

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS DA NATUREZA  
CURSO DE GRADUAÇÃO EM ENGENHARIA AGRÔNOMICA

LUARA FRANCIANE DE MEIRELLES

**PREDIÇÃO DA PRODUTIVIDADE DE MILHO (*Zea mays* L) POR MEIO DA  
INTERPRETAÇÃO TEMPORAL DE ÍNDICES DE VEGETAÇÃO**

Buri-SP

2022

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS DA NATUREZA  
CURSO DE GRADUAÇÃO EM ENGENHARIA AGRONÔMICA

LUARA FRANCIANE DE MEIRELLES

**PREDIÇÃO DA PRODUTIVIDADE DE MILHO (*Zea mays* L) POR MEIO DA  
INTERPRETAÇÃO TEMPORAL DE ÍNDICES DE VEGETAÇÃO**

Trabalho de Conclusão de Curso apresentado  
ao Curso de Engenharia Agrônômica para  
obtenção do título de Bacharel em Engenharia  
Agrônômica.

Orientação: Prof. Dr. Paulo Guilherme Molin

Financiamento: CNPQ

Buri-SP

2022

Meirelles, Luara Franciane de

Predição da produtividade de milho (*Zea mays* L) por meio da interpretação temporal de índices de vegetação / Luara Franciane de Meirelles -- 2022.  
46f.


TCC (Graduação) - Universidade Federal de São Carlos, campus Lagoa do Sino, Buri  
Orientador (a): Paulo Guilherme Molin  
Banca Examinadora: Paulo Guilherme Molin, Flávio Sérgio Afférri, Daniel Garbellini Duft  
Bibliografia

1. Produtividade . 2. Sensoriamento Remoto. 3. Índices de Vegetação. I. Meirelles, Luara Franciane de. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Lissandra Pinhatelli de Britto - CRB/8 7539




## ATA DE APRESENTAÇÃO DE TRABALHO DE CONCLUSÃO DE CURSO


Aos 18 dias do mês de abril de 2022, no Centro de Ciências da Natureza da Universidade Federal de São Carlos, realizou-se, a sessão pública de apresentação de Monografia do Curso de Graduação em Engenharia Agrônômica, do(a) aluno(a) Luara Franciane de Meirelles sob orientação do(a) Prof(a) Paulo Guilherme Molin, intitulada "Predição da produtividade de milho (Zea mays L) por meio da interpretação temporal de índices de vegetação".

Pelos Professores/Membros da banca foram atribuídas as seguintes notas:

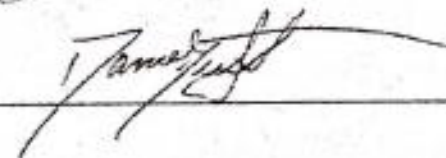
Prof.(a)/Membro: Paulo Guilherme Molin

Nota: 9,8 \_\_\_\_\_ Assinatura: 

Prof.(a)/Membro: Flávio Sérgio Affêrri

Nota: 9,8 \_\_\_\_\_ Assinatura: 

Prof.(a)/Membro: Daniel Garbellini Duft

Nota: 9,8 \_\_\_\_\_ Assinatura: 

O(A) aluno(a) foi APROVADO com a média final de 9,8.

## **AGRADECIMENTO**

Agradeço primeiramente a Deus, por toda a compaixão e bondade conosco, dentro de um momento tão conturbado que passamos e ainda sentimos o seu efeito do COVID-19, Ele nos deu forças para chegar até aqui.

Aos meus pais, Carlos e Francisca, pelo apoio incondicional e por sempre buscarem fazer o melhor; ao meu irmão e a minha cunhada. As minhas amigas Renata, Grazielle e Raíssa, pela parceria e o carinho recíproco, vocês foram fundamentais para a minha formação, por isso merecem meu eterno agradecimento.

À minha família que sempre me motivou e me faz sentir que posso alcançar meus objetivos; aos meus amigos da faculdade, pela amizade, os churrascos, as conversas, as caronas e toda parceria nos momentos longe de casa; às pessoas especiais que estão na minha vida e que sempre estendem a mão.

Ao Centro de Pesquisa e Extensão em Geotecnologias (CePE-Geo) pela oportunidade de me desenvolver profissionalmente e me aproximar de futuros engenheiros agrônomos e ambientais de excelência e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

De forma geral, a todos que contribuíram, direta ou indiretamente, para a minha formação profissional, o meu muito obrigada.

## RESUMO

A estimativa de produção de grão faz-se necessária diante das exigências do agronegócio. No Brasil, a cultura do milho (*Zea mays* L.) torna-se uma das principais *commodities* agrícolas, fundamental para o agronegócio do país. O maior destaque da produção do grão é o Centro-Sul brasileiro, representando 83% da produção nacional. O uso de sensoriamento remoto pode gerar um grande banco de dados, auxiliando o produtor na gestão e monitoramento da lavoura, até mesmo na predição de produtividade. Um exemplo de uso do sensoriamento remoto aliado ao monitoramento e predição de produtividade é através de técnicas que relacionam a produtividade com índices de vegetação obtidos por imagens de satélites, adquiridas e processadas de forma gratuita. Este trabalho buscou avaliar métodos de estimativa de produtividade da cultura do milho de segunda safra de uma propriedade, na região Sudoeste Paulista, usando índices de vegetação. Para tal finalidade utilizou-se o Índice de Vegetação por Diferença Normalizada (NDVI – do inglês *Normalized Difference Vegetation Index*) e Normalizada na Banda *Red-Edge* (NDRE – do inglês *Normalized Difference red-edge*), além dos dados de produção obtidos diretamente de um sensor de produtividade instalado na colhedora, modelo da John Deere S660. A área de estudo situa-se em uma propriedade no município de Capão Bonito-SP, em uma área de 19 ha de milho de segunda safra. Os valores dos índices de vegetação foram obtidos através de imagens do satélite *Sentinel-2* (pixel 10x10m) e do uso do *software* QGIS. No total foram adquiridas 15 cenas espaçadas entre o plantio e a colheita. Usamos os valores médios da produtividade obtidos dentro de cada pixel, correlacionando, portanto, os valores dos índices de vegetação com o valor de produtividade dentro do pixel. O cálculo de regressão linear de produtividade gerou 30 gráficos, sendo 15 para cada índice com a produtividade da máquina. Nesse estudo observou-se que a regressão linear mais acurada foi utilizando NDVI na data de 13 de junho de 2020, o que corresponde a 100 dias após a semeadura. Percebe-se que através dessa técnica é possível proporcionar o monitoramento da produtividade de milho antes da colheita, oferecendo maior facilidade de obtenção de dados e gestão da lavoura.

**Palavras-chaves:** NDRE, NDVI, Produtividade, Sensoriamento Remoto

## ABSTRACT

The estimation of grain production is necessary for agribusiness. In Brazil, the corn culture (*Zea mays* L.) has become one of the leading agricultural commodities, being the basis for the country's agribusiness. Brazil's biggest region corn producer is the Center-South, which represents 83% of national production. The use of remote sensing can generate an extensive database, helping the producer manage and monitor the crop and predict productivity. An example of remote sensing combined with monitoring and predicting productivity is through techniques that relate productivity with vegetation indices obtained from satellite images. This work aimed to evaluate methods for estimating the yield of second-crop corn on a property in the Southwest region of São Paulo using vegetation indexes. For this purpose, we used the Normalized Difference Vegetation Index (NDVI), Normalized Difference Vegetation Index (NDRE), and data production obtained directly from a productivity sensor installed in the harvester John Deere S660 model. The study area is located on a property in the municipality of Capão Bonito-SP, in an area of 19 ha of second-crop corn. The values of vegetation indices were obtained through Sentinel-2 satellite images (pixel 10×10m) and using the QGIS software. In total, 15 scenes between planting and harvesting were acquired. We used the average productivity values obtained within each pixel, thus correlating the values of vegetation indices with the productivity value within the pixel. The linear regression calculation of productivity generated 30 graphs, 15 for each index with the machine's productivity. In this study, it was observed that the most accurate linear regression was using NDVI on June 13, 2020, which corresponds to 100 days after sowing. Therefore, it can be seen that through this technique, it is possible to monitor corn productivity before harvesting, offering an easier way to obtain data and manage the crop.

**Keywords:** NDRE, NDVI, Productivity, Remote Sensing

## LISTA DE FIGURAS

Figura 1: Espiga de milho da cultivar AG 9000 Pro 3 da área de estudo.....	5
Figura 2: Localização da área de estudo, no município de Capão Bonito -SP.....	5
Figura 3: Funcionários da fazenda que realizaram a colheita .....	8
Figura 4: Índice de Vegetação NDVI que apresentou a melhor correlação .....	15
Figura 5: Mapa de produtividade com os dados filtrados .....	15



## LISTA DE TABELAS

Tabela 1: Data de aquisição das imagens .....	6
Tabela 2: Estatística descritiva dos Índices de vegetação correspondente aos períodos avaliados .....	12

## LISTA DE GRÁFICOS

Gráfico 1: Análise temporal dos índices de vegetação.....	11
Gráfico 2: Comportamento do $R^2$ com a média dos Índices de vegetação.....	13
Gráfico 3: Melhor regressão linear entre índices de vegetação e produtividade .....	13

## SUMÁRIO

1 INTRODUÇÃO E JUSTIFICATIVA, COM SÍNTESE DA BIBLIOGRAFIA FUNDAMENTAL.....	1
2 OBJETIVOS.....	3
3 MATERIAL E MÉTODOS.....	4
3.1 Localização e Caracterização da Área de Estudo .....	4
3.2 Obtenção das Imagens de Satélites .....	6
3.3 Processamento das imagens e cálculos dos Índices de Vegetação .....	6
3.4 Pré-processamento dos dados do sensor de produtividade .....	8
3.5 Amostragens .....	9
3.5.1 Correção e umidade do grão .....	9
3.5.2 Amostragens para estatística.....	10
3.6 Análise dos dados .....	10
4 RESULTADOS E DISCUSSÃO .....	11
CONCLUSÕES .....	16
REFERÊNCIAS BIBLIOGRÁFICAS .....	17
Anexo 1 – Correlação entre índices de vegetação e produtividade.....	20

## **1 INTRODUÇÃO E JUSTIFICATIVA, COM SÍNTESE DA BIBLIOGRAFIA FUNDAMENTAL**

No Brasil, a cultura do milho (*Zea mays* L.) está entre as mais cultivadas, tornando-a fundamental para o agronegócio nacional. Devido à sua alta produtividade, o grão se torna uma das principais *commodities* agrícolas do país e do mundo (CONAB, 2019). O destaque é a região Centro-Sul, com a maior concentração de produção do grão do país, representando 83% da produção nacional (CONAB,2020).

A produção de milho em território brasileiro encontra-se dividida em duas épocas de semeadura. Tradicionalmente temos os “plantios” de verão, ou comumente chamado de primeira safra, que ocorrem durante os períodos mais chuvosos, onde no Sudeste esses períodos são marcados entre os meses de outubro e novembro. Em decorrência do expressivo aumento de produção, o milho que antes era chamado de “safrinha”, passou a ser chamado de milho de segunda safra. Geralmente, a nomenclatura “safrinha” se dá ao milho semeado em locais de sequeiro durante os meses de fevereiro ou março, após a colheita de soja, que é predominante no Centro-Sul do Brasil (EMBRAPA, 2015).

Realizar ou ter uma previsão da estimativa de produção de cultura no setor do agronegócio, faz-se necessário para a melhor gestão dos produtos agrícolas. Tal ação pode garantir a demanda de suprimento, capacidade de transporte e armazenamento, além de auxiliar na comercialização de safras anteriores à colheita (BERTOLIN et al., 2017). Na atualidade, as estimativas de produção são dadas através de órgãos oficiais como o Instituto Brasileiro de Geografia e Estatística - IBGE e Companhia Nacional de Abastecimento - CONAB (ROSA et al., 2010; BERTOLIN et al., 2017). Esses órgãos se baseiam em métodos de modelos estatísticos, entrevista subjetiva com produtores, acompanhamento agrometeorológico e análise de produção de safras anteriores (CONAB, 2016).

Com o avanço da tecnologia no setor agrícola, são notórias as melhorias de informações de produtividades a partir do momento em que as colhedoras conseguem reproduzir uma alta densidade de dados, o chamado mapa de colheita, que é um dos conjuntos de dados mais completos para se visualizar a variabilidade espacial e temporal da produção (MOLIN, 2002).

Várias ferramentas tecnológicas que são usadas levam em consideração a variabilidade espacial de atributos que estão ligados à produção de grão na agricultura de precisão. O uso de colhedoras com sensores de produtividade e GNSS acoplados é um exemplo de ferramenta, os pontos gerados são georreferenciados e mostram a quantidade de grãos obtidos naquela posição, demonstrando depois de processados a variabilidade espacial daquela área. Através do mapeamento da colheita é possível localizar áreas com diferentes potenciais de produtividades,

visto que uma área nunca apresenta dados uniformes. O conjunto de sensores presente na colhedora geram um resumo da produtividade do local, posto que estes quantificam massa, umidade e volume dos grãos quando colhidos (MOLIN, 2000).

Com a ampla concorrência em produtividade do grão de milho, tanto pelo mercado mundial como entre produtores, os avanços em pesquisas para métodos de predição de produtividade têm ganhado grande espaço na área de agricultura de precisão. O uso das ferramentas tecnológicas fornece análises adequadas de dados sobre o plantio, crescimento e colheita da cultura, possibilitando a atuação de mecanismos capazes de otimizar o uso de recursos naturais (CHINO, et, al. 2010).

Além do uso dos mapas de colheita, uma das ferramentas comumente utilizadas na Agricultura de Precisão, é o sensoriamento remoto, no qual se baseia na coleta de dados para análise espacial dentro do campo, sem ter contato com o alvo. Com o seu uso é possível obter dados de grandes extensões territoriais, com a possibilidade de realização de várias repetitividades ao longo do ciclo das culturas, criando um histórico da área ou avaliação temporal (OLDONI et al. 2013).

Técnicas presentes no sensoriamento remoto, como o uso de índices de vegetação, possibilitam coletar dados da superfície terrestre a partir de sinais do espectro eletromagnético. Isso ocorre devido a interação das bandas espectrais disponibilizadas nos sensores orbitais, que associa-se à atributos de campo, e que auxiliam no monitoramento agrícola (TURCATTO, & ZANDONAD 2018).

Entre diversos índices de vegetação existentes, pode-se citar dois que são utilizados na agricultura. Primeiro, o Índice de Vegetação por Diferença Normalizada (NDVI – do inglês *Normalized Difference Vegetation Index*), utilizado para avaliação das mudanças do vigor vegetativo das plantas e correlação com outros parâmetros como o índice de área foliar, a biomassa ou a produtividade da vegetação (GALVANIN, et al., 2014). E o Índice de Vegetação por Diferença Normalizada na Banda *Red-Edge* (NDRE – do inglês *Normalized Difference Red-Edge*). Este segundo índice é indicado para vegetação estabelecida e em maturidade fisiológica (BARNES et al., 2000). Esses índices permitem avaliar o vigor vegetativo de determinada vegetação ou cultura, bem como identificar e diferenciar áreas com vegetação e sem cobertura vegetal (LIMA, et al., 2013).

Para gerar os índices de vegetação são necessárias imagens multiespectrais geradas por sensores óticos. Os sensores mais comumente utilizados no sensoriamento remoto são aqueles transportados por satélites orbitais. O acesso às imagens multiespectrais pode ser feito

gratuitamente por meio de plataformas digitais, como *Land Viewer – Earth Observing System* como é o caso do sensor *Multi Spectral Imager* a bordo do satélite Sentinel 2.

As imagens multiespectrais fornecidas pelo satélite *Sentinel-2*, possibilitam o cálculo de vários índices de vegetação (FEIO, 2017). Dentre as 13 bandas espectrais disponíveis do sensor, três são utilizadas para a resolução das equações dos índices de NDVI e NDRE. Sendo essas bandas a do vermelho (~670 nm - banda 04), infravermelho próximo (~760 nm - banda 08) e *red edge* (~720 nm - banda 05).

A aplicação de uso de imagens de satélites junto com índice de vegetação, já vem sendo estudado por diversos autores e empregado constantemente no monitoramento agrícola. O objetivo de auxiliar na otimização da avaliação e detecção de parâmetros biofísicos das plantas com os diferentes comprimentos de ondas (PEREIRA et al., 2016).

Turcatto & Zandonadi (2018) utilizou dados de campo para calibrar NDVI de Landsat, obtendo valores 0,78 de coeficiente de correlação entre NDVI e mapa de produtividade. Bertolin (2017) obteve um valor de coeficiente de determinação ( $R^2$ ) de 0,81 para NDVI através de imagens do Landsat 8, para a estimativa de produtividade de milho irrigado. A ampliação desses estudos contribui para que as técnicas fiquem cada vez mais acessíveis aos interessados proporcionando obter mais informações úteis para o setor agrícola (SCHWALBERT, et al 2019).

Dado que previsão de safra é essencial para um bom planejamento agrícola e que existem diversas técnicas de amostragem e previsão de safra, este trabalho buscou avaliar métodos de estimativa de produtividade da cultura do milho de segunda safra, de uma propriedade na região Sudoeste Paulista, relacionando dados de produtividade extraídos do sensor da colhedora com dois índices de vegetação (NDVI e NDRE) oriundos do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS) do satélite Sentinel-2 multitemporais.

Os resultados deste estudo possibilitam determinar através de uma regressão linear, o melhor momento e índice de vegetação para prever produtividade de milho de segunda safra diante das condições da região e disponibilidade de material e informação do proprietário.

## **2 OBJETIVOS**

O objetivo geral do trabalho consiste em prever a produção de milho de segunda safra utilizando o NDVI e o NDRE multitemporais oriundos do Sentinel 2, comparado aos valores obtidos pelo sensor de produtividade instalado na colhedora.

Os objetivos específicos do estudo consistem em:

- Comparar o poder de predição da produção do milho através de índices de vegetação (NDVI e NDRE);
- Comparar diferentes datas de aquisição dos índices, entre plantio e colheita;

### 3 MATERIAL E MÉTODOS

#### 3.1 Localização e Caracterização da Área de Estudo

A área de estudo situa-se no município de Capão Bonito, no Sudoeste do Estado de São Paulo, nas coordenadas latitude 48°15'4" Sul e longitude 24°2'23" Oeste. Ela possui uma área total de 19 ha destinada aos cultivos de milho de primeira e segunda safra, soja e trigo durante o calendário agrícola (Figura 2).

A região onde se situa Capão Bonito é caracterizada por se concentrar os maiores produtores de grãos e cereais de inverno do estado de São Paulo. O município possui foco no desenvolvimento do agronegócio de pequenos, médios e grandes produtores diante da característica agroecológicas e sócio culturais que o local apresenta.

Segundo Alvares et al (2013), no local predomina-se o clima Subtropical Úmido (classificação climática de *Köppen-geiger*: Cfa), sendo quente e úmido durante o verão. A pluviosidade é distribuída durante o ano, mesmo nos meses mais secos ainda há pluviosidade (entre maio e agosto), com uma média anual de 1.184 mm e com uma temperatura média anual 19,9°C.

A área conta também com solo do tipo Latossolo Vermelho Distoférrico, que apresenta um tom de vermelho acentuado e de baixa fertilidade e altos teores de ferro, o que caracteriza o seu terceiro nível categórico do SiBCS (Sistema Brasileiro de Classificação de Solos) (EMBRAPA, 1999).

No momento do estudo, a área estava cultivada com milho de segunda safra da cultivar AG 9000 Pro3 da Sementes Agrocerees (Figura 1, sob palhada de soja, cultura que antecede. A semeadura ocorreu no dia 04 de março de 2020 e a colheita foi no dia 16 de setembro de 2020. A semeadora foi regulada para a distribuição de 30 mil plantas/ha. Na colheita, utilizou-se uma colhedora John Deere S660 com sensor de produtividade modelo G2, devidamente calibrado.



Figura 1: Espiga de milho da cultivar AG 9000 Pro 3 da área de estudo




Figura 2: Localização da área de estudo, no município de Capão Bonito -SP



### 3.2 Obtenção das Imagens de Satélites

As imagens orbitais foram obtidas a partir do sensor MSI - *Sentinel 2*, que possui um campo de visada de 290Km, resolução temporal de cinco dias na linha do equador e conta com 13 bandas com resolução radiométrica de 12 bits, sendo quatro delas com 10 metros de resolução espacial, seis com 20 metros e três com 60 metros, de acordo com a banda (VAN DER MEER et al., 2014).

A aquisição das imagens MSI foi realizada de forma gratuita pelo site *Land Viewer - EOS (Earth Observing System)*, onde estão disponibilizados os produtos nível 2A, ou seja, imagens ortorretificadas e com correção atmosférica, prontas para as análises.

Foram selecionadas todas as imagens disponíveis e ausentes de nuvens no período entre semeadura e colheita. No total obteve-se 15 datas com imagens (Tabela 1), de onde extraiu-se as bandas 04 (red), 05 (*red edge*) e 08 (*near infrared*) do sensor MSI.

Tabela 1: Data de aquisição das imagens

Nº	Data
1	15/03/2020
2	29/04/2020
3	09/05/2020
4	29/05/2020
5	13/06/2020
6	18/06/2020
7	13/07/2020
8	18/07/2020
9	23/07/2020
10	28/07/2020
11	07/08/2020
12	12/08/2020
13	27/08/2020
14	06/09/2020
15	16/09/2020

### 3.3 Processamento das imagens e cálculos dos Índices de Vegetação

As imagens foram processadas no *software* de distribuição livre QGIS 3.10 LAS PALMAS (GRASSGIS 7.8).

O NDVI de forma simplificada se baseia na relação de medidas espectrais das bandas do infravermelho próximo e do vermelho. Estes comprimentos de ondas eletromagnéticas interagem com as plantas, diminuindo a forma interferências do solo na resposta da vegetação.

O NDVI está correlacionado com a área foliar e a biomassa da vegetação, de acordo com o seu ciclo fenológico da cultura (PONZONI et, al. 2012; OLDONI et, al. 2013). Seu cálculo é expresso conforme a seguinte equação (Equação 1).

$$\text{NDVI} = (\text{IVP} - \text{V}) / (\text{IVP} + \text{V}) \quad (1)$$

Onde:

IVP: Banda Infravermelho próximo

V: Banda do vermelho

No sensor MSI -*Sentinel* – 2A, os comprimentos de ondas IVP e V são dados pelas refletâncias das bandas B08 e B04 respectivamente, ambas com resolução espacial de 10m.

O NDRE consistiu-se na combinação de duas frequências distintas de radiação eletromagnética, sendo normalizada pela divisão da soma das faixas de forte absorção de luz Red-Edge (~720 nm) e a banda altamente reflexiva do infravermelho próximo (~760 nm).

Segundo Barnes et al. (2000) e Rodriguez et al. (2006), o *Red-Edge* se modifica ligeiramente mais longo com o aumento do teor de clorofila, ou seja, conforme uma folha apresenta maior quantia de clorofila, maior se torna o comprimento de onda *Red-Edge*. O cálculo desse índice se expressa na seguinte equação (Equação 2).

$$\text{NDRE} = (\text{IVP} - \text{RE}) / (\text{IVP} + \text{RE}) \quad (2)$$

Onde:

IVP: Banda Infravermelho próximo

RE: Banda *Red-Edge*

Esses comprimentos de ondas IVP e RE são representadas no *Sentinel* – 2A, pelas refletâncias das bandas B08 e B05 respectivamente. A B08 possui uma resolução espacial de 10m enquanto a B05 é de 20m, a qual foi reamostrada para 10m utilizando a ferramenta *Sample* no Qgis.

### 3.4 Pré-processamento dos dados do sensor de produtividade

Os dados brutos de produtividade de milho foram obtidos a partir do sistema de monitoramento embarcado na colhedora do modelo John Deere S660, dotada de um sensor de marca modelo G2 e plataforma de 8,50m (Figura 3). A calibração e demais operações de ajustes foram feitas previamente pelo operador da máquina. A colheita da área foi realizada no dia 16 de setembro de 2020, trafegando a uma velocidade média de 5,0 Km/h, onde o sensor de umidade registrou em média 21,4% de umidade dos grãos.



Figura 3: Funcionários da fazenda que realizaram a colheita

Após o fim da colheita, os dados de produtividade foram coletados para que pudessem ser manipulados no computador. O arquivo exportado em *shapefile* armazena uma tabela de atributos, que relaciona a posição geográfica da colhedora a cada 1 segundo, com os atributos de produtividade como massa úmida e informações como velocidade da máquina e elevação do terreno.

Por ser um processo automático e de grande quantidade de dados, a introdução de alguns dados inconsistentes pode ocorrer. Para tanto, foi realizada uma filtragem de valores de *outliers*, onde a sua remoção pode ser feita de forma simples (TAYLOR et al. 2007).

Para a remoção dos outliers utilizou-se o *software* MapFilter 2.0, que é uma ferramenta usada para realizar a identificação e remoção em um conjunto de dados de alta densidade. Durante a filtragem, o *software* remove pontos que estão fora de um limite superior e inferior a

partir dos parâmetros da população em estudo e um limite de variação escolhido pelo usuário (MALDANER, 2017).

O primeiro passo para a remoção dos *outliers* é a filtragem global que remove os pontos cujo valores estão fora do limite superior e do limite inferior estabelecido, sendo neste caso utilizado o valor de 110%, conforme proposto por Maldaner (2017). Em seguida é realizada a filtragem local que seleciona todos os pontos que estão na mesma fileira e calcula-se a mediana, e a partir dessa mediana são calculados os limites superiores e inferiores, sendo usado os valores de 40 e 10% respectivamente, conforme proposto por Maldaner (2017). Esses valores de porcentagem são escolhidos de acordo com o valor de CV (%) que o *software* nos mostra. Ou seja, após a filtragem dos dados é realizada uma comparação dos dados originais e dos dados depois de filtrado, se o valor colocado diminuir o CV (%) melhor será a representatividade dos dados.

### 3.5 Amostragens

#### 3.5.1 Correção e umidade do grão

Através da delimitação da área usou-se um *buffer* de 10m para dentro da área com a finalidade de eliminar o efeito de borda da cultura. Esse efeito é ocasionado através de mudanças de fatores climáticos ambientais que interferem de forma direta no desenvolvimento da planta, fazendo com que parte da população apresenta distribuição desuniforme.

Nos dados de colheita o peso dos grãos vem com a umidade presente naquele momento, no entanto nem sempre é a umidade ideal de colheita. No caso do milho a granel, o armazenamento após a colheita na propriedade ou em armazéns, os grãos deverão ter no máximo 13% de umidade. Como os grãos no dia da colheita apresentaram valores superiores a 13% realizou-se uma correção para apresentar a real quantificação da produção atual (NUNES & BACKES, 2021).

Para isso usou-se uma fórmula pré-definida para grãos ou sementes que possibilita estimativa do peso de grãos de qualquer umidade para 13% ou outra umidade desejada, conforme a Equação 3.

$$\text{Peso corrigido para Ud\%} = \text{Peso úmido} \times \frac{100 - \text{Umidade Atual}}{100 - \text{Ud\%}} \quad (3)$$

Onde:

Ud% = Umidade desejada

Peso Úmido = Umidade Atual

A prática de correção da umidade dos grãos ou sementes pode resultar em redução da produção em comparação aos valores observados em campo no momento da colheita. Por conta disso, é costume que passem pela secadora para atingir essa umidade desejada.

### **3.5.2 Amostragens para estatística**

Os pixels das imagens de satélite foram convertidos em polígonos (arquivos vetoriais) através da ferramenta *r.to.vect*, onde gerou um total de 1.927 células de 100m<sup>2</sup>. Como são 2 índices avaliados com 15 imagens cada, e para não ter que repetir o processo 30 vezes, utilizou-se uma ferramenta *Add raster values to features*. Dessa forma, todos os valores médios dos índices ficaram em um único arquivo vetorial de grade amostral. Os valores pontuais de produtividade contidos dentro de cada célula também foram atribuídos ao arquivo vetorial através de uma média.

Dessa forma todos os dados foram associados espacialmente em um único arquivo vetorial. Por fim, converteu-se os atributos em uma planilha de excel, para facilitar o processamento dos dados na estatística.

Na estatística descritiva para cada data de imagem disponível avaliada, realizou-se uma análise de regressão linear entre os períodos foram realizadas levando em consideração os valores médios de pixel a pixel, entre a produtividade e os Índices de Vegetação, além da média, mediana, mínimo, máximo, desvio padrão e coeficiente de variação dos valores de NDVI e NDRE por período avaliado.

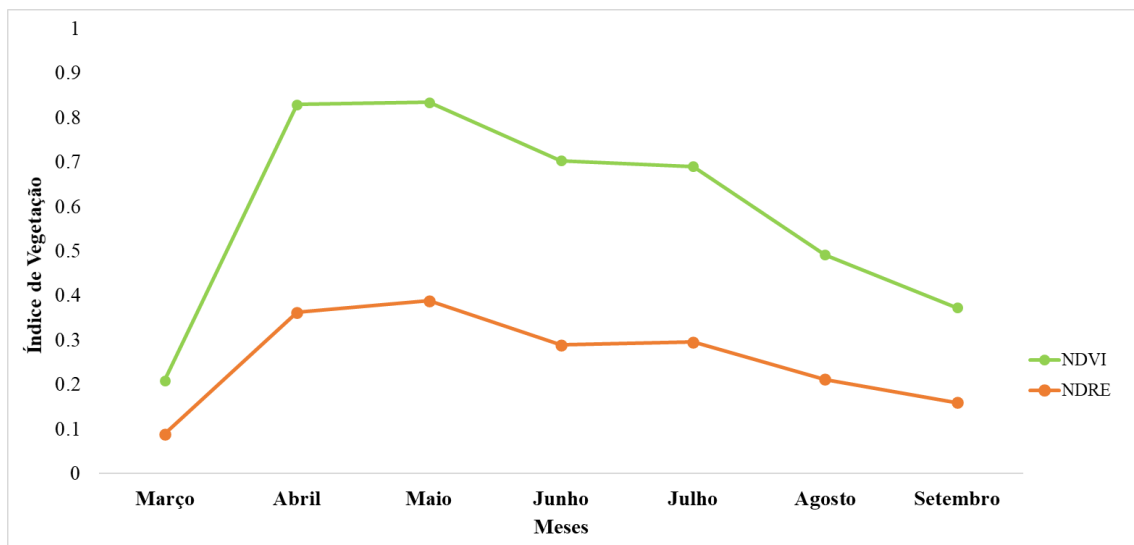
### **3.6 Análise dos dados**

Todas as análises dos dados foram realizadas com os valores médios de produção de milho extraídos por meio da grade amostral de 10x10m. As médias de produção foram correlacionadas com os respectivos valores dos índices de vegetação em diferentes datas a fim de possibilitar a predição da produção por meio da regressão linear.

## 4 RESULTADOS E DISCUSSÃO

Através da análise temporal dos índices de vegetação das imagens de satélite disponíveis dentro do período de semeadura e colheita, nota-se que há um comportamento semelhante entre os dois índices diferenciando apenas os valores. Essa diferença se dá devido ao uso de bandas diferentes nos cálculos (Gráfico 1).

Gráfico 1: Análise temporal dos índices de vegetação



Como pode-se observar o índice de vegetação com maior média foi o NDVI no período de 9 de maio de 2020, com 0,864, assim também como na mediana, no qual foi o período que obteve maior valor, com 0,883. O valor da máxima também foi observado no período de 9 de maio, com NDVI, com 0,927. Porém, a data e índice de vegetação que melhor apresentou o coeficiente de variação dentro da avaliação foi 13 de julho de 2021, com NDVI. O valor encontrado nesse período foi de 84,2%, o que representa uma alta dispersão e dados mais heterogêneos (Tabela 2).

Tabela 2: Estatística descritiva dos Índices de vegetação correspondente aos períodos avaliados

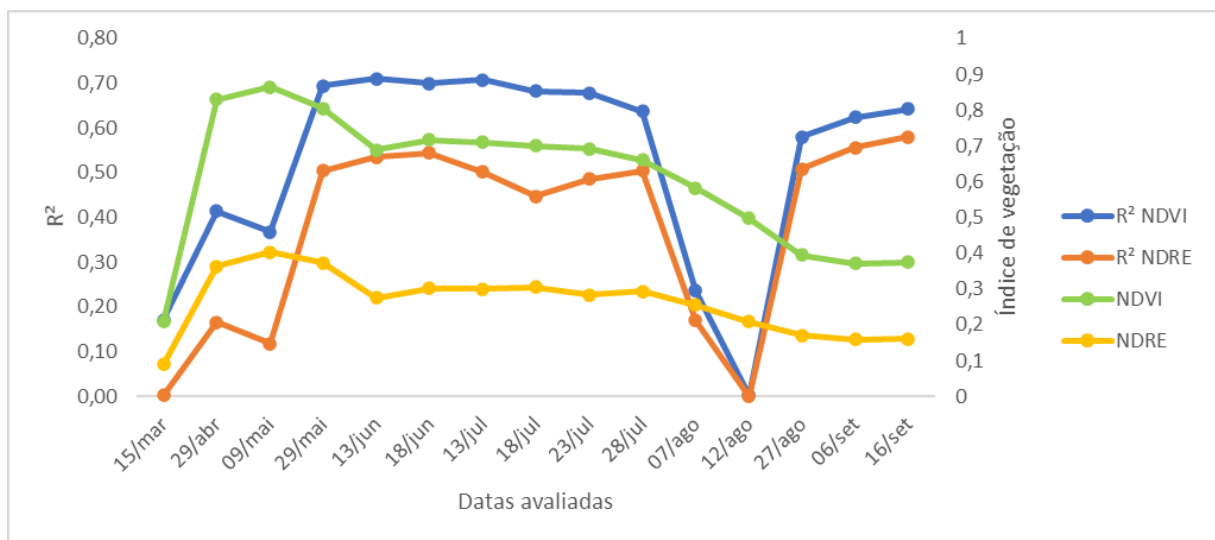
PERÍODO AVALIADO	Índice de Vegetação	R <sup>2</sup>	RES (%)	P-value	Coef. Pearson	Média	mediana	mínimo	máximo	desvio padrao	Coef. Variação
15/mar	NDVI	0.170	40.23	<2e-16*	-41.3%	0.209	0.204	0.166	0.469	0.027	-41%
	NDRE	0.002	44.13	0.0733**	4.2%	0.089	0.089	-0.019	0.261	0.017	0.042
29/abr	NDVI	0.414	33.82	<2e-16*	64.3%	0.829	0.850	0.533	0.898	0.055	0.643
	NDRE	0.166	40.34	<2e-16*	40.7%	0.362	0.374	0.035	0.549	0.051	0.407
09/mai	NDVI	0.367	35.14	<2e-16*	60.6%	0.864	0.883	0.554	0.927	0.050	0.606
	NDRE	0.117	41.50	<2e-16*	34.2%	0.404	0.417	-0.011	0.581	0.055	0.342
29/mai	NDVI	0.694	24.43	<2e-16*	83.3%	0.804	0.819	0.519	0.915	0.083	0.833
	NDRE	0.504	31.11	<2e-16*	71.0%	0.373	0.380	0.104	0.633	0.070	0.710
13/jun	NDVI	0.710	23.80	<2e-16*	84.2%	0.689	0.730	0.301	0.880	0.159	0.842
	NDRE	0.534	30.14	<2e-16*	73.1%	0.275	0.289	0.054	0.535	0.095	0.731
18/jun	NDVI	0.700	24.20	<2e-16*	83.7%	0.716	0.762	0.338	0.902	0.157	0.837
	NDRE	0.545	29.81	<2e-16*	73.8%	0.301	0.313	0.076	0.591	0.110	0.738
13/jul	NDVI	0.707	23.89	<2e-16*	84.1%	0.710	0.736	0.395	0.862	0.116	0.841
	NDRE	0.501	31.20	<2e-16*	70.8%	0.300	0.310	0.075	0.537	0.078	0.708
18/jul	NDVI	0.682	24.92	<2e-16*	82.6%	0.700	0.730	0.388	0.853	0.115	0.826
	NDRE	0.447	32.87	<2e-16*	66.8%	0.305	0.317	0.113	0.523	0.075	0.668
23/jul	NDVI	0.679	25.03	<2e-16*	82.4%	0.692	0.714	0.413	0.836	0.102	0.824
	NDRE	0.485	31.69	<2e-16*	69.7%	0.283	0.293	0.098	0.515	0.065	0.697
28/jul	NDVI	0.637	26.63	<2e-16*	79.8%	0.659	0.679	0.387	0.828	0.099	0.798
	NDRE	0.504	31.12	<2e-16*	71.0%	0.294	0.304	0.118	0.526	0.066	0.710
07/ago	NDVI	0.236	38.61	<2e-16*	48.6%	0.582	0.585	0.376	0.758	0.064	0.486
	NDRE	0.170	40.25	<2e-16*	41.2%	0.255	0.258	0.111	0.460	0.043	0.412
12/ago	NDVI	0.002	44.14	0.0898**	-4.0%	0.497	0.496	0.280	0.727	0.062	-0.040
	NDRE	0.000	44.18	0.884**	0.3%	0.209	0.206	0.038	0.421	0.038	0.003
27/ago	NDVI	0.580	28.63	<2e-16*	-76.2%	0.395	0.343	0.241	0.706	0.120	-0.762
	NDRE	0.509	30.96	<2e-16*	-71.3%	0.171	0.143	0.056	0.430	0.067	-0.713
06/set	NDVI	0.624	27.10	<2e-16*	-79.0%	0.371	0.317	0.188	0.739	0.145	-0.790
	NDRE	0.557	29.42	<2e-16*	-74.6%	0.159	0.129	0.051	0.415	0.073	-0.746
16/set	NDVI	0.642	26.44	<2e-16*	-80.1%	0.374	0.334	0.177	0.696	0.131	-0.801
	NDRE	0.580	28.63	<2e-16*	-76.2%	0.160	0.136	0.065	0.409	0.064	-0.762

Obs: Valores de regressão onde \* p-value < =0,05 são significativos; e \*\*p-value > 0,05 não significativos

Já o menor valor mínimo foi encontrado no período de 15 de março com NDRE, este valor se justifica visto que no período ainda tinha a presença de solo exposto. Posto que, ainda não tinha ocorrido a emergência completa das folhas fotossinteticamente ativas, que foram semeadas na data de 04/03/2021.

Com os dados obtidos nota-se um comportamento de  $R^2$  tanto de NDVI quanto de NDRE semelhantes, e que entre os índices de vegetação o NDVI apresenta um comportamento de correlação, a média do índice sobe quando  $R^2$  é maior (Gráfico 2).


Gráfico 2: Comportamento do  $R^2$  com a média dos Índices de vegetação



Entre as datas e índices de vegetação avaliados, o qual apresenta uma regressão mais satisfatória, comparado aos dados de produtividade, é o dia 13 de junho com o índice de vegetação NDVI. Para a melhor apresentação deste resultado, o Gráfico 3 abaixo mostra o comportamento dos pontos quando correlacionados. Os demais gráficos encontram-se no Anexo 1.



Gráfico 3: Melhor regressão linear entre índices de vegetação e produtividade



Em análise de regressão linear entre índice de vegetação e produtividade de grãos, um resultado similar foi observado por Araújo et al (2004), onde encontraram uma tendência de maior relação entre NDVI e a produtividade quando ocorre o maior coeficiente de variação através de videografia aérea multiespectral. Para os autores esse comportamento significa que a imagem se correlaciona de forma significativa quando há uma variabilidade entre os pixels.

Nos resultados obtidos através do estudo percebeu-se esse mesmo comportamento entre coeficiente de variação e NDVI, e o caso de repete entre o NDVI, assim como citado por Araújo et al (2004). Com isso nota-se que a produtividade obtida pela máquina apresenta uma correlação com os índices de vegetação.

Fernandes (2016), ao realizar um possível estimativa entre a produtividade de milho através de utilização de imagens de veículo aéreo não tripulado com base no NDVI, também observou uma regressão linear significativa através de  $R^2$ . Nesse caso o  $R^2$  foi de 0,75 entre o índice de vegetação NDVI e a produtividade de milho, resultado muito semelhante ao obtido.

Bertolin (2017) e Blosfeld (2018), por exemplo, observaram que quando a produtividade do milho estava baixa, os valores dos índices de vegetação avaliados, também se apresentavam baixos. Considerando dessa forma que os valores dos índices se correlacionam com os valores de produtividade.

Venancio et al (2019) concluíram que aos 100 dias após a semeadura (DAS) de milho o NDVI apresenta uma alta relação de forma positiva com a produtividade de milho, notando que quanto maior o índice de vegetação maior a produtividade. O que também foi observado no resultado do experimento, a data que apresentou o melhor índice de vegetação foi o NDVI de

13/06/2020 e considerando a data de plantio de 04/03/2020, o intervalo desse período foi de exatamente 100 DAS. No entanto é difícil afirmar que sempre após os 100 DAS irá se obter a melhor correlação, devido à disponibilidade de imagens e fatores agronômicos da cultura,

Em outras culturas também se têm testados novas metodologias para estimar produtividade. Oliveira (2019), por exemplo, utilizou imagens do *Sentinel – 2*, na predição da produtividade na de algodão, demonstrando que é possível o uso índice de vegetação na estimativa de produção.

No entanto, nos estudos realizados por Sharma et al (2015) e Blosfeld (2018), através do *Crop Circle* e *Sentinel-2A* respectivamente, utilizaram NDVI e NDRE correlacionados com produtividade. O resultado observado por ambos os autores apresentou o índice de vegetação NDRE como mais significativo nos últimos estágios de crescimento vegetativo do milho. No entanto, nos primeiros estágios do milho, os índices de vegetação NDVI e NDRE se mostraram semelhantes.

Para Oliveira (2017), a predição de produtividade da cultura de milho por índice de vegetação apesar de muitas vezes ela correlacionar com a produtividade, ela pode ser um pouco complexa, pois o milho é cultivado sob espaçamentos e populações de plantas diferentes, fazendo com o que não se tenha um modelo único de predição de produtividade através de índice de vegetação.

Por isso, em alguns casos o NDVI se correlaciona melhor com a produtividade quando comparado com NDRE. Pois o NDVI é um índice que muitas vezes está associado a variáveis agronômicas, por exemplo, a produtividade, que está diretamente ligado ao espaçamento entre plantas. Já o NDRE por ter a banda do Red-Edge, que é baixa onde se dá a maior absorção de clorofila está mais associada a plantas mais saudáveis, que são as que apresentam maior clorofila o que pode estar relacionado com a sua captação de nitrogênio e a demanda de fertilizantes.

E A melhor regressão linear de NDVI com a produtividade pode-se observada no NDVI de 13/06/2020 na Figura 4, onde marcas no talhão são visivelmente significativas, desta forma mostrando a elevada relação entre os índices e a produtividade (Figura 5).




Figura 4: Índice de Vegetação NDVI que apresentou a melhor correlação

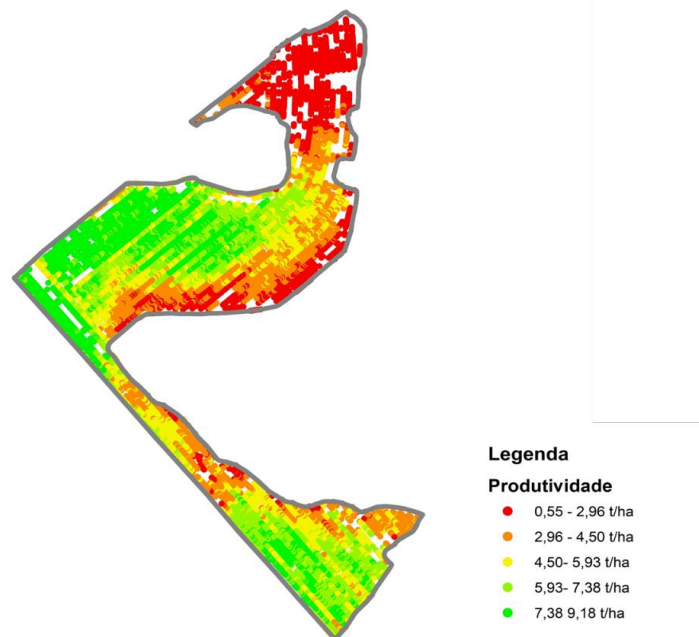


Figura 5: Mapa de produtividade com os dados filtrados

Nota-se que há uma semelhança espacial entre o mapa de NDVI e o mapa de produtividade. Mas para verificar a correlação entre eles é necessário realizar uma análise estatística entre todas as imagens e verificar qual a apresenta a melhor correlação. Podendo ser realizado para novos trabalhos de pesquisa.

## CONCLUSÕES

Os índices de vegetação NDVI e NDRE apresentaram uma relação com os dados de produtividades. No entanto, nesse estudo observou-se que a regressão linear mais significativa foi com NDVI na data de 13 de junho de 2020, o que corresponde a 100 após a semeadura, corroborando com outros autores. O NDRE apresenta melhor regressão linear nessa mesma data de 13 de junho de 2020. No entanto, quando comparado entre os dois índices de vegetação nesta data o NDVI apresenta-se melhor.

O uso de recursos gratuitos para a obtenção e processamento das imagens para a realização dos valores de NDVI e NDRE e processamento dos dados da máquina, apresentou excelentes condições para a geração de mapas de produtividade e avaliações de índices de vegetação. A utilização dessas ferramentas faz com que produtores possam ter acesso à predição de produtividade da sua lavoura, podendo inferir sobre as melhores condições de manejo das suas áreas e da sua variabilidade espacial.

O uso das técnicas de SR, com índices de vegetação podem auxiliar os produtores em um planejamento de produtividade e tomadas de decisões sobre os manejos agronômicos mais sustentáveis. Dessa forma proporcionar o monitoramento da produtividade de milho antes da colheita, oferece ao produtor facilidade na obtenção de dados, menor custo, avaliações e características espaciais em um menor tempo.

## REFERÊNCIAS BIBLIOGRÁFICAS


- ALVARES, C. A. et al. Koppen's climate classification map for Brazil. *Meteorologische Zeitschrift* Vol. 22 No. 6 (2013), p. 711 - 728. published: Dec 1, 2013.
- ARAÚJO, J. C.; VETTORAZZI, C. A.; MOLIN, J. P.. Estimativa da produtividade e determinação de zonas de manejo, em culturas de grãos, por meio de videografia aérea multiespectral. *Acta Scientiarum. Agronomy*. v. 27. p. 437-447. 2004.
- BARNES, E. M. et al. Coincident detection of crop wáter stress, nitrogen status and canopy density using ground-based multispectral data. In: *International Conference On Precision Agriculture, 2000*, Bloomington. Madison: ASA: CSSA: SSSA, 2000.
- BERTOLIN, Natalia et al. Predição da produtividade de milho irrigado com auxílio de imagens de satélite. *Revista Brasileira de Agricultura Irrigada*, v. 11, n. 4, p. 1627, 2017.
- BLOSFELD, Letycia Hass et al. Correlação linear entre os índices de vegetação NDVI e NDRE com a produtividade do milho segunda safra. 2019.
- CHINO, D. Y. T.; ROMANI, L. A. S.; TRAINA, A. J. M.. *Construindo Séries Temporais de Imagens de Satélite para Sumarização de Dados Climáticos e Monitoramento de Safras Agrícolas*. 2010.
- CONAB - Companhia Nacional de Abastecimento, Acompanhamento da safra brasileira de grãos | v. 8 – safra 2020/21, n. 1 – primeiro levantamento | outubro de 2020, p 15.
- CONAB - Companhia Nacional de Abastecimento, Perspectivas para a agropecuária. Vol. 7 – Safra 2019/2020, p. 79.
- CONAB - Companhia Nacional de Abastecimento. Acompanhamento de safra brasileira: Grãos – Safra 2016/2017, Primeiro levantamento Outubro/2016 - Companhia Nacional de Abastecimento. - Brasília: Conab Brasília, v. 4. p. 1-164.
- CONGEDO, L. Semi-Automatic Classification Plugin Documentation, Release 4.8.0.1. 2016. User Manual doc. for QuantumGIS.
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. *Sistema Brasileiro de Classificação de Solos*. 1999. 412p
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA MILHO E SORGO. *Sistema de Produção*, 1 ISSN 1679-012X, 2015.
- FEIO, S. V. M. Análise Multitemporal de imagem de satélite Sentinel-2 como suporte à elegibilidade das ajudas comunitárias agrícolas. *Dissertação (Mestrado em Engenharia Geográfica, Geofísica e Energia)*. Universidade de Lisboa, Lisboa Portugal, 2017.
- FERNANDES, Pablo. *CORN YIELD ESTIMATES ZEA MAYS L.) THROUGH IMAGES OBTAINED BY MANNED AERIAL VEHICLE*. 2016. 79 f. *Dissertação (Mestrado em Agronomia)* - Universidade Federal de Santa Maria, Santa Maria, 2016.
- GALVANIN, E. A. S.; NEVES, S. M. A. S.; CRUZ, C. B. M.; NEVES, R. J.; JESUS, P. H. H.; KREITLOW, J. P. Avaliação dos índices de vegetação NDVI, SR e TVI na discriminação de fitofisionomias dos ambientes do Pantanal de Cáceres/MT. *Ciência Florestal*, Santa Maria, v. 24, n. 3, p. 707-715, 2014.
- LIMA, G. C.; SILVA, M. L. N.; CURI, N.; SILVA, M. A.; OLIVEIRA, A. H.; AVANZI, J. C.; UMMUS, M. E. Avaliação da cobertura vegetal pelo índice de vegetação por diferença normalizada (IVDN). *Ambi-Água*, Taubaté, v. 8, n. 2, p. 204-214, 2013.

- MALDANER, Leonardo Felipe. **Processamento de dados de monitores de produtividade de cana-de-açúcar**. Tese de Doutorado. Universidade de São Paulo, 2017.
- MOLIN, J. P. Definição de unidades de manejo a partir de mapas de produtividade. *Engenharia Agrícola*, v.22, n.1, p.83-92, 2002.
- MOLIN, J. P. Geração e interpretação de mapas de produtividade para agricultura de precisão. In: Borém, A.; Giúdice, M. P.; Queiroz, D. M.; Mantovani, E. C.; Ferreira, L. R.; Valle, F. X. R.; Gomide, R. L. (Orgs.). *Agricultura de Precisão*. Viçosa: Universidade Federal de Viçosa, 2000. p.237-258
- NUNES, U. R.; BACKES, R. L. B. DETERMINAÇÃO DO GRAU DE UMIDADE E PESO DE MIL SEMENTES. Universidade Federal de Santa Maria, Departamento de Fitotecnia, Curso de Agronomia, Produção e Tecnologia de Sementes, 2021
- OLDONI, L. V.; PRUDENTE, V. H. R.; MERCANTE, E.; LIMA, P. H. P.; JUSTINA, D. D. D.; Wrublack, S. C.; Lima, L. E. P. Acompanhamento da cultura da soja através do índice de vegetação NDVI para 35 municípios localizados no oeste do Paraná. In: *Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*, 2013, Foz do Iguaçu. Anais... Foz do Iguaçu.
- OLIVEIRA, M. F de. Modelos de predição de produtividade da cultura do milho por meio de NDVI em arranjos espaciais. Universidade Estadual Paulista – UNESP *Câmpus* de Jaboticabal, 2017.
- OLIVEIRA, R. F. Estimativa da produtividade do algodoeiro a partir de índices de vegetação derivados de imagens orbitais de alta resolução espacial. 2019. Dissertação de mestrado – Universidade Federal do Rio Grande do Sul. Porto Alegre, 2019.
- PONZONI, J. SHIMABUKURO, Y. E. KUPLICH, T.M. *Sensoriamento Remoto da Vegetação*. 2. ed. atual. ampl. São Paulo - Oficina de Textos, 2012
- RODRIGUEZ, D.; FITZGERALD, G. J.; BELEFORD, R.; CHRISTENSEN, L. Detection of nitrogen deficiency in wheat from spectral reflectance indices and basic crop eco-biophysiological concepts. *Australian Journal of Agricultura Research*, v.57, n7. p. 781-89. 2006.
- ROSA, V. G. C. da; MOREIRA, M. A.; RUDOFF, B. F. T.; ADAMI, M. Estimativa da produtividade de café com base em um modelo agrometeorológico-espectral. *Pesquisa Agropecuária Brasileira*, Brasília, v. 24, n. 12, p.1478-1488, dez. 2010.
- SCHWALBERT, Raí Augusto et al. **Imagens de satélite para predição espaço-temporal da produtividade de milho e soja em diferentes escalas geográficas**. 2019. Tese de Doutorado. Universidade Federal de Santa Maria
- SECO, M.A.P.O. Comportamento espectral de plantas como ferramenta de determinação metodológica para monitoramento de espécies invasoras. Tese de doutorado. UEM, Maringá, 2017.
- SHARMA, L.K.; Bu, H.; DENTON, A.; FRANZEN, D.W. Active-optical sensors using red NDVI compared to red edge NDVI for Prediction of corn grain yield in North Dakota, USA. *Sensors* 2015, v. 15, p. 27832–27853.
- TAYLOR, J. A., MCBRATNEY, A. B., & WHELAN, B. M. Establishing management classes for broad acre agricultural production. *Agronomy Journal*, 2007
- TURCATTO, L. M., ZANDONAD, R. S. Variabilidade da produtividade e a relação com padrões de NDVI obtidos com imagens do landsat8. 1º SIMPÓSIO Mato-Grossense De Mecanização Agrícola e Agricultura De Precisão – SIMAP UFMT, CAMPUS UNIVERSITÁRIO DE SINOP, 2018.
- VAN DER MEER, F. D.; VAN DER WERFF, H. M. A.; VAN RUITENBEEK, F. J. A. Potential of ESA's Sentinel-2 for geological applications. *Remote Sensing of Environment*, v. 148, p. 124–133, 2014.

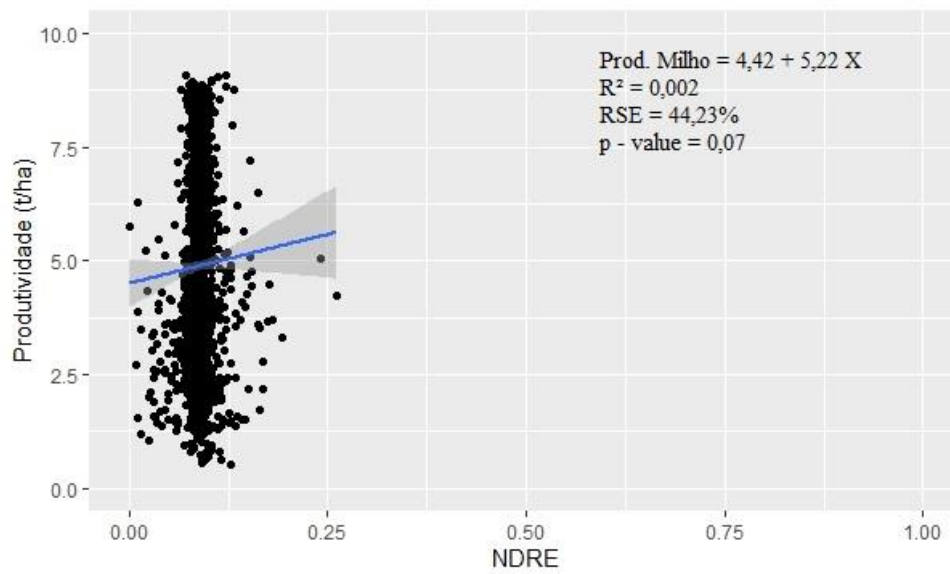
VENANCIO, L. P., *et al.* Biomassa e produtividade de grãos na cultura do milho irrigado por meio do NDVI acumulado. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto ISBN: 978-85-17-00097-3. Vol 19, 2019 – 96307

**ANEXO 1 – CORRELAÇÃO ENTRE ÍNDICES DE VEGETAÇÃO E PRODUTIVIDADE**

## 1) Produtividade x NDVI– 15 de março de 2020




## 2) Produtividade x NDRE– 15 de março de 2020







## 3) Produtividade x NDVI – 29 de abril de 2020




## 4) Produtividade x NDRE – 29 de abril de 2020




## 5) Produtividade x NDVI – 09 maio de 2020




## 6) Produtividade x NDRE – 09 maio de 2020




## 7) Produtividade x NDVI – 29 maio de 2020




## 8) Produtividade x NDRE – 29 maio de 2020




## 9) Produtividade x NDVI– 13 de junho de 2020




## 10) Produtividade x NDRE – 13 de junho de 2020




## 11) Produtividade x NDVI – 18 de junho de 2020




## 12) Produtividade x NDRE – 18 de junho de 2020




## 13) Produtividade x NDVI – 13 de julho de 2020




## 14) Produtividade x NDRE – 13 de julho de 2020




## 15) Produtividade x NDVI – 18 de julho de 2020




## 16) Produtividade x NDRE – 18 de julho de 2020



## 17) Produtividade x NDVI – 23 de julho de 2020




## 18) Produtividade x NDRE – 23 de julho de 2020







## 19) Produtividade x NDVI – 28 de julho de 2020




## 20) Produtividade x NDRE – 28 de julho de 2020




## 21) Produtividade x NDVI – 7 de agosto de 2020




## 22) Produtividade x NDRE – 7 de agosto de 2020




## 23) Produtividade x NDVI – 12 de agosto de 2020




## 24) Produtividade x NDRE – 12 de agosto de 2020




## 25) Produtividade x NDVI – 27 de agosto de 2020




## 26) Produtividade x NDRE – 27 de agosto de 2020




27) Produtividade x NDVI – 6 de setembro de 2020



28) Produtividade x NDRE – 6 de setembro de 2020



## 29) Produtividade x NDVI – 16 de setembro de 2020



## 30) Produtividade x NDRE – 16 de setembro de 2020

