

**UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS DE CHAPADINHA
CURSO DE ENGENHARIA AGRÍCOLA**

**ELABORAÇÃO DE MAPA DE PRODUTIVIDADE EM LAVOURA DE
SOJA E CORRELAÇÕES COM ÍNDICES DE VEGETAÇÃO**

**Chapadinha – MA
Dezembro de 2023**

LUÍS EDUARDO CARVALHO SILVA

**ELABORAÇÃO DE MAPA DE PRODUTIVIDADE EM LAVOURA DE
SOJA E CORRELAÇÕES COM ÍNDICES DE VEGETAÇÃO**

Trabalho de Conclusão de Curso apresentado à coordenação de Engenharia Agrícola da Universidade Federal do Maranhão, como requisito para obtenção do título de Bacharel em Engenharia Agrícola.

Orientador: Prof. Dr. Marcus Willame Lopes Carvalho.

Coorientador: Me. Eduardo Arouche da Silva.

**Chapadinha – MA
Dezembro de 2023**

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Silva, Luís Eduardo Carvalho.

ELABORAÇÃO DE MAPA DE PRODUTIVIDADE EM LAVOURA DE SOJA
E CORRELAÇÕES COM ÍNDICES DE VEGETAÇÃO / Luís Eduardo
Carvalho Silva. - 2023.

40 f.

Coorientador(a): Eduardo Arouche da Silva.

Orientador(a): Marcus Willame Lopes Carvalho.

Curso de Engenharia Agrícola, Universidade Federal do
Maranhão, Chapadinha, 2023.

1. Agricultura de Precisão. 2. Colheita. 3.
Correlação. 4. Mecanização. 5. Produção. I. Carvalho,
Marcus Willame Lopes. II. Silva, Eduardo Arouche da. III.
Título.

LUÍS EDUARDO CARVALHO SILVA

**ELABORAÇÃO DE MAPA DE PRODUTIVIDADE EM LAVOURA DE
SOJA E CORRELAÇÕES COM ÍNDICES DE VEGETAÇÃO**

Trabalho de conclusão de curso apresentado a coordenação do curso de Engenharia Agrícola, da Universidade Federal do Maranhão como requisito indispensável para a obtenção do título de Bacharel em Engenheiro Agrícola.

Nota:_____.

Defendido e aprovado em _____ de _____ de _____, pela comissão examinadora constituída pelos professores:

Marcus Willame Lopes Carvalho (Orientador)

Doutorado em Agronomia pela Universidade Federal do Piauí (UFPI)

Professor Adjunto do curso de Engenharia Agrícola (CCCh/UFMA)

Eduardo Arouche da Silva (Co-orientador)

Engenheiro Agrícola pela Universidade Federal do Maranhão (UFMA/CCCh)

Mestre em Engenharia de Sistemas Agrícola pela Escola Superior de Agricultura Luiz de Queiroz (ESALQ/USP)

Washington da Silva Sousa (Avaliador)

Doutorado em Física pela Universidade de São Paulo (USP)

Professor Adjunto do curso de Engenharia Agrícola (CCCh/UFMA)

Eduardo Silva dos Santos (Avaliador)

Doutorado em Engenharia Agrícola pela Universidade Federal Rural de Pernambuco (UFRPE)

Professor Adjunto do curso de Engenharia Agrícola (CCCh/UFMA)

Dedico este trabalho a minha mãe,
Raimunda Souza Carvalho, que não
mediu forças para que este nosso sonho se
concretizasse.

AGRADECIMENTOS

A Deus, em primeiro lugar, que foi e sempre será meu alicerce me dando força, coragem e perseverança para que esse sonho se realizasse.

A minha mãe, Raimunda Souza Carvalho, que segurou minha mão e caminhou comigo durante todo meu percurso dentro e fora da universidade, me incentivando, guiando e comemorando minhas vitórias. Te amo mãe.

Ao meu pai, Francisco Lima da Silva, que sempre me apoiou e acreditou no meu potencial.

Aos meus avós Gessir Carvalho, Nelson Sousa, Manoel da Silva e Maria Helena da Silva (*in memoriam*) que sempre estiveram comigo me apoiando e me incentivando. Amo todos vocês.

A todos da minha família, em especial meus primos, Jadson Carvalho de Aguiar e Carina Silva Carvalho, que sempre acreditaram em mim e me ajudaram a realizar mais um sonho.

Ao meu orientador professor Marcus Willame Lopes Carvalho e co-orientador Eduardo Arouche da Silva pelos aprendizados, paciência e amizade ao longo do curso e desenvolvimento deste trabalho.

A todos os meus amigos, que sempre me ajudaram e me apoiaram durante a minha trajetória acadêmica. Em especial a, Renata Gamboa Silva, João Mateus Santana dos Santos, Melissa Lima da Silva, Elida Costa Rabelo, Bruna da Silva Brito Ribeiro, Elayne Silva Carvalho e Marcus Vinícius Amorim Pontes. Obrigado pelo companheirismo, vocês são os melhores.

A professora Daiane Fossati Dalloglio e Julianna Santos Farias Castelo Branco e Fabiano de Carvalho Simas que são grandes incentivadores da educação e exemplos de profissionais para mim.

A Universidade Federal do Maranhão pela oportunidade de realizar um sonho e conhecer pessoas maravilhosas e a todos os professores pelos conhecimentos adquiridos e aos funcionários pelo zelo do nosso Centro de Ciências de Chapadinha ao longo destes anos.

“O sucesso é uma soma de pequenos
esforços repetidos dia após dia.”

Roberto Collier

SUMÁRIO

1. INTRODUÇÃO	9
2. OBJETIVOS	10
2.1 Objetivo geral.....	10
2.2 Objetivos específicos	10
3. REVISÃO DE LITERATURA	10
3.1. Produção de soja (<i>Glycine Max</i>) no Brasil.....	11
3.2. Agricultura de precisão	12
3.2. Dados brutos provenientes da colheita mecanizada	14
3.3. Filtragem de dados brutos	16
3.4. Índices de vegetação (NDVI e EVI).....	17
3.5. Importância dos mapas de produtividade, NDVI e EVI.....	18
4. MATERIAL E MÉTODOS.....	20
4.1. Caracterização da área de estudo	20
4.2. Procedimentos e Ferramentas utilizados para a pesquisa	20
4.3. Processamento de Imagens	22
4.4. Correlação dos dados.....	24
5. RESULTADOS E DISCUSSÃO	24
5.1. MAPAS DE PRODUTIVIDADE	24
5.2. MAPAS DOS ÍNDICES DE VEGETAÇÃO (IVs)	26
5.3. CORRELAÇÃO DA PRODUTIVIDADE COM OS IVs	28
6. CONCLUSÕES	30
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	31

LISTA DE FIGURAS

Figura 1. Mapa de localização da área de estudo..	19
Figura 2. Mapas de produtividade. (A) Dado bruto; (B) Dado bruto filtrado.	24
Figura 3. NDVI em 26/02/2022 (A) e NDVI em 02/04/2022 (B).	26
Figura 4. EVI em 26/02/2022 (A) e em 02/04/2022 (B).	27
Figura 5. Gráfico de correlação entre produtividade e índices de vegetação. (A) NDVI em 26/02/2022; (B) NDVI em 02/04/2022; (C) EVI em 26/02/2022; (D) EVI em 02/04/2022.	28

LISTA DE TABELAS

Tabela 1. Quantidade de pontos e produtividade mínima e máxima antes e após filtragem dos dados.	24
Tabela 2. Coeficiente de determinação (R^2) e coeficiente de Pearson (r) dos IVs.	29

LISTA DE EQUAÇÕES

Equação 1.....	21
Equação 2.....	22
Equação 3.....	22

LISTA DE SIGLAS

AP	Agricultura de Precisão
DP	Desvio Padrão
EVI	Índice de Vegetação Melhorado
GPS	Sistema de Posicionamento Global
IAF	Índice de Área Foliar
IDW	Inverso da Distância à Potência
IVs	Índice de Vegetação
NDVI	Índice de Vegetação por Diferença Normalizada
SIG	Sistema de Informação Geográfica
VANT	Veículo Aéreo Não Tripulado

RESUMO

A agricultura 4.0 está fazendo com que o setor agrícola use mais tecnologia, como mapas de produtividade e mapas de índice de vegetação, para auxiliar no manejo das lavouras. Desta forma, este trabalho objetivou correlacionar os índices de vegetação com o mapa de produtividade gerado a partir da filtragem de dados brutos provindo da colheita mecanizada. Para tal finalidade, utilizou dados brutos obtidos do monitor de colheita Gen4 Command Center™ que foram filtrados utilizando o desvio padrão, onde pontos que se situavam a mais de 2,5 DP acima ou abaixo da média de produtividade foram excluídos e para o cálculo dos índices de vegetação (NDVI e EVI) foram utilizadas imagens do satélite Sentinel-2 em duas datas diferentes, correspondendo às fases vegetativa (R3) e reprodutiva (R7), sem a presença de nuvens sobre a área de estudo. Verificou-se que a filtragem dos dados brutos excluiu cerca de 13.467 pontos associados a erros de colheita e permitiu uma melhor visualização do mapa de produtividade. O índice NDVI para as duas datas obteve valores superiores a 0,60, o índice EVI demonstrou valores abaixo de 0,40 para as duas datas. Constatou-se a baixa representatividade dos dados entre a produtividade e os índices de vegetação com valores de R^2 variando entre 0,01 a 0,064, assim, precisamos de mais pesquisas para correlacionar os IVs com valores de produtividade.

Palavras-chave: Agricultura de Precisão, Mecanização, Colheita, Produção, Correlação.

ABSTRACT

Agriculture 4.0 is causing the agricultural sector to use more technology, such as productivity maps and vegetation index maps, to help manage crops. Therefore, this work aimed to correlate the vegetation indices with the productivity map generated from the filtering of raw data from mechanized harvesting. For this purpose, raw data obtained from the Gen4 Command Center™ harvest monitor was used, which were filtered using the standard deviation, where points that were more than 2.5 SD above or below the productivity average were excluded and to calculate the indices. of vegetation (NDVI and EVI) images from the Sentinel-2 satellite were used on two different dates, corresponding to the vegetative (R3) and reproductive (R7) phases, without the presence of clouds over the study area. It was found that filtering the raw data excluded around 13,467 points associated with harvesting errors and allowed a better visualization of the productivity map. The NDVI index for both dates obtained values above 0.60, the EVI index showed values below 0.40 for both dates. The low representation of the data between productivity and vegetation indices was found, with R2 values varying between 0.01 and 0.064, so we need more research to correlate the IVs with productivity values.

Keywords: Precision Agriculture, Mechanization, Harvest, Production, Correlation.

1. INTRODUÇÃO

Com o aumento significativo na produção agrícola e os crescentes custos associados, foram adotadas tecnologias para otimizar os recursos, viabilizando a produção em larga escala. Isso visa não apenas reduzir os custos de mão de obra, mas também auxiliar na gestão e na tomada de decisões (Santos, 2020).

A Agricultura de Precisão (AP) representa uma abordagem de gestão agrícola que visa compreender minuciosamente uma plantação, incluindo todas as suas flutuações espaciais e temporais, a fim de otimizar o manejo do solo, o uso de insumos e o cultivo, visando alcançar uma produção mais eficiente (Junges, 2020). Neste cenário, os mapas de produtividade se tornaram uma fonte de informações essenciais para a agricultura de precisão, uma vez que representam de maneira tangível os resultados dos esforços direcionados para aprimorar a produção agrícola.

De acordo com Junges (2020) esses mapas consistem em um conjunto de dados coletados pelos sensores disponíveis nas colhedoras durante a sua operação, ilustrando a quantidade de grãos colhidos em diferentes seções do talhão, a posição geográfica, a umidade dos grãos e o tamanho da área colhida.

A automação das colhedoras para monitorar a produtividade através de mapas de produtividade possibilita a coleta de uma vasta quantidade de dados, frequentemente resultando em erros durante esse processo de coleta. Menegatti e Mollin (2004) resalta que os arquivos de dados brutos apresentam erros significativos, incluindo imprecisões na localização, registros de produtividade ausentes ou nulos, interpretações incorretas da largura da plataforma, falta de informações sobre umidade, distâncias entre pontos inexistentes, intervalos de enchimento problemáticos e valores de produtividade discrepantes. Esses dados brutos antes da produção de um mapa de produtividade devem ser observados cuidadosamente (Menegatti e Mollin, 2003).

Tylén *et al.*, (1997) conseguiram identificar vários erros nos mapas de produtividade de grãos, sendo relacionados a diferentes fontes de erro. Estes foram classificados conforme as seguintes origens: características físicas da colhedora, sistema de medição da produtividade, variações intrínsecas no talhão, ações do operador e procedimentos envolvidos na obtenção do mapa.

Outra forma de monitorar uma lavoura é por meio da avaliação da cobertura vegetal. A elaboração de mapas através da modelagem dos índices de vegetação é

fundamental na observação da quantidade e condições da vegetação. Esta análise é feita por meio do agrupamento das informações de reflectância portada pelas bandas geradas por sensores de satélites. Desta forma à medida em que a densidade vegetal aumenta, a reflectância diminui, devido à absorção da radiação pelos pigmentos fotossintetizantes. Por outro lado, quanto maior a densidade vegetal, maior é a reflectância, devido à propagação da luz nas várias camadas das folhas (Boratto e Gomidea, 2013).

O emprego do Índice de Vegetação por Diferença Normalizada (NDVI) e Índice de Vegetação Melhorado (EVI) no monitoramento de coberturas vegetais, no acompanhamento do crescimento e desenvolvimento de culturas é generalizado e tem se destacado em várias regiões do mundo. É importante observarmos que a eficácia dos dados obtidos está sujeita a vários fatores, por exemplo a combinação de índices e condições climáticas (Silva, 2021). Em algumas culturas agrícolas a produtividade pode ser medida pelo nível de biomassa disponível e os índices de vegetação calculados a partir de imagens orbitais e suborbitais, sendo bons indicativos para estimativa de produtividade (Speranza *et al.*, 2023).

Portanto, para a estimativa da produtividade por meio dos índices de vegetação a filtragem de dados brutos desempenha um papel crucial na garantia de que os dados usados em análises subsequentes sejam confiáveis e representativos da realidade. Sem esse processo, os resultados das análises podem ser distorcidos, levando a conclusões incorretas e decisões inadequadas. Assim, é uma prática essencial em qualquer projeto de análise de dados, pesquisa científica ou tomada de decisão baseada em dados.

2. OBJETIVOS

2.1 Objetivo geral

Correlacionar os índices de vegetação com o mapa de produtividade gerado a partir da filtragem de dados brutos provindo da colheita mecanizada em lavoura de soja.

2.2 Objetivos específicos

- Filtragem dos dados brutos de colheita de soja e geração de mapa de produtividade;
- Geração de mapas de NDVI e EVI;
- Correlacionar dados de produtividade com os índices de vegetação.

3. REVISÃO DE LITERATURA

3.1. Produção de soja (*Glycine Max*) no Brasil

O Brasil destaca-se como um dos países de maior produção de cereais do mundo (Yu et al. 2019), o crescimento equilibrado e a otimização das áreas cultiváveis, juntamente com melhorias na produtividade, contribuem para o aumento da produção agrícola. Esses elementos desempenham um papel crucial na minimização dos impactos ambientais, sendo reconhecidos como um dos caminhos para alcançar a produção sustentável (Silva, 2021).

Assegurar a máxima produtividade da monocultura de soja (*Glycine max*) é crucial para a economia do país (Conab 2021). Conforme destacado por Agussabti et al (2020), não basta apenas aumentar as áreas de cultivo é essencial considerar fatores como o manejo adotado, as características físicas e químicas do solo, bem como o controle de pragas e doenças que podem impactar o potencial produtivo.

Segundo Hirakuri e Lazzaroto (2014), a produção de soja tem aumentado consistentemente no cenário interno, impulsionada pelo crescente índice de produtividade. Na região Sul, esse avanço resulta da expansão da sojicultura para áreas previamente destinadas a outros cultivos e pastagens, integrando a cultura em sistemas de produção anteriormente não explorados. Já na região Centro-Oeste, o avanço da soja é mais expressivo, especialmente em extensas áreas de pastagens degradadas, que são incorporadas para a produção exclusiva de grãos.

Em Goiás, o desenvolvimento agrícola foi influenciado pelas políticas públicas com o objetivo de ampliar a participação do estado na economia e nas exportações, impulsionado pelo aumento da produção de commodities. A infraestrutura necessária para novos investimentos foi expandida durante os projetos de integração nacional, com destaque para a década de 1950, marcada pela construção de Brasília e das rodovias que facilitaram a mobilidade de capital e trabalho em todo o território brasileiro (Bezerra e Cleps Jr, 2004).

Machado (2014) afirma que, a cultura da soja foi introduzida em Goiás em 1950, mas não se expandiu devido à ausência de programas específicos e incentivos governamentais para promover o desenvolvimento agrícola naquele período. A expansão da cultura da soja em Goiás começou na década de 1960, impulsionada por uma campanha de diversificação agrícola. Nesse período, a cultura enfrentava desafios devido

à falta de técnicas de cultivo adequadas ao cerrado, sendo necessário adaptar a soja ao fotoperíodo e às condições climáticas locais (Pedroso e Silva, 2005).

Conforme citado por Pires e Ramos (2009), o crescimento do agronegócio no estado do Goiás foi marcado pela disseminação do cultivo de soja no estado. No entanto, essa expansão não foi uniforme, pois em algumas regiões, a soja experimentou um crescimento significativo, enquanto em outras não alcançou uma importância considerável na produção. A soja desempenhou um papel crucial na transformação da base produtiva de Goiás, sendo a cultura mais incentivada pelo estado por meio de políticas de financiamento e apoio à cadeia produtiva, destacando-se das demais culturas.

3.2. Agricultura de precisão

Agricultura de Precisão (AP) é o conceito relacionado a técnicas específicas utilizadas para manejar o solo, obter características da área, verificar a variabilidade dentro do talhão agrícola e técnicas relacionadas ao planejamento da safra e da cadeia produtiva como um todo. A análise do solo, mapa de produtividade e atividades relacionadas ao gerenciamento são as principais ferramentas da Agricultura de Precisão (Balafoutis *et al.*, 2017). Atualmente os diversos setores econômicos do país procuram se destacar de maneiras diferentes, e uma delas é o uso da tecnologia em busca de aumentar a visibilidade e a produção. A agricultura atualmente abrange essas novas tecnologias e utilizam com o intuito de monitorar, fiscalizar, otimizar e aumentar a produtividade. De acordo com Nunes (2018), o setor agrícola utiliza com frequência geotecnologias, principalmente pelo fato de que os Sistemas de Posicionamento Global (GPS) proporcionam diversas vantagens ao setor, uma delas é o controle da área, e a partir dessas informações o produtor obtém diversos produtos, como o mapa de produtividade.

Nunes, (2018) reforça a vantagem de trocar sistemas convencionais para os sistemas automáticos e mais tecnológicos da Agricultura de Precisão, essa mudança se tornou necessária quando otimiza o tempo do produtor em relação ao planejamento e manejo das produções, a datar dessas aplicações de geotecnologias e outras tecnologias, as informações detalhadas sobre diversas áreas de cultivo estão no alcance do produtor sem que ele precise se deslocar até a área cultivada.

Grande parte dos especialistas consideram a AP como uma aliada na tomada de decisão e no planejamento de safras. O conjunto de informações provenientes de estudos e análises da Agricultura digital, conforme Guedes e Dorneles (2017) otimizam as práticas nos sistemas agrícolas, buscando o manejo assertivo através dos fatores que

envolvem toda a cadeia produtiva. A variabilidade dentro da produção agrícola, é o principal motivo de se utilizar a AP para verificação de diferentes áreas.

Com intuito de solucionar problemas dentro das unidades produtoras, principalmente de grãos, Roza (2017) sugere utilizar a Agricultura Digital nessas áreas extensas, e verificar se há homogeneidade ou não dentro do perímetro de interesse, e a partir da verificação das necessidades desses talhões recomendar as aplicações necessárias e cabíveis como: insumos, defensivos, fertilizantes e até irrigação.

Nos anos de 1700, as máquinas agrícolas eram tracionadas apenas por tração animal, e somente após as revoluções industriais esse maquinário começou utilizar combustíveis dos mais diversos para se locomoverem. As máquinas desenvolvidas na época, com intuito de trabalhar dentro das lavouras comerciais eram maiores, e mais pesadas que as atuais, resultando na compactação do solo, na má infiltração da água na área e conseqüentemente pouca produtividade no final na época da colheita (Durigon e Schlosser, 2018).

Carvalho (2017) afirma que, as primeiras máquinas colhedoras de grãos utilizadas em campo no Brasil, começaram a ser utilizadas na década de 60, em sua maioria as máquinas tinham capacidade de colher 500 sacas por dia, o que para a época era uma máquina com maior tecnificação. Atualmente essas máquinas colhem cerca de seis vezes mais.

Diante da vasta evolução, as operações mecanizadas foram adaptadas a operarem com mais eficiência e de forma específica em cada uma das regiões diagnosticadas dentro de uma análise de talhão. Existe a necessidade de processamentos mais avançados para realizar o diagnóstico e aplicação dentro do campo. Porém, a indústria de máquinas atende às solicitações para a realização dessas tarefas cada vez mais precisas e detalhadas, destacando equipamento capazes de realizarem intervenções em tempo real (EMBRAPA, 2018).

As diferentes categorias de máquinas agrícolas, de acordo com Buck (2020) necessariamente não são de forma diretas as responsáveis pelo aumento da produtividade em si, é de extrema importância garantir a correta regulagem destas, afim de poder auxiliar na redução de perdas mecânicas que, muitas vezes, podem se mostrar bastante significativas. Realizar de forma periódica a revisão minuciosa de cada componente das colhedoras destaca a atenção que os produtores devem dedicar ao longo de toda a safra. Isso se deve ao fato de que, quando os sensores estão bem calibrados e existe a distância

apropriada entre o molinete e a barra de corte, o côncavo mais próximo do rotor para permitir o maior impacto nos grãos e garantir a limpeza, além de manter as lâminas da barra de corte em perfeito funcionamento, é possível evitar a evasão.

Ainda de acordo com Burck (2020) as diversas tecnologias acopladas às máquinas agrícolas colaboraram para o aprimoramento do processo de colheita de grãos, como soja, milho e trigo, nas regiões do Sul e do Centro-Oeste brasileiro, que são os principais produtores de grãos do país nesse período. Contudo, essa situação começou a se transformar nos primeiros anos dos anos 2000, quando houve o fortalecimento e expansão da agricultura de precisão no país. Devido a expansão da AP, os produtores passaram a ter um melhor fluxo operacional de máquinas como a colhedora dentro das lavouras de forma concisa e precisa evitando e diminuindo perdas nessa atividade.

Diante da necessidade da melhoria das operações de colheita, segundo Carvalho (2017), atualmente grandes indústrias iniciaram a implementação de mais tecnologia nas colhedoras de grande porte. Esse progresso das máquinas agrícolas ocorreu por meio do avanço de tecnologias que até então não eram utilizadas nas lavouras, como o Sistema de Navegação Global por Satélites (GNSS). Após a adequação nessas máquinas agrícola, estas a ter possibilidade de empregar mapas georreferenciados e sensores, que viabilizam a mensuração da variabilidade espacial de uma determinada área ou talhão. Com a possibilidade de subdividir os hectares da propriedade em microáreas para análise de produtividade e fertilidade do solo mais minuciosas, surgem estratégias como semeadura de sementes e aplicação de fertilizantes em taxas variáveis, o que resulta na otimização das operações e, conseqüentemente, na economia de recursos (EMBRAPA, 2018).

Descrito por Durigon e Schlosser (2018), o operador tem vantagens durante a operação de colheita, relacionadas ao posicionamento da máquina. A utilização do piloto automático diminui as perdas na colheita e até a compactação no solo, pois o percurso dentro da lavoura é totalmente planejado, evitando repetir a mesma área.

3.2. Dados brutos provenientes da colheita mecanizada

Dentre as definições de agricultura de precisão, conforme Leonardo e Molim (2017) discorrem, todas abrangem o gerenciamento agrícola, levando em consideração a variabilidade referente aos fatores de produção, fatores ambientais, sustentáveis e que busquem lucro. Neste sentido, a variabilidade espacial dentro do sistema se torna ampla pela quantidade de informações adquirida ao longo das análises.

A mensuração da produtividade é um processo totalmente automatizado que utiliza sensores instalados nas colhedoras para determinar com relativa precisão a quantidade de produto colhido e a área onde foi produzido. Os receptores GPS fornecem recursos de posicionamento e georreferenciamento da área de produção que permitem este mapeamento mais preciso. Por ser uma operação automatizada, esse processo pode coletar grande quantidade de dados, o que podem gerar erros segundo Guilhoto e Sesso Filho (2017).

A presença de erros ou falhas no momento das atividades com máquinas agrícolas impactam de forma significativa toda a produtividade final e podem ter um impacto económico significativo. Nesse sentido, recomenda-se levar em consideração os volumes de produção com perdas eliminadas as quais podem de forma gradual aumentar as receitas de exportação e conseqüentemente aumentar a demanda por serviços do comércio dessa cadeia de produção, transporte e processamento de produtos. Além disso, uma maior oferta leva a preços mais baixos dos produtos (Molin e Gimenez, 2018).

Costa e Guilhoto *et al.* (2017) verificaram em pesquisas, dados de seis anos consecutivos de mapeamento de produtividade e identificaram erros como suavização, calibração de volume, largura incorreta da plataforma de corte e tempo de enchimento da colhedora. Leonardo e Molin (2017) também citam erros de posicionamento referentes a essa operação de colheita, erros por retorno de grãos nos mecanismos de trilha e retenção da colhedora, perda de grãos da colhedora e precisão dos sensores de produtividade e desenvolvem rotinas de redução de erros.

Uma das primeiras propostas para reduzir erros em mapas de produtividade foi proposta por Blackmore e Marshall (1996) e foi chamada de mapeamento potencial. A tecnologia desenvolvida propõe que o monitor de produtividade registrasse a massa colhida e não a massa por área. Os dados são então inseridos em um sistema de informação geográfica (SIG) para definir áreas que representam cada local, e o próprio GIS obtém produtividade. Essa tecnologia elimina erros na medição de área e largura da plataforma, pois a área é calculada pós-colheita (Guilhoto e Sesso Filho, 2017).

De acordo com Menegatti e Molin (2004) os mapas de produtividade utilizam os pontos gerados nos monitores das colhedoras, todos esses pontos apresentam ordem e coordenadas. De uma mesma área é obtida diversas informações, e existe opções para estudar e processar estas de forma coerente, dentre elas podemos citar a interpolação. Menegatti e Molin (p. 128-129, 2004) afirmam que “na agricultura de precisão utilizam-

se, basicamente, os algoritmos de interpolação, denominados inverso da distância a determinada potência e krigagem”. De acordo com Costa e Guilhoto et al. (2017), apresenta o inverso da proposta de Menegatti e Molin (2004), sendo este é necessário estipular os pesos dos respectivos pontos que estão posicionados inversamente proporcionais à distância, feito isso elevada a uma potência usual quadrática.

3.3. Filtragem de dados brutos

A colheita monitorizada, de acordo com Silva e Borges (2018), consiste em múltiplos processos nos quais podem ocorrer erros, pelo que é necessário um método de filtragem de dados para obter mapas confiáveis que giram em torno dos principais fatores de erro, nomeadamente tempo de processamento e latência. O tempo de atraso é o tempo entre o corte da planta na barra de corte da plataforma e o tempo que o grão passa pelos sensores de produtividade e umidade. Para determinar esses erros, analisa-se um conjunto de dados para 10 tempos de atraso diferentes, variando de 0 a 27 segundos com intervalos de 3 segundos. A filtragem determina primeiramente os tempos de enchimento e esvaziamento, ou seja, o momento em que todos os espaços e componentes internos da colhedora são preenchidos ou esvaziados com grande quantidade de grãos, o que ocorre a cada entrada e saída da colhedora (Michelan, 2005).

A filtragem pós-processamento de erros em gráficos de produtividade tornou-se uma prática adotada globalmente devido à sua segurança e praticidade. Conforme explicado por Mialhe (2019), esta filtragem é atualmente realizada de duas maneiras. Aplicar um algoritmo de filtragem, que é mais rápido, mas na verdade menos confiável, pois o número de pontos removidos é maior, e aplicar um filtro simples para eliminar pontos manualmente. Este último método requer conhecimento especializado da área de colheita e muito tempo, mas geralmente resulta em resultados mais confiáveis.

Avanços significativos foram alcançados na incorporação de filtros nos programas de geração de mapas de colheita, mas ainda não identifica completamente os erros e limpa os dados de produtividade gerados pelos monitores, o que reduz a confiabilidade do processo quando decisões de gestão são necessárias, de acordo com esses dados (Silva e Borges, 2018).

Balestreire (2017), afirma que quando os produtores olham para os mapas de produtividade, observam padrões e tendências gerais, tais como áreas de produtividade involuntariamente alta ou baixa. Uma vez identificado, a tarefa do técnico é trabalhar com produtores mais familiarizados com o solo e o histórico de uso para tentar deduzir a causa

da alteração. Se o conhecimento das características do solo e do histórico de utilização permitir aos agricultores formular hipóteses sobre fatores que limitam a produtividade, então algumas ações podem ser tomadas para gerir de forma diferente as áreas menos produtivas para alcançar taxas de rendimento mais elevadas.

3.4. Índices de vegetação (NDVI e EVI)

A vegetação é um dos componentes mais relevantes do ciclo hidrológico e um fator chave na avaliação da biodiversidade dentro de uma área geográfica específica. Mudanças na dinâmica da vegetação terrestre afetam os sistemas terrestres. A interação entre vegetação e clima e a sua relação com as alterações climáticas tem atraído a atenção global. As alterações climáticas representam uma grande ameaça à saúde e à diversidade das comunidades vegetais em todo o mundo, e é importante mitigar estes impactos através de ações como a redução das emissões de gases com efeito de estufa e o reforço da proteção dos ecossistemas (Bayma, 2018).

Dias (2017) sugere que ao estimar as características biofísicas das florestas, monitorizar os seus stocks de carbono em grande escala para se obter uma compreensão detalhada das copas das florestas, é necessário aplicar modelos ecofisiológicos e deteção remota.

O Índice de Vegetação Diferencial Normalizado (NDVI), é considerado um dos índices mais utilizados dentro da agricultura de precisão, utiliza-se as bandas espectrais do vermelho e do infravermelho próximo e combina os resultados obtidos com propriedades biofísicas das vegetações como a biomassa. Apesar do uso generalizado deste índice, o NDVI ainda apresenta limitações em termos de sensibilidade à atenuação atmosférica, variações de brilho da terra e saturação em regiões com alto IAF. Para superar essas limitações, foi criado um Índice de Vegetação Melhorado (EVI), que apresenta maior sensibilidade em áreas de alta produção de biomassa e reduz os efeitos atmosféricos e de solo. Não obstante, este índice foi desenvolvido para um sensor específico, o *Moderate Resolution Imaging Spectroradiometer* (MODIS), ele também pode ser usado com imagens obtidas do satélite Landsat TM e 5, entretanto o EVI apresenta algumas limitações, bem como o NDVI (Rudorff e Shimabukuro *et al.*, 2017).

Dias (p. 19, 2017), explica que “o NDVI é mais sensível à clorofila e outros pigmentos responsáveis pela absorção da radiação solar na zona vermelha, enquanto o EVI é mais sensível a mudanças na estrutura do dossel, incluindo índice de área foliar

(IAF), fisionomia do plano e arquitetura do dossel”. Uma característica do NDVI é a sua rápida saturação, o que o torna sensível para detectar variações no crescimento da biomassa vegetal em um determinado estágio de crescimento da planta. Em contrapartida, o EVI foi desenvolvido para promover a redução dos diversos efeitos da atmosfera e do solo. Em áreas com uma maior densidade de biomassa, ainda segundo o autor, o EVI apresenta características superiores aos do NDVI (Dias, 2017).

3.5. Importância dos mapas de produtividade, NDVI e EVI

Os sistemas agrícolas são os pilares da nutrição global e a produtividade das culturas é ameaçada por muitos fatores, quer sejam atividades humanas, como a degradação dos solos, ou fatores antropogênicos. No caso das culturas de soja (*Glycine max*) e milho (*Zea mais*), garantir a máxima produtividade dessas monoculturas é fundamental do ponto de vista da economia nacional, pois não basta simplesmente aumentar as áreas cultivadas, mas é preciso atenção as opções como o tratamento utilizado, propriedades físicas e químicas do solo, controle de pragas e doenças (Aggussabti e Romano *et al.*, 2020).

Mao e Zhou *et al.* (2021), afirma que a utilização de imagens na agricultura abre inúmeras oportunidades, permitindo ao produtor tomar decisões mais assertivas e com um elevado número de informações que, se bem utilizadas, podem reduzir custos de produção.

Segundo Ouzemou e Harti *et al.* (2018), os recursos e características naturais da superfície terrestre beneficiam a detecção remota facilitando sua identificação, descrição, determinação e monitorização espacial. Esses sistemas de detecção remota fornecem dados periódicos e contínuos da superfície da Terra e são uma ferramenta fundamental para a monitorização global e uma das ferramentas mais importantes utilizadas para compreender os processos dinâmicos inerentes às diferentes formas de ecossistemas e a sua resposta às alterações climáticas.

As técnicas de processamento de imagens obtidas por sensoriamento remoto são os índices de vegetação (IV), que visam estudar as características espectrais da vegetação com base no seu comportamento de reflexão nas regiões do visível e do infravermelho próximo, bem como aplicações para monitoramento e planejamento de florestas costeiras para o local

A alta demanda pela tecnologia tem crescido ano a ano e ela é amplamente utilizada em todos os setores industriais estabelecidos, tanto no país como em outras partes do mundo. Essas tecnologias são indispensáveis na produção agrícola, por exemplo, para aumentar a produtividade com decisões mais decisivas e menores taxas de erro dos gestores (Mao e Zhou *et al.*, 2021).

A detecção remota tornou-se mais fácil de usar tanto na cidade como no campo, e é também uma forma econômica de pesquisar grandes áreas. Hoje, existem diversas soluções em desenvolvimento para diversos setores agrícolas que permitiram ao mercado global crescer bilhões de dólares. As técnicas de sensoriamento remoto têm grande potencial para caracterizar a produtividade com base nas propriedades biofísicas da cultura ou do solo (Valle Júnior e Siqueira *et al.*, 2019).

Segundo Ouzemou e Hart *et al.* (2018), o Índice de Vegetação por Diferença Normalizada (NDVI) tem sido utilizado em estudos de monitoramento de culturas, vale ressaltar que os índices NDVI são afetados por alguns fatores como mudanças climáticas e fatores antrópicos, nutrição, efeitos residuais de plantas anteriores, espécies avaliadas e inúmeras interações possíveis de uma combinação de fatores relacionados ao processo de produção.

A utilização do NDVI para monitorar a cobertura vegetal, o crescimento e o desenvolvimento das culturas se difundiram e ganharam destaque em diversos países, e nota-se que a eficácia dos dados obtidos depende de fatores como a combinação de índices e condições climáticas. O mapa de produtividade é composto por pontos que representam a parte melhorada. Essas informações são obtidas a partir dos sensores das colheitadeiras que medem o fluxo alimentar do grão de acordo com a largura da plataforma de colheita e o comprimento do caminho percorrido em um determinado tempo (1-3 segundos). Essas informações são armazenadas em computadores embutidos e podem então ser visualizadas nas plataformas do fabricante ou de terceiros (Aggussabti e Romano *et al.*, 2020).

O uso correto dos mapas de produtividade apresenta extrema importância, porém de acordo com Valle Júnior; Siqueira *et al.* (2019), para apresentar os resultados, cabe ao profissional executar todos os passos do processamento de forma ética e precisa.

Para garantir a confiabilidade dos dados, a máquina deve ser devidamente calibrada antes da colheita e o resultado resultante processado para filtrar pontos irregulares. (Valle Júnior; Siqueira *et al.*, 2019).

4. MATERIAL E MÉTODOS

4.1. Caracterização da área de estudo

A área de estudo localiza-se na Fazenda Mara Rosa, no município de Mara Rosa no Estado do Goiás, situada na região norte goiano com coordenadas $14^{\circ} 1' 1''$ S de latitude e $49^{\circ} 10' 40''$ W de longitude. A área estudada (Figura 1) possui uma superfície de aproximadamente 373 hectares destinada principalmente ao cultivo de soja (*Glycine max*) e milho (*Zea mays*) sob sistema de plantio direto.

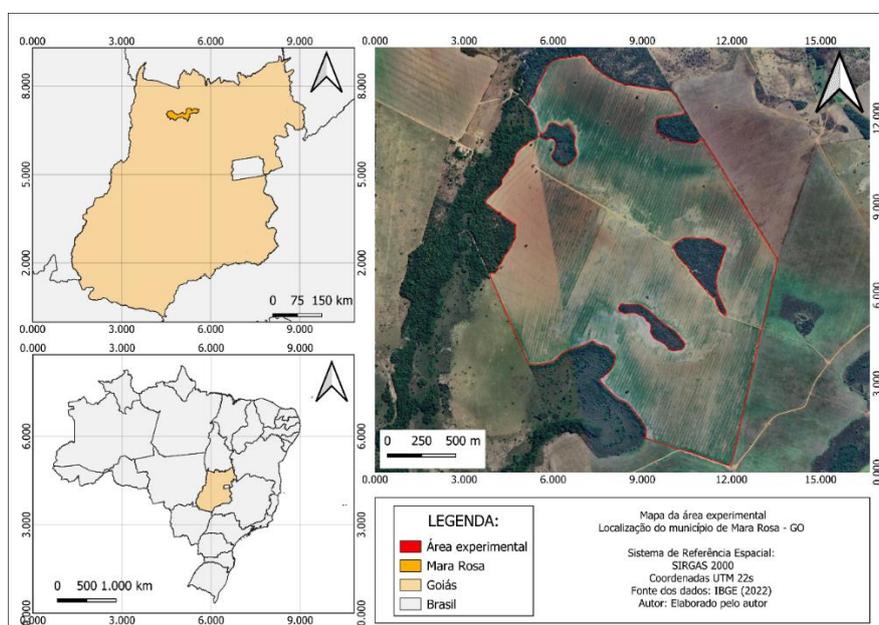


Figura 1. Mapa de localização da área de estudo. **Fonte:** Elaborado pelo autor.

O clima na região segundo a classificação Köppen-Geiger (Cardoso et al, 2014) é Aw, delinea o estado como tropical com uma estação seca durante o inverno, com temperatura média anual variando entre 24°C e 27°C e precipitação média anual de 1400 mm. O solo da área é classificado como LATOSSOLO Vermelho-Amarelo distrófico (LVAd), com baixa fertilidade natural, devido à sua acidez e escassez de nutrientes e é caracterizado por sua coloração avermelhada.

4.2. Procedimentos e Ferramentas utilizados para a pesquisa

Utilizou-se um conjunto de dados obtidos dos dias 10/04/2022, 11/04/2022, 12/04/2022, 13/04/2022, 14/04/2022 e 16/04/2022 através de uma colhedora modelo

S790 com plataforma Draper de 40 pés e monitor de colheita Gen4 Command Center™. Os dados adquiridos foram extraídos da colhedora, passaram por um pré-processamento por meio de um sistema de telemetria, e foram exportados para o formato "xlsx" com um total de 90.526 pontos coletados.

No banco de dados haviam diversas informações referentes às condições da operação tais como: data, hora, coordenadas geográficas, cultura, variedade, máquina, umidade, produtividade, massa seca. Para este trabalho, foram utilizadas informações de produtividade corrigida para a umidade de 13% (Kg/ha^{-1}), umidade do grão (%), coordenadas geográficas (latitude e longitude). Usando o Excel os valores zerados ou nulos em qualquer variável foram excluídos, resultando na eliminação completa da respectiva amostra, ou seja, de toda a linha da planilha, a fim de preservar a integridade das referências de dados. Dada a elevada densidade de dados provenientes da colheita, essas exclusões não afetam adversamente os resultados da análise nem a interpolação dos dados.

A tabela com os dados brutos pré-filtrados no formato apropriado (CSV) contendo as informações de produtividade de matéria seca e com os identificadores geográficos (latitude e longitude) foi adicionada no *software Qgis* através do gerenciador de fontes de dados na forma de *camada de texto delimitado* e realizado as configurações dos parâmetros de importação.

Os dados foram transformados em um arquivo shapefile, com a localização convertidas para o datum SIRGAS 2000 e coordenadas planas em UTM zone 22S. A filtragem e remoção de outliers foram realizadas primeiramente no *software QGIS* para eliminar informações incorretas, buscando dados mais representativos da produtividade real. A ferramenta "Resumo Estatístico" foi empregada para calcular a média e o desvio padrão (DP). Em conformidade com as diretrizes de Taylor et al (2007), pontos de dados que se situavam a mais de 2,5 DP acima ou abaixo da média de produtividade foram removidos.

O desvio padrão (Equação 1), que é uma medida estatística desenvolvida pelo matemático e estatístico Karl Pearson (1894) indica o quanto os valores de um conjunto de dados variam em relação à média. Ele mostra a dispersão dos dados em torno da média, ou seja, quanto os valores se afastam dessa média. Quanto maior o desvio padrão, maior a dispersão dos valores em relação à média; quanto menor, mais próximos os valores estão da média, ou seja, quanto mais próximo de 0 (zero) maior a homogeneidade dos dados.

Equação 1.

$$DP = \sqrt{\sum \frac{(Xi - \bar{X})^2}{N}}$$

Em que:

DP: É o desvio padrão;

Xi: Valor na posição i no conjunto de dados;

\bar{X} : É a média aritmética dos dados;

N: É a quantidade de dados.

Com os valores de produtividade filtrados, optou-se por uma abordagem determinística para visualizar o padrão espacial da produtividade na área, a Interpolação pela Ponderação do Inverso da Distância (IDW) para a geração do mapa de produtividade. De acordo com Trindade et al (2019) o método IDW fundamenta-se na dependência espacial, pressupondo que pontos próximos uns aos outros apresentam uma maior semelhança em seus valores. Assim, concede maior peso às amostras mais próximas em comparação com aquelas mais distantes do ponto a ser interpolado.

4.3. Processamento de Imagens

No processamento de imagens para a geração dos mapas de NDVI e EVI foi utilizado duas imagens para as datas 26/02/2022 e 02/04/2022 do satélite do Setinel Hub (Sentinel-2), as imagens foram adquiridas através do site do SENTINEL hub, disponível em (<https://www.sentinel-hub.com/>), correspondendo às fases vegetativa (R3) e reprodutiva (R7), cobrindo toda área de estudo. Todos os passos foram conduzidos em um ambiente de Sistema de Informações Geográficas (SIG), empregando o software *Qgis 3.32.3-Lima*.

O NDVI (índice de vegetação por diferença normalizada) é um indicador sensível da quantidade e condição da vegetação, cujos valores variam no intervalo de -1 a 1. Nas superfícies que contêm água ou nuvens, esta variação é sempre menor do que 0. É calculado pela Equação 2, proposta por Rouse *et al.* (1973).

Equação 2.

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Onde:

NDVI: É o índice de vegetação por diferença normalizada;

NIR: Corresponde a banda (B08) no infravermelho próximo (842 nm);

Red: Corresponde a banda (B04) na faixa do vermelho (665 nm).

Diferente do índice anterior, o EVI (índice de vegetação melhorado) emprega os coeficientes C1 e C2 para corrigir a interferência da atmosfera, especialmente a dispersão de aerossóis, em imagens de sensoriamento remoto. Além disso, utiliza o coeficiente L para ajustar a contribuição do solo e do dossel na imagem, possibilitando uma avaliação mais precisa da vegetação. É calculado pela equação 3, proposta por Huet *et al.*, (2002), que compensa os efeitos da atmosfera na banda do vermelho utilizando a banda do azul para a correção das influências atmosféricas no índice.

Equação 3.

$$EVI = \frac{2.5 * (NIR - Red)}{((NIR) + (C1 * Red) - (C2 * Blue) + L)}$$

Onde:

EVI: É o índice de vegetação melhorado;

NIR: Corresponde a banda (B08) no infravermelho próximo (842 nm);

Red: Corresponde a banda (B04) na faixa do vermelho (665 nm).

Blue: Corresponde a banda (B02) na faixa espectral do azul (523 nm)

C1 e C2: Corresponde aos valores de 6 e 7.5, respectivamente;

L: Corresponde ao valor de 1.

Durante o processo de geoprocessamento dos dados, foram empregadas as bandas espectrais B02, B04 e B08 no formato tif (Tagged Image File Format), correspondentes aos valores de reflectância nos comprimentos de onda do azul, vermelho e do infravermelho próximo. Essa escolha visa facilitar a visualização das disparidades nas respostas espectrais, destacando características distintas na vegetação. Segundo Novo e Ponzoni (2001) uma folha de vegetação saudável apresenta sua principal banda de absorção concentrada na região visível da luz vermelha, ao passo que a área de maior reflectância encontra-se no espectro do infravermelho próximo. Posteriormente, foi produzido os mapas de NDVI e EVI através da ferramenta "Raster Calculator".

4.4. Correlação dos dados

No *software Qgis 3.32.3-Lima* foi criado 375 pontos aleatórios com espaçamento de 100 x 100 metros por toda área de estudo através do comando “Investigar”. Para a coleta desses dados foi utilizado o complemento "Point Sampling Tool" (Ferramenta de Amostragem de Ponto), para coletar valores de atributos associados aos pontos específicos no mapa de produtividade, NDVI e EVI. A ferramenta permitiu extrair informações de pontos distribuídos de forma aleatória, facilitando análises dos dados. Os valores extraídos dos mapas foram exportados para o formato “XLSX” compatível com o *software Excel* para realizar a correlação entre os dados.

Com os dados de produtividade e valores de NDVI e EVI obtidos foram realizadas correlações usando o coeficiente de correlação de Pearson (r), considerando a classificação de Dancey e Reidy (2006), em que o $r = 0,1$ até $0,39$ (fraco); $r = 0,4$ até $0,69$ (moderado); $r = 0,7$ até 1 (forte). Será considerada correlação significativa com $p \leq 0,05$.

De acordo com Pereira (2021) a correlação de Pearson (r) é calculada com base na existência de uma relação entre duas variáveis quantitativas. Se o coeficiente de correlação exibir valores negativos, uma variável tende a aumentar enquanto a outra diminui, e, por outro lado, se apresentar valores positivos, ambas as variáveis aumentam em conjunto.

5. RESULTADOS E DISCUSSÃO

5.1. MAPAS DE PRODUTIVIDADE

Na Tabela 1 apresenta-se os valores em quantidade de dados brutos provenientes da colhedora, que foi de 90.256 pontos com valor mínimo de $8,69 \text{ kg ha}^{-1}$ e valor máximo $415.294,24 \text{ kg ha}^{-1}$, após o processo de filtragem houve a retirada de 13.467 pontos, reduzindo a densidade para 76.789 com valor mínimo de 2.713 kg ha^{-1} e valor máximo de 5.690 kg ha^{-1} . Estudo feito por Menegatti e Molin (2004) realizando a filtragem de dados brutos em diferentes monitores comerciais retiraram cerca de 4,6% a 27,3%, dos dados originados da colheita mecanizada.

Tabela 1. Quantidade de pontos e produtividade mínima e máxima antes e após filtragem dos dados.

Densidade	Dados Bruto	Dados Filtrados
Pontos	90.256	76.789
Produtividade (kg ha^{-1})		
Mínima	8,69	2.713
Máxima	415.294	5.690

Fonte: Elaborado pelo autor.

A Figura 2 mostra os mapas de produtividade sem filtragem dos dados brutos (A) e o mapa com a produtividade filtrada (B), pode-se observar que o processo de filtragem contribuiu para melhor percepção da variabilidade espacial dos dados. De acordo com estudos realizados por Santos (2020) entre os elementos associados à máquina, podem ser mencionados aspectos como a colheita com meia plataforma ou arremate de áreas, bem como falhas em sensores, entre outros, que são inerentes ao processo de colheita. É importante notar que esses fatores não devem ser automaticamente descartados, pois fazem parte integrante da colheita mecanizada. Além disso, dado que esses elementos não demonstram consistência ao longo das safras no mesmo local, a interpolação dos dados pode contribuir para atenuar seus efeitos, proporcionando uma visão mais precisa e abrangente ao longo do tempo de toda área.

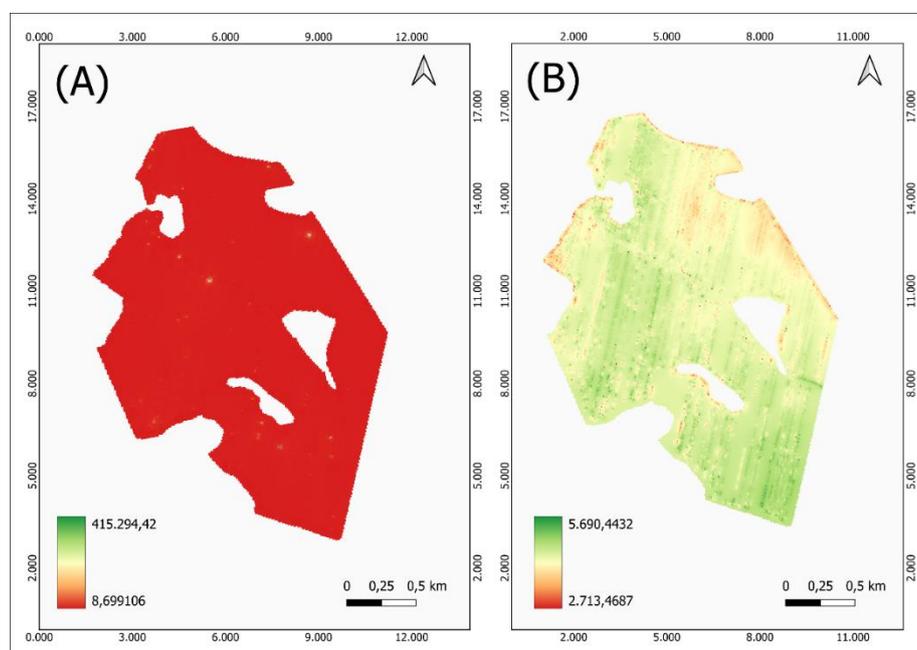


Figura 2. Mapas de produtividade. (A) Dado bruto; (B) Produtividade Filtrada
Fonte: Elaborado pelo autor.

Na Figura 2 (A) observa-se em quase todo o mapa, pontos com valores de produtividade muito baixo, valores estes que estão associados ao estudo feito por Oliveira (2021) para analisar variação entre o NDVI e EVI e dados de produtividade entre diferentes áreas ao longo de dois anos de colheita, dados de produtividade baixo são inseridos através de manobras frequentes, variações na velocidade de colheita e o ajuste inadequado dos equipamentos.

Observou-se também valores de produtividade extremos, chegando aproximadamente a $415.294 \text{ kg/ha}^{-1}$ que estão associados a erros da alta coleta de dados

no mesmo ponto causado por baixa velocidade de operação da colhedora, o GPS consequentemente não conseguiu detectar a mudança de posição durante a colheita inserido dados no mesmo ponto aumentando o valor da produtividade. Erros como estes foram encontrados por Menegatti e Molin (2004) realizando um estudo para analisar o índice de deslocamento no início e fim de cada passada feita pela colhedora, observaram que quando a velocidade de colheita é reduzida, a distância percorrida pela colhedora durante o intervalo de coleta de dados é igualmente limitada, permanecendo dentro do círculo de erro provável da maioria dos receptores (GPS) utilizados na agricultura de precisão, posição sendo erroneamente considerada equivalente à anterior.

5.2. MAPAS DOS ÍNDICES DE VEGETAÇÃO (IVs)

Na Figura 3, pode-se observar o mapa de NDVI em duas datas diferentes sem a presença de nuvens sobre a área de estudo. O mapa (A) refere-se a data 26/02/2022, observa-se valores homogêneo por toda a área de estudo, com valores acima de 0,80, representando ótima sanidade da cultura. De acordo com Variani (2011) realizando estudo sobre a variação do NDVI durante todo o ciclo em diferentes cultivares de trigo, os valores altos de NDVI demonstra que, quando a biomassa e o teor de clorofila estão elevados sinalizam condições favoráveis para o crescimento da cultura e um bom desenvolvimento da cultura.

Conforme Pereira et al (2021) as fases fenológicas V5, R1 e R2, são as mais utilizadas para identificar os reflexos das condições do solo e outros fatores que podem provocar alterações ópticas na cultura da soja.

Na Figura 3, o mapa (B), representa o NDVI do dia 02/04/2022, observa-se diferentes estágios de maturação da cultura, com maior parte da área com valor do NDVI entre 0,20 a 0,40, valor expressado pela baixa atividade de biomassa e baixa sanidade, com o estágio entre o R7 e R8 caracterizando o grau de maturação da cultura elevada próximo a data da colheita da área de estudo. Nas bordaduras os valores de NDVI encontra-se acima de 0,60 com atividade biomassa ativa, mas valores baixos em relação a data anterior.

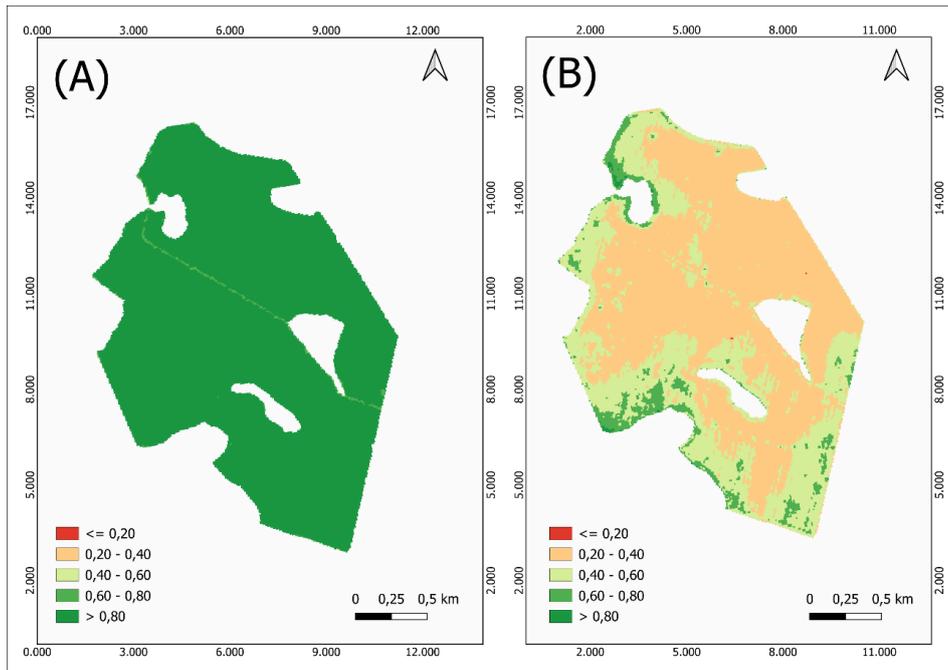


Figura 3. NDVI em 26/02/2022 em estágio fenológico R3 (A) e NDVI em 02/04/2022 em estágio fenológico R7 (B). **Fonte:** Elaborado pelo autor.

Observa-se na Figura 4, os mapas referentes ao EVI, percebe-se no mapa A o EVI para data do dia 26/02/2022, mostrando grande homogeneidade dos valores em grande parte da área com valores acima de 0,80. Observou-se também pequenas áreas com valores de 0,40 nas bordaduras e no meio do mapa que são referentes a estrada e mancha de solos com pouca densidade vegetal.

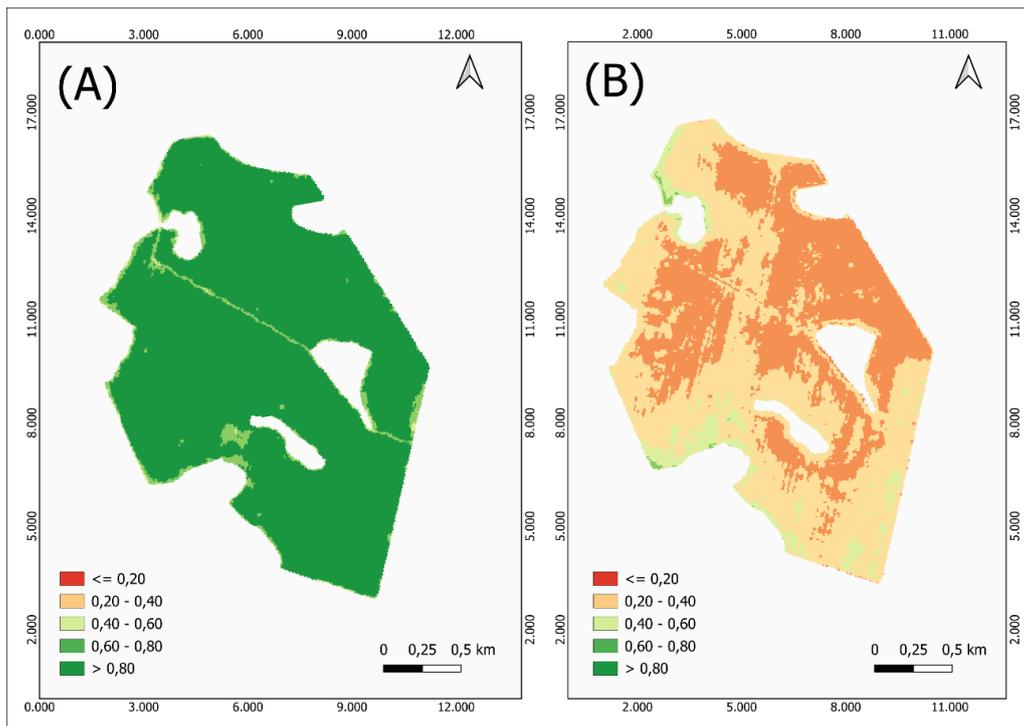


Figura 4. EVI em 26/02/2022 em estágio fenológico R3 (A) e em 02/04/2022 em estágio fenológico R7 (B). **Fonte:** Elaborado pelo autor.

Observou-se no mapa B, valores de EVI abaixo de 0,40, caracterizando o final de ciclo da cultura e com status de maturação próximo a R8, valores acima de 0,40 são encontrados nas bordaduras da área, essas áreas são mais úmidas pois estão próximas a área de vegetação mais densas.

5.3. CORRELAÇÃO DA PRODUTIVIDADE COM OS IVs

A Figura 5 (A) representa a correlação da produtividade com o índice de NDVI do dia 26/02/2022 no início da fase fenológica da cultura, em que o valor do coeficiente de determinação (R^2) foi igual a 0,01 e o coeficiente de correlação de Pearson (r) igual a 0,1.

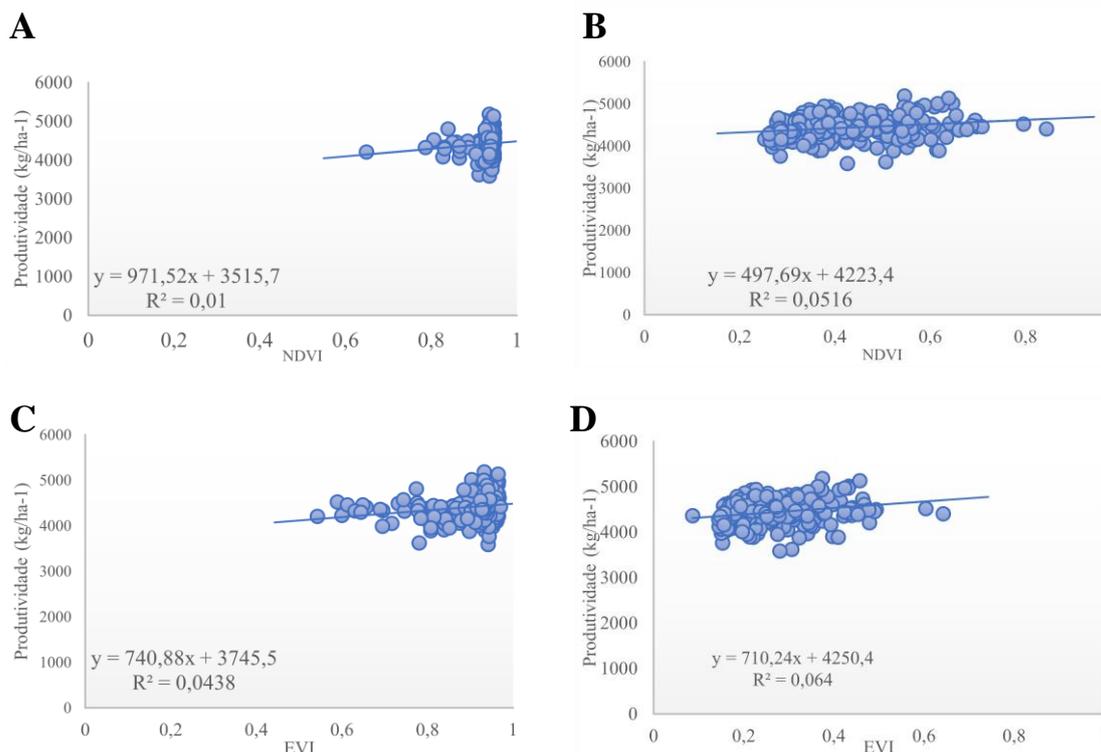


Figura 5 - Gráfico de correlação entre produtividade e índices de vegetação. (A) NDVI em 26/02/2022; (B) NDVI em 02/04/2022; (C) EVI em 26/02/2022; (D) EVI em 02/04/2022. **Fonte:** Elaborado pelo autor.

A Figura B, refere-se à correlação da produtividade com o índice NDVI próximo da data de colheita (02/04/2022), o valor do coeficiente de determinação (R^2) foi igual a 0,05 e o coeficiente de correlação de Pearson (r) igual a 0,23. A Figura C, refere-se à correlação da produtividade com o índice EVI na fase vegetativa da cultura (26/02/2022), o valor do coeficiente de determinação (R^2) foi igual a 0,04 e o coeficiente de correlação de Pearson (r) igual a 0,21. A Figura D, refere-se à correlação da produtividade com o índice EVI na fase de maturação próxima a data da colheita (02/04/2022), o valor do coeficiente de determinação (R^2) foi igual a 0,064 e o coeficiente de correlação de Pearson (r) igual a 0,25.

Pode-se observar que o maior coeficiente de determinação (R^2) foi do índice EVI (02/04/2022) com valor de 0,064, seguido NDVI (02/04/2022) com valor de 0,051, EVI (26/02/2022) com valor de 0,043 e NDVI (26/02/2022) com valor de 0,01. Valores se diferem de estudos realizados por Bolton e Friedl (2013) na região central dos EUA para a avaliação de produtividade de milho e soja usando três índice de vegetação (EVI, NDVI e NDWI) estes autores conseguiram resultados importantes ao estimar a produtividade de soja e milho usando modelos lineares simples. Os pesquisadores constataram que, para a

soja, não houve diferença significativa entre o EVI e NDVI encontrando valores de R^2 de 0,70 e 0,69 respectivamente.

Observa-se que o valor do coeficiente de correlação (R^2) entre o NDVI para o dia 26/02/2022 e a produtividade foi de 0,01, valor ineficiente não podendo ser usado para predição de produtividade de soja. Valor que são reforçados por Silva (2021) analisando a relação entre a produtividade da soja sobre o imageamento antecipado da cultura através de imagens de NDVI utilizando VANT com 150 m de altura, o pesquisador conclui que a tentativa de prever o rendimento da plantação de soja usando apenas imagens do NDVI não mostrou uma similaridade forte entre a quantidade de grãos de soja colhidos.

Matias, Streck e Aguilar (2015) encontraram uma relação evidente entre os valores médios estimados pelo NDVI e os valores reais obtidos pelas colhedoras nas condições do estudo feito com milho, foi estabelecida pela correlação de Pearson entre esses conjuntos de dados um valor de R^2 de 1 com significância $p < 0,01$.

Portanto, os coeficientes de determinação (R^2), que indicam o grau de ajuste dos dados ao modelo linear, foram considerados baixos. Isso sugere que há apenas uma tendência fraca de relação entre esses dados.

6. CONCLUSÕES

A metodologia permitiu uma boa filtragem dos dados brutos para a geração do mapa de produtividade, reduzindo os erros inseridos durante a operação de colheita da cultura de soja na área de estudo. Os mapas de IVs gerados possibilitou uma melhor visualização da área referente a atividade de biomassa da área em duas datas distintas.

A correlação entre os valores de produtividade resultou em valores de coeficiente muito baixos, resultando em uma baixa correlação da produtividade com os IVs obtidos nas diferentes datas do estudo.

No entanto, são necessárias mais pesquisas, abrangendo outros estágios fenológicos, áreas produtivas, culturas e índices de vegetação para validar a aplicação de correlações entre os dados de mapas de produtividade.

7. REFERÊNCIAS BIBLIOGRÁFICAS

AGGUSSABTI, A.; ROMANO, R. et al. **Fatores que afetam o risco tolerância entre pequenos agricultores sazonais de estratégias para sua melhoria.** Helião 6-12. 2020.

Agussabti, A.; Romano, R.; Rahmaddiansyah, R. & Isa, R. M. 2020. Factors affecting risk tolerance among small-scale seasonal commodity farmers and strategies for its improvement. **Heliyon**, 6: 12.

BALAFOUTIS, A. T.; BECK, B.; FOUNTAS, S.; TSIROPOULOS, Z.; VANGEYTE, J.; WAL, T. van der; SOTO-EMBODAS, I.; GÓMEZ-BARBERO, M.; PEDERSEN, S. M. Smart farming technologies—description, taxonomy and economic impact. Precision Agriculture: Technology and Economic Perspectives. Springer, V. 48, n. 50, 2017.

BALESTREIRE, L. A. **Estudo de caso, uma pesquisa brasileira em agricultura de precisão.** LAVRAS: UFLA. p. 231-302, 2017.

BAYMA, A. P. **Análise do potencial de seres temporais de índices de vegetação (NDVI e EVI) do sensor MODIS para detecção de desmatamentos no bioma cerrado.** 99. 2018. Dissertação. Universidade de Brasília. 2018.

BEZERRA, L. M. C.; CLEPS JR, J. O desenvolvimento agrícola da região Centro-Oeste e as transformações no espaço agrário do estado de Goiás. **Revista Caminhos de Geografia**, v. 2, n. 12, p. 29-49, jun. 2004

BOLTON, D. K.; FRIEDL, M. A. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. **Agricultural and Forest Meteorology.** v. 173. p. 74-84. 2013.

BUCK, Guilherme. **Agricultura moderna: descubra as vantagens da mecanização agrícola que reduz prejuízos.** Agrônomo de desenvolvimento de Mercado. Bayer. 2020.

CARDOSO, Murilo Raphael Dias et al. **Classificação climática de Köppen-Geiger para o estado de Goiás e o Distrito Federal.** 2014.

CARVALHO, M. T. Variabilidade espacial de atributos de um solo sob videira em Vitória Brasil (SP). **Revista Brasileira de Ciência do solo.** Viçosa, v.27. n.4. p. 695-703, 2017.

CONAB. 2021. Acompanhamento da Safra Brasileira de Grãos, **Safra 2020/21 – 10º levantamento**, Brasília.

COSTA, Cinthia Cabral; GUILHOTO, Joaquim José Martins et al. **Impactos Socioeconômicos de Reduções nas perdas pós-colheita de produtos agrícolas no Brasil.** RESR. Piracicaba –SP. v. 53, n. 3, p. 394-408, jul/set., 2017.

DANCEY, C.; REIDY, J. **Estatística sem matemática para psicologia: usando SPSS para Windows.** Porto Alegre: Artmed, 2006. 608 p.

DE BORATTO, I. M.; GOMIDE, Reinaldo Lúcio. **Aplicação dos índices de vegetação NDVI, SAVI e IAF na caracterização da cobertura vegetativa da região Norte de Minas Gerais.** 2013.

DIAS, I. M. **Relação entre índices de vegetação e precipitação pluvial no estado de Sergipe.** 131 f. Dissertação. Universidade Federal do Paraná, Curitiba. 2017.

DURIGON, R.; SCHLOSSER, J. F et al. **Amostragem em Malha**. Cultivar Máquinas. v. 77, p.12-14, 2018.

EMBRAPA. EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Manual de métodos de análise de solo**. 3 ed. Rio de Janeiro. Serviço nacional de Levantamento e Conservação de solo. Rio de Janeiro. p. 35. 2018.

GUEDES, J.V.C.; DORNELES, S.H.B. **Tecnologia e segurança na aplicação dos agrotóxicos-novas tecnologias**. Santa Maria: Departamento de Fitossanitária. Sociedade de agronomia de Santa Maria, 2017.

GUILHOTO, J. M.; SESSO FILHO, V. A. **Estimação da matriz insumo-produto a partir de dados preliminares das contas nacionais**. Revista Economia Aplicada. v. 9, n.3, abr/jun., 2017.

HIRAKURI, M. H.; LAZZAROTO, J. J. **O agronegócio da soja nos contextos mundial e brasileiro**. Londrina: Embrapa soja, 2014.

HUETE, A. DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. **Overview of the radiometric and biophysical performance of the MODIS vegetation indices**. Remote Sensing of Environment, v.83, n.1-2, p.195-213, 2002.

JUNGES, Rafael. Entenda a coleta de dados para a criação dos mapas de produtividade. **Austertecnologia**, 2020. Disponível em: <https://www.austertecnologia.com/single-post/coleta-dados-mapas-produtividade>. Acesso em: 09, setembro e 2023.

LEONARDO, A.; MOLIN, José P. **Remoção de erros em mapas de produtividade via filtragem de dados brutos**. Revista Brasileira de Engenharia Agrícola e Ambiental. v. 11, n.5, p.126-134, 2017.

MACHADO, A. T. Construção histórica do melhoramento genético de plantas: do convencional ao participativo. **Revista Brasileira de Agroecologia**, v. 9, n. 1, p. 35-50, 2014.

MAO, H.; ZHOU, L. et al. **Preferências temporais e agricultura verde, adoção de tecnologias: evidências de campo de produtores na China**. Políticas de Uso do Solo. 109. 2021.

MATIAS, João Fillipe Generoso; STRECK, Luciano; AGUILAR, Damião Dulau. Geração de mapas de produtividade de milho (*Zea mays*) com índice de crescimento NDVI de imagens Landsat 8. **XVII Simpósio Brasileiro de Sensoriamento Remoto**, 2015.

MENEGATTI, Leonardo A. Angeli; MOLIN, José P. Metodologia para identificação e caracterização de erros em mapas de produtividade. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 7, p. 367-374, 2003.

MENEGATTI, Leonardo AA; MOLIN, José P. Remoção de erros em mapas de produtividade via filtragem de dados brutos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 8, p. 126-134, 2004.

MIALHE, L. G. **Manual de mecanização agrícola**. São Paulo: Agronômica Ceres. p. 297, 2019.

MICHELAN, Ricardo et al. Determinação e remoção de erros em mapas de colheita de milho. 88. **Dissertação** de Mestrado em Engenharia Agrícola – Universidade Estadual do Oeste do Paraná, 2005.

MOLIN, J. P.; GIMENEZ, L. M. **Desenvolvimento de um algoritmo para redução de erros em mapas de rendimento obtidos em agricultura de precisão.** Congresso e mostra de Agroinformática. 2018.

NOVO, E. M. L. M.; PONZONI, F. J. **Introdução ao Sensoriamento Remoto.** São José dos Campos, p. 68. 2001.

NUNES, José Luis da Silva. **Inovação do Campo.** Piracicaba. 2018. Disponível em: <http://www.portaldocampo.com.br/inovacoes/agri-precisao.htm>. Acesso: 31 de out. de 2023.

OLIVEIRA, Vinícius Henrique Dias de et al. Unidades de Gestão Diferenciada por meio de índices de vegetação e mapas de produtividade. 2021. 69. **Dissertação** de Mestrado em Engenharia Agrícola - Universidade Estadual do Oeste do Paraná, 2021.

OUZEMOU, J.; HARTI, A. E. et al. **Um caso de sistema agrícola altamente fragmentado e intensivo.** Aplicação de Sensoriamento Remoto. Sociedade e Meio Ambiente. 2018.

PEDROSO, Í. L. P. B.; SILVA, A. R. P. O papel das políticas públicas no desenvolvimento agroindustrial de Rio Verde-GO. **Caminhos de Geografia**, v. 3, n. 15, p. 20-27, jul. 2005.

PEREIRA, LUANA MARQUES et al. Correlação da produtividade da soja com os atributos químicos do solo e o NDVI. **Revista Brasileira de Agropecuária Sustentável**, v. 11, n. 1, p. 430-438, 2021.

PIRES, M. J. S.; RAMOS, P. Implicações do processo de modernização na estrutura e nas atividades agropecuárias da região centro-sul do estado de Goiás. **Sociedade Brasileira de Economia, Administração e Sociologia Rural**, 2009.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: **EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM**, 3., 1973, Washington. Proceedings... v. 1, sec. A, p. 309-317.

ROZA, D. **Novidade no Campo:** Geotecnologia renovam a agricultura. Revista InfoGEO, n.15. jan/fev. 2017.

RUDORFF, F.T.; MABUKURO, Y. E et al. **O sensor MODIS e suas aplicações ambientais no Brasil.** São José dos Campos: Parêntese. p. 423. 2017.

SANTOS, L.M.G. Tratamento e interpretação de dados de produtividade para agricultura de precisão. 2020. 39. **Dissertação** de Mestrado em Agronomia - Universidade Estadual de Londrina, Londrina, 2020.

SILVA, F. M.; BORGES, P. H. de M. **Mecanização e agricultura de precisão.** Computação Eletrônica e Agricultura. v. 14, n. 2, p. 215-223, 2018.

SILVA, Rômulo Moreira et al. **ÍNDICES DE VEGETAÇÃO NA PREDIÇÃO DE PRODUTIVIDADE DE SOJA.** 2021. **Dissertação** (Mestrado) – Curso de Programa de Pós-graduação em Bioenergia e Grãos, Instituto Federal Goiano, Goiás, 2021.

SPERANZA, E. A., ANTUNES, J. F. G., BARBOSA, L. A. F., DE ALMEIDA CANÇADO, G. M., & VANSCONCELOS, J. C. Importância de índices de vegetação para modelos de estimativa de produtividade em cana-de-açúcar. *Anais / Proceedings XX SBSR*. Vol 20, 2023. - 155908

TAYLOR, J. A., MCBRATNEY, A. B., & WHELAN, B. M. Establishing management classes for broad acre agricultural production. *Agronomy Journal*, 99(5), 1366-1376. 2007.

THYLÉN, L.; JURSCHIK, P.; MURPHY, D.L.P. Improving the quality of yield data, In: EUROPEAN CONFERENCE ON PRECISION AGRICULTURE, 1., Warwick, 1997. Precision agriculture'97, Warwick: **BIOS Scientific Publishers**, 1997. v.1, p. 743-750.

TRINDADE, Filipe Silveira et al. Relação espectro-temporal de índices de vegetação com atributos do solo e produtividade da soja. *Revista de Ciências Agrárias Amazonian Journal of Agricultural and Environmental Sciences*, v. 62, 2019.

VALLE JÚNIOR, R. F.; SIQUEIRA, H. E. et al. **Diagnóstico de pastagens degradadas utilizando uma abordagem aprimorada de sensoriamento remoto baseada em NDVI: uma aplicação ao meio ambiente**. Sensoriamento remoto. Aplicações: Sociedade e Meio Ambiente. 14. 2019.

VARIANI, Clever. **Sensor óptico ativo como ferramenta para aplicação de nitrogênio na cultura do trigo**. 2011. 109 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Fitotecnia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

YU, Q.; XIANG, M.; WU, W.; TANG, H. 2019. Changes in global cropland area and cereal production: An inter-country comparison. *Agriculture, Ecosystems & Environment*. v. 15, n. 4, p. 269, 2019.