. 12})$$

$$AFD = p CAD \quad (\text{Eq. 13})$$

3.3. Resultados e Discussão

3.3.1. Condição meteorológica das safras de Soja

As temperaturas médias mensais de todos os anos/safras (Figura 2) foram próximas às temperaturas médias normais para o município de Cruz Alta - RS (DINIZ; RAMOS; REBELLO, 2018). Em relação às variações térmicas diárias, na safra 2017/18 a temperatura média do ar, na região dos talhões (Figura 1) entre os meses de novembro de 2017 e abril de 2018, foi de 21,5°C. Nesse período as temperaturas mínima e máxima médias ficaram em 16,4°C e 28,2°C, respectivamente. Os extremos térmicos foram registrados no dia 19/11/2017 quando a temperatura mínima foi de 7,9°C, e no dia 16/12/2017 quando a temperatura máxima atingiu os 35,5°C (Figura 2-A).

Na safra 2018/19, de novembro de 2018 e abril de 2019, a temperatura do ar seguiu tendência da safra anterior, incluindo valores médios muito similares aos da safra passada. A temperatura média durante a produção da soja, safra 2018/19, foi de 21,9°C, com valores médios de temperatura mínima de 17°C e de temperatura máxima de 28,3°C. Nessa safra os extremos térmicos foram de 8,4°C de temperatura mínima, registrada em 3/12/2018, e máxima absoluta de 35,5°C, no dia 11/12/2018.

Durante a última safra analisada, de novembro de 2019 a abril de 2020, mais uma vez a variabilidade térmica foi similar às duas safras passadas, com temperatura média de 23,3°C. As temperaturas médias mínima e máxima foram de 17,5°C e 30,4°C, com extremos de temperatura mínima de 8,2°C, em 22/2/2020 e máxima em 38,1°C de 29/12/2019.

A cultura da soja é mais bem adaptada a locais com temperaturas do ar entre 20°C e 30°C, conforme a temperatura média da região durante as três safras. Além disso, a condição térmica (Figura 2) não apresentou temperaturas abaixo dos 10°C ou superior aos 40°C, as quais são consideradas impróprias para o cultivo da soja, podendo reduzir o crescimento vegetativo, de forma a restringir a floração ou antecipar a maturação (FARIAS; NEUMAIER; NEPOMUCENO, 2009). Os dias com temperaturas abaixo de 10°C foram pontuais em cada safra, não prejudicando o crescimento vegetativo da soja.

Figura 2 - Temperaturas máxima, média e mínima do ar ao longo do ciclo da cultura da soja para as safras (A) 2017/18, (B) 2018/19 e (C) 2019/20 em Cruz Alta - RS.

Em relação a precipitação, os registros mostram eventos mais frequentes e de maiores volumes acumulados para as safras 2017/18 e 2018/19 (Figura 3-A e B). Na safra 2017/18 foram registrados 37 dias com precipitação superior a 5 mm, enquanto na safra 2018/19 foram 29 dias. Para a safra 2017/18, os meses de janeiro e março foram os mais chuvosos,

com precipitação acumulada de 361 mm e 240 mm, respectivamente. Na safra 2018/19, os meses mais chuvosos foram novembro e janeiro, com 213 mm e 266 mm, respectivamente.

Na safra 2017/18, ao longo de todo o ciclo da cultura, a precipitação acumulada foi de 961 mm, quantia que supera o limiar de 800 mm, estabelecido por Zanon et al. (2016), necessário para o crescimento e desenvolvimento da soja, o que possibilita maximizar a produtividade, desde que os outros fatores condicionantes da produção não a limitem. Para a safra 2018/19 a precipitação acumulada chegou a 781 mm, valor pouco abaixo do limite citado de 800 mm.

Figura 3 - Precipitação diária e acumulada ao longo do ciclo da cultura da soja para as safras (A) 2017/18, (B) 2018/19 e (C) 2019/20 em Cruz Alta - RS.

Segundo Assad e Castro (1991), a precipitação acumulada pode não ser o elemento meteorológico mais indicado para avaliar o desenvolvimento da cultura, já que ocorre significativa flutuação dos dados diários mesmo a curtas distâncias. Nas safras 2017/18 e 2018/19 foram observados dias com precipitações elevadas, em torno de 100 a 120 mm e

dias sem precipitação. Porém, de forma geral, a precipitação apresentou boa distribuição ao longo do tempo, com no máximo 15 dias secos consecutivos.

A cultura da soja apresenta maior sensibilidade hídrica nos períodos de germinação-emergência e floração-enchimento de grãos. No período entre germinação e emergência, tanto excesso quanto déficit hídrico são prejudiciais. A partir desse período, a necessidade hídrica da planta aumenta com o seu desenvolvimento, até atingir a fase de florescimento-enchimento de grãos (FARIAS, NEUMAIER, NEPOMUCENO, 2009). No período entre germinação e emergência, na safra 2017/18, a precipitação acumulada foi de 22,8 mm. Até a floração, que ocorreu no início do mês de fevereiro, ocorreram 21 dias com precipitação acima de 5 mm, com precipitação acumulada de 595 mm.

A safra de 2018/19 apresentou dados semelhantes, com precipitação acumulada de 213 mm no mês de novembro, desde a data de semeadura da soja. Até a floração ocorreram 20 dias com precipitação acima de 5 mm, com precipitação acumulada de 547 mm. As condições meteorológicas, aqui retratadas pela temperatura do ar (Figura 2) e precipitação (Figura 3) ao longo das safras de soja 2017/18 e 2018/19 foram favoráveis à cultura, o que resultou em produtividades médias de 3,9 ton ha⁻¹ e 4,2 ton ha⁻¹, respectivamente.

Na safra 2019/20 a distribuição temporal e os valores de precipitação foram distintos, aquém do registrado para as duas safras prévias. Com apenas 11 dias chuvosos, acumulando ao menos 5 mm dia⁻¹, ao longo de todo o ciclo da soja foram somados 235 mm, valor que representa 29,4% do limiar apontado por Zanon et al. (2016), portanto já sugerindo perda produtiva por deficiência hídrica (Figura 3-C).

Além da distribuição irregular das precipitações no período de produção da soja, safra 2019/20, observa-se queda significativa da precipitação a partir de fevereiro. No período entre germinação e emergência foram contabilizados apenas dois dias chuvosos, com menos de 5 mm cada, acumulando 6 mm nesse subperíodo. Da semeadura, no mês de novembro de 2019, ao início do mês de fevereiro de 2020, compreendendo todo subperíodo vegetativo, florescimento e início do desenvolvimento de vagens, foram acumulados apenas 187 mm de precipitação, volume bem abaixo do normal para o município de Cruz Alta - RS (INMET, 2010). Desse ponto à maturação foram registrados mais 48 mm, totalizando os 235 mm na safra.

Essa condição meteorológica, de baixos índices pluviométricos, de fato, resultou em baixas produtividades no talhão, cuja média foi de $2,1 \text{ ton ha}^{-1}$, concordando com os resultados obtidos por Fontana e Berlato (1998), que mostraram baixas produtividades de soja associados a baixa disponibilidade hídrica entre os meses de dezembro a março no estado do Rio Grande do Sul.

Segundo Farias et al. (2001), a estiagem ocorrida na safra de 1990/91 gerou uma perda de até 70% na produtividade, com produtividade média 2.000 kg ha^{-1} . Nóia Júnior et al. (2020) estudaram os efeitos do El Niño Oscilação Sul (ENOS) na produtividade de soja nos estados do sul do Brasil e observaram queda de 15,6% no rendimento da soja na safra 2011/12, com relação à safra anterior. Segundo os autores, a queda ocorreu, principalmente, em decorrência da estiagem e temperaturas altas nos meses de novembro e dezembro de 2011, causadas pelo fenômeno ENOS.

Em média, a evapotranspiração da cultura (ETc) foi de 4,64 mm, 4,04 mm e 4,97 mm em relação as safras 2017/18, 2018/19 e 2019/20 (Figura 4). O consumo hídrico da soja varia em função do seu estágio de desenvolvimento e da demanda evaporativa da atmosfera (BERLATO; MATZENAUER; BERGAMASCHI, 1986). Além de apresentar maior valor médio, a safra 2019/20 também apontou valores de até $9,4 \text{ mm dia}^{-1}$. Com predominância de tempo seco e temperatura elevada (Figuras 2 e 3) há naturalmente o aumento da evapotranspiração de referência e, por conta disso, da evapotranspiração da cultura (ETc).

Figura 4 – Evapotranspiração da cultura (ETc), evapotranspiração real da cultura (ETr) e déficit hídrico acumulado ao longo do ciclo da cultura da soja para as safras (A) 2017/18, (B) 2018/19 e (C) 2019/20, em Cruz Alta - RS.

Para as três safras analisadas, as maiores taxas evapotranspiratórias da cultura da soja (ETc) ocorrerem entre os meses de dezembro e fevereiro (Figura 4), meses que contemplam o final do subperíodo vegetativo e início dos estádios reprodutivos. Nessas fases ocorre maior atividade fotossintética da planta, pois há maior formação de nós e maior acréscimo na área foliar (FARIAS; NEPOMUCENO; NEUMAIER, 2007).

A evapotranspiração real da soja, que varia em função da água disponível no solo suficiente para que a planta atinja a evapotranspiração máxima, apresenta queda em meados de fevereiro na safra 2017/18, devido ao aumento do déficit hídrico nesse período. Na safra

2018/19 há queda mais acentuada da ETr nos meses de dezembro e fevereiro, meses com menores índices pluviométricos (Figura 3). Na safra 2019/20 tem-se baixos valores de ETr, com elevada deficiência hídrica em quase toda a safra, com taxas máximas no mês de janeiro, quando houve precipitação de ~90 mm e um decorrente acúmulo de água no solo.

As frequência e totais acumulados de precipitação nas duas primeiras safras resultaram deficiência hídrica em torno de 130 mm. Já na última safra, a predominância de tempo seco causou aumento de forma linear, desde a semeadura à colheita, acumulando mais de 400 mm de déficit hídrico.

3.3.2. Variabilidade temporal do NDVI da cultura da soja

A variação temporal do NDVI das safras (Figura 5) caracterizou o período de cultivo da soja nos talhões, com semeadura em novembro e colheita em abril (safra 2017/18) e março (safras 2018/19 e 2019/20), dentro do que é esperado para a produção de soja no Rio Grande do Sul (RIZZI; RUDORFF, 2005).

Para as três safras foi observado um acréscimo mais lento do índice NDVI até meados do subperíodo vegetativo, mais especificamente nos primeiros trinta dias de produção, momento de condição meteorológica favorável à produção (Figuras 2 e 3) quase sem deficiência hídrica (Figura 4). Posteriormente, o esperado aumento exponencial da área foliar (CRUSIOL et al., 2012) pode ser observado através do aumento do NDVI, especialmente nas safras 2017/18 e 2018/19.

Nesses dois primeiros anos de produção, já no início dos meses de janeiro de cada ano, em média 50 dias após a semeadura, o NDVI foi de 0,78 e 0,61, respectivamente. No terceiro ano de produção o incremento em NDVI a partir do primeiro mês de produção foi menor, basicamente ocasionado pela deficiência hídrica (Figura 4). No início de janeiro de 2020 o NDVI da cultura foi de 0,53.

A partir daí, com condição hídrica satisfatória (Figura 3 e 4), a soja produzida nas safras 2017/18 e 2018/19, baseado nos resultados de NDVI (Figuras 5-A e 5-B), prosseguiu com crescimento e desenvolvimento normal, mantendo a folhagem ativa de janeiro a março, período de floração e formação de vagens e grãos (SANTOS et al., 2014). Já na safra 2019/20, apesar do NDVI chegar à limites superiores similares ao que foi mensurado para as safras anteriores, o tempo de permanência com máxima folhagem foi 26% menor (Figura

5-C). Ocorre que, uma das consequências da deficiência hídrica é a antecipação da senescência de folhas e da maturação (DE SOUZA; EGLI; BRUENING, 1997), resultando em menor reflectância do NIR e maior quantidade refletida na região vermelha do espectro, mostrando intensa relação com IAF (BREUNIG et al., 2011; DE LA CASA et al., 2018; GROFF, 2010; KROSS et al., 2015; RICHETTI et al., 2019).

Figura 5 - NDVI médio e deficiência hídrica (em valor negativo) do talhão ao longo do ciclo da cultura da soja para as safras (A) 2017/18, (B) 2018/19 e (C) 2019/20.

Na safra 2017/18 o NDVI máximo foi verificado aos 94 dias de ciclo, similar ao registrado para a safra 2019/20 (91 dias de ciclo). A safra 2018/19 apresentou máximo valor de NDVI aos 113 dias de ciclo. Ressalta-se que erros em determinar o momento de máximo valor do NDVI também decorrem da disponibilidade das imagens. No caso das três safras, o tempo médio entre imagens consecutivas que integram o platô de valores de NDVI (Figura 5), foi de 8 dias para as safras 2017/18 e 2018/19 e 5 dias na safra 2019/20.

Bariani et al. (2015) avaliaram o NDVI ao longo do desenvolvimento da cultura da soja irrigada em Cruz Alta/RS. Os resultados apresentados mostraram a relação existente entre dados de NDVI e desenvolvimento da soja, possibilitando associar o NDVI ao estágio de desenvolvimento da cultura, assim como apresentado na Figura 5. Ainda, os resultados evidenciaram as tendências de aumento quase que linear do NDVI no início do desenvolvimento da soja e a tendência decrescente, acompanhando a maturação da cultura, ao final do ciclo de produção. O mesmo foi apontado por Schaparini et al. (2020) no município de Carazinho - RS, a 100 km de Cruz Alta. O padrão de crescimento da curva de NDVI revela, também, as boas condições hídricas no período.

Apesar da similaridade das curvas para as safras 2017/18 e 2018/19 (Figura 5), observa-se menores valores de NDVI no começo da safra 2018/19. Em função da ausência de deficiência hídrica no início do ciclo da soja, para ambas as safras (Figura 4), julga-se que a diferença não se deve à questão hídrica, mas, possivelmente, à radiação solar acumulada, que na safra 2017/18 foi de 450 MJ m^{-2} e na safra 2018/19 foi de 277 MJ m^{-2} nos primeiros 50 dias de ciclo. O resultado é uma menor taxa fotossintética e crescimento vegetativo em 2018/19, influenciando nos valores de NDVI.

Outros fatores como doenças e déficit nutricional, que alteram a estrutura celular, também podem ter influenciado na diferença espectral do dossel (GROFF, 2010). As diferenças de NDVI no início do desenvolvimento da cultura, durante o mês de dezembro de 2017 e 2018 e, a redução do índice vegetativo nos meses de fevereiro das safras 2017/18 e 2019/19, exatamente no meio do ciclo, decorrem, possivelmente, da nebulosidade, portanto não devem ser consideradas como queda real do NDVI em função da condição da vegetação.

Segundo Crusiol et al. (2013), que avaliou o perfil do NDVI de acordo com os estádios fenológicos da cultura da soja, sem restrição hídrica, valores máximos de NDVI coincidem

com os estádios reprodutivos, desde R1-R2, e podem chegar a valores de até 0,9. Rodrigues et al. (2013) encontraram valores máximos de NDVI para a soja no estágio V9 para o município de Cruz Alta - RS. Bariani et al. (2015) encontraram os valores máximos no estágio R5, também estudando a soja no estado do Rio Grande do Sul. Os resultados para as safras 2017/18 e 2018/19 (Figuras 5-A e 5-B) refletem isso, com valores máximos a partir do início da floração, prolongando-se por, aproximadamente, 70 dias.

Para a safra de 2019/20 (Figura 5-C), a curva de NDVI (Figura 5-A; 5-B) indica um crescimento e desenvolvimento diferenciado da cultura da soja em relação às safras anteriores. Nesse último período de produção de soja analisado, safra 2019/20, teve-se acentuada influência da condição meteorológica sobre a cultura, basicamente causada pela escassez de precipitação (Figura 3-C), acentuando a deficiência hídrica (Figura 4-C).

A deficiência hídrica observada na safra 2019/20 (Figura 4-C) teve reflexos sobre o comportamento do NDVI da cultura (Figura 5-C). Os 100 mm de déficit, acumulados entre a semeadura e o final do mês de dezembro de 2019, claramente atrasaram o crescimento vegetativo da soja (Figura 5-C). Nas safras 2017/18 e 2018/19 a deficiência, nesse mesmo período, era de menos de 10 mm, e NDVI mostrava-se linearmente crescente (Figura 5-A, 5-B). Em 2019/20 o platô relativo ao máximo valor de NDVI foi temporalmente mais curto, permanecendo nessa condição de NDVI máximo por 37 dias, enquanto nas safras anteriores o platô permaneceu por 73 dias em 2017/18 e 75 dias 2018/19.

O atraso em crescimento da soja, no início do ciclo, constatado por meio do NDVI (Figura 5-C), somado à condição hídrica que novamente prejudicou a cultura, especialmente durante o mês de fevereiro de 2020 (Figuras 3-C e 4-C), se refletiu em um menor tempo com máxima folhagem até se dar o início da senescência de folhas e maturação das plantas, detectado através do menor período com máximos valores de NDVI (Figura 5-C).

Fontana, Berlato e Bergamaschi (1992); Souza et al. (2018) e Almeida et al. (2009) mostram que uma deficiência hídrica precoce acaba encurtando o tempo e valor máximo do IAF, resultando em redução do potencial de produção por conta da menor capacidade fotossintética. Outra questão importante, já determinada por Barros et al. (2003) e Stülp et al. (2009), é a deficiência hídrica entre fevereiro e março. Tradicionalmente, em função da época preferencial para semeadura, as lavouras de soja, nesses meses, estão em estádios reprodutivos, com maior sensibilidade à deficiência hídrica (DOORENBOS e KASSAM,

1979). Essa condição meteorológica adversa tem como principal consequência a antecipação da senescência das folhas e maturação, o que resulta em redução dos valores de NDVI (HOYOS-VILLEGAS et al., 2014; TAIZ; ZEIGER, 2009).

Para outras culturas também é possível observar a influência da precipitação nos valores de NDVI. Wang, Rich e Price (2003) estudaram o NDVI para culturas agrícolas, pasto e vegetação de floresta e observaram a forte relação com a precipitação, identificando ainda o período de acúmulo de precipitação que antecede tal valor de NDVI para determinada vegetação, concluindo que esses dados podem prever mudanças na produtividade. Utilizando o índice VCI (*Vegetation Condition Index*) para o efeito da estiagem sobre a cultura da cana-de-açúcar, Picoli et al. (2019) encontraram boa correlação entre o índice e a produtividade da cultura, mostrando ainda a eficiência do índice em avaliar a estiagem agrícola, por sua relação com conteúdo de água no solo.

3.3.3. Análises das correlações entre a disponibilidade hídrica e o índice espectral NDVI para a cultura da Soja

A precipitação, principal aporte hídrico para o solo, atua como fator limitante ao crescimento e desenvolvimento da soja. Períodos de estiagem podem interferir na emissão, expansão e atividade fotossintética da folhagem e, assim, influenciar o NDVI da cultura (ALMEIDA; FONTANA, 2009; BIRTWISTLE et al., 2016). Por isso, a variabilidade espaço-temporal da precipitação pode modular a variabilidade produtiva em uma mesma unidade de produção (talhão) (DOS SANTOS, 2020), ou mais claramente quando são observadas as nuances produtivas em áreas maiores, dentro de municípios ou estados (GOULART et al., 2015; OLIVERA RODRIGUEZ et al., 2020; WOLF; GUPTA; ROSEN, 2020).

Os resultados das correlações entre dados de precipitação e NDVI acumuladas para todo o período da safra mostram relação positiva entre as variáveis (Figura 6). A partir das equações ajustadas para as safras 2017/18 e 2018/19, considerando os coeficientes angulares das equações (Figura 6), tem-se um maior incremento de biomassa por milímetro de precipitação em 2018/19.

Cai et al. (2019), para trigo produzido na Austrália, também descrevem correlações positivas entre precipitação e frequências de dias úmidos com a produtividade da cultura. Entretanto, ao analisar os volumes de precipitação acumulada em diferentes subperíodos de

desenvolvimento com a produtividade, observaram que a condição meteorológica em pico de crescimento da cultura melhor elucidava o resultado. Com objetivo similar, Birtwistle et al. (2016) analisaram 26 anos de dados do índice espectral NDVI/Landsat para a vegetação do semiárido no Arizona (EUA), concluindo que as variações do NDVI foram capazes de explicar 73% dos totais de precipitação ao longo dos anos.

Ao considerar a variação do NDVI como função única da precipitação acumulada, sem ponderar a capacidade de armazenagem (CAD), o armazenamento hídrico existente no solo e possíveis excedentes hídricos gerados, observa-se que um acumulado de chuva, de mais de 800 mm, essencial à maximização da produtividade (ZANON et al., 2016), pela equação ajustada nota-se redução da taxa de crescimento – aumento da biomassa das plantas (Figura 6). Nesse caso, o resultado negligencia a minimização da deficiência hídrica (Figura 4C) e, como já mencionado, a geração de excedente hídrico. Uma tendência de acréscimo do NDVI por unidade de precipitação acumulada fica ainda mais evidente ao se comparar as safras 2017/18 e 2018/19 com a safra 2019/20.

Nessa última safra (2019/20), uma distribuição temporal irregular da precipitação, na maior parte dos casos acumulando menos de 20 mm dia⁻¹, acentuou a deficiência hídrica, linearmente crescente da semeadura à maturação da soja (Figuras 4 e 5). A condição hídrica interferiu direta e negativamente no crescimento e desenvolvimento da soja, identificado pela evolução temporal do índice espectral NDVI (Figura 5).

O crescimento das plantas de soja nessa safra, principalmente o aumento da cobertura foliar, indiretamente descrito a partir da evolução do NDVI (Figura 5-C), apesar de evidenciar uma interferência negativa ocasionada pela disponibilidade hídrica, não apresentou redução proporcional à diminuição da precipitação acumulada (Figura 3-C).

Como crescimento e desenvolvimento da cultura estão diretamente condicionados ao armazenamento de água no solo, e não simplesmente à precipitação, exercendo ação sobre a evapotranspiração (Figura 4-C) e produção de fitomassa, vislumbra-se um maior incremento do NDVI por unidade de precipitação acumulada para a safra 2019/20 (Figura 6-C), em relação às duas safras prévias (Figuras 6A e 6B).

Ao se comparar os coeficientes angulares das equações, 0,0062 (2017/18), 0,007 (2018/19) e 0,0136 (2019/20) (Figura 6) com os dados de produtividade média de cada safra, de 3,9 ton ha⁻¹ (2017/18), 4,2 ton ha⁻¹ (2018/19) e 2,1 ton ha⁻¹ (2019/20), tem-se

exposto que, apesar da relação entre as variáveis, deve-se ter cautela ao utilizar dados de NDVI para associar crescimento e potencial produtivo à precipitação acumulada.

Figura 6 – Correlação entre o NDVI acumulado e precipitação acumulada para as safras (A) 2017/18, (B) 2018/19 e (C) 2019/20.

Goulart et al. (2015) e Birtwistle et al. (2016) enfatizam que os índices vegetativos não apresentaram boa correlação quando da ocorrência de altos índices pluviométricos. O mesmo resultado foi obtido por Lucas e Schuler (2007) quando estudaram o comportamento do NDVI para cana-de-açúcar.

A fim de integrar o efeito do sistema solo-planta-atmosfera, uma nova correlação foi analisada (Figura 7). Dessa vez dados de deficiência hídrica e de NDVI acumulados foram correlacionados. A deficiência hídrica, que integra as características do solo, condição meteorológica (Figuras 2, 3) e fenologia da cultura (Figura 5), mostrou-se crescente da safra 2017/18 à safra 2019/20 (Figura 4).

Além dos resultados indicarem maior correlação entre variáveis, definido a partir dos coeficientes de determinação (R^2) de cada ajuste (Figura 7), os coeficientes angulares das equações melhor externam a condição real de crescimento (Figura 5) e o potencial produtivo da soja. Para as safras 2017/18 e 2018/19 os acréscimos de NDVI por unidade de deficiência hídrica foram similares, 0,0379 para 2017/18 e 0,0375 para 2018/19. Como previamente

discutido, as condições meteorológicas nas duas safras foram favoráveis à cultura da soja (Figuras 2, 3 e 4) resultando em elevada produtividade, de 3,9 ton ha⁻¹ (2017/18), 4,2 ton ha⁻¹ (2018/19).

Resultados obtidos para a safra 2019/20 (Figura 7-C) expõem a redução do potencial produtivo, frente às duas safras anteriores (Figuras 7-A e 7-B), devido a condição meteorológica ter desfavorecido a cultura (Figura 4-C). Com menor taxa de incremento de biomassa por unidade de tempo, aqui expresso pelo acúmulo dos dados de NDVI (Figura 7C) teve-se como resultado a redução da produtividade, para 2,1 ton ha⁻¹. Assim, com base nos resultados obtidos para esse conjunto de dados (Figura 7) pode-se considerar que a análise do crescimento e do potencial produtivo da soja, ao longo da safra, pode ser feita a partir dos dados de NDVI acumulados, pois mostram o efeito meteorológico sobre a cultura, nesse caso especialmente a influência da deficiência hídrica.

Figura 7 - Correlação entre NDVI acumulado e a deficiência hídrica acumulada para as safras (A) 2017/18, (B) 2018/19 e (C) 2019/20.

Portanto, utilizando imagens de NDVI para mesmos estádios fenológicos, é possível inferir sobre a influência da disponibilidade hídrica na cultura da soja (Figura 7). Atrasos no incremento do índice vegetativo podem ser relacionados a uma condição hídrica adversa

para a cultura. Ressalta-se que os resultados referentes à Figura 7 não devem ser extrapolados para outras áreas e/ou épocas de produção de soja, mas sim, a reforçar a possibilidade de identificação, a partir do índice espectral NDVI, a influência meteorológica sobre o crescimento e desenvolvimento de cultura da soja e seu potencial de produção em talhões de produção.

3.4. Conclusão

O estudo analisou as condições meteorológicas ao longo de três safras de soja (2017/18, 2018/19 e 2019/20) na região de Cruz Alta (RS), com objetivo de explorar a relação entre a cobertura vegetal, definida pelo NDVI, com a disponibilidade hídrica. Com distribuição regular e volumes elevados de chuva, em concordância ao necessário para maximizar a produção no estado do Rio Grande do Sul, a cultura da soja, nas safras 2017/18 e 2018/19, apresentou evolução temporal do NDVI tal como observado para áreas irrigadas. Nessas duas safras, o índice espectral elucidou a favorabilidade meteorológica, confirmada a partir das produtividades de grãos. A terceira safra de soja analisada, 2019/20, apresentou menores índices pluviométricos, aumentando o déficit hídrico ao longo do ciclo. O efeito adverso da deficiência hídrica foi identificado através do NDVI, permitindo verificar a influência meteorológica sobre a evolução temporal da cobertura foliar da soja. O NDVI apresentou correlações positivas tanto com a precipitação quanto com a deficiência hídrica acumuladas nos ciclos de produção da soja. Os resultados evidenciaram a capacidade de identificar o efeito meteorológico a partir da observação do NDVI.

Referências

- ALLEN, R.G.; PEREIRA, L.S.; RAES, D.; SMITH, M. Crop evapo- transpiration: Guidelines for computing crop requirements. Irrigation and Drainage Paper No. 56, FAO, 1998.
- ALMEIDA, T. S. DE; FONTANA, D. C. Desempenho dos índices de vegetação NDVI e PVI para a cultura da soja em diferentes condições hídricas e de sistema de manejo do solo. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 , INPE**, v. 53, n. 9, p. 17–22, 2009.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.

- ASSAD, E. D.; CASTRO, L. H. R. Análise Frquencial da Pluviometria para a estação de Sete Lagoas, MG. **Pesq. agropec. bras., Brasília**, v. 26, n. 3, p. 397–402, 1991.
- BARIANI, C. J. M. V. et al. Monitoramento Da Fenologia Da Soja Irrigada Usando Perfis De Série Temporal De Ndvi. n. September, p. 1610–1618, 2015.
- BARNETT, T. L.; THOMPSON, D. R. The use of large-area spectral data in wheat yield estimation. **Remote Sensing of Environment**, v. 12, n. 6, p. 509–518, 1982.
- BARROS, H. B. et al. **Efeito das épocas de semeadura no comportamento de cultivares de soja, no sul do estado do Tocantins**Revista Ceres, 2003.
- BATTISTI, R. Épocas de semeadura da cultura da soja com base no risco climático e na rentabilidade líquida para as principais regiões produtoras do Brasil. p. 261, 2013.
- BATTISTI, R.; SENTELHAS, P. C. Characterizing Brazilian soybean-growing regions by water deficit patterns. **Field Crops Research**, v. 240, n. June, p. 95–105, 2019.
- BERGAMASCHI, H. et al. Distribuição hídrica no período crítico do milho e produção de grãos. **Pesquisa Agropecuaria Brasileira**, v. 39, n. 9, p. 831–839, 2004.
- BERLATO, M.A., MATZENAUER, R., BERGAMASCHI, H. Evapotranspiração máxima da soja, relações com a evapotranspiração calculada pela equação de Penman, evaporação de tanque “classe A” e radiação solar global. **Agronomia Sulriogradense**, Porto Alegre, v.22, n.2, p.243-259, 1986.
- BREUNIG, F. M. et al. Directional effects on NDVI and LAI retrievals from MODIS: A case study in Brazil with soybean. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 1, p. 34–42, 1 fev. 2011.
- CAI, Y. et al. Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches. **Agricultural and Forest Meteorology**, v. 274, n. February, p. 144–159, 2019.
- CLEVERS, J. et al. Using Sentinel-2 Data for Retrieving LAI and Leaf and Canopy Chlorophyll Content of a Potato Crop. **Remote Sensing**, v. 9, n. 5, p. 405, 25 abr. 2017.

CONAB. Acompanhamento da Safra Brasileira. **Companhia Nacional de Abastecimento**, v. 5, n. 4, p. 1–113, 2019.

CONAB. Acompanhamento da safra brasileira 2019/2020. **Acompanhamento da Safra Brasileira de Grãos 2019/2020**, v. 8, p. 1–29, 2020.

CRUSIOL, L. G. T. et al. Comportamento espectral de diferentes genótipos de soja (GM para tolerância a seca e convencionais), em condição irrigada e sob estresse hídrico. **VI Congresso Brasileiro de Soja**, p. 1–4, 2012.

CRUSIOL, L. G. T. et al. NDVI de estádios de desenvolvimento da soja BRS 284 em condições de campo. **Jornada Acadêmica da Emprapa Soja**, n. 1973, p. 87–91, 2013.

CRUSIOL, L. G. T. et al. Sensoriamento Remoto como Suporte ao Monitoramento do Déficit Hídrico na Cultura da Soja. **VIII Congresso Brasileiro de Soja**, p. 299–301, 2018.

CUNHA, G. R. DA et al. Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. **Revista Brasileira de Agrometereologia**, v. 9, n. 3, p. 446–459, 2001.

DE JONG VAN LIER, Q. Field capacity, a valid upper limit of crop available water? **Agricultural Water Management**, v. 193, p. 214–220, 2017.

DE LA CASA, A. et al. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 146, n. October, p. 531–547, 2018.

DE MELO, R. W.; FONTANA, D. C.; BERLATO, M. A. Indicadores de produção de soja no Rio Grande do Sul comparados ao zoneamento agrícola. **Pesquisa Agropecuaria Brasileira**, v. 39, n. 12, p. 1167–1175, 2004.

DE SOUZA, P. I.; EGLI, D. B.; BRUENING, W. P. Water stress during seed filling and leaf senescence in soybean. **Agronomy Journal**, v. 89, n. 5, p. 807–812, 1997.

DINIZ, F. DE A.; RAMOS, A. M.; REBELLO, E. R. G. Brazilian climate normals for 1981-2010. **Pesquisa Agropecuaria Brasileira**, v. 53, n. 2, p. 131–143, 2018.

DOORENBOS, J.; KASSAM, A.M. **Yield response to water**. Rome: FAO, 1979. 300 p. (Irrigation and Drainage Paper, 33).

DOS SANTOS, Thais Leticia. **Variabilidade espacial e temporal da precipitação em Piracicaba (SP) e influência sobre a produtividade estimada da Soja**. 2020. 63 f. Dissertação (Mestrado em Engenharia de Sistemas Agrícolas) - Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2020.

EMBRAPA. **Agência de Informação Embrapa**. [Home page]. Disponível em: <<https://www.embrapa.br/soja/cultivos/soja1/dados-economicos>>. Acesso em: 21 mai. 2020.

FARIAS, J. R. B. et al. Caracterização de risco de déficit hídrico nas regiões produtoras de soja no Brasil. **Revista Brasileira de Agrometeorologia**, v. 9, n. 3, p. 415–421, 2001.

FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. Ecofisiologia da Soja. **Circular Técnica - Embrapa Soja**, v. 48, 2007.

FARIAS, J.R.B.; NEUMAIER, N.; NEPOMUCENO, A.L. Soja. In: MONTEIRO, J.E.B.A. **Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola**. Brasília: INMET, 2009. cap. 15, p. 261-278.

FENG, W. et al. Measuring leaf nitrogen concentration in winter wheat using double-peak spectral reflection remote sensing data. **Field Crops Research**, v. 159, p. 43–52, 2014.

FONTANA, D. C.; BERLATO, M. A. RELAÇÃO ENTRE EL NINO OSCILAÇÃO SUL (ENOS), PRECIPITAÇÃO E RENDIMENTO DE MILHO NO ESTADO DO RIO GRANDE DO SUL. **Pesq. agropec. Gaúcha**, v. 2, n. 1, p. 39–46, 1996.

FONTANA, D. C.; BERLATO, M. A. Modelo agrometeorológico-espectral para a estimativa do rendimento de soja no Rio Grande do Sul: um estudo preliminar. **Anais IX Simpósio Brasileiro de Sensoriamento Remoto, Santos, Brasil**, p. 17–24, 1998.

FONTANA, D. C.; BERLATO, M. A.; BERGAMASCHI, H. **Alterações micrometeorológicas na cultura da soja submetida a diferentes regimes hídricos** Pesquisa Agropecuária Brasileira, 1992.

GOULART, A. C. DE O. et al. Relação espectro-temporal entre índices de vegetação e a chuva na cidade do Rio de Janeiro. **Revista de Ciências Agrárias - Amazon Journal of Agricultural and Environmental Sciences**, v. 58, n. 3, p. 277–283, 2015.

GROFF, Edson Cristiano. **Comportamento do NDVI da Cultura da Soja e sua Relação com as Variáveis Agronômicas**. 2010. 50 f. Dissertação (Mestrado em Agronomia) - Universidade Estadual de Maringá, Maringá, 2010.

HOYOS-VILLEGAS, V. et al. Ground-based digital imaging as a tool to assess soybean growth and yield. **Crop Science**, v. 54, n. 4, p. 1756–1768, 2014.

IBGE, Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal**. Disponível em: <<https://cidades.ibge.gov.br/brasil/rs/cruz-alta/pesquisa/14/10193>>. Acesso em: 14 abr. 2020.

JIANG, Z. et al. Application of crop model data assimilation with a particle filter for estimating regional winter wheat yields. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 11, p. 4422–4431, 2014.

JIN, Z. et al. Smallholder maize area and yield mapping at national scales with Google Earth Engine. **Remote Sensing of Environment**, v. 228, n. March, p. 115–128, 2019.

KROSS, A. et al. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. **International Journal of Applied Earth Observation and Geoinformation**, v. 34, p. 235–248, 1 fev. 2015.

LI, C. et al. Using NDVI percentiles to monitor real-time crop growth. **Computers and Electronics in Agriculture**, v. 162, n. April, p. 357–363, 2019.

LOBELL, D. B. The use of satellite data for crop yield gap analysis. **Field Crops Research**, v. 143, p. 56–64, 1 mar. 2013.

LOBELL, D. B.; ORTIZ-MONASTERIO, J. I. Regional importance of crop yield constraints: Linking simulation models and geostatistics to interpret spatial patterns. **Ecological Modelling**, v. 196, n. 1–2, p. 173–182, 10 jul. 2006.

LUCAS, A. DE A.; SCHULER, C. A. B. Análise do NDVI/NOAA em cana-de-açúcar e Mata Atlântica no litoral norte de Pernambuco, Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 11, n. 6, p. 607–614, 2007.

MARTORANO, Lucieta Guerreiro. **PADRÕES DE RESPOSTA DA SOJA A CONDIÇÕES HÍDRICAS DO SISTEMA SOLO-PLANTA-ATMOSFERA, OBSERVADOS NO CAMPO E SIMULADOS NO SISTEMA DE SUPORTE À DECISÃO DSSAT**. 2007. 151 f. Tese (Doutorado em Fitotecnia) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

MÉNDEZ-BARROSO, L. A. et al. Seasonal and interannual relations between precipitation, surface soil moisture and vegetation dynamics in the North American monsoon region. **Journal of Hydrology**, v. 377, n. 1–2, p. 59–70, 2009.

MENG, J.; DU, X.; WU, B. Generation of high spatial and temporal resolution NDVI and its application in crop biomass estimation. **International Journal of Digital Earth**, v. 6, n. 3, p. 203–218, 2013.

NICHOLSON, S. E.; FARRAR, T. J. The influence of soil type on the relationships between NDVI, rainfall, and soil moisture in semiarid Botswana. I. NDVI response to rainfall. **Remote Sensing of Environment**, v. 50, n. 2, p. 107–120, 1994.

NÓIA JÚNIOR, R. DE S. et al. Effects of the El Niño Southern Oscillation phenomenon and sowing dates on soybean yield and on the occurrence of extreme weather events in southern Brazil. **Agricultural and Forest Meteorology**, v. 290, n. November 2019, p. 108038, 2020.

NÓIA JÚNIOR, R. DE S.; SENTELHAS, P. C. Soybean-maize off-season double crop system in Brazil as affected by El Niño Southern Oscillation phases. **Agricultural Systems**, v. 173, n. March, p. 254–267, 2019.

OLIVERA RODRIGUEZ, P. et al. Spatial variability of the green water footprint using a medium-resolution remote sensing technique: The case of soybean production in the Southeast Argentine Pampas. **Science of the Total Environment**, n. xxxx, p. 142963, 2020.

PEREIRA, A.R.; ANGELOCCI, L.R.; SENTELHAS, P.C. **Agrometeorologia: fundamentos e aplicações práticas**. Guaíba: Agropecuária, 2002. 478 p.

PICOLI, M. C. A. et al. Sugarcane drought detection through spectral indices derived modeling by remote-sensing techniques. **Modeling Earth Systems and Environment**, v. 5, n. 4, p. 1679–1688, 2019.

REICHERT, J. M. et al. ESTIMATION OF WATER RETENTION AND AVAILABILITY IN SOILS OF RIO GRANDE DO SUL. **R. Bras. Ci. solo**, n. 33, p. 1547–1560, 2009.

RICHETTI, J. et al. Remotely sensed vegetation index and LAI for parameter determination of the CSM-CROPGRO-Soybean model when in situ data are not available. **International Journal of Applied Earth Observation and Geoinformation**, v. 79, p. 110–115, 1 jul. 2019.

RIZZI, R.; RUDORFF, B. F. T. Soybean crop area estimation in Rio Grande do Sul through Landsat images. **Revista Brasileira de Cartografia**, v. 3, p. 226–234, 2005.

RODRIGUES, C. P. et al. **NDVI E FLUXO DE CO₂ EM LAVOURA DE SOJA NO RIO GRANDE DO SUL**. Universidade Federal do Rio Grande do Sul (UFRGS), Centro Estadual de Pesquisas em Sensoriamento Universidade Federal de Santa Maria (UFSM), Centro de Ciências Naturais e Exatas , Santa Mari. p. 95–104, 2013.

ROMANO, N.; PALLADINO, M.; CHIRICO, G. B. Parameterization of a bucket model for soil-vegetation-atmosphere modeling under seasonal climatic regimes. **Hydrol. Earth Syst. Sci.**, 15, 3877–3893, 2011.

SALVADORI, J.R.; BACALTCHUK, B. Indicações Técnicas para a Cultura da Soja no Rio Grande do Sul e em Santa Catarina, safras 2016/2017 e 2017/2018. **Reunião de Pesquisa da Soja da Região Sul**, 41: 2016, Passo Fundo, RS, n. 1, p.55-112, 2016.

SANTOS, Humberto Golçalves dos [et al.]. **Sistema Brasileiro de Classificação de Solos**. 5. ed., rev. e ampl. Brasília, DF: Embrapa, 2018. 356 p.

SCHAPARINI, L. P. et al. Analise comparativa entre índices de vegetação e sua relação com o balanço hídrico em soja. **Agrometeoros**, v. 27, n. 1, p. 183–190, 2020.

SOUZA, P. J. O. P. DE et al. Consumo Hídrico Da Soja No Nordeste Paraense. **Irriga**, v. 1, n. 01, p. 218, 2018.

STÜLP, M. et al. Desempenho agrônômico de três cultivares de soja em diferentes épocas de semeadura em duas safras. **Ciência e Agrotecnologia**, v. 33, n. 5, p. 1240–1248, 2009.

TAIZ, L.; ZEIGER, E. Fotossíntese: as reações luminosas. In: TAIZ, L.; ZEIGER, E. **Fisiologia Vegetal**. Porto Alegre: Artmed, 2009, p. 147-181

THORNTHWAITE, C.W.; MATHER, J.R. **The water balance**. Nex Jersey: Drexel Institute of Technology, 1955. 104 p. (Publications in Climatology, 1).

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

VELOSO, A. et al. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. **Remote Sensing of Environment**, v. 199, p. 415–426, 2017.

WANG, J.; RICH, P. M.; PRICE, K. P. Temporal responses of NDVI to precipitation and temperature in the central Great Plains, USA. **International Journal of Remote Sensing**, v. 24, n. 11, p. 2345–2364, 2003.

WOLF, K. A.; GUPTA, S. C.; ROSEN, C. J. Precipitation Drives Nitrogen Load Variability in Three Iowa Rivers. **Journal of Hydrology: Regional Studies**, v. 30, n. December 2019, p. 100705, 2020.

YANG, C. et al. Using high-resolution airborne and satellite imagery to assess crop growth and yield variability for precision agriculture. **Proceedings of the IEEE**, v. 101, n. 3, p. 582–592, 2013.

ZANON, A. J.; STRECK, N. A.; GRASSINI, P. Climate and management factors influence Soybean yield potential in a subtropical environment. **Agronomy Journal**, v. 108, n. 4, p. 1447–1454, 2016.

4. ANÁLISE DA INTEGRAÇÃO DE UM MODELO AGROMETEOROLÓGICO AO NDVI PARA A ESTIMATIVA DE PRODUTIVIDADE DA SOJA EM CRUZ ALTA – RS.

Resumo

A estimativa de safra possibilita para o produtor rural o maior controle do manejo e proporciona maior segurança na venda do seu produto. Os modelos agrometeorológicos simulam o crescimento e desenvolvimento das plantas com base nos fatores meteorológicos, de solo e características da cultura. No entanto, sua estimativa considera uma região homogênea. Os produtos do sensoriamento remoto, como as imagens de satélite, auxiliam na identificação da variabilidade espacial de atributos de solo e planta e, indiretamente, fornecem informações da ação dos elementos meteorológicos sobre a cultura. O objetivo deste estudo foi avaliar um modelo agrometeorológico-espectral para a estimativa de produtividade da soja em talhões no município de Cruz Alta-RS. Foram avaliados os mapas de produtividade de três talhões de soja, da Cooperativa Central Gaúcha LTDA. (CCGL), na safra 2017/18, bem como os seus mapas de NDVI para o mesmo período. Os dados meteorológicos foram utilizados para estimar as produtividades potencial (Y_o) e atingível (Y_a) da soja, por meio do modelo de Dorenbos e Kassam (1979), em diferentes pontos dos talhões, variando apenas a CAD como dado de entrada. Foram feitas regressões lineares múltiplas com NDVI e a relação Y_o/Y_a como variáveis independentes e a produtividade real (Y_r) como variável dependente. Os resultados mostraram boas correlações entre produtividade final e o NDVI. O modelo foi capaz de explicar de 47 a 67% das estimativas de produtividade de soja para a safra 2017/18. Porém, os dados simulados não aumentaram significativamente as estimativas de produtividade. Os resultados foram promissores, indicando a necessidade de novas análises, em diferentes safras, para que maior variabilidade de clima seja computada ao modelo.

Palavras-chave: *Glycine max* L.; NDVI; Modelagem; Agricultura de Precisão

Abstract

Estimating the harvest allows greater control of management and offers security when selling the product. Agrometeorological models simulate plant growth and development based on meteorological factors, and soil and crop characteristics. However, the models estimate yield considering a homogeneous field, not providing information on the variability of the plot. Remote sensing products, such as satellite images, help to identify the spatial variability of soil and plant features and, indirectly, provide information on the action of meteorological elements on the crop. The objective of the study was to evaluate an agrometeorological-spectral model to estimate soybean yield in stands in the municipality of Cruz Alta-RS. The yield maps of three soybean plots by Cooperativa Central Gaúcha LTDA (CCGL) were taken in the 2017/18 harvest, as well as the NDVI maps for the same period. Meteorological data were used to estimate potential (Y_o) and attainable (Y_a) yields of soybeans, using the Dorenbos and Kassam (1979) model, in different spots of

the plots, varying only Available Water Capacity (AWC) as input data. Multiple linear regressions were performed with NDVI and the Yo/Ya ratio as independent variables and the actual yield (Yr) as the dependent variable. The results showed good correlations between final yield and NDVI. The model was able to explain 47 to 67% of the soybean yield for the 2017/18 harvest. However, the simulated data did not increase the estimated yield. The results were promising, indicating the need for new analyzes, in different harvests, so that climate variability is computed in the model.

Keywords: *Glycine max* L.; NDVI; Modeling; Precision Agriculture

4.1. Introdução

A soja representa 47,9% da produção nacional de grãos, com área ocupada de 36,9 milhões de hectares no Brasil (CONAB, 2020). No estado do Rio Grande do Sul estão 5,9 milhões de hectares, e dentre as principais áreas de produção está o município de Cruz Alta, quinto maior município produtor, com 93 mil hectares de soja plantada na safra 2019/20 (EMATER/RS, 2019).

As estimativas de produtividade a níveis municipal e estadual são importantes para o planejamento, controle e gerenciamento da economia, logística e segurança alimentar bem como controle de preços de commodities (RICHETTI, 2018; ASSAD et al., 2007; FIGUEIREDO, 2005). Na escala de talhão, a estimativa é de suma importância para o produtor, de forma a auxiliá-lo no manejo e ter maior segurança na venda da sua produção.

Para auxiliar na estimativa da produtividade das culturas agrícolas, propõe-se o uso de modelos, capazes de simular o crescimento e desenvolvimento da planta com base nas características da planta, elementos meteorológicos e características de solo, especialmente os relacionados à capacidade de armazenamento de água (HOLZWORTH et al., 2014; JONES et al., 2003; NENDEL et al., 2011; DOORENBOS & KASSAM, 1979; JENSEN, 1968). Nessa temática, dentre as culturas mais estudadas, a soja (*Glycine max* (L.) Merr.) se destaca mundialmente pela sua importância (BATTISTI; BENDER; SENTELHAS, 2019; BOOTE et al., 1998; NÓIA JÚNIOR; SENTELHAS, 2019; RUÍZ-NOGUEIRA; BOOTE; SAU, 2001; SILVA, 2018). Tais estudos buscam compreender e quantificar as relações ecofisiológicas que interferem na formação da produção da cultura.

Na categoria dos modelos empíricos, propostas como as de Jensen (1968) e Doorenbos & Kassam (1979), eles relacionam a depleção da produtividade à sensibilidade das culturas

ao estresse hídrico, nas várias fases de desenvolvimento das plantas. Ambos são compostos por dois módulos para estimativa da produtividade, um que integra a estimativa da produtividade potencial (Y_o) – a partir da disponibilidade energética local – outro que determina a produtividade atingível (Y_a).

Embora não considerem os processos biofísicos do crescimento das plantas para a estimativa da produtividade, como deficiências nutricionais e ocorrência de pragas e doenças, os modelos agrometeorológicos empíricos são usuais e acessíveis, por sua simplicidade e menor exigência de dados de entrada (ASSAD et al., 2007; BATTISTI et al., 2017; FONTANA et al., 2001; MELLO; FONTANA; BERLATO, 2003; SENTELHAS et al., 2015).

Com a agricultura de precisão, um dos avanços na agricultura foi a possibilidade de representar a produtividade real das áreas na forma de mapas, evoluindo da produtividade média para a mensuração da produtividade detalhada em diversos pontos do talhão. Com isso criou-se a expectativa de estimar a produtividade potencial (Y_o) e atingível (Y_a) para mesmas escalas espaciais, o que permite análise completa da eficiência de produção (HANSEN; JONES, 2000; HEINEMANN; STONE; SILVA, 2010).

A principal limitação dos modelos, empíricos ou mesmo mecanísticos, está justamente na estimativa pontual, por conta dos dados exigidos, em especial meteorológicos que provém de um ponto de coleta, de estação meteorológica. Para contornar essa limitação, diversos estudos buscam validar o uso de modelos juntamente com análises espaciais (BASSO et al., 2001; SHELIA et al., 2019; THORP et al., 2008; YANG et al., 2013). Para isso, os produtos do sensoriamento remoto, como as imagens de satélite, vêm sendo amplamente utilizados (AZZARI; JAIN; LOBELL, 2017; DE LA CASA et al., 2018; FENG et al., 2014; KLERING et al., 2016; LOBELL, 2013; LOBELL et al., 2003).

Além de ser uma técnica não destrutiva para avaliação das características da cultura, as imagens de satélite fornecem informações espacializadas, podendo agregar informações não consideradas especialmente por modelos empíricos, como práticas de manejo e estresses ocasionados por pragas e doenças, possibilitando melhores estimativas de produtividade (KLERING et al., 2016; KRÜGER; FONTANA; MELO, 2007; MELLO; FONTANA; BERLATO, 2003; RUDORFF; BATISTA, 1990).

Dentre os índices espectrais usados, o Índice de Vegetação por Diferença Normalizada (NDVI) (TUCKER, 1979) é o mais comum em estudos sobre o crescimento e desenvolvimento das plantas (FIORI et al., 2015; LABUS et al., 2002; LAI et al., 2018; REED et al., 1994). O NDVI utiliza as bandas do espectro eletromagnético vermelho e infravermelho próximo (NIR) para inferir sobre o estado vegetativo da planta, refletindo sobre o índice de área foliar (IAF) e atividade fotossintética. Diversos trabalhos já utilizaram o NDVI na estimativa de produtividade de culturas agrícolas, tanto por meio de modelos regressivos (LEWIS; ROWLAND; NADEAU, 1998; LOPRESTI; DI BELLA; DEGIOANNI, 2015; SCHWALBERT et al., 2018), como juntos a modelos de crescimento de plantas, denominados como modelos agrometeorológico-espectrais (JUNGES; FONTANA, 2011; KRÜGER et al., 2007; MELLO et al., 2003).

Krüger et al. (2007) avaliaram um modelo agrometeorológico-espectral na intenção de melhorar as estimativas de produtividade da soja para o Rio Grande do Sul, com dados de NDVI/AVHRR e de consumo hídrico, calculada pelo balanço hídrico de Thornthwaite e Mather (1955). O modelo apresentou bom grau de detalhamento temporal e espacial. Richetti (2018) mostrou que a determinação dos valores de índice de área foliar (IAF) e interceptação luminosa (LI) a partir de índices de vegetação de sensoriamento remoto, como NDVI, pode ser usada para calibração do modelo CSM-CROPGRO para a cultura da soja.

Com base na favorabilidade dos resultados obtidos a partir da integração de modelos agrometeorológicos e imagens espectrais, vislumbra-se a oportunidade de prosseguir com o exploratório dessa metodologia em escalas espaciais menores, como para os talhões de uma unidade de produção agrícola. Assim, o objetivo deste capítulo foi analisar o uso de um modelo agrometeorológico-espectral para a estimativa da produtividade da soja, ao nível de talhão, na região de Cruz Alta-RS. A hipótese é de que é possível identificar a variabilidade produtiva de um talhão utilizando imagens de satélite em alta resolução juntamente com um modelo agrometeorológico.

4.2. Material e Métodos

4.2.1. Local de estudo

O estudo realizado avaliou três talhões, individualmente com área de 35,7 ha (1), 20,9 ha (2) e 19,1 ha (3) de produção de soja, totalizando 75,7 ha de produção de soja. As áreas de produção pertencem à Cooperativa Central Gaúcha LTDA (CCGL). A área está

localizada no município de Cruz Alta (RS), na região norte do estado do Rio Grande do Sul (Latitude 28° 38 '19" Sul, Longitude 53° 36' 23" Oeste e Altitude 452 metros) (Figura 1). Os dados de produção de soja foram obtidos na safra 2017/18.

Figura 1 - Área de produção da Cooperativa Central Gaúcha LTDA (CCGL), no município de Cruz Alta, estado do Rio Grande do Sul. Os três talhões de produção de soja safra 2017/18 demarcados como 1, 2 e 3.

Os passos da execução deste trabalho são descritos nos itens a seguir e sintetizados no fluxograma da Figura 2.

Figura 2 - Atividades de execução do trabalho.

4.2.2. Dados meteorológicos

Os dados meteorológicos, temperaturas máxima, mínima e média do ar, precipitação, umidade relativa do ar, radiação solar e velocidade do vento (2 m), para os anos de 2017 e 2018, foram coletados da estação meteorológica automática do Instituto Nacional de Meteorologia (INMET), instalada no município de Cruz Alta - RS (28° 36 '12" Sul, 53° 40' 24" Oeste e 427 metros de altitude), localizada na área da CCGL (Figura 1). Os dados meteorológicos também foram usados para a estimativa de outros elementos meteorológicos requeridos pelos modelos de estimativa da evapotranspiração (ALLEN et al., 1998), de balanço hídrico (THORNTHWAITE & MATTER, 1955) e da estimativa da produtividade (DOORENBOS & KASSAM, 1979).

Assim foram calculadas ou estimadas a irradiância solar global extraterrestre (Q_0), a insolação (n) e o fotoperíodo (N) (Equações 1, 2 e 3). Adotando proposta de Battisti (2013),

para a estimativa da insolação foi usada uma função que associa os métodos propostos por Angström-Prescott e Hargreaves para o cálculo da radiação solar, que é função da temperatura e fotoperíodo.

$$Q_o = 37,6 \left(\frac{d}{D}\right)^2 \left(\frac{\pi}{180}\right) (\sin \phi \sin \delta \, hn + \cos \phi \cos \delta \sin hn) \quad (\text{Eq. 1})$$

$$N = 2 \frac{hn}{15^\circ \, h^{-1}} \quad (\text{Eq. 2})$$

$$n = N \left(\frac{0,16(T_{max}-T_{min})^{0,5} - 0,29 \cos \phi}{0,52} \right) \quad (\text{Eq. 3})$$

Onde: Tmax é a temperatura máxima do ar (°C); Tmin é a temperatura mínima do ar (°C); δ é a declinação solar calculada (Eq. 4); NDA a contagem de dias do ano; hn é o ângulo horário ao nascer do sol (Eq. 5); ϕ é a latitude (graus decimais) e $(d/D)^2$ é a distância relativa entre a Terra e o Sol (Eq. 6).

$$\delta = 23,45 \, \text{sen}[360 (NDA - 80)/365] \quad (\text{Eq. 4})$$

$$hn = \arccos(-tg\phi \, tg\delta) \quad (\text{Eq. 5})$$

$$\frac{d^2}{D} = 1 + 0,033 \cos\left(\frac{360}{365} NDA\right) \quad (\text{Eq. 6})$$

4.2.3. Dados de solo

Os dados de textura do solo, provenientes de 37 pontos amostrados no Talhão 1, 20 pontos no Talhão 2 e 18 pontos no Talhão 3 (Figura 3) foram utilizados para a determinação da capacidade de armazenamento de água no solo (CAD).

Figura 3 - Distribuição dos pontos de solo analisados nos talhões 1, 2 e 3.

As amostras de solo (Figura 3) foram coletadas na camada de 0 a 15 cm de profundidade. A partir dos dados percentuais de argila e das funções de pedotransferência propostas por Reichert et al. (2009), específicas para solos do estado do Rio Grande do Sul, foram estimados os referenciais de umidade na Capacidade de Campo (θ_{cc}) (Eq. 7) e em Ponto de Murcha Permanente (θ_{pmp}) (Eq. 8), para então calcular a CAD (Eq. 9) para cada ponto dos três talhões (Figura 2). Para o cálculo da CAD foi adotada a profundidade do sistema radicular da soja (z) de 0,5 m (BATTISTI, 2013).

$$\theta_{cc}(10kPa) = 0,506 \text{ Argila}^{0,31} \quad (\text{Eq. 7})$$

$$\theta_{pmp}(1500kPa) = 0,39 \text{ Argila}^{0,51} \quad (\text{Eq. 8})$$

$$CAD = (\theta_{cc} - \theta_{pmp})Z \quad (\text{Eq. 9})$$

Os valores de CAD dos talhões foram usados para simulações do balanço hídrico (Thornthwaite e Matter, 1955), descritos no capítulo anterior (item 4.2.5) e do modelo de estimativa da produtividade (Doorenbos e Kassam, 1979) em cada ponto de solo amostrado, descritos a seguir (item 5.2.5).

4.2.4. Produtividade da soja

Nos talhões 1, 2 e 3 (Figura 1) foi semeada a cultivar de soja Monsoy 6410, grupo de maturidade relativa (GMR) 6.4, semeada nos dias 14, 15 e 21 de novembro de 2017,

respectivamente. O espaçamento entre linhas adotado foi de 0,45m. A população final era de 300 mil plantas por hectare.

A adubação de base foi a mesma nos três talhões, aportando 250 kg ha⁻¹ do adubo NPK 07-34-11, de acordo com recomendações para a cultura da soja para o estado do Rio Grande do Sul (SALVADORI et al., 2016). Todo manejo da lavoura buscou manter as áreas de produção (Figura 1) sem interferência de plantas daninhas, pragas e doenças.

A colheita foi realizada com uma colheitadeira John Deere 9670 com sistema de identificação espacial da produtividade, por meio do sensor de fluxo de grãos do tipo placa de impacto, receptor StarFire, georreferenciado no sistema de coordenadas geográficas WGS 84, com frequência de leitura de dados a cada um segundo. A umidade dos grãos foi corrigida para a base de 13%.

Os mapas de produtividade da soja, em formato de vetor, foram reprojetados para o datum WGS 84, Zona 22 S. Em seguida os dados foram filtrados localmente com dependência espacial de 10 metros, seguindo a metodologia de Maldaner et al. (2018), para eliminar dados inconsistentes.

A filtragem dos dados, segundo Maldaner et al. (2018), foi feita em duas etapas:

1. Filtragem global, considerando todos os pontos, em que são eliminados os outliers.
2. Filtragens locais anisotrópica e isotrópica, que avaliam a baixa consistência dos pontos com relação aos seus vizinhos, dentro do raio determinado, para uma única linha e em todas as direções, respectivamente.

A Tabela 1 apresenta o número de pontos restantes, bem como o desvio padrão e amplitude dos dados após filtrações, para os três talhões.

Tabela 1 - Dados do shapefile de pontos de produtividade após filtração.

	Talhão 1		Talhão 2		Talhão 3	
	Original	Filtrado	Original	Filtrado	Original	Filtrado
Número de pontos	37554	17879	21718	11416	19945	9929
Valor mínimo (ton ha ⁻¹)	0.34	1.89	0.34	0.95	0.34	1.67
Valor máximo (ton ha ⁻¹)	107.65	5.37	100.34	4.66	107.50	4.99
Valor médio (ton ha ⁻¹)	3.91	3.95	3.54	3.62	3.75	3.92
Desvio padrão (ton ha ⁻¹)	3.31	0.61	2.76	0.63	2.48	0.58
C.V. (%)	84.60	12.61	77.82	13.35	66.02	10.53

Após a filtragem (Tabela 1), um segundo processo para exclusão de dados inconsistentes de produtividade foi realizado. As bordaduras dos talhões, por serem áreas muito sujeitas à erros de estimativa da produtividade (MENEGATTI; MOLIN, 2004) foram delimitadas e removidas. Para isso, um buffer de 10 m ao longo de todo o perímetro de cada área foi delimitado, considerando a largura da plataforma, de 30 pés, e excluído. Assim, dados de produtividade dessas áreas não foram contabilizados das análises.

Em seguida, os dados em formato *shapefile* em pontos foram interpolados pelo método interpolador krigagem ordinária e transformados para o formato *raster*, na plataforma ArcGIS.

4.2.5. Estimativa pontual da produtividade de soja por talhão

Com o modelo da zona agroecológica (Doorenbos e Kassam, 1994) foram estimadas as produtividades potencial (Y_o) e atingível (Y_a) para cada ponto de coleta de solo nos talhões (Figura 2). Para os cálculos foi usada uma única base de dados meteorológicos, coletados pela estação meteorológica do INMET, distante 500 m, 1050 m 1015 m do ponto central dos talhões 1, 2 e 3, respectivamente.

Portanto, as simulações não integraram variabilidade espacial de nenhum elemento meteorológico, assumindo que devido à proximidade dos talhões à estação meteorológica, e suas características altimétricas, a variabilidade meteorológica pode ser negligenciada. As simulações, porém, integraram a variabilidade de caracteres de solo, mais precisamente a variabilidade espacial de textura e, conseqüentemente, da capacidade de retenção de água.

Para simular o ciclo de desenvolvimento da soja foram usadas as datas de semeadura e os dados de NDVI. De acordo com o trabalho de Crusiol et al. (2013), foi adotado o valor de NDVI de 0,7 para a maturidade da cultura da soja. A data referente a esse valor de NDVI, para cada talhão, foi obtida por meio de análise de regressão. A estimativa apontou a maturidade fisiológica, definida pelo NDVI igual a 0,7, ocorreu nos dias 21/03/2018 para o talhão 1, em 19/03/2018 no talhão 2 e em 21/03 no talhão 3. As simulações seguiram o ciclo de desenvolvimento da cultivar, determinado em função da data de semeadura e maturidade fisiológica, pois a partir desse período não há incremento de produtividade. As simulações totalizaram 128, 125 e 121 dias de produção para os talhões 1, 2 e 3, respectivamente.

A produtividade potencial (Y_o), foi calculada com base nos dados de radiação solar global (Q_g), temperatura do ar, fotoperíodo (N) e insolação (n), a partir da equação 10. Ressalta-se que, por considerar apenas dados meteorológicos, a simulação por talhão foi única.

$$PP = (PPbn + PPbc)CIAF CR CC \quad (\text{Eq. 10})$$

PP é a produtividade de matéria seca em kg MS ha⁻¹ dia⁻¹.

PPbn (Eq. 11) é a estimativa da produtividade para o dia de céu nublado e PPbc (Eq. 12) é a estimativa da produtividade para dia de céu limpo.

$$PPbn = (31,7 + 0,219 Q_o)cTn \left(1 - \frac{n}{N}\right) \quad (\text{Eq. 11})$$

$$PPbc = (107,2 + 0,36 Q_o)cTc \left(\frac{n}{N}\right) \quad (\text{Eq. 12})$$

Os parâmetros cTc e cTn são usados para a correção da taxa fotossintética. Ambos são funções da temperatura média do ar. Esses parâmetros são determinados em função da cultura. Para culturas de metabolismo C3, de verão, como a soja, as condições para o cálculo dos parâmetros são:

Para $16,5^\circ\text{C} < T_{med} < 37^\circ\text{C}$:

$$cTc = -0,0425 + 0,035 T_{med} + 0,00325 T_{med}^2 - 0,0000925 T_{med}^3 \quad (\text{Eq. 13})$$

$$cTn = 0,583 + 0,014 T_{med} + 0,0013 T_{med}^2 - 0,000037 T_{med}^3 \quad (\text{Eq. 14})$$

Para $T_{med} < 16,5^\circ\text{C}$ e $T_{med} > 37^\circ\text{C}$:

$$cTc = -1,085 + 0,07 T_{med} + 0,0065 T_{med}^2 - 0,000185 T_{med}^3 \quad (\text{Eq. 15})$$

$$cTn = -0,0425 + 0,035 T_{med} + 0,00325 T_{med}^2 - 0,0000925 T_{med}^3 \quad (\text{Eq. 16})$$

Para o cálculo do parâmetro correção para índice de área foliar (CIAF) (Eq. 17), assumiu-se IAF padrão igual a 5.

$$CIAF = 0,0097 + 0,185 IAF - 0,0175 IAF^2 \quad (\text{Eq. 17})$$

O parâmetro correção para respiração (CR) assumiu valor igual a 0,6, para dias com média do ar menor que 20°C e 0,5 em dias com temperatura média do ar maior que 20°C.

O parâmetro índice de colheita (CC) usado foi de 0,4 (DOORENBOS e KASSAM, 1994).

À produtividade PP, base matéria seca, foi então adicionada a umidade residual dos grãos (U%), igual a 13% para a soja, através da equação 18.

$$Yo = \frac{PP}{(1-0,01)*U\%} \quad (\text{Eq. 18})$$

Para o cálculo da produtividade atingível (Ya) foi usado o modelo (Eq. 19) que relaciona a perda produtiva relativa $(1 - Ya/Yo)$ à deficiência hídrica relativa $(1 - ETr/ETc)$, correlacionadas por meio do coeficiente de sensibilidade à deficiência hídrica (Ky). No modelo, Yo representa a produtividade potencial (Eq. 18), ETc a evapotranspiração da cultura e ETr a evapotranspiração real da soja.

$$(1 - Ya/Yo) = ky (1 - ETr / ETc) \quad (\text{Eq. 19})$$

Para estimar a evapotranspiração da cultura da soja (ETc) foi necessário calcular a evapotranspiração de referência (ETo) através do método de Penman-Monteith (ALLEN et al., 1998) (Eq. 20), e utilizar o coeficientes da cultura (Kc) (Eq. 21). A evapotranspiração real foi calculada de acordo com o método do balanço hídrico de Thornthwaite e Mather (1955). Esses procedimentos foram previamente descritos no capítulo anterior.

$$ETo = \frac{0,408 \Delta (R_n - G) + \gamma \frac{900}{T+273} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0,34 u_2)} \quad (\text{Eq. 20})$$

$$Kc = -0,0001DAS^2 + 0,0168DAS + 0,4268 \quad (\text{Eq. 21})$$

Os valores de ky para a soja, propostos Doorenbos e Kassam (1979), foram de 0,2 0,8 e 1 para as fases de desenvolvimento vegetativo, floração e frutificação, respectivamente.

O balanço hídrico foi simulado para cada ponto de coleta de solo nos talhões (Figura 3), utilizando a CAD específica para o local. O cálculo da produtividade atingível, portanto, foi realizado para cada ponto amostral também.

Para cada talhão, em cada ponto amostral, a partir das produtividades potencial (Y_o) e atingível (Y_a) calculadas, foi determinada a produtividade relativa (Y_a/Y_o). Com uso do software ArcGIS, foram elaborados mapas de produtividade relativa utilizando o método krigagem ordinária.

4.2.6. Dados de NDVI

Foram obtidas imagens provenientes dos sensores a bordo do satélite Sentinel-2, lançados na missão da Agência Espacial Europeia (ESA). Os dados do Sentinel-2 contêm 13 bandas espectrais com refletância TOA. Foram coletadas 15 imagens para a safra 2017/18, com filtro de 2% de nuvens, obtidos pela plataforma GEE. Cada imagem abrange os três talhões estudados. Foi feito o cálculo do NDVI para cada imagem na própria plataforma do GEE.

Para a análise da estimativa da produtividade, utilizando os dados espectrais juntamente com os dados meteorológicos, foram adotadas duas abordagens. Primeiro, seguindo a metodologia de Azzari et al. (2017), utilizou-se a imagem de máximo NDVI. Essa metodologia se mostrou aplicável no trabalho de diversos autores (BECKER-RESHEF et al., 2010; FRANCH et al., 2015; LOBELL et al., 2015; MELLO; FONTANA; BERLATO, 2003), apresentando boas correlações com a produtividade final, inclusive para outras culturas além da soja, como arroz (KLERING et al., 2016), trigo (BARNETT; THOMPSON, 1982; LOPRESTI; DI BELLA; DEGIOANNI, 2015) e milho (NAGY; FEHÉR; TAMÁS, 2018). Apesar de essa metodologia apresentar bons resultados, ela não se aplica em situações de adversidades, tanto climáticas ou de infestação de doenças, que ocorrem após o período de máximo NDVI e que podem causar danos à produção, levando a um baixo nível de produtividade final (SCHWALBERT et al., 2018).

Dessa forma, para uma segunda abordagem, baseou-se no período crítico de desenvolvimento da cultura, do florescimento (R1) à fase de enchimento de grãos (R6), pois adversidades meteorológicas, coincidentes a esses estádios fenológicos, definem melhor as perdas produtivas. As imagens selecionadas para esse período foram adicionadas na plataforma ArcGIS e, para obter uma única imagem do período, foi feita a média dos valores de cada pixel de NDVI entre as imagens, utilizando a ferramenta *Raster Calculation*.

O alto número de pixels por imagem apresenta baixa correlação com os dados de produtividade real e as análises devem ser feitas por classes, de forma que cada talhão possa

ser classificado em pequenos grupos homogêneos, de acordo com o seu valor de NDVI. Nesse caso, para fins de correlação entre os dados de NDVI e produtividade, foram utilizados os valores superiores das classes. Segundo Yang et al. (2013), agrupar zonas dentro do talhão reduz a variação dos dados e ainda permite o gerenciamento de forma detalhada para cada área. Lopresti, Di Bella e Degioanni (2015) avaliaram um método para estimativa da produtividade de trigo no norte da Argentina utilizando dados agrometeorológicos e espectrais e, em sua metodologia, os autores dividiram os talhões em 5 (cinco) classes iguais de forma a atenuar contrastes de pixels e obter distribuição mais clara dos dados, em subzonas homogêneas.

Os dados de NDVI foram agrupados em oito classes. O número de classes foi definido com base em uma classificação prévia dos dados de produtividade dos talhões. Tomando-se como referência a produtividade média dos talhões, de aproximadamente 3800 kg ha^{-1} , e o erro médio do modelo (BATTISTI, 2013), de aproximadamente 478 kg ha^{-1} , foi definido o número de oito classes. O método utilizado foi *Natural Breaks*, que divide os valores semelhantes em agrupamentos de forma a maximizar as diferenças entre as classes.

Em seguida, as imagens foram reduzidas aos limites de cada talhão. O que gerou duas imagens: uma de máximo NDVI e outra de NDVI médio, quem continham 2679, 1663 e 1320 pixels cada, para os talhões 1, 2 e 3, respectivamente.

Ao final desses processos foram feitas as análises com os dados de máximo NDVI que, para a safra 2017/18 corresponde ao dia 15 de fevereiro, e do NDVI médio, compreendendo os estádios R1 à R6, cronologicamente definido pelo período de 31/01/2018 à 17/03/2018.

De acordo com Neiverth et al. (2013), a partir do momento em que a soja atinge a maturidade fisiológica, já com início da senescência e queda de folhas, os valores do NDVI se aproximam de 0,7. Utilizando esse valor de referência, a partir de uma análise de regressão com dados coletados entre os dias 17 de março a 18 de abril de 2018, foi definido o momento de maturidade fisiológica. Assim, contando da semeadura à maturidade fisiológica, os ciclos de desenvolvimento estimados da soja foram de 128 dias para o talhão 1, 125 dias para o talhão 2 e de 121 dias para o talhão 3.

4.2.7. Correlação entre dados agrometeorológicos e espectrais para soja

Para proceder a uma análise da correlação dos dados de produtividade real com dados do NDVI, e com os dados de produtividade estimada, foram extraídos os valores médios de produtividade real, NDVI e Y_a/Y_o de cada classe em cada um dos talhões.

Os dados de produtividade real, da razão Y_a/Y_o e de NDVI das respectivas classes, foram então correlacionados por meio de regressão linear. Segundo Rudorff e Batista (1990), a utilização do termo espectral juntamente com o termo agrometeorológico não pode ser feita de forma multiplicativa, pois o termo espectral apresenta o efeito do clima no crescimento das culturas. Dessa forma, o modelo apresenta os termos agrometeorológico (Y_a/Y_o) e espectral (NDVI) assim definidos:

$$Y_r = a + b \text{NDVI} + c \frac{Y_a}{Y_o} \quad (\text{Eq. 22})$$

Por meio de regressão linear múltipla (Eq. 22) entre dados de produtividade da soja (Y_r), do índice espectral NDVI e da produtividade relativa (Y_a/Y_o) por classe, foram obtidos os parâmetros a, b e c da equação 21 (Tabela 5). Para isso foram utilizados os dados de dois talhões (talhões 2 e 3). Dados do talhão 1 foram reservados para a avaliação da equação ajustada.

Além disso foram analisadas as correlações entre os dados de produtividade real (Y_r) e o índice espectral NDVI, a fim de avaliar a influência do fator agrometeorológico incluso através do modelo (Eq. 18), a partir da equação 23:

$$Y_r = a + b \text{NDVI} \quad (\text{Eq. 23})$$

4.2.8. Avaliação do modelo para estimativa da produtividade em escala espacial para Cruz Alta-RS

O modelo gerado foi testado com dados do Talhão 1, utilizando os dados da mesma safra, 2017/18. Os dados de NDVI foram obtidos de forma agrupada, considerando as classes de produtividade. Foram feitas análises com o coeficiente de determinação (R^2) (Eq. 24), erro médio (EM) (Eq. 25), erro absoluto médio (EAM) (Eq. 26) e índice de concordância de Willmott (1981) (d) (Eq. 27), a fim de se quantificar a homogeneidade da dispersão em relação à linha 1:1. O índice d varia de 0 (zero) a 1 (um), representando nenhuma ou total concordância, respectivamente. Os valores estimados pelo modelo e os

valores reais de produtividade foram submetidos à análise estatística de significância pelo teste t de Student ($p < 0,05$).

$$R^2 = \frac{(\sum_i^n (Y_{obs} - \bar{Y}_{obs}) * Y_{est})^2}{\sum_i^n (Y_{est} - \bar{Y}_{est})^2 - \sum_i^n (Y_{obs} - \bar{Y}_{obs})^2} \quad (\text{Eq. 24})$$

$$EM = \frac{1}{n} \sum_i^n (Y_{est} - Y_{obs}) \quad (\text{Eq. 25})$$

$$EAM = \frac{1}{n} \sum_i^n (|Y_{est} - Y_{obs}|) \quad (\text{Eq. 26})$$

$$d = \frac{\sum_i^n (Y_{obs} - Y_{est})^2}{\sum_i^n (|Y_{est} - \bar{Y}_{obs}| + |Y_{obs} - \bar{Y}_{obs}|)^2} \quad (\text{Eq. 27})$$

Em que Y_{est} são os dados estimados e Y_{obs} são os dados reais observados.

Com relação aos erros, buscam-se valores próximos a zero. O EM indica se o modelo subestima ou superestima os valores e o EAM indica o quão longe da média está o valor estimado (RICHETTI, 2018).

4.3. Resultados e Discussão

4.3.1. Mapas de produtividade da soja

Os mapas (Figura 4) apresentam os valores interpolados da produtividade da soja, safra 2017/18, para os três talhões. Áreas de baixa produtividade estão principalmente concentradas nas bordas dos talhões, com valores de 1,0 a 2,2 ton ha⁻¹. Nesse caso, bordaduras com 10 metros de largura, equivalem a 25%, 20% e 31% das áreas dos talhões 1, 2 e 3 (Figura 4). Em relação as áreas totais (Figura 4), incluso as bordaduras, as produtividades médias foram de 3,90 ton ha⁻¹ (Talhão 1), 3,54 ton ha⁻¹ (Talhão 2) e 4,00 ton ha⁻¹ (Talhão 3), com desvio padrão de 0,61, 0,63 e 0,58 ton ha⁻¹, respectivamente.

Figura 4 – Mapas de produtividade da soja (Yr) para os talhões 1 (A), 2 (B) e 3 (C), referentes a safra 2017/18. Produtividade (Yr) dada em toneladas por hectare (ton ha⁻¹).

As áreas de borda dos talhões de produção de soja são complexas no que se refere as atividades de manejo, desde a semeadura à colheita, devido ao maior número de manobras e, portanto, maior tempo de estabilização do fluxo de grãos no sensor da colheitadeira (MOLIN; DO AMARAL; COLAÇO, 2015; SUDDUTH; DRUMMOND; MYERS, 2012; ZANELLA, 2018). Erros sistemáticos dos mapas de colheita para esses perímetros, sobretudo relacionados ao sistema de medição e manejo da colhedora, devem ser criteriosamente analisados e, se necessário, excluídos das análises. Menegatti e Molin (2003) enfatizam essa problemática ao proporem uma metodologia de identificação dos erros gerados em mapas de colheita. Os autores destacam que os erros estão, em sua maioria, relacionados a leituras no sensor de fluxo com a plataforma da colhedora levantada, ocorrência de umidade nula e ocorrências de distâncias nulas entre pontos. Por esses motivos as bordaduras, com 10 metros de largura, foram excluídas (Figura 5).

Após a exclusão das bordaduras as produtividades médias passaram à 3,96, 3,66 e 3,93 ton ha⁻¹(Figura 5), com desvio padrão reduzido para 0,58, 0,51 e 0,50 ton ha⁻¹, para os talhões 1, 2 e 3, respectivamente.

Figura 5 - Produtividade real em toneladas por hectare de cada talhão na a safra 2017/18, com *buffer* de 10 metros das bordas dos talhões.

Em relação aos dados de produtividade coletados e processados, o Talhão 1 foi o que apresentou a maior produtividade média, de $3,96 \text{ ton ha}^{-1}$, com variação espacial de $2,4$ à $5,2 \text{ ton ha}^{-1}$. A produtividade média do Talhão 2 foi de $3,66 \text{ ton ha}^{-1}$, variando de $1,1$ a $4,5 \text{ ton ha}^{-1}$, e o talhão 3 teve produtividade média de $3,93 \text{ ton ha}^{-1}$, com variação espacial de $1,7$ a $5,0 \text{ ton ha}^{-1}$. Os valores médios de produtividade dos três talhões (Figura 5) se assemelham à produtividade média para o município de Cruz Alta, de $3,51 \text{ ton ha}^{-1}$, e da média para o Rio Grande do Sul de $3,4 \text{ ton ha}^{-1}$, safra 2017/18 (IBGE, 2020).

Como mencionado no capítulo anterior, a variabilidade da produtividade, especialmente em maiores escalas espaciais ocorre, sobretudo, em decorrência da variabilidade meteorológica (CUNHA et al., 2001; FARIAS et al., 2001). Como a safra de 2017/18 apresentou boa disponibilidade hídrica, com pluviosidade acumulada de mais de 800 mm, suficiente para maximizar a produtividade da soja (ZANON et al., 2016), a produtividade média até extrapolou a média do município. Apesar da ocorrência de alguns períodos de déficit hídrico, as perdas produtivas foram baixas - evidenciadas pela relação Y_a/Y_o de 0,8, dado que os momentos de estresse hídrico não coincidiram com os períodos de maior sensibilidade da soja.

Os resultados apresentados por Gonçalves e Sibaldelli (2018) descreveram avaliações de produtividade em 20 áreas do RS, incluindo o município de Cruz Alta, associando a perda produtiva à deficiência hídrica. Os autores afirmam que a região de Cruz Alta, na safra 2017/18, apresentou produtividade média elevada por conta de condição hídrica

satisfatória à cultura da soja, corroborando com a análise agrometeorológica realizada (capítulo anterior). Schaparin et al. (2020) discutem o mesmo para a safra de 2017/18, em que a disponibilidade hídrica resultou em altas produtividades de soja no município de Carazinho, a 100 km de distância de Cruz Alta.

4.3.2. Variabilidade espacial da capacidade de armazenamento de água no solo (CAD)

A partir dos dados de granulometria (Tabela 2) e das funções de pedotransferência (REICHERT et al., 2009), foram determinados os valores de CAD (Tabela 3) para cada ponto amostral dos três talhões (Figura 2). Em função da uniformidade do solo, expresso pelos valores médios e desvio padrão da fração de argila (Tabela 2), os valores estimados de CAD apresentaram mínima variação espacial (Tabela 3).

Tabela 2 - Teor de Argila na profundidade 0-15 cm dos pontos de solo dos três talhões da Cooperativa Central Gaúcha LTDA.

Ponto	Teor de Argila (%)			Ponto	Teor de Argila (%)			Ponto	Teor de Argila (%)		
	T1	T2	T3		T1	T2	T3		T1	T2	T3
1	40	26	30	14	49	36	41	27	45	-	-
2	52	26	34	15	48	45	31	28	44	-	-
3	40	31	37	16	42	39	30	29	50	-	-
4	41	37	39	17	40	40	28	30	42	-	-
5	45	34	31	18	49	41	28	31	44	-	-
6	35	29	29	19	46	40	-	32	44	-	-
7	48	34	26	20	44	36	-	33	41	-	-
8	46	26	24	21	43	-	-	34	44	-	-
9	37	42	28	22	49	-	-	35	44	-	-
10	40	44	28	23	48	-	-	36	40	-	-
11	37	35	31	24	43	-	-	37	44	-	-
12	46	42	36	25	38	-	-	Média	43.68	36.45	31.00
13	54	46	27	26	34	-	-	DP	4.46	6.03	4.39

Os resultados apresentaram pouca variabilidade dos teores de argila do solo, com desvio padrão (DP) entre 4,39% (T3) e 6,03% (T2) para a área analisada de, aproximadamente, 76 ha. Ferneda (2020) estudou a variabilidade da produtividade da soja em uma área de produção de 500 ha, no município de General Carneiro, MT, e observou desvio padrão de até 56,6% nos teores de argila na camada superficial do solo. Já em uma área menor, de 4,9 ha, Li et al. (2019) encontraram valores de 9,6%. Isso demonstra a baixa variabilidade dos

atributos físicos do solo e a uniformidade dos valores da CAD (Tabela 3) para os três talhões estudados, no município de Cruz Alta, RS, distinto do observado para as outras áreas referenciadas.

Tabela 3 - Valores máximos, mínimos, médios e desvio padrão da CAD em cada talhão.

Talhões	CAD (mm)			Desvio Padrão
	Máximo	Mínimo	Média	
T1	68.60	66.59	67.84	0.46
T2	68.66	67.64	68.32	0.30
T3	68.66	68.15	68.56	0.14

A uniformidade espacial do solo dos três talhões, em relação ao teor de argila e CAD, ao considerar uniformidade espacial também da precipitação, dado o tamanho das áreas (DOS SANTOS, 2020) permite inferir sobre a ausência de nuances em relação a deficiência hídrica. Delin e Berglund (2005), observaram a correlação entre o teor de argila no solo e a produtividade final dos grãos e ressaltaram ainda que em safras com condições hídricas ótimas, as diferenças produtivas não foram significativas mesmo entre áreas com solo de texturas distintas.

4.3.3. Variabilidade do índice espectral NDVI

Os dados de NDVI obtidos para os três talhões, entre novembro de 2017 e abril de 2018, compreendendo o ciclo de produção da soja, foram extraídos de 15 imagens (Tabela 4). A evolução temporal dos valores médios de NDVI dos três talhões (Tabela 4) se assemelha aos resultados obtidos para áreas de produção de soja em sistema irrigado (CRUSIOL et al., 2012; OLIVEIRA; FERREIRA; DANTAS, 2016), evidenciando condição hídrica favorável ao crescimento e desenvolvimento da cultura (Figura 3A – item 4.3.1).

No dia 24/11/2017, 10 dias após a semeadura do talhão 1, 9 dias após a semeadura do talhão 2 e três dias após a semeadura do talhão 3, foi obtida a primeira imagem de NDVI, já indicando a presença de plantas com baixo IAF, visto o período de início da fase vegetativa. A partir dessa data observa-se incremento exponencial do NDVI da soja, elucidando crescimento normal da cultura (BARIANI et al., 2015), já que as condições meteorológicas favoreceram a soja (Figura 3 – item 4.3.1).

No dia 15/02/2018, 94 dias após a semeadura do talhão 1, 93 dias após a semeadura do talhão 2 e 87 dias após a semeadura do talhão 3, foi observado o máximo valor de NDVI

(Tabela 4). A permanência nesse patamar (estádios de floração/formação de vagem/enchimento de grãos – favorecidos pela condição meteorológica e manutenção da área foliar) foi de, aproximadamente 10 dias.

Valores de NDVI iguais ou maiores que 0,8, já registrados a partir de 72 dias após a semeadura da soja, foram identificados entre as datas 31/01/2018 e 25/02/2018, nesse caso totalizando 26, 23 e 26 dias para os talhões 1, 2 e 3 (Tabela 4), indicando mais uma vez condição favorável tanto ao crescimento vegetativo quanto aos estádios de floração e frutificação, resultando em valores de produtividade elevada (Figura 5).

Em seguida ao período de máximo NDVI, com mais de 117 dias de ciclo foi então observado início da maturação, com NDVI atingindo valores de 0,7, 35 dias após o máximo valor de NDVI (Tabela 4). Após o período de maturação fisiológica, os valores de NDVI reduzem mais bruscamente, no período de senescência das folhas.

A lavoura foi cultivada com adequada população de plantas, manejo fitossanitário adequados e a safra 2017/18 apresentou boas condições meteorológicas, o que resultou em valores de NDVI similares aos de culturas irrigadas (BARIANI et al., 2015; CRUSIOL et al., 2018).

Tabela 4 - Datas das imagens de NDVI e seus respectivos valores médios para o período de produção da cultura da soja, nos talhões de produção 1, 2 e 3.

Data/Evento	NDVI médio		
	Talhão 1	Talhão 2	Talhão 3
Semeadura	14/11/2017	15/11/2017	21/11/2017
24 Nov/2017	0.16	0.17	0.15
29 Nov/2017	0.17	0.17	0.16
09 Dez/2017	0.28	0.26	0.23
12 Dez/2017	0.33	0.29	0.29
03 Jan/2018	0.78	0.72	0.77
31 Jan/2018	0.85	0.82	0.85
07 Fev/2018	0.82	0.80	0.83
15 Fev/2018	0.85	0.83	0.86
22 Fev/2018	0.84	0.80	0.85
25 Fev/2018	0.83	0.79	0.83
17 Mar/2018	0.78	0.73	0.77
Maturidade fisiológica* (NDVI = 0,7)	~21/03/2018	~19/03/2018	~21/03/2018
06 Abr/2018	0.35	0.31	0.36
08 Abri/2018	0.31	0.27	0.29

16 Abr/2018	0.25	0.23	0.24
18 Abr/2018	0.25	0.20	0.21

*Data estimada por análise de regressão simples

As imagens de máximo valor de NDVI (Figura 6), relativos à imagem do dia 15 de fevereiro de 2018 apresentam pouca variabilidade (Tabela 4). Ainda que apresentem datas de semeadura distintas (uma semana de diferença entre os talhões 1 e 2 quando comparados ao talhão 3), a data do NDVI máximo foi a mesma para os três talhões.

Figura 6 - NDVI máximo observado para os talhões 1 (A), 2 (B) e 3 (C) na safra 2017/18.

Para as imagens de máximo NDVI (Figura 6), o Talhão 1 apresenta valores variando de 0,68 a 0,89 (Figura 6A). O Talhão 2 apresenta valores entre 0,55 e 0,89 (Figura 6B) e o Talhão 3 apresenta valores entre 0,85 e 0,89 (Figura 6C). Esses valores se assemelham aos encontrados por Fontana et al. (2019), que citam valor máximo de NDVI igual a 0,9, e Crusiol et al. (2013) que encontraram valor máximo de NDVI de 0,89 para soja irrigada. Observa-se que, os maiores valores de NDVI para toda a safra não chegam a 1,0 (unidade), indicando que não houve saturação do índice para a soja. Diversos autores demonstram a ocorrência de saturação do valor de NDVI apenas para áreas de soja com IAF superior a 5 (FONTANA et al., 2019; SCHAPARINI et al., 2020).

A homogeneidade dos mapas de NDVI de pico pode ser mais bem observada por meio das classes de NDVI (Tabela 5). A partir da frequência de distribuição dos valores de NDVI observa-se que, no talhão 1 apenas 0,2% da área apresentou NDVI máximo inferior a 0,8, enquanto toda área do talhão 3 teve NDVI máximo de mais de 0,85. No talhão 2, 4,4% da área apresentou NDVI máximo inferior a 0,8. Esses locais estão lateralmente posicionados

a uma estrada que percorre a área, portanto não devem ser considerados como valores de NDVI para a soja.

Tabela 5 - Distribuição de frequência das classes de NDVI máximo.

Classe	Talhão 1		Talhão 2		Talhão 3	
	NDVI	%	NDVI	%	NDVI	%
1	0.727	0.2%	0.633	0.7%	0.859	0.8%
2	0.810	0.5%	0.720	1.0%	0.867	3.3%
3	0.844	0.6%	0.781	2.7%	0.872	6.9%
4	0.863	2.7%	0.823	3.3%	0.876	11.0%
5	0.871	11.9%	0.847	5.7%	0.879	18.7%
6	0.875	29.1%	0.864	10.5%	0.881	25.1%
7	0.879	36.7%	0.873	35.5%	0.884	23.9%
8	0.887	18.3%	0.885	40.6%	0.889	10.5%

Esse resultado, além de evidenciar uniformidade de manejo da área e ausência ou controle eficiente de pragas ou doenças, destaca uma condição meteorológica favorável, especialmente relacionado a disponibilidade hídrica, que pode ser espacial e temporalmente variável na área por conta de variabilidade do solo (Tabela 2) ou da precipitação, nesse caso não mensurada (Figura 3), mas que devido a frequência e acumulados não influenciou negativamente as áreas de produção. De La Casa et al. (2018) estudaram a relação entre NDVI e cobertura da cultura de soja na Argentina avaliando as safras de 2010/11 e 2014/15 e identificaram menor variabilidade na área na safra de 2014/15, quando a cultura foi submetida à disponibilidade hídrica favorável. Isso sugere que a homogeneidade dos mapas de NDVI representam as condições climáticas favoráveis ao crescimento da cultura, evidenciadas no capítulo anterior, e à uniformidade da umidade do solo (Tabela 3).

As imagens de NDVI médio (R1-R6) (Figura 7) apresentam valores de NDVI variando de 0,617 a 0,802 para o talhão 1, 0,568 a 0,776 para o talhão 2 e 0,751 a 0,810 para o talhão 3. Para este caso, os valores são menores devido à média considerar valores menores de NDVI, entre 0,7 e 0,8, que antecedem e precedem a data de NDVI máximo.

Figura 7 - NDVI médio entre R1 e R6 para os talhões 1 (A), 2 (B) e 3 (C) na safra 2017/18.

A frequência de distribuição das classes de NDVI (Tabela 6) mostram que, assim como para a imagem de pico de NDVI, mais de 70% dos dados se encontram nas classes de NDVI entre 0,74 e 0,79. O talhão 2 apresenta mais de 2% de área com NDVI abaixo de 0,7, influenciados pela estrada que atravessa a área.

Tabela 6 - Distribuição de frequência das classes de NDVI médio entre R1-R6.

Classe	Talhão 1		Talhão 2		Talhão 3	
	NDVI	%	NDVI	%	NDVI	%
1	0.687	0.3%	0.631	0.8%	0.769	2.8%
2	0.741	0.6%	0.680	2.0%	0.775	9.6%
3	0.761	6.4%	0.711	3.9%	0.778	20.6%
4	0.769	20.7%	0.731	7.2%	0.781	22.7%
5	0.774	27.0%	0.744	12.4%	0.785	20.2%
6	0.780	24.5%	0.753	23.0%	0.789	14.7%
7	0.786	14.7%	0.760	30.5%	0.796	5.5%
8	0.802	5.7%	0.776	20.3%	0.810	3.9%

Em um estudo analisando o NDVI da soja irrigada no Paraná, Crusiol et al. (2013) encontrou valor médio de 0,76 para as safras R1 e R5, valores próximos aos encontrados para os talhões estudados neste trabalho. Esses resultados evidenciam as boas condições meteorológicas para a safra 2017/18, visto os valores próximos aos valores de NDVI em condições de soja irrigada.

4.3.4. Produtividade potencial (Y_o) e atingível (Y_a) simuladas

Para as simulações da produtividade potencial, os dados meteorológicos, de temperatura e umidade relativa do ar, precipitação e velocidade do vento, coletados nos anos de 2017 e 2018 foram usados para todos os talhões.

O cálculo da produtividade potencial (Y_o) considera dados de fotoperíodo, radiação solar, temperatura do ar e duração do ciclo. Portanto, a diferença nos resultados entre talhões ocorre apenas em função da duração do ciclo, pois as outras variáveis utilizadas para o cálculo são as mesmas em toda a área estudada. O Talhão 1 apresentou o maior valor de Y_o , de $6,91 \text{ ton ha}^{-1}$, pois o ciclo da soja foi maior, com duração de 128 dias. Para o Talhão 2, com 125 dias de ciclo, a produtividade potencial foi de $6,76 \text{ ton ha}^{-1}$ e para o Talhão 3, esse com ciclo de 121 dias, a produtividade potencial estimada de $6,49 \text{ ton ha}^{-1}$.

Ao analisar dados de produtividade potencial de soja de 15 localidades do Brasil, Sentelhas et al. (2015) mostram que produtividade potencial se aproximou de $6,0 \text{ ton ha}^{-1}$, com os maiores valores ocorrendo no Sul do Brasil, incluindo Cruz Alta, como resultado do fotoperíodo mais longo e maior radiação solar durante a estação de crescimento. Áreas de produção de soja que visam alta produtividade – de sequeiro e soja irrigada – alcançam valores elevados. O Comitê Estratégico da Soja no Brasil (CESB) ratifica os valores de produtividade potencial obtidos a partir do modelo agrometeorológico, com produtores de Cruz Alta registrando produtividade de $7,4 \text{ ton ha}^{-1}$ na safra 2018/19.

Para determinar produtividade atingível (Y_a) de cada talhão, com simulações pontuais, de acordo com os pontos de amostragem de solo, mais uma vez foi considerada uniformidade espacial dos elementos meteorológicos, incluindo a precipitação. Sobre esse elemento meteorológico específico, Dos Santos (2020) e Ferneda (2020) apontam que, mesmo para pequenas áreas, até mesmo de tamanho inferior aos talhões analisados, há variabilidade espacial, e que a mesma pode interferir sobre a produtividade da cultura.

As simulações de produtividade atingível (Y_a), portanto, incluíram especificamente a variabilidade da capacidade de armazenamento de água do solo (CAD). Assim, diferenças em condição hídrica decorrem unicamente do fator solo.

Os resultados de produtividade atingível (Y_a) estimada variaram de $5,525$ a $5,549 \text{ ton ha}^{-1}$ para o Talhão 1, de $5,417$ a $5,422 \text{ ton ha}^{-1}$ para o Talhão 2 e $5,243$ a $5,245 \text{ ton ha}^{-1}$ para o Talhão 3 (Figura 8). A quase ausência de variabilidade espacial da produtividade atingível simulada é devida à condição meteorológica, favorável ao desenvolvimento da cultura (Figura 3 – item 4.3.1), associada a elevada capacidade de armazenamento de água de cada ponto dos três talhões, situação que possibilitou uma condição hídrica satisfatória à cultura mesmo em períodos curtos de estiagem (Figura 2).

A baixa variabilidade dos dados é também reforçada pelo que foi apontado por Zanon et al. (2016), ao destacarem que os valores de produtividade máximos não são mais responsivos ao montante de precipitação a partir de um limite de 800 mm. Na safra (2017/18), a regularidade e volume de precipitação acumulada no ciclo de produção da soja permitiram a maximização da produtividade, chegando-se a uma perda produtividade relativa ($1 - Y_a/Y_o$) média de apenas 0,2 nos três talhões, ou seja, uma diferença de 80%. Estudos mostram que a diferença relativa entre produtividade potencial e atingível chega a níveis de 85% (GRASSINI et al., 2011; HOCHMAN et al., 2012; VAN ITTERSUM et al., 2013).

Figura 8 - Produtividade atingível (Y_a) para a soja simulada dos talhões 1 (A), 2 (B) e 3 (C), na safra 2017/18.

4.3.5. Lacuna de produtividade da soja (*Yield gap*)

Foram quantificadas as lacunas de produtividade a partir dos dados de produtividade atingível e real (Figura 9). Como a produtividade atingível simulada se mostrou espacialmente homogênea nos três talhões, na safra 2017/18, as maiores lacunas produtivas foram justamente observadas nas áreas às margens dos talhões, sobretudo nos talhões 1 e 2, por conta dos baixos valores de produtividade real para esses locais.

Figura 9 - Lacuna de produtividade da soja (Ya-Yr) ou ‘yield gap’ para os Talhões 1 (A), 2 (B) e 3 (C) na safra 2017/18.

É importante destacar que o processo de colheita nas bordas dos talhões é complexo, muitas vezes incorporando falhas devido a operação da colhedora. Entretanto, não se pode negligenciar que as menores produtividades também podem estar relacionadas a maior compactação do solo das bordas, a falhas de aplicação de fertilizantes ou defensivos agrícolas.

O talhão 3 apresentou a menor diferença entre a produtividade real e atingível (Figura 9) ao longo de toda a sua extensão. Nas áreas centrais dos três talhões a lacuna de produtividade variou de 0,6 a 2 ton ha⁻¹. Valores próximos foram encontrados por Sentelhas et al. (2015) para o município de Cruz Alta, quando avaliaram as lacunas de rendimento da soja, levando em conta o déficit hídrico. Os autores encontraram valores entre 2,05 e 2,6 ton ha⁻¹.

O talhão 2 apresentou os maiores valores de lacunas de produtividade. Observa-se maior variabilidade junto a estrada – que acaba tornando-se um canal para escoamento da água da chuva. Como o ano foi chuvoso, com eventos de ultrapassaram a intensidade de 120 mm/dia, pode-se ter prejuízos em relação a própria densidade de plantas nesse local, além de maior lixiviação de nutrientes. Na área mais ao sul do talhão 2 há a ocorrência de área de mata nas margens, o que pode ser ocasionado um sombreamento na soja. Além disso, é uma área de menor altitude, e pode ter ocorrido encharcamento do solo, e soja é uma planta pouco tolerante ao excesso hídrico (FARIAS et al., 2007; SCHÖFFEL et al., 2001). A baixa produtividade nessas áreas também pode ser verificada nas imagens de NDVI (Figuras 6 e 7).

4.3.6. Correlações de dados agrometeorológicos e espectrais: aplicação em talhões de produção de soja

A partir das correlações entre produtividade real (Y_r), dados de NDVI e produtividade relativa (Y_a/Y_o) foram gerados modelos empíricos, com o intuito de analisar a possibilidade de aumentar a resolução espacial para estimativa de produtividade da soja (FONTANA et al., 2001; RUDORFF; BATISTA, 1990). Para processar as análises de regressão foram utilizados os dados dos talhões 2 e 3, aleatoriamente definidos. Dados de produtividade real (Y_r), de NDVI (máximo e médio) e produtividade relativa (Y_a/Y_o) do talhão 1 foram então usados para avaliar a capacidade preditiva do modelo gerado para a área de produção. A Tabela 7 apresenta os coeficientes de ajuste das equações e os coeficientes de determinação (R^2) e valor p para os modelos gerados (Eq. 22 e 23). Todos os modelos foram estatisticamente significativos (Tabela 7). Os coeficientes de ajustes do modelo foram altos, com valores de R^2 entre 0,88 a 0,96.

Tabela 7 – Coeficientes das equações geradas pelas regressões entre Y_r , NDVI e Y_a/Y_o e seus respectivos valores de coeficiente de determinação (R^2) e valor p.

Correlações	Coeficientes equação			R^2	p
	a	b	c		
$Y_r \times NDVI_{\max}$	-3,7	8,5	-	0.936	<0,05
$Y_r \times NDVI_{\max} \times Y_a/Y_o$	-29,8	7,7	33,3	0.959	<0,05
$Y_r \times NDVI_{R1R6}$	-4,6	10,8	-	0.876	<0,05
$Y_r \times NDVI_{R1R6} \times Y_a/Y_o$	14,1	12,0	-24,4	0.888	<0,05

Modelos de regressão entre dados de produtividade, índices de vegetação e dados climáticos já foram testados por diversos autores (LOBELL et al., 2015; MELLO; FONTANA; BERLATO, 2003). Mello, Fontana e Berlato (2001) utilizaram dados de NDVI e consumo hídrico para estimar a produtividade de soja no Rio Grande do sul por meio de um modelo regressivo, com R^2 entre 0,51 e 0,74. Essa abordagem simples apresentou desempenho satisfatório para os casos citados, e foi testada neste trabalho para a escala ao nível de talhão com resultados satisfatórios.

Lobell et al. (2015) utilizaram um modelo empírico com dados de índices de vegetação e variáveis meteorológicas, calibrado com centenas de simulações de produtividade – que abrange certo número de condições climáticas e de solo – para estimar a produtividade de milho e soja nos EUA. Os autores explicam que essa abordagem foi capaz de explicar, em

média, 32% da variação de produtividade a nível de talhão (R^2 de 0,03 a 0,55). E, adicionam que, abordagens mais simples apresentam bons resultados quando utilizados pixels da mesma data (apenas uma imagem), próxima ao pico da estação de crescimento, no entanto esses métodos são fracos em extrapolar os resultados para outras regiões ou anos.

Os resultados (Tabela 7) apresentaram-se em consonância às conclusões de muitos estudos sobre modelos agrometeorológicos-espectrais que, em geral, apresentam melhores resultados quando unem informações climáticas e índices de vegetação. Guan et al. (2017) aprimoraram os resultados do modelo de estimativa de produtividade (de $R^2=0,55$ para $R^2=0,61$) quando incluíram no modelo informações climáticas. Segundo os autores, o modelo com apenas dados de clima explica menos que modelos com somente dados espectrais, sendo que a junção dos dados apresentou as melhores estimativas.

Entretanto, ao analisar o desempenho dos modelos (Tabela 7) frente aos dados de produtividade do talhão 1 (Figura 10), tem-se resultados não tão conclusivos. O desempenho dos modelos que integram a informação agrometeorológica aos dados de NDVI, não apresentaram distinção àqueles que utilizam apenas NDVI, não acrescentando, portanto, melhora na estimativa da produtividade. Os modelos com NDVI médio, entre as fases R1 e R6, descreveram melhor a produtividade do Talhão 1 na safra 2017/18, com pouca diferença entre os modelos espectral e agrometeorológico-espectral, mas com vantagem para esse último. Os modelos com a imagem de NDVI máximo, espectral e agrometeorológico-espectral explicaram 49% da variabilidade produtiva (Figuras 10A e 10B), enquanto o modelo com o NDVI médio explicou 67% da variabilidade (Figuras 10C e 10D).

Figura 10 - Relação entre produtividade estimada pelo modelo $NDVI_{max} \times Yr$ (A), $NDVI_{max} \times Ya/Yo \times Yr$ (B), $NDVI_{R1R6} \times Yr$ (C) e $NDVI_{R1R6} \times Ya/Yo \times Yr$ (D) e produtividade real do Talhão 1.

Com o uso do NDVI médio, entre as fases R1 e R6, foi possível captar as adversidades que tenham ocorrido no subperíodo reprodutivo, a exemplo de pragas que, preferencialmente, podem ocorrer nesse momento ou, especialmente, qualquer evento meteorológico que tenha causado prejuízo à produção, como granizo, vento, encharcamento do solo etc. O estresse abiótico nos períodos de floração e enchimento dos grãos afetam a produtividade final de forma mais intensa e a estimativa da produtividade depende das condições na fase reprodutiva (SCHWALBERT et al., 2018). Dessa forma, a avaliação por meio dos dados de NDVI médio ao longo do subperíodo reprodutivo da soja é mais assertiva.

Considerando-se a escala espacial de avaliação dos modelos, todos apresentaram boa precisão (com R^2 entre 0,48 e 0,67), similar ao que Eugenio et al. (2020) encontraram ao realizar análises em escala similar. A partir dos resultados do índice de concorância de Willmott (d), entre 0,10 e 0,26 (Tabela 8), conclui-se que apesar de se apresentarem funcionais, para a escala espacial analisada não são capazes de prever a variabilidade produtiva com exatidão.

Jin et al. (2019) utilizaram modelos de crescimento junto a dados espectrais do Sentinel-2 para estimar a produtividade de milho em pequenas áreas no Quênia. Segundo os autores, a utilização de dados de pico do índice de vegetação pode não considerar informações sobre o processo de crescimento do dossel, no entanto, para o modelo utilizado por eles, a maior

correlação ocorreu com os dados de pico, sendo que a utilização de outras imagens causou instabilidade das estimativas de produtividade.

Já Hill e Donald (2003) utilizaram o NDVI de forma cumulativa. Os autores avaliaram a correlação entre o *Time-Integrated NDVI* (TINDVI) e a produtividade de culturas agrícolas no oeste da Austrália e encontraram relação entre os dados, principalmente em anos com precipitação escassa, assim como apontado por Yang et al. (1998). Da mesma forma, Meroni et al. (2013) utilizaram dados de NDVI integrados entre início do período de crescimento e o início da fase de senescência das plantas para obter um modelo de estimativa de rendimento de trigo na Tunísia por meio de regressão linear, com resultados de até 80% das estimativas de produtividade explicadas pelo NDVI.

Segundo Mkhabela et al. (2011), a integração dos valores de NDVI evita oscilações nos valores da resposta espectral que não diz respeito à vegetação, além de contabilizar o acúmulo da fotossíntese. Para o modelo de previsão de produtividade da soja de Krüger, Fontana e Melo (2007), os melhores resultados são obtidos com imagens a partir do mês de janeiro, indicando que os períodos mais críticos para a determinação da produtividade final são florescimento e enchimento dos grãos (entre R2 e R7).

Em relação aos índices de erros (Tabela 8), todos os modelos apresentaram EAM abaixo dos 400 kg ha⁻¹ (Tabela 8), com tendência de subestimação dos resultados (EM), exceto o modelo NDVI_{R1R6} x Ya/Yo.

Tabela 8 - Resultados da avaliação dos modelos por meio dos indicadores Índice de Willmot (d), Erro Médio (EM), Raiz Quadrada do Erro Médio (RQEM), Erro Absoluto Médio (EAM).

Modelo	d	EM*	EAM*
Yr x NDVI _{max}	0.180	-0.026	0.272
Yr x NDVI _{max} x Ya/Yp	0.263	-0.234	0.334
Yr x NDVI _{R1R6}	0.104	-0.034	0.201
Yr x NDVI _{R1R6} x Ya/Yp	0.125	0.128	0.204

*EM e EAM em ton ha⁻¹.

Os erros calculados (Tabela 8) foram superiores aos encontrados por Krüger, Fontana e Melo (2007). Os autores testaram um modelo agrometeorológico-espectral para estimar a produtividade da soja no Rio Grande do Sul. O componente agrometeorológico utilizado foi o consumo hídrico, dado pela razão entre ETr e ETc. Os autores compararam os resultados com os dados oficiais do IBGE e encontraram erros (Soma dos Quadrados dos

Erros) em torno de 140 kg ha^{-1} . Deve-se considerar que as estimativas foram feitas para a média dos municípios e, portanto, com menos detalhes do que o presente trabalho.

A sensibilidade da cultura se desenvolver, quanto à condição hídrica, é expressa pelo fator meteorológico fornecido pelo modelo (MELLO; FONTANA; BERLATO, 2003). Como a safra de 2017/18 não apresentou déficit hídrico significativo, que impactasse negativamente no desenvolvimento da planta, a variabilidade das características físico-hídricas do solo não foi suficiente para explicar a variabilidade da produtividade nos talhões.

Dos Santos (2020) analisou a variabilidade da precipitação na estimativa de produtividade para áreas de até 1000 ha e concluiu que para talhões a partir de 36 ha há variabilidade significativa da precipitação, que impacta na produtividade. A utilização de dados climáticos juntamente com dados espectrais já foi validada por diversos autores (DE LA CASA et al., 2018; JAIN et al., 2016; JUNGES; FONTANA, 2011), dessa forma, a abordagem utilizada nesse trabalho deve ser estudada em outras culturas e regiões, englobando um período de estudo maior e maior variabilidade dos dados climáticos, para que sua eficácia seja comprovada.

O modelo regressivo utilizado não analisou a estrutura de autocorrelação espacial das variáveis e os resultados são aplicáveis apenas para situações similares àquelas em que o modelo foi gerado (SCHWALBERT et al., 2018). A busca por um modelo simples e de fácil acesso e programação pode levar a erros, no entanto apresenta resultados aceitáveis, que podem ser de grande benefício para os produtores de soja.

Este trabalho mostrou que é possível identificar a variabilidade produtiva com maior detalhamento, podendo analisar o talhão de acordo com a sua variabilidade produtiva. Deve-se considerar que os dados utilizados para o trabalho são limitados temporalmente, já que foram utilizados os dados de apenas uma safra. Para uma melhor estimativa da produtividade são necessários dados de diferentes safras, para integrar condições meteorológicas e produtivas diversas.

4.4. Conclusão

O presente trabalho buscou analisar o uso de uma metodologia, que incorpora um modelo agrometeorológico às imagens espectrais, para determinar a produtividade em talhões de produção de soja, no entanto, em maior resolução espacial que trabalhos

realizados anteriormente. Os resultados mostram a possibilidade de estimar a produtividade da soja, para as condições nas quais os modelos foram gerados. Os modelos que utilizaram o NDVI médio, entre as fases fenológicas de R1 a R6, foram capazes de explicar até 67% da produtividade final da soja no talhão. Devido a condição meteorológica específica da safra analisada, favorável à produção da soja, não houve melhoria do modelo a partir da adição do termo dos dados de produtividade potencial e atingível simulados.

Os resultados obtidos são promissores. Porém, deve-se considerar as limitações das análises, como a baixa variabilidade dos dados meteorológicos. Os modelos de regressão entre dados espectrais e de culturas podem variar em função de muitos aspectos, dependendo da cultura, índice de vegetação, local e solo. Portanto, novas análises devem ser feitas. Sugere-se que as novas bases de dados integrem maior variabilidade de solo e condições meteorológicas, utilizando uma escala temporal maior.

Referências

- ALLEN, R. G et al. **Crop evapotranspiration: guidelines for computing crop water requirements**. Rome: FAO, 1998. 300p. (FAO. Irrigation and Drainage Paper, 56).
- ASSAD, E. D. et al. Sistema de previsão da safra de soja para o Brasil. **Pesquisa Agropecuária Brasileira**, v. 42, n. 5, p. 615–625, 2007.
- AZZARI, G.; JAIN, M.; LOBELL, D. B. Towards fine resolution global maps of crop yields: Testing multiple methods and satellites in three countries. **Remote Sensing of Environment**, v. 202, p. 129–141, 1 dez. 2017.
- BARIANI, C. J. M. V. et al. Monitoramento Da Fenologia Da Soja Irrigada Usando Perfis De Série Temporal De Ndzi. n. September, p. 1610–1618, 2015.
- BARNETT, T. L.; THOMPSON, D. R. The use of large-area spectral data in wheat yield estimation. **Remote Sensing of Environment**, v. 12, n. 6, p. 509–518, 1982.
- BASSO, B. et al. Spatial validation of crop models for precision agriculture. **Agricultural Systems**, v. 68, n. 2, p. 97–112, 1 maio 2001.

BATTISTI, R. **Épocas de semeadura da cultura da soja com base no risco climático e na rentabilidade líquida para as principais regiões produtoras do Brasil**. 2013. 261 f. Dissertação (Mestrado em Engenharia de Sistemas Agrícolas) - Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2013.

BATTISTI, R. et al. Gauging the sources of uncertainty in soybean yield simulations using the MONICA model. **Agricultural Systems**, v. 155, n. April, p. 9–18, 2017.

BATTISTI, R.; BENDER, F. D.; SENTELHAS, P. C. Assessment of different gridded weather data for soybean yield simulations in Brazil. **Theoretical and Applied Climatology**, v. 135, n. 1–2, p. 237–247, 2019.

BECKER-RESHEF, I. et al. Monitoring Global Croplands with Coarse Resolution Earth Observations: The Global Agriculture Monitoring (GLAM) Project. **Remote Sensing**, v. 2, n. 6, p. 1589–1609, 2010.

BOOTE, K. J. et al. The CROPGRO model for grain legumes. v. 1983, n. 1985, p. 99–128, 1998.

CONAB. Acompanhamento da safra brasileira 2019/2020. **Acompanhamento da Safra Brasileira de Grãos 2019/2020**, v. 8, p. 1–29, 2020.

CRUSIOL, L. G. T. et al. Comportamento espectral de diferentes genótipos de soja (GM para tolerância a seca e convencionais), em condição irrigada e sob estresse hídrico. **VI Congresso Brasileiro de Soja**, p. 1–4, 2012.

CRUSIOL, L. G. T. et al. NDVI de estádios de desenvolvimento da soja BRS 284 em condições de campo. **Jornada Acadêmica da Emprapa Soja**, n. 1973, p. 87–91, 2013.

CRUSIOL, L. G. T. et al. Sensoriamento Remoto como Suporte ao Monitoramento do Déficit Hídrico na Cultura da Soja. **VIII Congresso Brasileiro de Soja**, p. 299–301, 2018.

CUNHA, G. R. DA et al. Zoneamento agrícola e época de semeadura para soja no Rio Grande do Sul. **Revista Brasileira de Agrometereologia**, v. 9, n. 3, p. 446–459, 2001.

DE LA CASA, A. et al. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 146, n. October, p. 531–547, 2018.

DELIN, S.; BERGLUND, K. Management zones classified with respect to drought and waterlogging. **Precision Agriculture**, v. 6, n. 4, p. 321–340, 2005.

DOORENBOS, J.; KASSAM, A.M. **Yield response to water**. Rome: FAO, 1979. 300 p. (Irrigation and Drainage Paper, 33).

DOS SANTOS, Thais Letícia. **Variabilidade espacial e temporal da precipitação em Piracicaba (SP) e influência sobre a produtividade estimada da Soja**. 2020. 63 f. Dissertação (Mestrado em Engenharia de Sistemas Agrícolas) - Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2020.

EMATER-RS. **Associação Rio-Grandense de Empreendimentos de Assistência Técnica e Extensão Rural**. Notícias: Início do Plantio da Soja no RS. Disponível em: <<http://www.emater.tche.br/site/multimidia/noticias/detalhe-noticia.php?id=30558#.XsaPLmhKhPY>>. Acesso em: 21 mai. 2020.

EUGENIO, F. C. et al. Estimation of soybean yield from machine learning techniques and multispectral RPAS imagery. **Remote Sensing Applications: Society and Environment**, v. 20, n. August, 2020.

FARIAS, J. R. B. et al. Caracterização de risco de déficit hídrico nas regiões produtoras de soja no Brasil. **Revista Brasileira de Agrometeorologia**, v. 9, n. 3, p. 415–421, 2001.

FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. Ecofisiologia da Soja. **Circular Técnica - Embrapa Soja**, v. 48, 2007.

FENG, W. et al. Measuring leaf nitrogen concentration in winter wheat using double-peak spectral reflection remote sensing data. **Field Crops Research**, v. 159, p. 43–52, 2014.

FERNEDA, Brena Geliane. **Variabilidade e efeitos da precipitação pluvial sobre a disponibilidade hídrica, crescimento e produção de soja em uma fazenda no estado de Mato Grosso**. 2020. 79 f. Dissertação (Mestrado em Engenharia de Sistemas Agrícolas) - Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2020.

FIGUEIREDO, D.C. Projeto GeoSafras - aperfeiçoamento do sistema de previsão de safras da CONAB. **Revista de Política Agrícola**, v.14, p.110-120, 2005.

FIORI, D. et al. Relação entre NDVI e dados de precipitação em diferentes safras de soja no município de Cruz Alta - RS. **XVII Simpósio Brasileiro de Sensoriamento Remoto**, n. 1999, p. 6351–6357, 2015.

FONTANA, D. C. et al. Modelo de estimativa de rendimento de soja no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, v. 36, n. 3, p. 399–403, 2001.

FONTANA, D. C. et al. NDVI E ALGUNS FATORES DE VARIABILIDADE Denise. **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto**, v. ISBN: 978-, 2019.

FRANCH, B. et al. Improving the timeliness of winter wheat production forecast in the United States of America, Ukraine and China using MODIS data and NCAR Growing Degree Day information. **Remote Sensing of Environment**, v. 161, p. 131–148, 1 maio 2015.

GONÇALVES, S. L.; SIBALDELLI, R. N. R. Riscos climáticos e viabilidade econômica da produção de soja no sul do Rio Grande do Sul. **Comunicado Técnico 94. Embrapa Soja**, 2018.

GRASSINI, P. et al. High-yield irrigated maize in the Western U.S. Corn Belt: I. On-farm yield, yield potential, and impact of agronomic practices. **Field Crops Research**, v. 120, n. 1, p. 142–150, 14 jan. 2011.

GUAN, K. et al. The shared and unique values of optical, fluorescence, thermal and microwave satellite data for estimating large-scale crop yields. **Remote Sensing of Environment**, v. 199, p. 333–349, 2017.

HANSEN, J. W.; JONES, J. W. Scaling-up crop models for climate variability applications. **Agricultural Systems**, v. 65, n. 1, p. 43–72, 1 jul. 2000.

HEINEMANN, A. B.; STONE, L. F.; SILVA, S. C. Modelos de simulação do crescimento, desenvolvimento e produtividade na pesquisa agrônômica. **Embrapa Arroz e Feijão**, p. 26, 2010.

HILL, M. J.; DONALD, G. E. Estimating spatio-temporal patterns of agricultural productivity in fragmented landscapes using AVHRR NDVI time series. **Remote Sensing of Environment**, v. 84, n. 3, p. 367–384, 2003.

HOCHMAN, Z. et al. Quantifying yield gaps in rainfed cropping systems: A case study of wheat in Australia. **Field Crops Research**, v. 136, p. 85–96, 2012.

HOLZWORTH, D. P. et al. APSIM - Evolution towards a new generation of agricultural systems simulation. **Environmental Modelling and Software**, v. 62, p. 327–350, 2014.

IBGE, Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal**. Disponível em: <<https://cidades.ibge.gov.br/brasil/rs/cruz-alta/pesquisa/14/10193>>. Acesso em: 14 abr. 2020.

JAIN, M. et al. Mapping smallholder wheat yields and sowing dates using micro-satellite data. **Remote Sensing**, v. 8, n. 10, p. 1–18, 2016.

JIN, Z. et al. Smallholder maize area and yield mapping at national scales with Google Earth Engine. **Remote Sensing of Environment**, v. 228, n. March, p. 115–128, 2019.

JONES, J. . et al. The DSSAT cropping system model. **European Journal of Agronomy**, v. 18, n. 3–4, p. 235–265, 1 jan. 2003.

JUNGES, A. H.; FONTANA, D. C. Modelo agrometeorológico-espectral de estimativa de rendimento de grãos de trigo no Rio Grande do Sul. **Revista Ceres**, v. 58, n. 1, p. 09–16, 2011.

KLERING, E. V. et al. Modelo agrometeorológico-espectral para estimativa da produtividade de grãos de arroz irrigado no Rio Grande do Sul. **Bragantia**, p. 1–10, 2016.

KRÜGER, C. A. M. B.; FONTANA, D. C.; MELO, R. W. DE. Estimativa do rendimento de grãos da soja no Rio Grande do Sul usando um modelo agrometeorológico-espectral regionalizado. **Revista Brasileira de Agrometeorologia**, v. 15, n. 3, p. 210–219, 2007.

LABUS, M. P. et al. Wheat yield estimates using multi-temporal NDVI satellite imagery. **International Journal of Remote Sensing**, v. 23, n. 20, p. 4169–4180, 25 jan. 2002.

LAI, Y. R. et al. An empirical model for prediction of wheat yield, using time-integrated Landsat NDVI. **International Journal of Applied Earth Observation and Geoinformation**, v. 72, p. 99–108, 1 out. 2018.

LEWIS, J. E.; ROWLAND, J.; NADEAU, A. Estimating maize production in kenya using ndvi: Some statistical considerations. **International Journal of Remote Sensing**, v. 19, n. 13, p. 2609–2617, 1998.

LI, S. et al. Spatial variability of soil bulk density and its controlling factors in an agricultural intensive area of Chengdu Plain, Southwest China. **Journal of Integrative Agriculture**, v. 18, n. 2, p. 290–300, 2019.

LOBELL, D. B. et al. Remote sensing of regional crop production in the Yaqui Valley, Mexico: Estimates and uncertainties. **Agriculture, Ecosystems and Environment**, v. 94, n. 2, p. 205–220, 2003.

LOBELL, D. B. The use of satellite data for crop yield gap analysis. **Field Crops Research**, v. 143, p. 56–64, 1 mar. 2013.

LOBELL, D. B. et al. A scalable satellite-based crop yield mapper. **Remote Sensing of Environment**, v. 164, p. 324–333, 1 jul. 2015.

LOPRESTI, M. F.; DI BELLA, C. M.; DEGIOANNI, A. J. Relationship between MODIS-NDVI data and wheat yield: A case study in Northern Buenos Aires province, Argentina. **Information Processing in Agriculture**, v. 2, n. 2, p. 73–84, 2015.

MALDANER, L. F.; CORRÊDO, L. P.; TAVARES, T. R.; MENDEZ, L. G.; DUARTE, C.; MOLIN, J. P. Identifying and filtering out outliers in spatial datasets. **14th International Conference on Precision Agriculture**, Montreal, Quebec, Canada. 2018.

MELLO, R. W. DE; FONTANA, D. C.; BERLATO, M. A. Modelo agrometeorológico-espectral de estimativa de rendimento da soja para o Estado do Rio Grande do Sul. **Anais XI SBSR, Belo Horizonte, Brasil**, v. 36, n. 3, p. 173–179, 2003.

MENEGATTI, L. A. A.; MOLIN, J. P. Metodologia para identificação e caracterização de erros em mapas de produtividade. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 7, n. 2, p. 367–374, 2003.

MENEGATTI, L. A. A.; MOLIN, J. P. Remoção de erros em mapas de produtividade via filtragem de dados brutos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 8, n. 1, p. 126–134, 2004.

MERONI, M. et al. Remote Sensing Based Yield Estimation in a Stochastic Framework — Case Study of Durum Wheat in Tunisia. **Remote Sensing**, v. 5, n. 2, p. 539–557, 28 jan. 2013.

MKHABELA, M. S. et al. Crop yield forecasting on the Canadian Prairies using MODIS NDVI data. **Agricultural and Forest Meteorology**, v. 151, n. 3, p. 385–393, 2011.

MOLIN, J. P.; DO AMARAL, L. R.; COLAÇO, A. F. **Agricultura de Precisão**. 1. ed. São Paulo: Oficina de Textos, 2015.

NAGY, A.; FEHÉR, J.; TAMÁS, J. Wheat and maize yield forecasting for the Tisza river catchment using MODIS NDVI time series and reported crop statistics. **Computers and Electronics in Agriculture**, v. 151, n. March, p. 41–49, 2018.

NEIVERTH, W. et al. NDVI de estádios fenológicos da soja BRS 284 de crescimento indeterminado em casa de vegetação. **VIII Jornada Acadêmica da Embrapa Soja**, p. 6, 2013.

NENDEL, C. et al. The MONICA model: Testing predictability for crop growth, soil moisture and nitrogen dynamics. **Ecological Modelling**, v. 222, n. 9, p. 1614–1625, 2011.

NÓIA JÚNIOR, R. DE S.; SENTELHAS, P. C. Soybean-maize off-season double crop system in Brazil as affected by El Niño Southern Oscillation phases. **Agricultural Systems**, v. 173, n. March, p. 254–267, 2019.

OLIVEIRA, T. C. DE; FERREIRA, E.; DANTAS, A. A. A. Temporal variation of normalized difference vegetation index (NDVI) and calculation of the crop coefficient (K_c) from NDVI in areas cultivated with irrigated soybean. **Ciência Rural**, v. 46, n. 9, p. 1683–1688, 2016.

REED, B. C. et al. Measuring phenological variability from satellite imagery. **Journal of Vegetation Science** 5:, v. 5, n. 5, p. 703–714, 1994.

REICHERT, J. M. et al. ESTIMATION OF WATER RETENTION AND AVAILABILITY IN SOILS OF RIO GRANDE DO SUL. **R. Bras. Ci. solo**, n. 33, p. 1547–1560, 2009.

RICHETTI, Jonathan. **MODELOS AGROMETEOROLÓGICOS, ESPECTRAIS E DE INTELIGÊNCIA ARTIFICIAL PARA ESTIMAÇÃO DE PRODUTIVIDADE DE SOJA**. 2018. 81 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel, 2018.

RIZZI, R.; RUDORFF, B. F. T. Soybean crop area estimation in Rio Grande do Sul through Landsat images. **Revista Brasileira de Cartografia**, v. 3, p. 226–234, 2005.

RUDORFF, B. F. T.; BATISTA, G. T. Yield estimation of sugarcane based on agrometeorological-spectral models. **Remote Sensing of Environment**, v. 33, n. 3, p. 183–192, 1990.

RUIZ-NOGUEIRA, B.; BOOTE, K. J.; SAU, F. Calibration and use of CROPGRO-soybean model for improving soybean management under rainfed conditions. **Agricultural Systems**, v. 68, n. 2, p. 151–173, 2001.

SALVADORI, J.R.; BACALTCHUK, B. Indicações Técnicas para a Cultura da Soja no Rio Grande do Sul e em Santa Catarina, safras 2016/2017 e 2017/2018. **Reunião de Pesquisa da Soja da Região Sul**, 41: 2016, Passo Fundo, RS, n. 1, p.55-112, 2016.

SCHAPARINI, L. P. et al. Analise comparativa entre índices de vegetação e sua relação com o balanço hídrico em soja. **Agrometeoros**, v. 27, n. 1, p. 183–190, 2020.

SCHÖFFEL, E. R. et al. Excesso Hídrico Sobre Os Componentes Do Rendimento Da Cultura Da Soja. **Ciência Rural**, v. 31, n. 1, p. 7–12, 2001.

SCHWALBERT, R. A. et al. Forecasting maize yield at field scale based on high-resolution satellite imagery. **Biosystems Engineering**, v. 171, p. 179–192, 2018.

SENTELHAS, P. C. et al. The soybean yield gap in Brazil - Magnitude, causes and possible solutions for sustainable production. **Journal of Agricultural Science**, v. 153, n. 8, p. 1394–1411, 2015.

SHELIA, V. et al. A multi-scale and multi-model gridded framework for forecasting crop production, risk analysis, and climate change impact studies. **Environmental Modelling and Software**, v. 115, n. October 2018, p. 144–154, 2019.

SILVA, Evandro H. F. M. DA. **Simulação de cenários agrícolas futuros para a cultura da soja no Brasil com base em projeções de mudanças climáticas**. 2018. 95 f. Dissertação (Mestrado em Engenharia de Sistemas Agrícolas) - Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2018.

SUDDUTH, K. A.; DRUMMOND, S. T.; MYERS, D. B. Yield editor 2.0: Software for automated removal of yield map errors. **American Society of Agricultural and Biological Engineers Annual International Meeting 2012, ASABE 2012**, v. 4, n. 12, p. 3378–3391, 2012.

THORNTHWAITE, C.W.; MATHER, J.R. **The water balance**. Nex Jersey: Drexel Institute of Technology, 1955. 104 p. (Publications in Climatology, 1).

THORP, K. R. et al. Methodology for the use of DSSAT models for precision agriculture decision support. **Computers and Electronics in Agriculture**, v. 64, n. 2, p. 276–285, 2008.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

VAN ITTERSUM, M. K. et al. Yield gap analysis with local to global relevance-A review. **Field Crops Research**, v. 143, p. 4–17, 2013.

WILLMOTT, C. J. et al. Statistics for the evaluation and comparison of models. **Journal of Geophysical Research**, v. 90, n. C5, p. 8995–9005, 1985.

YANG, C. et al. Using high-resolution airborne and satellite imagery to assess crop growth and yield variability for precision agriculture. **Proceedings of the IEEE**, v. 101, n. 3, p. 582–592, 2013.

YANG, L. et al. An analysis of relationships among climate forcing and time-integrated NDVI of grasslands over the U.S. northern and central Great Plains. **Remote Sensing of Environment**, v. 65, n. 1, p. 25–37, 1998.

ZANELLA, Marco Antonio. **Delimitação de Zonas de Manejo Utilizando Imagens Orbitais e sua Relação com Mapas de Produtividade**. 2018. 47 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa, 2018.