

UNIVERSIDADE FEDERAL DA GRANDE DOURADOS

**PRODUTIVIDADE DO MILHO POR MEIO DA
AVALIAÇÃO ESPACIAL-TEMPORAL DE IMAGENS
ORBITAIS**

Hermano José Ribeiro Henriques

**DOURADOS
MATO GROSSO DO SUL
2021**

**PRODUTIVIDADE DO MILHO POR MEIO DA
AVALIAÇÃO ESPACIAL-TEMPORAL DE IMAGENS
ORBITAIS**

Me Hermano José Ribeiro Henriques

Engenheiro Agrônomo

ORIENTADOR: Prof. Dr. Jorge Wilson Cortez

COORIENTADORA: Prof. Dr.^a Vanessa Jordão Marcato Fernandes

Tese apresentada à Universidade Federal da Grande Dourados, como parte das exigências do Programa de Pós-Graduação em Agronomia, para obtenção do título de Doutor.

Dourados
Mato Grosso do Sul
2021

Dados Internacionais de Catalogação na Publicação (CIP).

H519p Henriques, Hermano Jose Ribeiro
Produtividade do milho por meio da avaliação espacial temporal de imagens orbitais [recurso eletrônico] / Hermano Jose Ribeiro Henriques. -- 2021.
Arquivo em formato pdf.

Orientador: Jorge Wilson Cortez.
Coorientadora: Vanessa Jordão Marcato Fernandes.
Tese (Doutorado em Agronomia)-Universidade Federal da Grande Dourados, 2021.
Disponível no Repositório Institucional da UFGD em:
<https://portal.ufgd.edu.br/setor/biblioteca/repositorio>

1. agricultura de precisão. 2. comprimentos de ondas. 3. índices de vegetação. 4. satélites. I. Cortez, Jorge Wilson. II. Fernandes, Vanessa Jordão Marcato. III. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

©Direitos reservados. Permitido a reprodução parcial desde que citada a fonte.

**PRODUTIVIDADE DO MILHO POR MEIO DE AVALIAÇÃO ESPACIAL-
TEMPORAL DE IMAGENS ORBITAIS**

por

Hermano José Ribeiro Henriques

Tese apresentada como parte dos requisitos exigidos para obtenção do título de
DOUTOR EM AGRONOMIA

Aprovado em 24/08/2021



Prof. Dr. Jorge Wilson Cortez
Orientador – UFGD/FCA



Prof. Dr. José Carlos Sorgato
UFGD/FCA



Prof. Dr. Gessi Ceccon
Embrapa



Prof. Dra. Anamari V. de A. Motomiya
UFGD/FCA

VINICIUS DE OLIVEIRA
RIBEIRO:00183405129

Prof. Dr. Vinicius de Oliveira Ribeiro
UEMS

Assinado de forma digital por
VINICIUS DE OLIVEIRA
RIBEIRO:00183405129
Data: 2021.08.26 09:34:41
-0400

AGRADECIMENTOS

Agradeço a Deus por iluminar meu caminho e guiar meus passos, todos os dias.

Agradeço a meu orientador Prof. Dr. Jorge Wilson Cortez, por todo o conhecimento compartilhado, orientação, paciência e amizade.

Agradeço aos professores da Comissão Examinadora, Prof. Dr. José Carlos Sorgato, Prof. Dr. Gessi Ceccon, Profa. Dra. Anamari V. de A. Motomiya e Prof. Dr. Vinícius de Oliveira Ribeiro, pela disponibilidade em colaborar e enriquecer o trabalho realizado durante o doutorado.

Agradeço a minha esposa Mirian Luísa Faria Freitas Ribeiro e aos meus falecidos pais Hermano José de Aguiar Henriques e Vera Lucia Ribeiro de Aguiar Henriques, por me incentivarem a cada passo de minha vida, sendo uma pessoa autêntica e perseverante.

Agradeço a Universidade Federal da Grande Dourados UFGD, por proporcionar a realização de um sonho.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior Capes, pela concessão de bolsa de doutorado.

BIOGRAFIA DO AUTOR

Hermano José Ribeiro Henriques, cursou todo o ensino fundamental em escolas públicas.

Formou-se como Engenheiro Agrônomo pela Escola Superior de Agronomia de Paraguaçu Paulista em janeiro de 2001.

Formou-se como Engenheiro de Segurança do Trabalho na Universidade Paulista UNIP em agosto de 2013.

Formou-se como Mestre em Agronomia pela Universidade Estadual Júlio de Mesquita Filho UNESP em fevereiro de 2018.

Cursa atualmente Doutorando em Agronomia pela Universidade Federal da Grande Dourados UFGD.

Trabalhou em várias empresas do seguimento agrícola adquirindo experiência gerencial, comercial, e técnica, nos mercados de Cana-de-Açúcar, Soja, Milho, Algodão, Reflorestamento, Comercialização de Cereais, e Máquinas Agrícolas, onde aprendeu a relacionar-se, ser líder e trabalhar em equipe, adquirindo experiência no processo de gestão de pessoas.

SUMARIO

RESUMO.....	vii
ABSTRACT.....	viii
1 INTRODUÇÃO.....	9
2 REVISÃO DE LITERATURA	10
2.1 Aspectos econômicos da cultura do milho.....	10
2.2 Agricultura de precisão	11
2.3 Sensoriamento remoto.....	14
2.4 Índices de vegetação	17
3 MATERIAL E MÉTODOS.....	20
3.1 Local.....	20
3.2 Clima.....	21
3.3 Esquema amostral	23
3.4 Equipamentos e insumos utilizados no manejo da cultura.....	24
3.5 Avaliações	26
3.5.1 Textura do solo	26
3.5.2 Levantamento da produtividade	27
3.5.3 Imagens.....	28
3.6 Análise dos dados.....	30
3.6.1 Filtragem dos dados de produtividade.....	30
3.6.2 Estatística descritiva dos IVs e a produtividade.	31
3.6.3 Correlação entre os Ivs e a Produtividade	31
3.6.4 Equação de regressão	31
3.6.5 Estimativa da produtividade média	32
4 RESULTADOS E DISCUSSÃO	33
4.1 Argila e produtividade.....	33
4.2 Índices de Vegetação e produtividade.....	37
4.3 Estimativa da produtividade.....	46
5 CONCLUSÕES	47
6 REFERÊNCIAS	48

HENRIQUES, H. J. R. **Produtividade do milho por meio da avaliação espacial temporal de imagens orbitais**. 2021. 66f. Tese (Doutorado em Agronomia), Universidade Federal da Grande Dourados, Dourados-MS.

RESUMO

Devido a presença de *novos* sensores capazes de captar *novos* comprimentos de ondas em plataformas orbitais, surge a necessidade de *um novo* estudo sobre os índices de vegetação (IVs) e sua correlação com a produtividade de grãos. Assim, objetivou-se, estimar a produtividade da cultura do milho vinculada a avaliação *espacial-temporal* de imagens orbitais em três anos agrícolas em propriedade comercial. Os índices utilizados foram: BNDVI – índice de vegetação por diferença normalizada azul, GNDVI - índice de vegetação por diferença normalizada verde NDVI - índice de vegetação por diferença normalizada, NDRE - índice de vegetação por diferença normalizada com a borda do vermelho (Red-Edge), GRNDVI - índice de vegetação por diferença normalizada verde com vermelho, e PNDVI - índice de vegetação por diferença normalizada pan com verde, vermelho e azul, sendo propostas alterações nas fórmulas dos índices GNDVI e PNDVI, substituindo o comprimento de onda vermelho (Red) pelo da borda do vermelho (Red-Edge). Como fonte de dados, para o cálculo dos IVs, foram utilizadas as bandas multispectrais B2, referente ao comprimento de onda azul, B3, ao verde, B4, ao vermelho, B5, ao da borda do vermelho (Red-Edge), e B8, ao infravermelho próximo, fornecidas pelos instrumentos imageadores Sentinel-2A e Sentinel-2B. O levantamento da produtividade foi obtido por meio de colhedoras de grãos constituídas por sistemas de navegação via satélite, painel e sensores embarcados. A textura do solo foi determinada por meio do teor de argila para todos os pontos amostrados, e os índices pluviométricos determinados por meio de estação meteorológica. No ano de menor regime hídrico os teores de argila influenciaram a produtividade. Foi possível observar alta correlação entre os índices de vegetação e a produtividade. Verificou-se que a substituição do comprimento de onda vermelho (Red) pelo da borda do vermelho (Red-Edge) melhora a correlação entre os IVs, e que os índices BNDVI e GNDVI saturam rapidamente, não permitindo a distinção entre classes. Assim, para a estimativa da produtividade do milho por avaliação espacial-temporal, os índices de vegetação que melhor representaram a produtividade foram NDRE e GRENDVI.

Palavras-chave: agricultura de precisão, comprimentos de ondas, índices de vegetação, satélites.

HENRIQUES, H. J. R. **Maize yield through spatial temporal evaluation of orbital images**. 2021. 66f. Thesis (PhD in Agricultural Engineering), Federal University of Grande Dourados, Dourados-MS.

ABSTRACT

Due to the new sensors able to determine new wavelengths in orbital platforms, the need for new studies on vegetation indices (VIs) and their correlation with grain productivity arises. Thus, the objective was to estimate the corn crop productivity linked to the spatial-temporal evaluation of orbital images in three agricultural years in a commercial property. The indexes used were: BNDVI - blue normalized difference vegetation index, NDVI - normalized difference vegetation index, NDRE - normalized difference vegetation index with red edge (Red-Edge), GNDVI - green normalized difference vegetation index, and PNDVI - pan normalized difference vegetation index with green, red and blue, with proposed changes in the formulas of the GNDVI and PNDVI indexes, replacing the red wavelength (Red) by the red edge (Red-Edge). As a data source, to calculate the IRs, the multispectral bands B2, referring to the blue wavelength, B3, to the green, B4, to the red, B5, to the edge of red (Red-Edge), and B8, to the near infrared, provided by the Sentinel-2A and Sentinel-2B imaging instruments, were used. Productivity data collection was obtained by grain harvesters consisting of satellite navigation systems, panel and on-board sensors. The soil texture was determined by clay content for all sampled points, and the precipitation rates were determined by weather station. In the year with the lowest hydric regime the clay content influenced the productivity. It was possible to observe a high correlation between vegetation indexes and productivity. It was verified that the replacement of red wavelength (Red) by red edge (Red-Edge) improves the correlation between the VIs, and that the BNDVI and GNDVI indexes quickly saturate, not allowing the distinction among classes. Thus, the vegetation index that best represented the average annual productivity estimate in corn crop were NDRE and GRENVI.

Keywords: precision agriculture, wavelengths, vegetation indexes, satellites.

1 INTRODUÇÃO

O milho é uma das mais importantes plantas com origem nas Américas. Há indicações de que sua origem tenha sido no México, América Central ou Sudoeste dos Estados Unidos, sendo uma das culturas mais antigas do mundo. Há provas por meio de escavações arqueológicas e por meio de medições por desintegração radioativa, de que é cultivado há pelo menos cinco mil anos. Logo depois do descobrimento da América, o milho foi levado para a Europa, onde era cultivado em jardins, até que seu valor alimentício se tornou conhecido. Passou, então, a ser semeado em escala comercial e espalhou-se desde a latitude de 58° Norte, União Soviética, até 40° Sul, Argentina (DUARTE et al., 2019).

Nas últimas décadas, o milho chegou ao patamar de maior cultura agrícola do mundo, ultrapassando a marca de um bilhão de toneladas, deixando para trás antigos concorrentes, como o trigo e o arroz. A cultura ainda se destaca no contexto mundial como parâmetro de segurança alimentar (CONTINI et al., 2019).

A gestão de recursos agrícolas tem se tornado uma realidade crescente a demanda alimentar mundial, ao mesmo tempo em que há uma crescente necessidade por alimentos, energia e demais produtos oriundos da agricultura, e os recursos naturais estão cada vez mais escassos. Diante desse cenário, a produção agrícola precisa ser otimizada, visando à sustentabilidade e a segurança alimentar. A gestão dos cultivos deve buscar o máximo de produtividade das culturas com o menor consumo de insumos possível. Nesse contexto, a agricultura de precisão torna-se uma prática essencial (MOLIN et al., 2015).

O tema agricultura de precisão (AP), com foco no Sensoriamento Remoto (SR) a nível de coleta orbital possui grande relevância para a área acadêmica e comercial, demonstrando maior conhecimento da variabilidade espaço temporal da cultura do milho e das diferenças existentes entre os estádios fenológicos, por meio de características biofísicas e morfológicas da cultura. Diante do exposto, objetivou-se determinar a produtividade anual média espacializada na cultura do milho, vinculada a avaliação espaço-temporal de imagens orbitais por meio de IVs, considerando a influência da textura do solo e respectivos índices pluviométricos.

2 REVISÃO DE LITERATURA

2.1 Aspectos econômicos da cultura do milho

O milho possui diversos usos, onde levantamentos apontaram para mais de 3.500 aplicações deste cereal. Além de grande relevância para a segurança alimentar humana e animal, é possível produzir com este cereal uma grande gama de outros produtos, como combustíveis, bebidas, polímeros, entre outros (CONTINI et al., 2019).

A produção mundial de milho passou de 591 milhões de toneladas na safra 2000/2001, para 1076 milhões de toneladas na safra 2017/2018, representando um aumento de 55%, principalmente em virtude do uso como ração animal para a produção de frangos e suínos. A produção é relativamente concentrada em poucos países do mundo, com destaque para os Estados Unidos, China e Brasil. Segundo Usda (2018a) e Usda (2018b), apenas dois países, os Estados Unidos e a China representam 59% de toda a produção mundial de milho. Ao ser adicionado Brasil e mais 27 países que compõem a União Europeia, aos dois maiores produtores mundiais, são responsáveis por 72,3% da produção mundial.

O mercado brasileiro de milho apresentou grande reestruturação na composição do processo de oferta e demanda ao longo das primeiras duas décadas do século XXI (CONAB, 2018a). Na oferta, os ganhos advindos da maior produtividade por unidade de área e a mudança da época de semeadura para após a colheita da soja, impactaram expressivamente os períodos de maior disponibilidade do produto (CONAB, 2018b). No caráter a demanda, além do crescimento interno pelo consumo animal, o grande excedente favorece exportação (CONTINI et al., 2019).

Os estados de Mato Grosso, Paraná, Goiás, Mato Grosso do Sul e Minas Gerais, produziram 74% da safra nacional de milho entre 2017 e 2018. A produção brasileira, teve uma colheita recorde em 2016 para 2017, sendo esta 97,8 milhões de toneladas, com previsões entre 121,4 e 182,7 milhões de toneladas para próxima década (GASQUES et al., 2018). Esses números são suportados pela importância do milho no mercado nacional e internacional, através do crescimento acentuado em segunda safra. A variável mais forte a impulsionar o cultivo deste cereal serão as exportações, projetadas para crescer 50%, correspondendo a um volume de 39 milhões de toneladas até 2027 (USDA 2018b).

Mato Grosso do Sul é o quinto maior produtor do Brasil, na 2ª safra 2019 foi cultivado em 2.173.294 hectares e uma produtividade média de 93,23 sc ha⁻¹. As médias de produtividade por regiões foram de 113,20 sc/ha para região Norte que representa 12,05% da área semeada, 90,60 sc/ha para a região Sul que representa de 67,3% da área semeada e 90,30 sc/ha para região Centro, que representa 20,69% da área semeada (CONAB 2018b).

2.2 Agricultura de precisão

Foley et al. (2011) verificaram que até o ano de 2050, para se atender às demandas de segurança alimentar e a sua sustentabilidade, será preciso duplicar os atuais níveis de produção agrícola no planeta, neste sentido, a AP é uma das alternativas para aumentar a produtividade das culturas.

A comissão Brasileira de AP, órgão consultivo do Ministério da Agricultura, Pecuária e Abastecimento, adota como definição para Agricultura de Precisão – AP é o conjunto de tecnologias e ferramentas que permitam a um sistema de gerenciamento agrícola, proporcionar o aumento do retorno econômico e a redução do impacto ambiental baseado na variabilidade espacial e temporal da unidade produtiva. Neste contexto a AP é um dos seguimentos que mais ganha adeptos no mundo, e tem utilizado tecnologias sofisticadas, como o Sistema de Informações Geográficas (SIG), o Sensoriamento Remoto (SR), e os Sistemas de Navegação Global por Satélite (GNSS - Global Navigation Satellite System) (BERNARDI et al., 2014; MOLIN et al., 2015). A AP é uma forma de gestão de todo o processo agrícola que leva em consideração todo o tipo de variabilidade existente na lavoura, sendo assim necessário avaliar, quantificar e mapear esta variabilidade para uma gestão eficiente, conceito diretamente relacionado com a geoestatística, sendo esta uma ferramenta que utiliza o conceito de variáveis regionalizadas na avaliação da variabilidade espacial por meio da extração e organização espacial dos dados disponíveis de acordo com a semelhança entre pontos vizinhos georreferenciados (GRECO et al., 2014). Nesse sentido, os mapas de produtividade (MP) são tidos como uma ferramenta completa e verdadeira para a visualização da variabilidade nos cultivos (VIAN et al., 2018).

Uma das características marcantes na utilização da AP, é o emprego do SR, ferramentas a campo com grande capacidade em gerar diagnósticos, estando entre estes a previsão do tempo, a avaliação nutricional de plantas, a detecção de doenças e pragas, e a estimativa da produtividade (SHIRATSUCHI et al., 2014).

Em AP as geotecnologias são uma vertente de fontes de informações, como o SR, o qual obtém informação de objetos por meio de sensores sem que haja o contato físico. Estes sistemas são fundamentados em comprimentos de onda específicos empregados para calcular índices de vegetação sendo utilizados para estimar os componentes da produção agrícola, entre muitas outras aplicações (ZERBATO et al., 2016).

Historicamente apenas no final dos anos 1980 é que surgiram as primeiras tentativas de se medir o fluxo de grãos em colhedoras de cereais para fins de estimativa a produtividade. Desde então, vários produtos têm sido disponibilizados no mercado para a geração de Mapas de Produtividade - MP (MOLIN et al., 2015).

No início da década de 2000, alguns modelos de colhedoras brasileiras, já eram comercializadas com esses dispositivos, instalados pelas montadoras. Mesmo assim, ainda existe o mercado de monitores genéricos, que podem ser instalados em qualquer marca ou modelo de colhedora (MOLIN et al., 2015).

A obtenção dos dados para identificar a produtividade compreende uma série de sensores e outros dispositivos que trabalham em conjunto. Os sensores medem o fluxo de massa diretamente ou indiretamente. Para a mensuração deste fluxo é fundamental a existência de um sensor ou conjunto de sensores em algum ponto da colhedora onde os grãos estejam passando. Estes sensores devem estar conectados a um monitor com sistema de posicionamento global - GPS, pelo tempo de deslocamento da colhedora. Estes dados se remetem a largura da plataforma de colheita em função da distância percorrida em um determinado tempo, proporcionando o volume colhido por área (MOLIN et al., 2015).

No mercado há o predomínio dos sensores gravimétricos associados a sensores de umidade, com algumas variações na forma de funcionamento e na mensuração do fluxo de grãos. Os sensores gravimétricos se caracterizam por mensurar diretamente a massa de grãos que está sendo colhida, sendo a medida feita quase que exclusivamente pelo sistema denominado placa de impacto. Nesse sistema, a força centrífuga provocada nos grãos pelo elevador de grãos gera um impacto proporcional à

massa de grãos que está sendo colhida. Para medir essa força, existem dois princípios comercialmente em uso, a célula de carga e o potenciômetro. A célula de carga é um dispositivo que converte a força exercida sobre uma placa de impacto em um sinal elétrico proporcional a essa força estimando assim o fluxo de massa. Já o potenciômetro é um dispositivo elétrico no qual a resistência elétrica é alterada mecanicamente, onde este sensor mede o deslocamento da placa de impacto causado pela força exercida pelos grãos colhidos, e quanto maior o deslocamento, maior será a massa de grãos que passa pelo elevador (MOLIN et al., 2015).

Os sensores de umidade de grãos são componentes indispensáveis aos monitores de produtividade, uma vez que a produtividade é sempre referenciada com base em grãos secos, padrão utilizado na comercialização. Os sensores de umidade utilizam o princípio da capacitância, da mesma forma que muitos dos determinadores de umidade disponíveis em unidades receptoras de grãos e laboratórios (MOLIN et al., 2015). Geralmente são instalados dentro dos tanques graneleiros das colhedoras de grãos, onde coletam de forma intermitente um volume determinado da massa de grãos, mensuram a umidade, e os associam aos dados de colheita.

Após a coleta georreferenciada dos dados de produtividade pelos monitores de colheita, é possível a utilização destes dados para confecção de Mapas de Produtividade - MP. Os dados de produtividade após extraídos dos monitores de colheita se apresentarão na forma pontual, contendo sua localização, bem como o referido dado de produtividade calibrado (BERTOLIN et al., 2017).

Um MP é um conjunto de pontos georreferenciados onde cada ponto representa certa área, com cerca de alguns metros quadrados, sendo determinado durante a configuração do monitor, por meio da largura da plataforma em função do tempo de deslocamento da máquina colhedora. Por MP também se entende a plotagem de cada um desses pontos em um sistema cartesiano, no qual o eixo x é representado pela longitude e o eixo y pela latitude. Para a obtenção dos MP é necessário a manipulação dos dados em um software de sistemas de informações geográficas SIG, onde por meio de métodos de interpolação entre estes pontos, se classificam em pixels de tamanho conhecido, diferentes classes em produtividade por meio de cores, compondo assim o mapa final.

Porém os sistemas de coleta de dados de produtividade embarcados em colhedoras de grão, ainda não são tão precisos, gerando uma relevante quantidade de dados discrepantes, como produtividades acima ou abaixo do real, sendo necessário a

adequação destes dados. Uma das formas mais praticas é a avaliação do desvio padrão segundo Molin et al. (2015) no conjunto de dados de produtividade, onde inicialmente realiza-se a subtração da média dos dados brutos pelo desvio padrão, sendo obtido o primeiro desvio, na sequência, o segundo desvio é obtido pela subtração com o primeiro desvio, e por fim, o terceiro desvio obtido pela subtração com o segundo. O terceiro desvio será considerado como o valor da classe de corte para a menor produtividade. O mesmo é feito para a maior produtividade, porém oposto a subtração realiza-se a adição.

O método de interpolação de dados utilizado para a geração dos MP é o inverso da potência das distâncias IDW (*Inverse Distance Weighting*), onde o modelo se baseia na dependência espacial, isto é, supõe-se que quanto mais próximo estiver um indivíduo do outro, maior será a correlação desse indivíduo com seus vizinhos. Dessa forma é atribuído maior peso para os indivíduos mais próximos do que para os mais distantes do ponto à ser interpolado. O modelo consiste em se multiplicar os valores observados pelo inverso das suas respectivas distâncias ao ponto central, sendo atribuído um ponderador a este cálculo. Ponderadores maiores atribuem maior peso aos pontos que se encontram mais próximos ao ponto central e ponderadores menores atribuem pesos menores aos pontos mais próximos, ou seja, neste último caso, pontos mais distantes têm maior interferência no resultado, gerando superfícies mais suavizadas. Em AP há predominância da utilização do ponderador dois, considerado como razoável na geração de MP (MOLIN et al., 2015).

Atualmente os MP são utilizados para a identificação regionalizada da produtividade, sendo ferramenta indispensável ao processo de recomendações de nutrientes por extração, tanto quanto para outras diversas ferramentas de análises regionalizadas.

2.3 Sensoriamento remoto

O sensoriamento remoto SR clássico, é aquele baseado exclusivamente em imagens obtidas por câmeras instaladas em plataformas aéreas e orbitais, podendo ser definido como a ciência ou a arte de se obter informações sobre um determinado objeto, área ou fenômeno, por meio de dados coletados por um sistema sensor sem contato com o alvo (MOLIN et al., 2015). O SR aplicado a agricultura tem sido estudado desde a década de 1970 (FORMAGGIO e SANCHES, 2017). Os Estados Unidos foi o primeiro

país a utilizar dados de SR via satélite, na agricultura, por meio do lançamento do primeiro satélite da série Landsat, a princípio, conhecido como ERTS – Earth Resources Technology Satellite (MACDONALD et al., 1975).

Desde a década de 1970, o país que mais demonstra pesquisas com a utilização de estatísticas agrícolas por meio dos dados de SR, é os Estados Unidos, sendo o NASS (National Agricultural Statistics Service) responsável pela maior parte desses avanços. Já no Brasil, desde o início da década de 1970, o INPE (Instituto Nacional de Pesquisas Espaciais) apresenta um importante papel da área de geotecnologias, com a utilização do SR a nível nacional, fortalecendo o país por ser um dos mais desenvolvidos nesta área (FORMAGGIO e SANCHES, 2017).

O SR está diretamente relacionado com a medida da radiação eletromagnética emitida ou refletida dos alvos da superfície terrestre, assim como a disponibilização dessa informação em forma passível de interpretação (MOREIRA, 2011).

A energia eletromagnética utilizada no SR, seja ela originária do Sol ou emitida pelos alvos, geralmente é dividida em faixas espectrais ou regiões, em termos de comprimento de onda ou de frequência, constituindo o espectro eletromagnético (LORENZZETTI, 2015).

Quando a energia proveniente do Sol, denominada radiação eletromagnética (REM) atinge um objeto, ocorre a interação com o alvo e a energia tende a ser fracionada em três partes: absorvida, refletida e transmitida (MOLIN et al., 2015).

Esta energia pode ser mensurada através de sensores ópticos que mensuram a forma como a radiação interage com os alvos, principalmente em relação à energia refletida, sendo denominados radiômetros, os quais variam em função das bandas espectrais e dos comprimentos de ondas com os quais trabalham, e também de acordo com a plataforma em que operam (MOLIN et al. 2015). De todos os comprimentos de onda do espectro eletromagnético, as regiões do visível (VIS) e do infravermelho próximo (NIR) são as mais utilizadas para aplicações no meio agrícola (400 a 3.000 nanômetros). Nesta faixa de comprimentos de onda trabalham os radiômetros denominados multiespectrais (MOLIN et al., 2015).

As imagens orbitais provenientes de instrumentos imageadores (satélites) com radiômetros multiespectrais embarcados, apresentam grande potencial na identificação da variabilidade espacial do desenvolvimento vegetal, sendo possível

estudar os causadores dessa intercorrência por meio de índices de Vegetação IVs (MOLIN et al., 2015; FLORES et al., 2019).

Uma das medidas de desempenho mais importantes para a prática de AP, tendo a cultura como o alvo do SR, é a resolução temporal das imagens. Essa resolução se aplica apenas às plataformas orbitais, já que é dependente do tempo de revisita de um satélite em determinada posição do globo terrestre, ou seja, de acordo com a órbita de cada satélite e das características de cada radiômetro embarcado, há um intervalo entre a possível obtenção das imagens. Quando há um intervalo de tempo em revisita maior, ou seja, uma resolução temporal baixa, há uma grande probabilidade de perda do momento exato a obtenção de dados da cultura para a execução de determinada intervenção. Ainda no caso da ocorrência da presença de nuvens no momento da passagem do satélite em certa região, a obtenção de dados estará prejudicada e, caso leve muito tempo para uma revisita do satélite, a intervenção que poderia ser realizada com base nesses dados fica completamente comprometida (MOLIN et al., 2015). Atualmente a pesquisa vinculada ao SR utiliza plataformas orbitais que proporcionam alta resolução temporal, ou seja, com o menor intervalo de tempo possível entre revistas, possibilitando assim um melhor recobrimento espaço temporal.

Outra medida de desempenho importantes para a prática de AP, tendo também a cultura como o alvo do SR, é a resolução espacial das imagens, sendo este o nível de detalhamento com que podemos observar objetos na superfície terrestre, sendo resumidamente definido como o nível de definição ou, a capacidade que um sensor tem em detalhar os objetos em relação ao seu tamanho. A nos mostra a resolução espacial de imagens orbitais oriundas de instrumentos imageadores que embarcam diferentes tipos de radiômetros multiespectrais, onde o nível de detalhamento está diretamente relacionado com a resolução espacial de cada imagem.

Outra medida fundamental de desempenho também está relacionada a calibração radiométrica das imagens orbitais. Este procedimento está associado a correção de distorções ocasionadas principalmente por variações atmosféricas e ao ângulo de incidência da REM em relação a superfície, para tanto, algum ponto da superfície é tomado como referência e, por meio de curvas de calibração e normalização dos dados, o restante da imagem passa a obedecer aos padrões de refletância (MOLIN et al., 2015).

Neste sentido, a pesquisa pontua muitos exemplos de utilização do SR como ferramenta para a prática de AP.

Trindade et al. (2019) em seu estudo procuraram avaliar relações espectrais e temporais dos índices *normalized difference vegetation index* (NDVI) e *enhanced vegetation index* (EVI) do sensor *MODIS* com a produtividade de grãos, relevo, textura e matéria orgânica do solo (MOS). O coeficiente de determinação (R^2) do EVI no estágio R1 com Matéria Orgânica - MOS, argila, silte e areia foram $R^2 = 0,77; 0,75; 0,74; 0,75$, respectivamente. Com NDVI no estágio fenológico R2 obteve $R^2 = 0,44$ com a produtividade. O EVI nos estádios R1, R2 e R3 gerou os melhores modelos de predição dos atributos do solo e o NDVI no estágio R2 para previsão da produtividade. A filtragem SG foi ferramenta necessária ao estudo, pois a correção dos ruídos nas séries temporais, de forma geral, gerou melhores modelos preditivos.

Bertolin et al (2017) posicionam em seu estudo o sensoriamento remoto como ferramenta para a estimativa da produtividade do milho irrigado, onde objetivaram modelar uma equação empírica, utilizando a relação de índices de vegetação (IV) obtidos via sensoriamento remoto, com a produtividade do milho sendo capaz de prever a produtividade das safras seguintes. Para essa análise foram testados os seguintes IV: NDVI (Normalized Difference Vegetation Index), NDWI (Normalized Difference Water Index), SAVI (Soil Adjusted Vegetation Index) e o GVI (Green Vegetation Index). As imagens utilizadas foram oriundas do satélite Landsat-8 para as safras 2013, 2014 e 2015, e com o intuito em validar o modelo de regressão linear adotado, a equação gerada foi testada para a safra de 2016, sendo que o NDVI foi o único IV a apresentar boa correlação com a produtividade, com coeficiente de determinação (R^2) de 0,81. A produtividade estimada, com base no NDVI, apresentou uma subestimativa média de 11,95 sacas/hectare, subestimando o valor da produtividade observada em 6,32%. Essa diferença percentual foi considerada satisfatória em se tratando de estimativa de produtividade.

2.4 Índices de vegetação

Uma das formas mais plausíveis e competentes para a identificação da variabilidade espacial ligada ao desenvolvimento vegetal, está associada a avaliação de IVs, sendo estes, fórmulas matemáticas com a função de avaliar a REM refletida (refletância) em função das características biofísicas vegetais (SHIRATSUCHI et al., 2014; MOLIN et al., 2015).

Para uma compreensão mais detalhada de como os IVs são criados há necessidade do entendimento da refletância da REM (assinatura espectral) em função do tipo de superfície avaliada, como vegetação, solo e água (FORMAGGIO E SANCHES, 2017).

A assinatura espectral de uma vegetação saudável é determinada entre as cores visíveis e invisíveis ao olho humano, sendo influenciada pela clorofila, onde a REM mais absorvida é a vermelha, estando seus comprimentos de onda compreendidos entre 600 e 700 nm, seguido da REM azul, com comprimentos de onda entre 400 e 500 nm, e a REM verde, com comprimentos de onda entre 500 e 600 nm (BERNARDI et al., 2014). Outra importante REM utilizada para a determinação dos IVs é o infravermelho próximo (NIR), com comprimentos de onda entre 750 a 1300 nm, tendo como principal característica refletir entre 30 e 80% da REM incidente (SHIRATSUCHI et al., 2014).

A borda do vermelho (Red-Edge) é uma nova alternativa para a estimativa da atividade fotossintética através de IVs, seu comprimento de onda se estende entre 680 a 740 nm, ficando alocado entre os espectros eletromagnéticos vermelho e infravermelho próximo (CUI e REKES, 2018). Em seu estudo Kanke et al. (2016) afirmam que o comprimento de onda vermelho e vermelho da borda, são fortemente absorvidos pelos pigmentos da clorofila, enquanto o infravermelho próximo é refletido com base na estrutura da folha.

Na agricultura foram desenvolvidos vários IVs com diversas finalidades, em que pesquisadores em todo o mundo utilizam a capacidade de absorção e reflexão da REM em alvos agrícolas. Dentre estes, se encontram os mais utilizados para a determinação do potencial fotossintético vegetal, IV por diferença normalizada (NDVI), IV por diferença normalizada da borda vermelha (NDRE), IV por diferença normalizada verde (GNDVI), IV por diferença normalizada azul (BNDVI), IV por diferença normalizada verde e vermelho (GRNDVI), IV por diferença normalizada verde com vermelho da borda (GRENDVI), IV por diferença normalizada PAN com verde, vermelho e azul (PNDVI), e IV por diferença normalizada PAN com verde, vermelho da borda e azul (PRENDEVI) (VIAN et al., 2018; FITZGERALD et al., 2006; GITELSON et al., 1996; FU-MIN et al., 2007).

Uma das desvantagens na utilização dos IVs está relacionado a sua saturação, onde ao atingirem valores máximos em sua classificação, não permitem a distinção entre classes amostrais (BERTOLIN et al, 2017).

A estimativa da produtividade através de IVs é uma das novas técnicas empregadas em AP com SR. Esta técnica consiste na determinação do volume médio produzido através da aplicação da média de um determinado IV a uma equação matemática (BERTOLIN et al., 2017).

Segundo Vian et al. (2018) uma das mais novas práticas agrícolas para se qualificar o manejo da cultura do milho, é a estimativa do potencial produtivo ao longo de seu ciclo de desenvolvimento. Neste contexto, se destacam os sensores de vegetação, tendo como principal função realizar o monitoramento do desenvolvimento vegetal ao longo de seu ciclo. Através destes, é possível determinar os limites críticos de um IV para a determinação de classes de potencial produtivo na cultura do milho, de acordo com seus estádios fenológicos. Estes pesquisadores avaliaram através de um sensor óptico ativo, os estádios fenológicos V3, V5, V6, V7 e V8 respectivamente. Os resultados mostraram que o NDVI, medido pelo sensor Greenseeker, foi eficiente na predição da produtividade do milho em diferentes estádios fenológicos. Os limites críticos de NDVI, os quais correspondem a diferentes classes de potencial produtivo, foram identificados de maneira rápida e precisa entre os estádios fenológicos V3 a V8, sendo esta informação empregada para a adubação nitrogenada em taxa variável de acordo com o potencial produtivo estimado.

Atualmente os modelos matemáticos mais utilizados para a estimativa da produtividade média na cultura do milho a campo, são os modelos de regressão linear simples Trindade et al. (2019), Vian et al (2018), Bertolin et al. (2017). Estes autores relatam graficamente em seu estudo o potencial com que as variáveis de campo se correlacionam com os IVs estudados, onde este potencial é representado por meio de uma reta em um gráfico de dispersão e uma equação de regressão linear simples com o respectivo índice de determinação R^2 .

A análise de regressão tem como função avaliar a amplitude da variação de uma variável decorrente de outra variável, neste caso, quando se estuda uma única variável independente, geralmente a mais importante, sobre uma variável dependente, chamamos de regressão simples. A variável independente explica a variação na variável dependente. Neste caso, quanto mais próximo for o resultado, mais próximo de 1 será o R^2 .

3 MATERIAL E MÉTODOS

3.1 Local

O estudo foi conduzido em área comercial com a cultura do milho em segunda safra, nos anos de 2018, 2019 e 2020.

A área comercial está localizada nas coordenadas geográficas de latitude $22^{\circ}22'10.51''\text{S}$ e longitude $5^{\circ}11'3.90''\text{W}$, situada no município de Ponta Porã, estado de Mato Grosso do Sul (Figura 1).

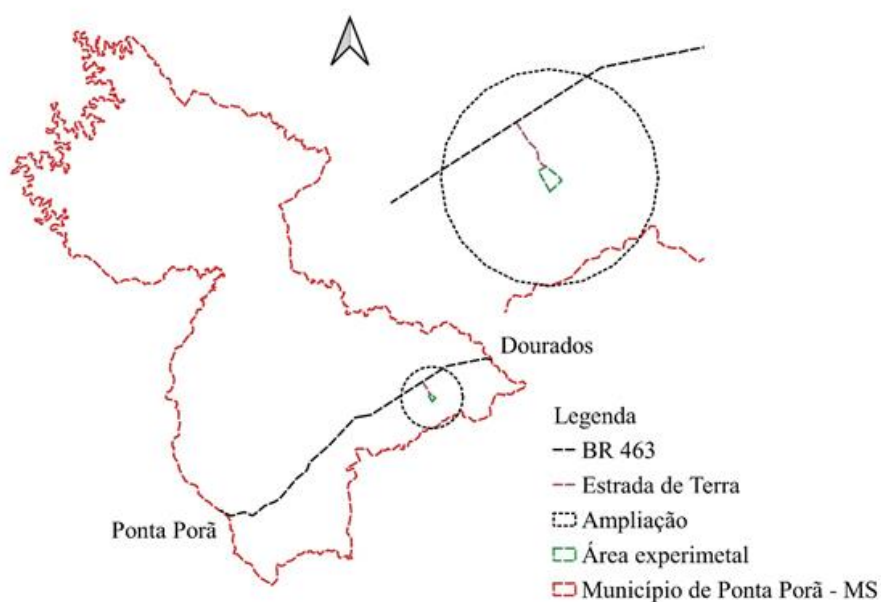


FIGURA 1. Croqui de localização da área experimental.

O terreno foi considerado plano com altimetria da área não variando mais que quatro metros entre cotas (Figura 2).




FIGURA 2. Croqui planialtimétrico da área experimental.

O solo foi classificado como Latossolo Vermelho distrófico segundo (SANTOS et al., 2018), possuindo como teores médios em fertilidade no perfil de 0,00 a 0,20 m, pH 5,5 (médio), matéria orgânica 35 g/dm^{-3} (alta), fósforo $13,8 \text{ mg/dm}^{-3}$ (baixo), potássio $3,4 \text{ mmol/dm}^{-3}$ (alto), cálcio 57 mmol/dm^{-3} (médio), magnésio $1,7 \text{ mmol/dm}^{-3}$ (baixo) e alumínio $0,0 \text{ mmol/dm}^{-3}$. A amostragem de solo foi realizada apenas no ano de introdução do experimento.

3.2 Clima

O clima é do tipo Cwa, caracterizado como temperado úmido com inverno seco, e verão quente segundo classificação de KÖPPEN (1948). Os dados meteorológicos durante o período de condução do experimento foram provenientes do Centro de Monitoramento do Tempo e do Clima de MS (CEMTEC) (Figura 3, 4 e 5).

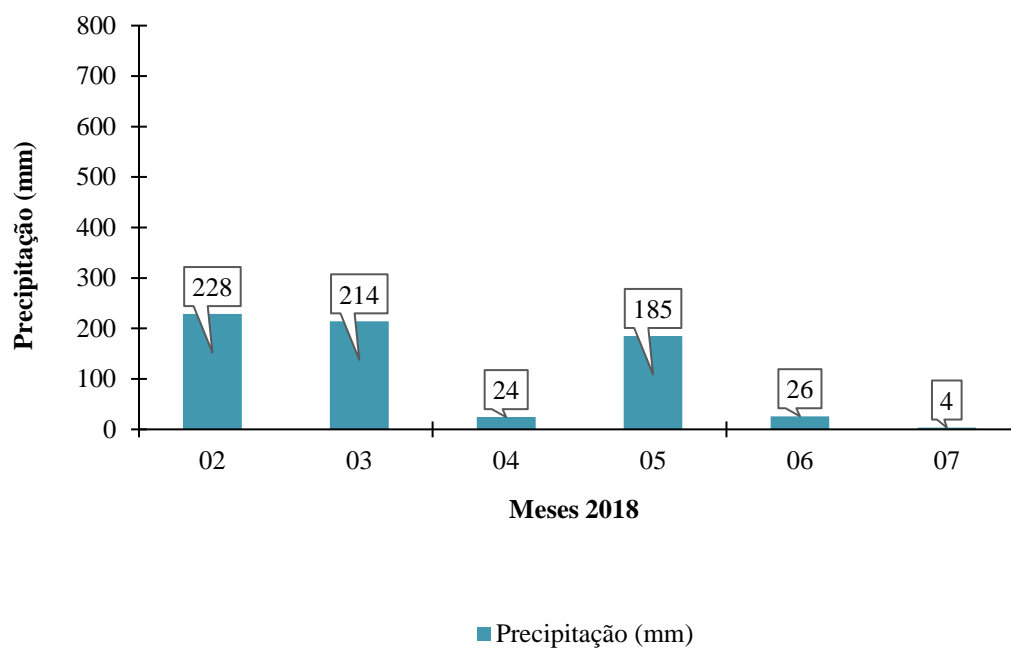


FIGURA 3. Dados meteorológicos mensais do ano 2018, desde a data de semeadura (28/02/2018) até a colheita (17/07/2018).

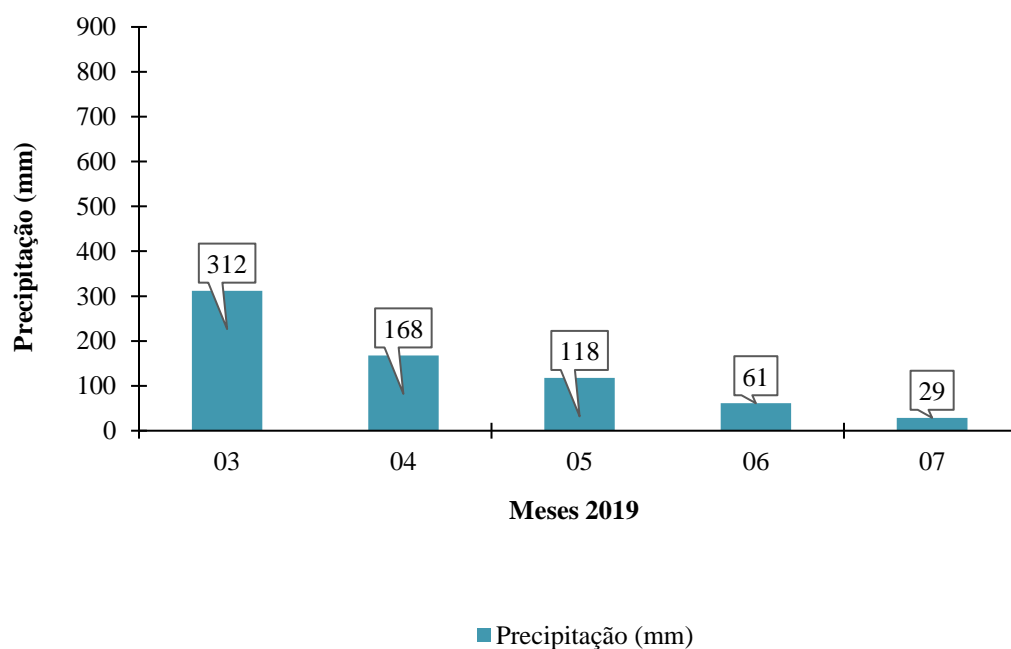


FIGURA 4. Dados meteorológicos mensais do ano 2019, desde a data de semeadura (28/02/2018) até a colheita (17/07/2018).

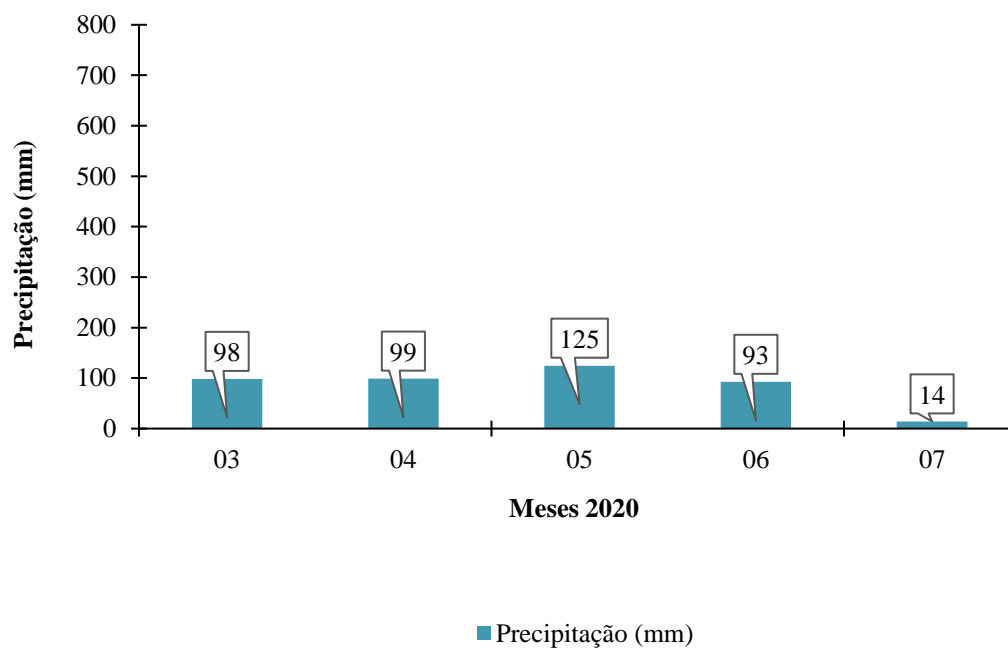


FIGURA 5. Dados meteorológicos mensais do ano 2020, desde a data de semeadura (05/03/2020) até a colheita (23/07/2020).

3.3 Esquema amostral

O esquema amostral utilizado foi constituído por 12084 parcelas, sendo cada parcela constituída por um pixel de dimensões 10 m x 10 m, perfazendo uma área de 100 m² (Figura 6).

Todos os demais dados foram ajustados e dimensionados para a mesma escala do esquema amostral, contendo cada pixel as características georreferenciadas dos mapas de produtividade, índices de vegetação e textura do solo.

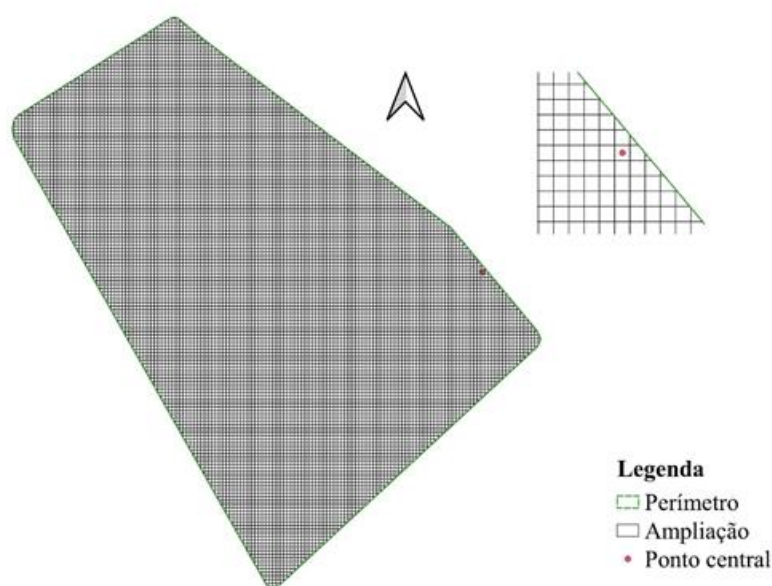


FIGURA 6. Área experimental com grade amostral de 100 m².

3.4 Equipamentos e insumos utilizados no manejo da cultura

O espaçamento entre ruas de plantio variou entre os anos de semeadura, tanto quanto a distribuição linear de sementes. Na data de 28/02/2018, foi semeado o híbrido Fórmula, em espaçamento entre linhas de 0,90 m e stand de plantas recomendado de 55000 plantas/ha, estabelecendo uma distribuição linear média de 4,9 plantas por metro. Em 05/03/2019 foram semeados os híbridos Fórmula e 7061 em espaçamento de 0,50 m entre linhas e 55000 plantas/ha, estabelecendo uma distribuição espacial de 2,7 plantas por metro linear. Em 2020 foi semeado o híbrido Fórmula em espaçamento de 0,50 m entre linhas e stand de 55000 plantas/ha, com distribuição espacial de 2,7 plantas por metro linear.

Os insumos e equipamentos utilizados estão descritos nos (Quadro 1 e 2).

QUADRO 1. Descrição dos insumos agrícolas utilizados na semeadura do milho.

	Milho 2018	Milho 2019	Milho 2020
Sistema	Plantio Direto	Plantio Direto	Plantio Direto
Híbrido	Fórmula	Fórmula e 7061	Fórmula
Semeadura	28/02/2018	05/03/2019	03/03/2019
Espaçamento	0,90 m	0,50 m	0,50 m
(N-P-K)	16/16/16 (220 kg ha ⁻¹)	16/16/16 (230 kg ha ⁻¹)	16/16/16 (230 kg ha ⁻¹)
Herbicida	Atrazina	Atrazina	Atrazina
Inseticida	Imidacloprid	Imidacloprid	Imidacloprid
Inseticida	Cipermetrina	Cipermetrina	Cipermetrina
Fungicida	Trifloxistrobina	Trifloxistrobina	Trifloxistrobina

Obs.: herbicidas e inseticidas de acordo com a recomendação comercial.

QUADRO 2. Descrição dos equipamentos agrícolas.

Tipo	Marca	Modelo	Especificações
Trator	New Holland	T8.320	235 kW (320 cv) a 2000 rpm, piloto automático, monitor, e receptor GNSS.
Semeadora	New Holland	TT	Mecânica com 23 linhas. 129 kW (175 cv) a 2200 rpm, barras de 27
Pulverizador	New Holland	Defensor	m, piloto automático, monitor, e receptor GNSS. 358 kW (487 cv) a 2000 rpm, sensor de
Colhedora	New Holland	CR 7090	colheita, piloto automático, monitor, e receptor GNSS.
Colhedora	New Holland	CR 9080	360 kW (489 cv) a 2000 rpm, sensor de colheita, piloto automático, monitor, e receptor GNSS.

Obs.: quilowatt (kW); cavalo vapor (cv), rotações por minuto (rpm), metro (m).

3.5 Avaliações

3.5.1 Textura do solo

Para a determinação da textura do solo, no ano de 2019 foram coletas amostras utilizando o perfil em profundidade de 0,0 a 0,20 m, por um quadriciclo com trado hidráulico acoplado. Cada amostra foi composta por 8 subamostras em torno do ponto central, respeitando um raio de 5 m referente ao erro do receptor GNSS.

A área experimental de 120,84 ha foi georreferenciada com grade amostral de 2 ha (141,4213 m x 141,4213 m) contendo 64 pontos amostrais, dimensões mínimas consideradas adequadas para a coleta e interpolação de dados de textura (MOLIN et al., 2015). A grade amostral foi gerada pelo software geoestatístico em plataforma livre QGIS, sendo representada na (Figura 7).

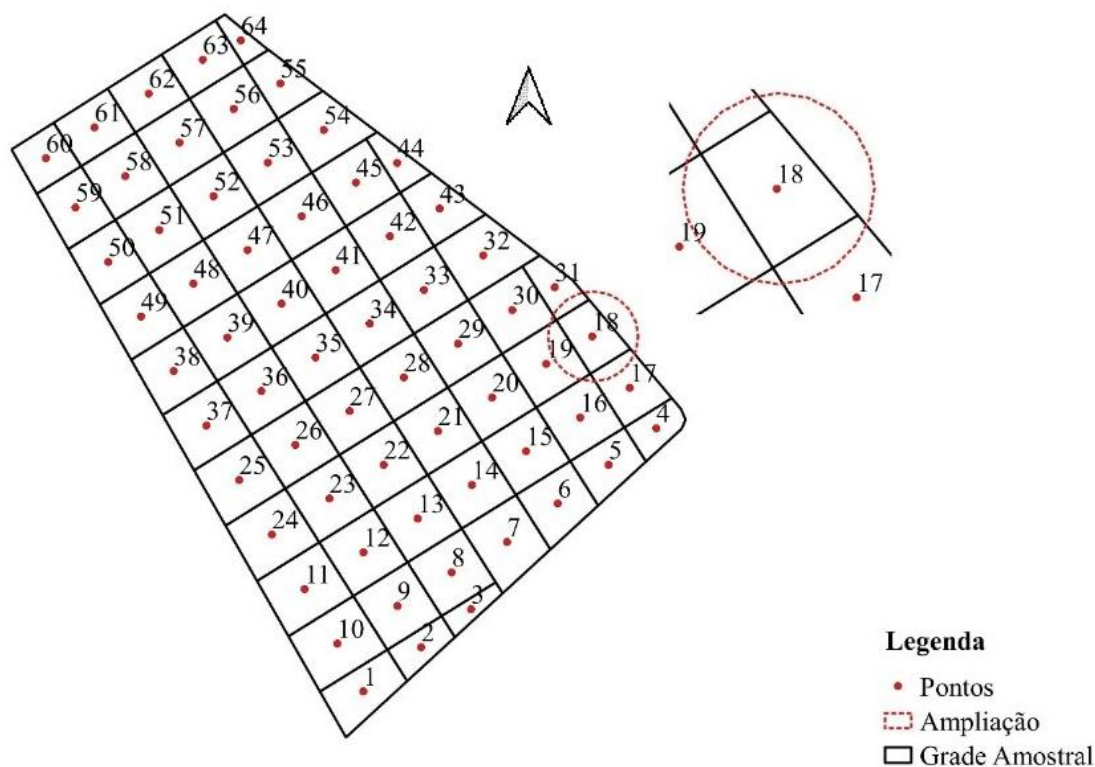


FIGURA 7. Grade amostral para a coleta de amostras de solo.

O agrupamento textural foi identificado de acordo com Santos, et al. (2018), através do guia para agrupamento de texturas (Figura 8). Os grupos são

determinados de acordo com a classe textural: Textura arenosa, material que compreende as classes texturais areia e areia franca, ou seja, teor de areia $> 700 \text{ g kg}^{-1}$, Textura média, material com menos de 350 g kg^{-1} de argila e mais de 150 g kg^{-1} de areia, excluídas as classes texturais areia e areia franca; Textura argilosa, material com conteúdo de argila entre 350 g kg^{-1} e 600 g kg^{-1} ; Textura muito argilosa, material com conteúdo de argila superior a 600 g kg^{-1} ; Textura siltosa, material com menos de 350 g kg^{-1} de argila e menos de 150 g kg^{-1} de areia.




FIGURA 8. Guia de agrupamento de classes texturais.

3.5.2 Levantamento da produtividade

A produtividade da cultura foi determinada pela coleta de dados georreferenciados no período de três anos, sendo estes dados providos de colhedoras munidas de sensor de colheita (placa de impacto), monitor e receptor GNSS com capacidade de coleta de dados a cada um segundo. Os dados extraídos posteriormente foram tratados pelo software geostatístico em plataforma livre QGIS.

No ano de 2018 as colhedoras utilizavam sinal de GPS gratuito e ausência de piloto automático, acentuando a margem de erro no processo de coleta de dados, já no ano de 2019 e 2020, trabalharam com piloto automático e sinal de GPS pago, proporcionando maior precisão aos dados.

3.5.3 Imagens

As imagens orbitais para a determinação dos índices de vegetação (IVs) foram obtidas por meio do site de Serviços Geológicos dos Estados Unidos, USGS (United States Geological Survey) nas datas de 24/04/2018, 09/05/2019 e 08/05/2020. Os instrumentos imageadores selecionados para o levantamento foram Sentinel-2A e Sentinel-2B.

Para a obtenção dos IVs foram utilizadas as bandas: B2 referente ao comprimento de onda azul, B3, ao verde, B4, ao vermelho, B8, ao infravermelho próximo, e B5, a borda do vermelho (Quadro 3).

QUADRO 3. Dados dos instrumentos imageadores Sentinel-2A e Sentinel- 2B.

Resolução (m)	Banda	Nome da banda	Comprimento de onda central (nm)	Largura da faixa (nm)
10	B2	Azul	490	400 a 500
	B3	Verde	560	500 a 600
	B4	Vermelho	665	600 a 800
	B8	Infravermelho Próximo	842	800 a 1000
20	B5	Borda do Vermelho	705	600 a 800

Obs.: Resoluções espaciais em metros (m), comprimentos de ondas em nanômetros (nm).

De posse das imagens, foram realizadas as correções atmosféricas pelo complemento Semi Automatic Classification Plugin do QGIS. O índice de refletância das bandas B2, B3, B4, B8 e B5, foi corrigido realizando a transformação da Refletância no Topo da Atmosfera (Top Of Atmosphere Reflectance - TOA) para Refletância na Base da Atmosfera (Bottom Of Atmosphere Reflectance – BOA). A

resolução espacial da banda B5 foi redimensionada automaticamente para 10 m no processo correção.

Os IVs foram calculados com a utilização do complemento Calculadora Raster do QGIS, algoritmo com a capacidade de realizar os cálculos referentes às expressões matemáticas de cada índice de vegetação (IV), sendo estes: IV por diferença normalizada (NDVI), Equação (1); IV por diferença normalizada da borda vermelha (NDRE), Equação (2); IV por diferença normalizada verde (GNDVI), Equação (3); IV por diferença normalizada azul (BNDVI), Equação (4); IV por diferença normalizada verde e vermelho (GRNDVI), Equação (5); IV por diferença normalizada verde com vermelho da borda (GRENDVI), Equação (6); IV por diferença normalizada PAN com verde, vermelho e azul (PNDVI), Equação (7); IV por diferença normalizada PAN com verde, vermelho da borda e azul (PRENDVI), Equação (8) (VIAN et al., 2018; FITZGERALD et al., 2006; GITELSON et al., 1996; FU-MIN et al., 2007).

$$NDVI = \frac{Nir-Red}{Nir+Red} \quad (1)$$

$$NDRE = \frac{Nir-Red\ Edge}{Nir+Red\ Edge} \quad (2)$$

$$GNDVI = \frac{Nir-Green}{Nir+Green} \quad (3)$$

$$BNDVI = \frac{Nir-Blue}{Nir+Blue} \quad (4)$$

$$GRNDVI = \frac{Nir-(Green+Red)}{Nir+(Green+Red)} \quad (5)$$

$$GRENDVI = \frac{Nir-(Green+Red\ Edge)}{Nir+(Green+Red\ Edge)} \quad (6)$$

$$PNDVI = \frac{Nir-(Green+Red+Blue)}{Nir+(Green+Red+Blue)} \quad (7)$$

$$PRENDVI = \frac{Nir-(Green+Red\ Edge+Blue)}{Nir+(Green+Red\ Edge+Blue)} \quad (8)$$

Espectros eletromagnéticos: (Nir) infravermelho próximo, (Red) vermelho, (Red Edge) borda do vermelho, (Green) verde, (Blue) azul.

Por fim, todos os IVs foram agrupados em cinco classes para a melhor visualização em forma de mapas.

3.6 Análise dos dados

3.6.1 Filtragem dos dados de produtividade

Como os sistemas de coleta de dados de produtividade embarcados em colhedoras de grão não são precisos, e geram relevante quantidade de dados discrepantes, como produtividades acima ou abaixo da real, a forma mais prática é a avaliação do desvio padrão no conjunto de dados de rendimento, onde inicialmente realiza-se a subtração da média dos dados brutos pelo desvio padrão, sendo obtido o primeiro desvio, na sequência, o segundo desvio é obtido pela subtração com o primeiro desvio, e o terceiro desvio obtido pela subtração com o segundo. O terceiro desvio será considerado como o valor da classe de corte para a menor produtividade. O mesmo é feito para a maior produtividade, porém oposto a subtração realiza-se a adição (MOLIN et al., 2015).

Após o processo de limpeza foi utilizado o software SIG em plataforma livre SAGA GIS de acordo com Conradi et al. (2015), sendo os dados interpolados pelo Inverso da Distância (IDW) Equação (9), utilizando-se como ponderador o valor 2 em virtude de uma melhor suavização do mapa (MOLIN et al. 2015; YAMAMOTO e LANDIN, 2013). Todos os dados foram dimensionados para uma resolução espacial de 10 m.

$$Z = \frac{\sum_{i=1}^n \frac{1}{d_i^p Z_i}}{\sum_{i=1}^n \frac{1}{d_i^p}} \quad (9)$$

Em que: (Z) valor estimado para um dado ponto; (n) número de pontos amostrais na vizinhança utilizados na estimativa; (Z_i) valor observado no ponto amostral; (d_i) distância entre o ponto amostral e o ponto estimado (Z_i e Z); (p) ponderador (YAMAMOTO et al., 2015).

Ao final do processo, todos os dados de produtividade foram agrupados em cinco classes para a melhor visualização em forma de mapas.

3.6.2 Estatística descritiva dos IVs e a produtividade.

Os dados dos IVs, produtividade e argila foram submetidos à análise estatística descritiva pelo software AgroStat, Barbosa e Maldonado Júnior (2015), sendo calculados: média, variância, desvio padrão, erro padrão da média e o coeficiente de variação.

3.6.3 Correlação entre os Ivs e a Produtividade

Para a determinação da correlação foram geradas matrizes de correlação pelo software AgroStat, correlacionando a produtividade e respectivos IVs no início do florescimento da cultura do milho, respectivamente estágio R2 (florescimento pleno) 65 a 70 dias após a semeadura. O coeficiente de correlação r , Equação (10), entre a produtividade e apenas um IV foi determinado pelo coeficiente de Pearson (YAMAMOTO e LANDIN, 2013).

$$r = \frac{\sum(x_i - \bar{x}) * (y_i - \bar{y})}{\sqrt{(\sum(x_i - \bar{x})^2) * (\sum(y_i - \bar{y})^2)}} \quad (10)$$

Onde: r é o coeficiente de Pearson; x_i e y_i os valores das variáveis X e Y; \bar{x} e \bar{y} médias dos valores x_i e y_i .

3.6.4 Equação de regressão

Para a definição do IV com maior potencial em termos de representatividade ao potencial produtivo da cultura do milho, foram geradas regressões lineares entre os IVs e a produtividade para o ano de 2018, sendo o coeficiente de determinação R^2 Equação (11), gerado pela utilização do software AgroStat (BARBOSA e MALDONADO JÚNIOR, 2015).

$$R^2 = 1 - \frac{SQRes}{STQ} \quad (11)$$

Onde: R^2 é o coeficiente de determinação; SQRes a soma do quadrado dos resíduos; STQ a soma total dos quadrados.

3.6.5 Estimativa da produtividade média

A estimativa da produtividade média foi obtida pela inserção do valor dos IVs a respectiva formula matemática gerada pela equação de regressão linear entre a produtividade e cada IVs no ano de 2018.

4 RESULTADOS E DISCUSSÃO

4.1 Argila e produtividade

A área experimental apresentou grande divergência em textura de solo (Figura 9), onde de acordo com o guia de agrupamento de classes de Santos, et al. (2018), 27,12 ha da área se classifica como solo de textura média, entre 150 e 350 g de argila por kg^{-1} de solo, 70,88 ha da área corresponde entre 350 a 600 g de argila por kg^{-1} solo, sendo classificado como de textura argilosa e 22,84 ha da área correspondendo a mais que 600 g de argila por kg^{-1} de solo, sendo o solo classificada como de textura muito argilosa.

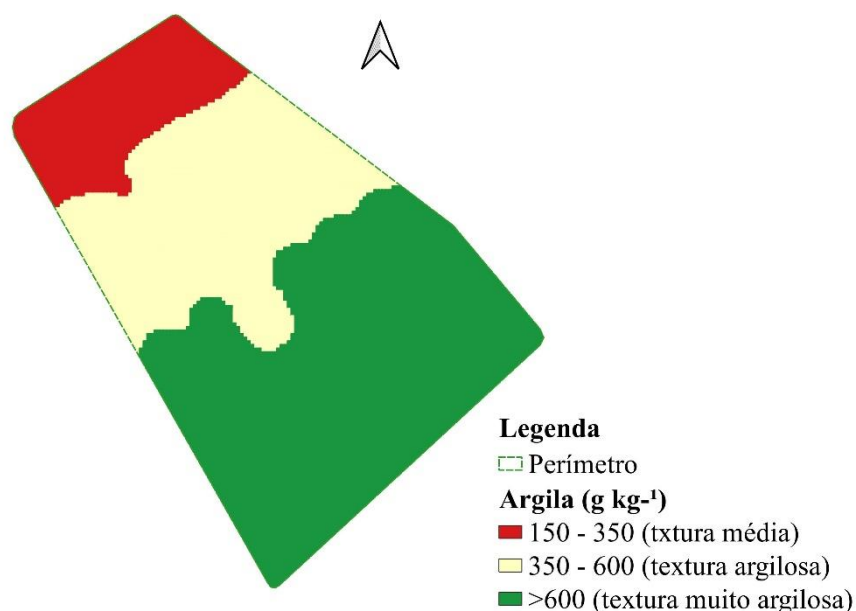


FIGURA 9. Distribuição de argila na área.

Solos com menor teor de argila tendem a possuir maior quantidade de macroporos em relação a solos mais argilosos, sendo assim retém menor conteúdo em água (SANTOS et al. (2018)).

Observa-se correlação positiva e forte entre a produtividade e o teor de argila para o ano 2018, este com índice pluviométrico de 24 mm no mês de abril (Quadro 4), mês de referências ao estágio fenológico R1, florescimento pleno para a cultura do milho, fato não observado devido ao maior índice pluviométrico dos anos 2019 com 118 mm e 2020 com 125 mm para o mês de maio, mês considerado como

referência ao estágio fenológico R1. Lima e Carvalho (2009) observaram grande correlação espacial entre a produção de forragem na cultura do milho e o teor de argila no solo.

QUADRO 4. Matriz de correlação entre o teor de Argila e Produtividade.

	Argila	Produtividade 2018	Produtividade 2019
Produtividade 2018	0,67**	-	-
Produtividade 2019	0,28**	0,37**	-
Produtividade 2020	0,25**	0,42**	0,28**

Obs.: ** (significativo a 1% de probabilidade).

Os coeficientes de determinação R^2 das regressões lineares entre a produtividade e os teores de argila também mostraram maior coeficiente para o ano de 2018, sendo este de 0,46, inversamente proporcional aos anos 2019 com 0,07 e 2020 com 0,06 (Quadro 5 e Figura 10), este coeficiente expressa a quantidade da variância dos dados que é explicada pelo modelo linear, assim, quanto maior o R^2 , mais explicativo é o modelo.

O baixo índice pluviométrico do mês de abril do ano de 2018, associado a distribuição dos teores de argila na área do estudo, valida o maior índice de determinação entre argila e a produtividade no ano de 2018 em relação aos anos 2019 e 2020 (Quadro 5, Figura 11). Como fato inerente ao baixo índice pluviométrico do mês de referência ao estágio fenológico R1, abril de 2018, florescimento pleno para a cultura do milho, a dispersão de pólen pode durar entre 5 a 8 dias, os quais, permanecem viáveis por até 24 horas após sua liberação, podendo variar de acordo com algumas condições ambientais como tempo seco e baixa umidade no solo, fazendo com que o estilo-estigma perca umidade resultando em baixa germinação do tubo polínico e conseqüentemente, baixa fecundação do óvulo, não formando grãos sendo uma das possíveis causas de falhas nas espigas e redução na produção da cultura do milho (TAZ et al., 2017; BORÉM et al., 2017), este fato se acentua em regiões com menores teores de argila, pois retém menor quantidade em água quando comparadas a regiões com maiores teores de argila.

QUADRO 5. Regressões lineares entre a produtividade e os teores de argila.

Anos	Equação	R ²	F
2018	$Y=1088,77+5,69X$	0,46	10101,25**
2019	$Y=4882,01+2,12X$	0,07	903,68**
2020	$Y=6103,16+2,09X$	0,06	849,45**

Obs.: ** (significativo a 1% de probabilidade).


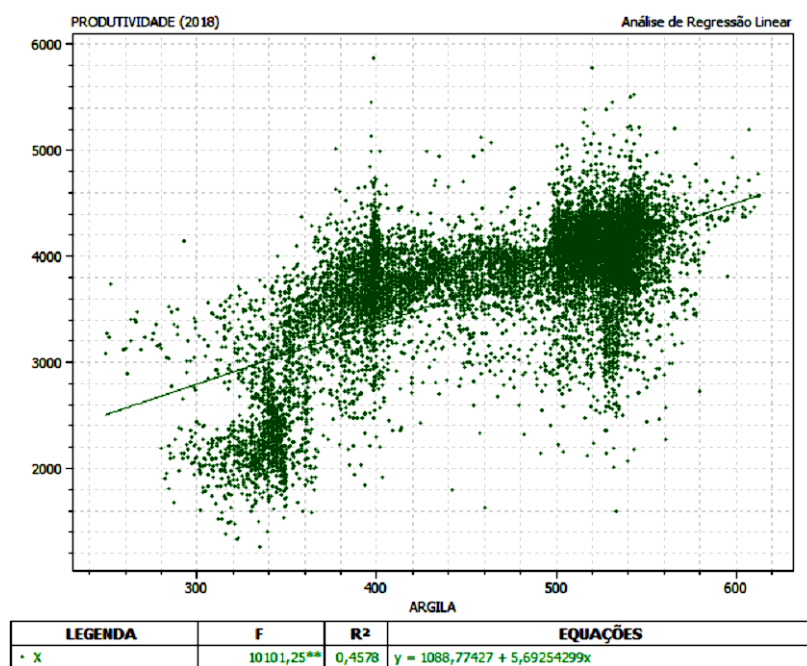


FIGURA 10. continua...




FIGURA 10. Gráficos das regressões lineares das variáveis dependente e independentes dos anos 2018, 2019 e 2020.

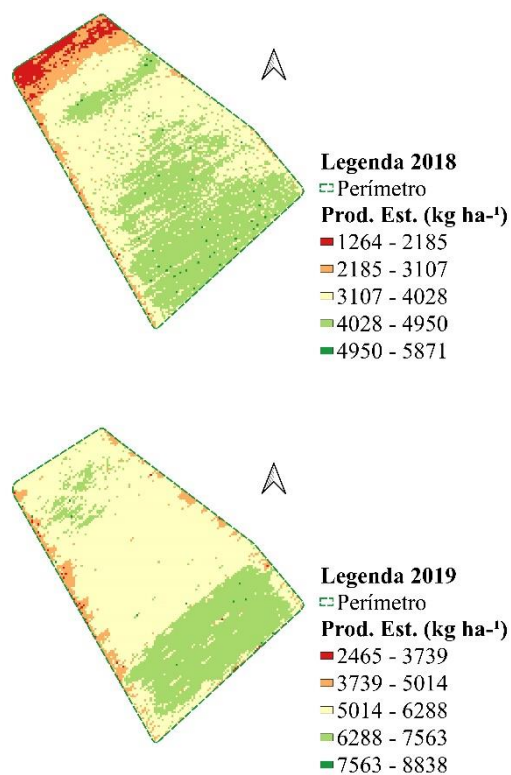
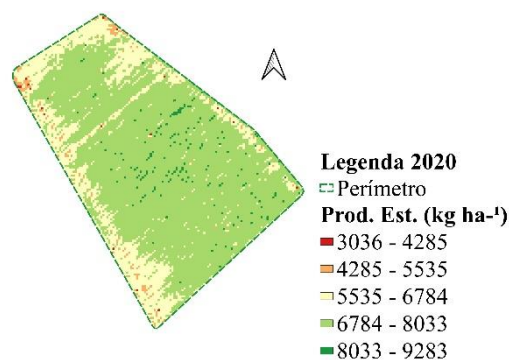


FIGURA 11. Continua...



Produtividade Estimada (Prod. Est).

FIGURA 11. Produtividade do milho nos anos de 2018, 2019 e 2020.

4.2 Índices de Vegetação e produtividade

Na estatística descritiva dos IVs podem ser observados os dados da média, amplitude, variância, desvio padrão, erro padrão da média e o coeficiente de variação (Quadro 6, 7 e 8).

Considerando as imagens coletadas nas datas de 24/04/2018, 56 dias após a semeadura 28/02/2018, 09/05/2019, 67 dias após a semeadura 03/03/2019, e 08/05/2020 66 dias após a semeadura 03/03/2020, como as melhores referências ao estágio fenológico R1, florescimento pleno para a cultura do milho. Os valores médios (M) dos IV_s foram discrepantes, podendo distinguir aqueles que apresentam maiores valores BNDVI e GNDVI daqueles com menores valores PRENDVI, PNDVI e GRENDVI (Quadro 6, 7 e 8). Bertolin et al. (2017), observaram características semelhantes para os IVs estudados.

Ao serem observados os (QUADROS 6, 7 e 8) em comparação ao (QUADRO 8), ano de referência 2020, pode ser observado menor DP e menor Coeficiente de Variação (CV) para o atributo produtividade em relação aos anos 2018 e 2019 (QUADROS 7 e 8), indicando maior precisão dos dados, logo menor erro amostral.

Também foram observados menor DP e CV para os IVs e a produtividade no ano de 2019, (Quadro 7), e 2020, (Quadro 8), comparado ao ano de 2018, (Quadro 8), fato associado a irregularidade na distribuição de chuvas no período de coleta das imagens. Baixos índices pluviométricos proporcionam alterações no tamanho e na

distribuição espacial de plantas na cultura do milho, proporcionando maior exposição do solo e interferência no cálculo dos IVs (VIAN et al., 2018).

QUADRO 6. Estatística descritiva dos IV_S e produtividade (kg ha⁻¹) safra 2018.

	M	A	V	DP	EPM	CV
BNDVI	0,79	0,21	0,00023165	0,01522013	0,00013846	1,86
GNDVI	0,70	0,21	0,00027472	0,01657461	0,00015078	2,26
NDVI	0,62	0,47	0,00127080	0,03564824	0,00032429	5,66
NDRE	0,57	0,38	0,00092231	0,03036957	0,00027627	5,94
GRNDVI	0,47	0,48	0,00146618	0,03829070	0,00034833	8,57
GRENDVI	0,38	0,41	0,00111910	0,03345296	0,00030432	9,47
PNDVI	0,35	0,45	0,00164742	0,04058839	0,00036923	11,6
PRENDVI	0,28	0,48	0,00146618	0,03829070	0,00034833	8,57
PROD.	3767	4607	390946,46	625,257111	0,00057568	16,59

Obs.: M - Média; A - Amplitude; V - Variância; DP - Desvio Padrão, EPM – Erro Padrão da Média; CV – Coeficiente de Variação (%); PROD. - Produtividade (kg ha⁻¹); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada ; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.

QUADRO 7. Estatística descritiva dos IV_S e produtividade (kg ha⁻¹) safra 2019.

	M	A	V	DP	EPM	CV
BNDVI	0,85	0,17	0,000135	0,011632	0,000106	1,37
GNDVI	0,78	0,18	0,000165	0,012860	0,000117	1,65
NDVI	0,69	0,39	0,000992	0,031498	0,000287	4,56
NDRE	0,61	0,39	0,000853	0,029209	0,000266	4,81
GRNDVI	0,53	0,41	0,001150	0,033911	0,000308	6,39
GRENDVI	0,61	0,39	0,000853	0,029209	0,000266	4,81
PNDVI	0,44	0,43	0,001295	0,035991	0,000327	8,19
PRENDVI	0,38	0,41	0,001124	0,033519	0,000305	8,87
PROD.	5881	6075	347245,25	589,2752	5,360593	10,02

Obs.: M - Média; A - Amplitude; V - Variância; DP - Desvio Padrão, EPM – Erro Padrão da Média; CV – Coeficiente de Variação (%); PROD. - Produtividade (kg ha⁻¹); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada ; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.


QUADRO 8. Estatística descritiva dos IV_s e produtividade (kg ha⁻¹) safra 2020.

	M	A	V	DP	EPM	CV
BNDVI	0,86	0,10	0,00007423	0,008615	0,000078	1,00
GNDVI	0,78	0,11	0,00009797	0,009897	0,000090	1,27
NDVI	0,83	0,21	0,00019462	0,013950	0,000126	1,68
NDRE	0,71	0,27	0,00026365	0,016237	0,000147	2,29
GRNDVI	0,64	0,24	0,00031478	0,017741	0,000161	2,76
GRENDVI	0,54	0,28	0,00036502	0,019105	0,000173	3,52
PNDVI	0,54	0,27	0,00040195	0,020048	0,000182	3,67
PRENDVI	0,46	0,30	0,00042997	0,020735	0,000188	4,54
PROD.	7091	6782	366003,742	604,9824	5,503480	8,53

Obs.: M - Média; A - Amplitude; V - Variância; DP - Desvio Padrão, EPM – Erro Padrão da Média; CV – Coeficiente de Variação (%); PROD. - Produtividade (kg ha⁻¹); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada ; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.


De maneira geral, os valores dos IVs para a cultura do milho no estádio vegetativo R1, foram estabelecidos por Vian et al. (2018) de acordo com a produtividade média, sendo esta baixa quando próxima ou abaixo do índice de 0,66, média entre 0,66 a 0,75, e alta quando maior que 0,75 respectivamente para o NDVI. Assim, observando os gráficos Box Plot das (Figuras 12, 13 e 14), estes índices podem ser correlacionados como próximos aos valores de BNDVI, GNDVI e NDVI.

Os gráficos Box Plot das (Figura 12, 13 e 14) com os dados médios dos IVs indicam que BNDVI, GNDVI e NDVI apresentaram menor variabilidade frente aos demais índices, logo foram os mais sensíveis às mudanças fisiológicas ocorridas no dossel da cultura do milho. Ao ser analisada a distribuição dos valores dos IVs e tomando o NDVI como padrão, observa-se que os dados estão próximos ao valor médio de 0,62 na safra 2018, com uma produtividade média de 3776 kg ha⁻¹, considerada baixa, 0,69 na safra 2019 com uma produtividade média de 5881 kg ha⁻¹, considerada como média e 0,83 na safra 2020, com uma produtividade média de 7267 kg ha⁻¹, considerada alta. Os IVs GNDVI e BNDVI apresentaram-se saturados, não sendo possível a distinção entre classes.




x – Média; Comprimentos de ondas (nm); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada ; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul

FIGURA 12. Box Plot dos índices de vegetação safra 2018.



x – Média; Comprimentos de ondas (nm); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada ; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.

FIGURA 13. Box Plot dos índices de vegetação safra 2019



x – Média; Comprimentos de ondas (nm); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada ; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.

FIGURA 14. Box Plot dos índices de vegetação safra 2020.

Como observação, no sentido taxativo a saturação de um IV, pode ser enfatizado que os índices BNDVI e GNDVI, tendem a saturar facilmente, atingindo valores máximos não permitindo a distinção entre classes amostrais, enquanto os índices NDVI, NDRE, GRNDVI, PNDVI, GRENDVI e PRENDVI, possibilitam distinção categórica e maior tempo para saturar. Bertolin et al. (2017) também observaram as mesmas características para o NDVI.

Foi observada alta correlação entre os IVs estudados, sendo esta superior a 86%, (Quadro 9), superior a 85%, (Quadro 10) e 60%, (Quadro 11). Para a produtividade o mesmo padrão é observado, porém com menor intensidade, variando entre 62 e 67%, (Quadro 9), 61 a 69%, (Quadro 10) e 40 a 50%, (Quadro 11). Yamamoto e Landim (2013) posicionam que correlações acima de 50% são satisfatórias. Com estes parâmetros, pode-se afirmar que os índices estudados podem ser utilizados para a estimativa da produtividade de grãos.

A substituição do comprimento de onda Vermelho pelo Vermelho da Borda, nas fórmulas dos IVs que a integram, proporcionaram melhores resultados na correlação com a produtividade (Quadro 9, 10 e 11) sendo estes NDRE, GRENDVI e

PRENDVI. Estudos de Kanke et al. (2016) mostraram que os IV_S que utilizaram o comprimento de onda da borda do vermelho, tem potencial para melhorar o algoritmo de previsão a produtividade, além de ter maior grau de relação linear com a biomassa, a absorção de N e a produtividade de grãos em comparação com índices baseados no comprimento de onda Vermelho. Há relatos também de uma melhor correlação com o índice de área foliar (FU-MIN et al., 2007).

O NDVI é um importante parâmetro para estimar o potencial produtivo da cultura do milho (VIAN et al., 2016; BERTOLIN et al., 2017). No entanto, ao se comparar os IVs dos (Quadro 9, 10 e 11), o NDVI se correlacionou com menor intensidade com a produtividade. Bagheri et al. (2013) ao estudarem IV_S na cultura do milho, verificaram que os índices se correlacionavam por meio de uma equação polinomial com doses de nitrogênio e a produtividade, onde o NDVI apresentou a menor correlação. Esse fato, associado aos dados inerentes a este experimento, indicam que o NDVI devido a utilização do comprimento de onda vermelho em sua formula será menos indicado para a estimativa da produtividade na cultura do milho.

QUADRO 9. Matriz de correlação para os índices de vegetação e produtividade 2018.

IV	PROD.	BNDVI	GNDVI	NDVI	NDRE	GRNDVI	GRENDVI	PNDVI
BNDVI	0,64**	-	-	-	-	-	-	-
GNDVI	0,66**	0,86**	-	-	-	-	-	-
NDVI	0,62**	0,89**	0,89**	-	-	-	-	-
NDRE	0,64**	0,87**	0,87**	0,95**	-	-	-	-
GRNDVI	0,67**	0,90**	0,90**	0,98**	0,96**	-	-	-
GRENDVI	0,64**	0,88**	0,88**	0,95**	0,98**	0,97**	-	-
PNDVI	0,67**	0,93**	0,93**	0,98**	0,95**	0,99**	0,97**	-
PRENDVI	0,65**	0,92**	0,92**	0,95**	0,97**	0,97**	0,98**	0,98**

Obs.: ** (significativo a 1% de probabilidade); PROD. (produtividade kg ha BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada ; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.

QUADRO 10. Matriz de correlação para os índices de vegetação e produtividade 2019.

IV	PROD.	BNDVI	GNDVI	NDVI	NDRE	GRNDVI	GRENDVI	PNDVI
BNDVI	0,61**	-	-	-	-	-	-	-
GNDVI	0,61**	0,85**	-	-	-	-	-	-
NDVI	0,68**	0,90**	0,89**	-	-	-	-	-
NDRE	0,69**	0,88**	0,91**	0,96**	-	-	-	-
GRNDVI	0,68**	0,90**	0,94**	0,99**	0,97**	-	-	-
GRENDVI	0,69**	0,88**	0,91**	0,96**	1,00**	0,97**	-	-
PNDVI	0,69**	0,93**	0,93**	0,99**	0,96**	0,99**	0,96**	-
PRENDVI	0,69**	0,92**	0,94**	0,96**	0,99**	0,98**	0,99**	0,98**

Obs.: ** (significativo a 1% de probabilidade); PROD. (produtividade kg ha⁻¹); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada ; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.

QUADRO 11. Matriz de correlação para os índices de vegetação e produtividade 2020.

IV	PROD.	BNDVI	GNDVI	NDVI	NDRE	GRNDVI	GRENDVI	PNDVI
BNDVI	0,40**	-	-	-	-	-	-	-
GNDVI	0,46**	0,60**	-	-	-	-	-	-
NDVI	0,43**	0,71**	0,69**	-	-	-	-	-
NDRE	0,44**	0,68**	0,74**	0,84**	-	-	-	-
GRNDVI	0,49**	0,72**	0,86**	0,91**	0,87**	-	-	-
GRENDVI	0,48**	0,69**	0,86**	0,84**	0,94**	0,92**	-	-
PNDVI	0,50**	0,81**	0,84**	0,91*	0,86**	0,96**	0,91**	-
PRENDVI	0,49**	0,78**	0,85**	0,85**	0,93**	0,93**	0,96**	0,94**

Obs.: ** (significativo a 1% de probabilidade); PROD. (produtividade kg ha⁻¹); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada ; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.

Mesmo o NDVI ter apresentado um resultado de menor correlação com a produtividade (Quadro 9, 10 e 11), trabalhos sugerem que este pode ser utilizado para outras aplicações que não seja a estimativa da produtividade do milho, como na pesquisa de Damian et al. (2018), que ao estudarem aplicação de dejetos em trigo, verificando a estimativa dessa aplicação por meio de IVs, constataram que apenas o

NDVI foi capaz de estimar as variações das doses de dejetos para a produtividade de grãos de trigo. Cattani et al. (2017) estudando padrões espectro-temporais de cultivares de trigo verificaram que os IVs foram consistentes na estimativa da produtividade, e ainda que, no estágio mais avançado tanto o espectro do Vermelho quanto o do da Borda do Vermelho, podem ser utilizados para diferenciar cultivares. Coelho et al. (2018) também verificaram para a aveia branca que o NDVI foi melhor estimador do que o Índice de Vegetação de Proporção Inversa, sendo um bom indicador para a determinação da produtividade após o aparecimento da folha bandeira.

O mapa de produtividade e os IVs do ano 2018 (Figura 15) indicaram que NDRE, GRENDVI e PRENDVI são índices que demoram mais a saturar, efeito observado nos mapas pela presença de classes entre 0,10 a 0,50, ou seja, valores baixos comparados com os demais índices NDVI, GNDVI e BNDVI, que apresentaram classes entre 0,20 a 0,80. Vian et al. (2018) citaram que através dos IVs foi possível separar em uma área regiões distintas em produtividade de milho.

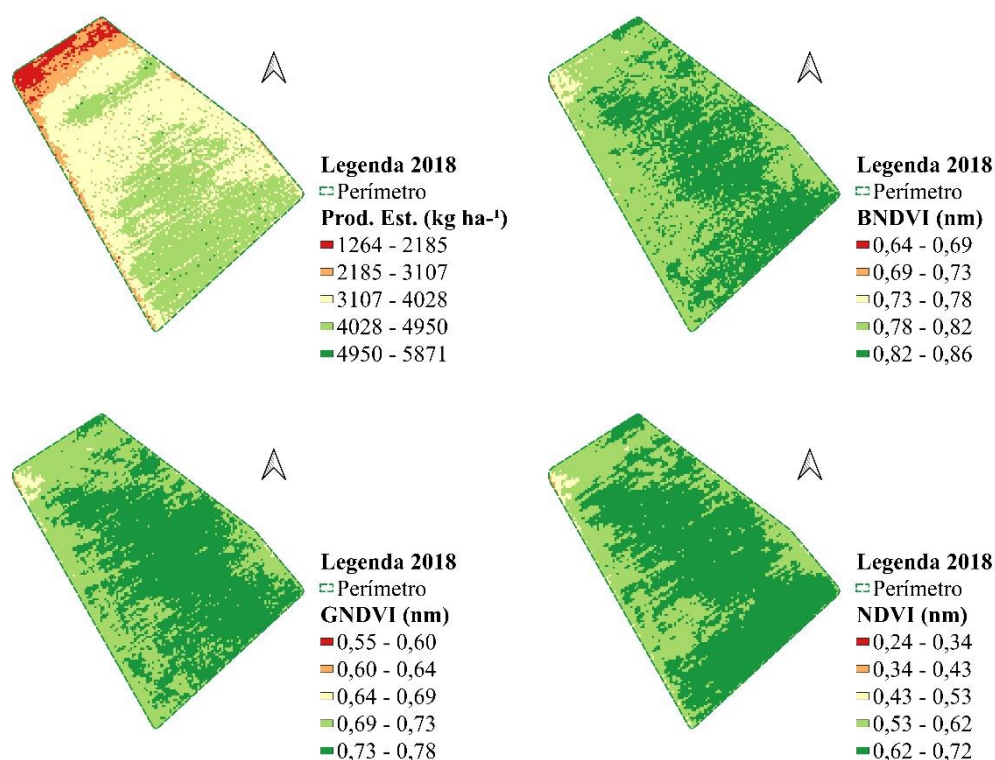
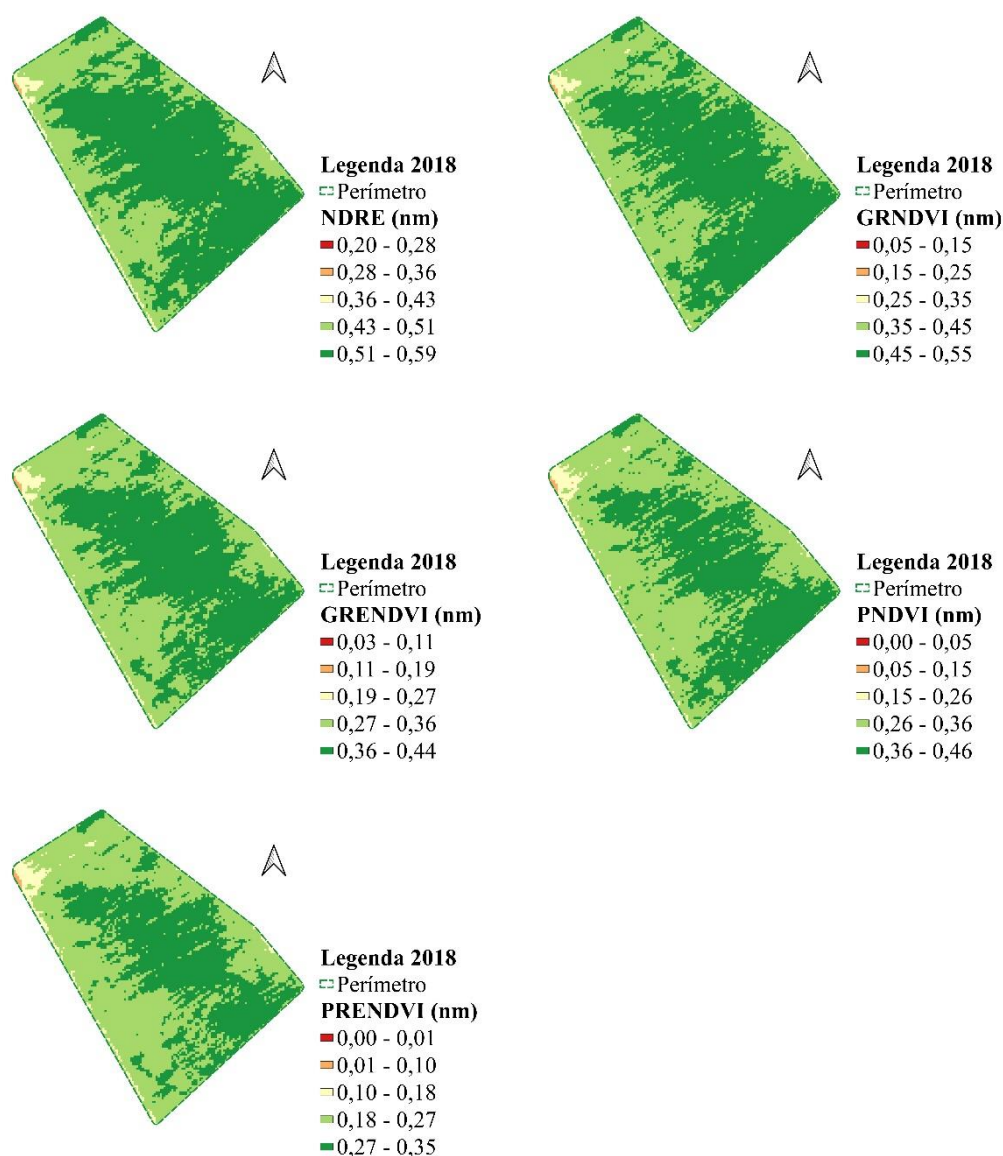


FIGURA 15. Continua...



Produtividade Estimada (Prod. Est.); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDAVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.

FIGURA 15. Produtividade do milho e índices de vegetação do ano 2018.

Como observado na (Figura 15), a produtividade de grãos apresentou elevada variabilidade espacial, sendo correlacionada a diversos aspectos da cultura, como o clima, a fertilidade solo, e a incidência de pragas e doenças. As maiores produtividades de grãos da cultura do milho, segundo Vian et al. (2016), dependem da população final e da distribuição espacial uniforme de plantas, sendo o número de

espigas por área o componente que mais contribui para a produtividade. Bernardi et al. (2017) verificaram também que há correlação entre os IV_S e os atributos do solo, como a condutividade elétrica no final do ciclo da cultura do milho, podendo estes serem indicadores de variações na cultura do milho, e serem utilizados para a definição de zonas de manejo.

4.3 Estimativa da produtividade

Os resultados das regressões lineares obtidas dos dados de produtividade e IVs do ano de 2018, indicaram que todos os IV_S podem ser utilizados na estimativa a produtividade. Os valores médios representados pelo coeficiente de determinação R² e a produtividade ficaram na ordem de 0,52 a 0,55 sendo representados no (QUADRO 12). Vian et al. (2018) ao avaliarem a estimativa da produtividade do milho irrigado por meio do NDVI, entre os estádios vegetativos V3 a V8, observaram coeficiente de determinação R² entre 0,63 e 0,83, respectivamente, e afirmam que a medida que a planta cresce esta correlação aumenta, e onde ocorre maior índice há maior produtividade.

QUADRO 12. Resultados das regressões lineares entre a produtividade e os IVs do ano 2018.

Variáveis		Equações	R ²	F	Prod Real	Prod Est	Erro
D	I						
PROD.	BNDVI	Y = -10140,84621+17657,201069X	0,53	13447,56**	3866,27	3634,20	232,07
	GNDVI	Y = -7634,752159+16255,534711X	0,54	13963,71**	3866,27	3637,25	229,02
	NDVI	Y = 109,0289615+5463,496703X	0,52	13024,57**	3866,27	3633,13	233,14
	NDRE	Y = 101,47565754+6610,9063125X	0,55	14650,35**	3866,27	3640,26	226,00
	GRNDVI	Y = -3887,105474+11051,004168X	0,54	13963,71**	3866,27	3637,25	229,02
	GRENDVI	Y = 1668,6525330+5775,3122601X	0,55	14445,41**	3866,27	3638,58	227,69
	PNDVI	Y = 2227,7225455+4622,3611183X	0,52	13251,37**	3866,27	3632,70	233,57
	PRENDVI	Y = 2388,9947011+5330,5777762X	0,54	14193,11**	3866,27	3636,88	229,38

Obs.: D (variável dependente); I (variável independente); ** (significativo a 1% de probabilidade); Y (produtividade - kg ha⁻¹); X (índice de vegetação); BNDVI – Índice de vegetação por diferença normalizada azul; GNDVI - Índice de vegetação por diferença normalizada verde; NDVI - Índice de vegetação por diferença normalizada; NDRE - Índice de vegetação por diferença normalizada com vermelho da borda; GRNDVI - Índice de vegetação por diferença normalizada verde com vermelho; GRENDVI - Índice de vegetação por diferença normalizada verde com vermelho da borda; PNDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho e azul; PRENDVI - Índice de vegetação por diferença normalizada pan com verde, vermelho da borda e azul.

5 CONCLUSÕES

No ano de menor regime hídrico 2018, os teores de argila influenciaram na produtividade da cultura do milho.

Os índices BNDVI, GNDVI saturam facilmente, atingindo valores máximos, não permitindo a distinção entre classes amostrais.

Os IVs que compuseram o comprimento de onda vermelho da borda (Red-Edge) no modelo matemático melhoram a estimativa e a correlação com a produtividade média do milho.

Os IVs que melhor se ajustaram ao modelo matemático experimental, para a estimativa da produtividade média da cultura do milho, foram o NDRE e GRENDVI apenas para o ano de 2018.

6 REFERÊNCIAS

- AMADO, T. J. C.; VILLABA, E. O.H.; BORTOLLOTO, R. P.; Nora, D. D.; BRAGAGNOLO, J.; LEON, E. A. B. Yield and nutritional efficiency of corn in response to rates and splits of nitrogen fertilization. **Revista Ceres**, v. 64, n. 4, p. 351-359, 2017.
- BAGHERI, N. A.; HOJJAT, A.; SEYED, K. A.; MAHMOUD, O. Multispectral remote sensing for site-specific nitrogen fertilizer management. **Pesquisa Agropecuária Brasileira**, v. 48, n. 10, p. 1394-1401, 2015.
- BERTOLIN, N. O.; ROBERTO, F.; LUAN, P. V.; EVERARDO, C. M. Predição da produtividade de milho irrigado com auxílio de imagens de satélite. **Revista Brasileira de Agricultura Irrigada**, v. 11, n. 4, p. 1627-1638, 2017.
- BERNARDI, A. C. C.; GREGO, C. R.; ANDRADE, R. C.; RABELLO, L. M.; INAMASU, R. Y. Spatial variability of vegetation index and soil properties in an integrated crop-livestock system. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v. 21, n. 8, p. 513-518, 2017.
- BERNARDI, A.C.C.; NAIME, J. M.; RESENDE, A.V.; BASSOI, L.H.; INAMASU, R.Y. Agricultura de Precisão. Resultados de um Novo Olhar. **Embrapa**, n. 2, P. 18-593, 2014.
- BORÉM, A.; MIRANDA, G.; V.; FRITSCHÉ, R. **Melhoramento de plantas**. 7ª ed. Viçosa: Editora UFV, 543p., 2017.
- JUNTOLLI, F. V.; SANTOS, R. L. B.; SOUB, M. C. R.; AQUINO, C. E.; FARIA, E. M.; ARGOLO, L. C.; MAIS, W. S. **Agenda Estratégica**. Ministério da Agricultura, Pecuária e Abastecimento, Brasília: BINAGRI. 21p.
- CATTANI, C.E.V.; GARCIA1, M.R.; MERCANTE1, E.; JOHANN1, J.A.; CORREA, M.M.; OLDONI1, L. V. Spectral-temporal characterization of wheat cultivars through NDVI obtained by terrestrial sensors. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 11, p. 769-773, 2017.
- CONTINI, E.; MOTA, M. M.; MARRA, R.; BORGHI, E.; MIRANDA, R. A.; SILVA, A. F.; SILVA, D. D.; MACHADO, J. R. A.; COTA, L. V.; COSTA, R. V.; MENDES, S. M. Milho - Caracterização e Desafios Tecnológicos. Relatório Técnico, Embrapa Milho e Sorgo, Brasília, 45p, 2019.
- CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WEHBERG, J.; WICHMANN, V.; BOEHNER, J. System for Automated Geoscientific Analyses (SAGA). **Geosci**. v. 8, p. 1991-2007, 2015.
- COELHO, A.P.; ROSALEN, D. L.; FARIA, R. T. Vegetation indices in the prediction of biomass and grain yield of white oat under irrigation levels. **Pesquisa Agropecuária Tropical**. v. 48, n. 2, p. 109-117, 2018.

CONAB. Companhia Nacional de Abastecimento. Série histórica das safras. Disponível em: <<https://www.Conab.gov.br/info-agro/safras/serie-historica-das-safras>>. Acessado em: 22 nov. 2018a.

CONAB. Companhia Nacional de Abastecimento. Boletim da safra de grãos. Disponível em: <<https://www.Conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>>. Acessado em: 22 nov. 2018b.

CUI, Z.; REKES, K. P. Potential of red edge spectral bands in future landsat satellites on agroecosystem canopy green leaf area index retrieval. **Remote Sensing**. v. 10, n. 1458, p. 1-14, 2018.

DAMIAN JM, MURARO DS, BASSO CJ, SILVA AN, PINTO MAB, SANTI AL. Strategies for fertilization with pig and cattle slurry in wheat crop. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v. 22, n. 4, p. 261-266, 2018.

DUARTE, J. O.; MATTOSO, M. J.; GARCIA, J. C. Importância socioeconômica. Sit: <https://www.agencia.cnptia.embrapa.br/gestor/milho/arvore/CONTAG01_8_168200511157.html>. Acessado em 12 de setembro de 2019.

EARTHEXPLORER. Sit <<https://earthexplorer.usgs.gov>>, acessado em maio 2018.

FLORES, R.A.; CUNHA, P.P.; MARCHÃO, R. L.; MORAES, F. R. **Nutrição e Aduação de Grandes Culturas na Região do Cerrado**. 1ª ed., Goiânia: UFG, 620p, 2019.

FOLEY JA, RAMANKUTTY N, ET AL. Solutions for a cultivated Planet. **Nature**, n. 478, p. 337-342, 2011.

FORMAGGIO, A. R.; SANCHES, L. Del'Arco. **Sensoriamento Remoto em agricultura**. São Paulo: Oficina de Textos, 284p, 2017.

FORMAGGIO, A. G.; MOURA, V.; EPIPHANIO, J. C. N.; SILVA, H. R.; FIORIO, P. R.; CAMPOS, R.C. Dados TM/Landsat na estimativa de áreas destinadas a culturas de verão, no estado de São Paulo. **INPE**, v. 11, p. 93-100, 2003.

FITZGERALD, G. J.; RODRIGUEZ, D.; CHRISTENSEN, L. K; BELFORD, R.; SADRAS, V. O.; CLARKE, T. R. Spectral and thermal sensing for nitrogen and water status in rainfed and irrigated wheat environments. **Precision Agriculture**, v. 7, n. 4, p 233–248, 2006.

FU-MIN, W.; JING-FENG, H.; YAN-LIN, T.; XIU-ZHEN, W. New Vegetation Index and Its Application in Estimating Leaf Area Index of Rice. **Rice Science**. v. 14, n. 3, p. 195-203, 2007.

GASQUES J G, SOUZA GS, BASTOS ET (2018) Tendências do agronegócio brasileiro para 2017-2030. Brasil alimentar o mundo. In: RODIGUES, R. Agro é paz: análises e propostas para o Brasil alimentar o mundo. ESALQ, P. 31-68, 2018.

GITELSON, A. A.; MERZLYAK, M. Remote Sensing of Chlorophyll Concentration in Higher Plant Leaves. **Advances in Space Research**. v. 22, n.5, p. 689-692, 1998.

GRECO, C. R.; OLIVEIRA, R.P.; VIEIRA, S. R. Agricultura de Precisão. Resultados de um Novo Olhar. **Embrapa**. n. 2, p. 18-593, 2014.

KÖPPEN, W.; GEIGER, R. Handbuch der Klimatologie. **Gebrüder Bornträger**. p. 1-44, 1936.

KANKE, Y.; TUBAÑA, B.; DALEN, M.; HARRELL, D. Evaluation of red and red-edge reflectance-based vegetation indices for rice biomass and grain yield prediction models in paddy fields. **Precision Agriculture**, v. 17, n. 5, p. 507-530, 2016.

LIMA, C. G. R.; CARVALHO, M. P. CORRELAÇÃO LINEAR E ESPACIAL ENTRE A PRODUTIVIDADE DE FORRAGEM DE MILHO E FRAÇÕES GRANULOMÉTRICAS DE UM LATOSSOLO VERMELHO DISTRÓFICO. **Bragantia**, VOL. 68, n. 4, p. 985-990, 2009.

LORENZZETTI, J. A. **Princípios físicos de sensoriamento remoto**. 1ª ed. São Paulo: Blucher, 293p, 2015.

MACDONALD, R. B.; HALL, F. G.; ERB, R. B. The use of Landsat data in a large area crop inventory experiment (LACIE). **LARS Symposia**, n. 46, p. 1-21, 1975.

MOLIN, J. P.; RIOS, A. M. COLAÇO, A. M. **Agricultura de precisão**. 1ª ed. Piracicaba: Oficina de Textos, 233p, 2015.

MOREIRA, M. A. **Fundamentos de sensoriamento remoto e metodologias de aplicação**. 4ª ed. Viçosa: Editora UFV, 422p, 2011.

NGIE, A.; AHAMED, F. Estimation of Maize grain yield using multispectral satellite data sets (SPOT 5) and the random forest algorithm. **South African Journal of Geomatics**, v. 7, n. 1, p. 11-30, 2018.

ROUSE, J. W.; HAAS, R. H.; WELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. **NASA**, p. 307-317, 1973.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBRERAS, J.F.; COELHO, M. R.; ALMEIDA, J. A.; ARAÚJO, J. C.; OLIVEIRA, J.B.; CUNHA, T. J. F. **Sistema Brasileiro de Classificação de Solos**. Sit <<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/181678/1/SiBCS-2018-ISBN-9788570358219-english.epub>>, acessado em agosto de 2018.

SHIRATSUCHI, L. S.; BRANDÃO, Z. N.; VICENTE, L. E.; VICTORIA, D.C.; DUCATI, J. R.; OLIVEIRA, R. P., VILELA, M.F. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A.V.; BASSOI, L. H.; INAMASU, R.Y.; **Agricultura de precisão: Resultados de um novo olhar**. 2ª ed. Brasília: Embrapa. 596p, 2014.

TAIZ, L.; ZEIGER, E.; MOLLER, I.; M.; MURPHY, A. **Fisiologia e desenvolvimento vegetal**. 6ª ed. Porto Alegre: Artmed, 731p, 2017.

TRINDADE, F. S.; ALVES, M. C.; Noetzold, r.; ANDRADE, I. C.; POZZA, A. A. A. Relação espectro-temporal de índices de vegetação com atributos do solo e produtividade da soja. *Amazonian Jornal*, vol. 62, p. 1-11, 2019.

USDA. United States Department of Agriculture. Grain: world markets and trade. Disponível em: <<https://www.fas.usda.gov/data/grain-world-markets-and-trade>>. Acessado em: 22 nov. 2018a.

USDA. United States Department of Agriculture. World agricultural production. Disponível em: <<https://www.fas.usda.gov/data/world-agricultural-production>>. Acessado em: 22 nov. 2018b.

VIAN, A. L.; SANTI, A. L.; AMADO, T. J. C.; CHERUBIN, M. R.; SIMON, D. H.; DAMIAN J. M.; BREDEMEIER, C. Variabilidade espacial da produtividade de milho irrigado e sua correlação com variáveis explicativas de planta. **Ciência Rural**, v. 46, n. 3, p. 464-471, 2016.

VIAN, A. L.; BREDEMEIER, C.; SILVA, P. R. F.; SANTI, A. L.; GIORDANO, C. P. S.; SANTOS, F. L. Limites críticos de NDVI para estimativa do potencial produtivo do milho. **Revista Brasileira de Milho e Sorgo**, v. 17, n. 1, p. 91-100, 2018.

YAMAMOTO, K. Y.; LANDIM, P. M. B. **Geoestatística conceitos e aplicação**. 1ª ed. Jaboticaba: Oficina de Textos, 215p, 2013.

ZERBATO, C.; ROSALEN, D. L.; FURLANI, C. E. A.; DEGHAID, J.; VOLTARELLI, M. A. Agronomic characteristics associated with the normalized difference vegetation index (NDVI) in the peanut crop. **Australian Journal of Crop Science**, v. 10, p.758-764, 2016.