



LEONARDO DE FREITAS VIANA

**AVALIAÇÃO DE DIFERENTES MÉTODOS DE CORREÇÃO
ATMOSFÉRICA APLICADOS A IMAGENS DO SENTINEL-2
VISANDO ESTIMATIVAS DE PRODUTIVIDADE NA
CULTURA DO MILHO**

**LAVRAS-MG
2023**

LEONARDO DE FREITAS VIANA

**AVALIAÇÃO DE DIFERENTES MÉTODOS DE CORREÇÃO ATMOSFÉRICA
APLICADOS A IMAGENS DO SENTINEL-2 VISANDO ESTIMATIVAS DE
PRODUTIVIDADE NA CULTURA DO MILHO**

Trabalho de Conclusão de Curso
apresentada à Universidade Federal de
Lavras, como parte das exigências do Curso
de Agronomia, para a obtenção do título de
Bacharel.

Prof. Dr. Adão Felipe dos

Santos Orientador

Prof. Dr. Lorena Nunes

Lacerda

Coorientadora

**LAVRAS - MG
2023**

LEONARDO DE FREITAS VIANA

**AVALIAÇÃO DE DIFERENTES MÉTODOS DE CORREÇÃO ATMOSFÉRICA
APLICADOS A IMAGENS DO SENTINEL-2 VISANDO ESTIMATIVAS DE
PRODUTIVIDADE NA CULTURA DO MILHO**

Trabalho de Conclusão de Curso
apresentada à Universidade Federal de
Lavras, como parte das exigências do Curso
de Agronomia, para a obtenção do título de
Bacharel.

APROVADO em 07 de JULHO de 2023

Thiago Orlando Costa Barboza

Octávio Pereira da Costa

Prof. Dr. Adão Felipe dos
Santos Orientador

Prof. Dr. Lorena Nunes
Lacerda
Coorientadora

**LAVRAS -MG
2023**

Agradecimentos

Primeiramente queria agradecer aos meus pais, Adevair e Claudinéia, por estarem sempre ao meu lado me apoiando mesmo de longe, por terem aguentado as emoções de verem uma criança sair de casa com 15 anos, para ir morar sozinho em buscar dos sonhos e principalmente, por serem o grande exemplo de pessoas e maiores motivações que são para mim. Meus pais sempre foram meus norteadores e meus pilares para que eu continuasse em frente. Junto aos meus pais, agradeço também à minha irmã e minha avó, Rayane e Cida, que também foram pessoas que sempre confiaram e me apoiaram, não só a mim, mas serviam de apoio aos meus pais também em momentos que não estive por perto.

À família República Mata Burro, onde morei por 5 anos com pessoas que hoje tenho o prazer e satisfação de chamar de irmãos. Todos lá sabem e eu sempre repito, se não fosse com eles, não teria sido tão incrível e tão fácil viver longe de casa, passar por barras pesadas e continuar tendo força para seguir em frente.

A todos do Grupo de Extensão e Pesquisa em Agricultura Digital (GEPAD), em especial ao orientador Adão, que me acolheram no início da minha trajetória profissional e me ensinaram praticamente tudo que eu sei de agricultura digital. Além de todos ensinamentos, Adão sempre foi uma pessoa amiga também, que não estava presente apenas em momentos de estudo e sempre fez questão de presenciar momentos de lazer com seu orientados.

Agradeço também à minha namorada, Gabriela, por ter sido meu ombro de desabafo nos últimos anos, me apoiou e me deu forças em muitos momentos de ansiedade, e principalmente, por estar ao meu lado me fazendo feliz e incentivando como sempre estive.

Por fim, agradeço de coração a todos as pessoas que passaram em minha vida e deixaram um pouco de si, mesmo que sejam traços, mas que contribuíram para eu chegar na pessoa que sou hoje, muito obrigado!

Há uma frase que eu vi quando estava na metade do curso, que eu não sei quem é o autor até hoje, mas mudou a minha mentalidade daquele dia em diante, que falava “*A gente acha que é difícil acordar cedo, ir para aula, estudar e trabalhar ao mesmo tempo, fazer 7 provas na semana, ter que lidar com problemas de saúde enquanto estuda e tudo mais. Mas na real, o difícil mesmo é você ficar 5 anos (ou mais) longe dos seus pais e família, perder aniversários, momentos de alegria para comemorar juntos e momentos de tristeza para ser apoio. Portanto, sempre dê o seu melhor porque tem pessoas em casa torcendo por você*”.

Resumo

A imagem de satélites vem sendo cada vez mais utilizadas na agricultura, no planejamento e monitoramento das lavouras. Uma operação de grande importância é a colheita, onde o sensoriamento remoto pode auxiliar na tomada de decisão, por meio de estimativas de produtividade. Porém, sensores em nível orbital necessitam de tratamento das imagens, sendo fundamental a realização da correção atmosférica. O objetivo do trabalho foi avaliar a eficiência das correções atmosféricas *Dark Object Subtraction (DOS)*, *Image correction for atmospheric effects (iCOR)* e *Sentinel-2 correction (Sen2Cor)* na estimativa de produtividade da cultura do milho, identificar qual índice de vegetação conferiu maior precisão para se estimar a produtividade e a época de desenvolvimento da cultura que é mais adequada para se realizar a estimativa. As imagens utilizadas são advindas da missão Sentinel-2 com resolução de 10m, adotando-se os índices de vegetação que contém bandas do verde, azul, vermelho e NIR (infravermelho-próximo) em seu cálculo, sendo eles, o *Índice de Vegetação por Diferença Normalizada (NDVI)*, o *Índice de Vegetação da Diferença de Verde Normalizado (GNDVI)*, o *Índice de Vegetação Melhorado (EVI)*, o *Índice Resistente à Atmosfera na Região Visível (VARI)* e o *Índice de Vegetação Resistente à Atmosfera (ARVI)*. As imagens foram coletadas com, 50, 60, 71 e 101 dias após o plantio (DAP). Os dados de produtividade foram obtidos de uma propriedade localizada próximo à Campo do Meio em Minas Gerais, em uma área de pivô irrigado contendo em torno de 55,7 hectares, no período da safrinha de 2019. Os dados de produtividade foram corrigidos utilizando o MapFilter, que é um software gratuito e disponibilizado pela Escola Superior de Agricultura "Luiz de Queiroz" da Universidade de São Paulo (ESALQ/USP). Além disso, utilizou-se o software QGIS para processar os índices de vegetação e os softwares PYTHON e R para análises estatísticas. Não se identificou diferenças entre os métodos de correção atmosféricas, os índices de vegetação apresentaram pouca variação, com o GNDVI se destacando um pouco mais. Conclui-se também que há potencial nas características de índices de vegetação para estimar produtividade, desde que sejam avaliadas em mais safras recorrentes e com mais dados.

Palavras-chave: Correção atmosférica.; índices de vegetação.; sensoriamento remoto.; produtividade.;

SUMÁRIO

<u>1</u>	<u>INTRODUÇÃO</u>	<u>7</u>
<u>2</u>	<u>REVISÃO BIBLIOGRÁFICA</u>	<u>10</u>
<u>2.1</u>	<u>A cultura do milho.....</u>	<u>10</u>
<u>2.2</u>	<u>Agricultura de Precisão</u>	<u>11</u>
<u>2.3</u>	<u>Sensoriamento Remoto.....</u>	<u>12</u>
<u>2.4</u>	<u>Correções atmosféricas</u>	<u>13</u>
<u>2.5</u>	<u>Índices de vegetação</u>	<u>15</u>
<u>3</u>	<u>MATERIAL E MÉTODOS.....</u>	<u>16</u>
<u>3.1</u>	<u>Área de estudo</u>	<u>16</u>
<u>3.2</u>	<u>Obtenção das imagens.....</u>	<u>17</u>
<u>3.3</u>	<u>Correções atmosféricas</u>	<u>18</u>
<u>3.3.1</u>	<u>Dark Object Subtration (DOS)</u>	<u>18</u>
<u>3.3.2</u>	<u>Image correction for atmospheric effects (iCOR)</u>	<u>19</u>
<u>3.3.3</u>	<u>Sentinel-2 correction (Sen2Cor)</u>	<u>20</u>
<u>3.4</u>	<u>Índices de vegetação e extração dos valores.....</u>	<u>21</u>
<u>4</u>	<u>RESULTADOS E DISCUSSÃO</u>	<u>23</u>
<u>5</u>	<u>CONCLUSÃO</u>	<u>27</u>
<u>6</u>	<u>REFERÊNCIAS</u>	<u>27</u>

1 INTRODUÇÃO

A cultura do milho é a produção agrícola que tem maior relevância no cenário mundial, sendo a cultura mais produzida mundialmente. A produção está prestes a atingir a segunda maior marca já vista na história. Estima-se que ao final da safra 2022/23, serão produzidas mais de 1.168 milhões de toneladas do grão. Neste cenário, o Brasil se enquadra no terceiro maior produtor mundial do grão, em que nos últimos 22 anos a produção teve aumento em torno de 75%. Ao final da safra 2022/23, espera-se que o Brasil chegue a uma produção em torno de 126 milhões de toneladas, que corresponde à 10,78% do total produzido no mundo (USDA, 2023).

Uma das formas de melhorar essa produtividade é por meio do monitoramento constante das áreas de produção, identificando eventuais problemas e realizando a correta tomada de decisão, o que pode ser realizado a partir do sensoriamento remoto. O sensoriamento remoto pode ser entendido como um conjunto de atividades que permite a obtenção de informações dos objetos que compõem a superfície terrestre sem a necessidade de contato direto. Esse conjunto de atividades envolve a detecção, aquisição e análise energia eletromagnética emitida ou refletida pelos objetos terrestres e registradas por sensores remotos (MOREIRA, 2008).

Sendo assim, as aplicações de técnicas de sensoriamento remoto podem fornecer informações sobre o cultivo agrícola. Para estudos de recursos naturais tem apresentado significância no âmbito agrícola, permitindo se avaliar informações quantitativas e qualitativas perante a caracterização espectral dos objetos. Para as aplicações no espaço agrícola, as imagens de satélites apresentam excelentes vantagens devido a sua capacidade de cobertura de grandes áreas, facilidade de obtenção de dados, qualidade geométrica e radiométrica dos dados (GAIDA, 2020).

A interação entre a energia eletromagnética e os objetos a campo, ocorre através da radiação eletromagnética, que afere a quantidade e qualidade da energia eletromagnética refletida e emitida pelos objetos. Essas interações são denominadas pelas propriedades físico-químicas e biológicas dos objetos, que podem ser identificadas nas imagens e nos dados de sensores remotos (MOREIRA, 2008).

Os sensores ópticos que realizam a captura das informações da energia eletromagnética, conhecidos como satélites, ficam localizadas em órbita na atmosfera. Por

consequência, na atmosfera são encontrados diversos constituintes presentes que vão afetar essa radiação, necessitando de correções para diminuir os erros associados as imagens. Dessa forma, a radiação eletromagnética é emitida pelo sol, que ao transpor toda a camada atmosférica realiza interações com as partículas e moléculas de gás, poeiras, etc. em suspensão, que ocasiona as alterações na radiação emitida. Os principais fenômenos que acontecem são, a absorção e o espalhamento causado por estes corpos presentes que pode causar aumento ou redução da radiância detectada nos sensores orbitais (HILKER, 2018).

No Brasil, as estimativas oficiais de produtividades são realizadas pelo Instituto Brasileiro de Geografia e Estatística IBGE (ROSA et al., 2010) e Companhia Nacional de Abastecimento-CONAB. Para a consecução desses serviços, os órgãos oficiais utilizam métodos que envolvem modelos estatísticos, pacotes tecnológicos modais das principais culturas em diversos locais de produção, acompanhamentos agrometeorológicos, pesquisa subjetiva de campo como entrevistas com produtores, informações de vendas de insumos agrícolas e as análises de safras anteriores (CONAB, 2016). Essa estatística de produção está sujeita a dados de entrada incorretos, pois não se tem como inferir o erro embutido de uma entrevista com um produtor, por exemplo (MELO et al., 2008; RIZZI et al., 2007).

Em nível de propriedade rural, os procedimentos convencionais de previsão de safra são realizados por meio de amostragens em campo (RODRIGUES et al., 2005), que por vezes se mostram onerosas e lentas, além de demandarem mão-de-obra. Outro ponto é que geralmente as amostragens de campo são realizadas nos dias da colheita, não possibilitando a antecipação de ações que visem o planejamento administrativo para as propriedades. Com o surgimento do sensoriamento remoto, iniciou-se o uso de diversas técnicas e metodologias capazes de perceber as mudanças e variações na cobertura da superfície, por meio de informações adquiridas por sensores orbitais. Tais resultados têm se mostrado altamente eficientes para estudos relacionados à dinâmica da vegetação (RAMOS, 2013).

Através da reflectância causada pelas plantas da radiação solar, é possível que sejam coletadas as informações que estão correlacionadas às condições da lavoura, assim como, cultura cultivadas, condições fenológicas ou nutricionais e, conseqüentemente, com a produtividade, possibilitando estimar a produção da cultura agrícola em questão (RUDORFF; MOREIRA, 2002). Dentre as diferentes abordagens, destaca-se as que fazem uso de relações diretas entre índice de vegetação e a produtividade medida no campo (VARELLA et al., 2011).

As combinações da reflectância de alvos da superfície em dois ou mais comprimentos de onda, especialmente na região do visível e infravermelho, geram medidas radiométricas adimensionais chamadas de índices de vegetação. O objetivo dos IV é destacar uma propriedade particular da vegetação como, por exemplo, o índice de área foliar (IAF), a porcentagem de cobertura verde, o teor de clorofila, a biomassa verde e a radiação fotossinteticamente ativa absorvida (JENSEN, 2009).

Com isso, as correções atmosféricas são imprescindíveis de serem realizadas, com o principal objetivo de reduzir a influência causada pelos componentes atmosféricos na radiância captada pelos sensores presentes na atmosfera (MOGRANE et al., 2019). Há diversos métodos de correção propostos nas literaturas, que devem considerar principalmente as especificações técnicas de cada sensor. Para obter-se maior eficiência no procedimento, deve-se combinar o melhor método de acordo com o sensor utilizado.

Hipótese

As estimativas de produtividade tendem a apresentar diferenças significativas quando submetidas à diferentes métodos de correções atmosférica utilizando diferentes índices de vegetação

Objetivos

Geral: Avaliar e comparar a eficiência de três diferentes métodos de correção atmosférica para estimar produtividade de milho, utilizando cinco índices de vegetação.

Específicos:

- Comparar a eficiência dos métodos de correção atmosféricas, “Dark Object Subtraction” (DOS), “Image correction for atmospheric effects” (iCOR) e “Sentinel-2 correction” (Sen2Cor) para estimar a produtividade de milho.
- Identificar dentre os índices de vegetação qual apresenta maior correlação com a estimativa de produtividade, sendo eles, Índice de Vegetação por Diferença Normalizada (NDVI), o Índice de Vegetação da Diferença de Verde Normalizado (GNDVI), o Índice de Vegetação Melhorado (EVI), o Índice Resistente à Atmosfera na Região Visível (VARI) e o Índice de Vegetação Resistente à Atmosfera (ARVI).
- Avaliar qual época de desenvolvimento da cultura é mais adequado de se realizar as estimativas de produtividade, utilizando índices de vegetação.

2 REVISÃO BIBLIOGRÁFICA

2.1 A cultura do milho

O milho pertence à classe Liliopsida, sendo uma Poaceae do gênero *Zea*, e classificada cientificamente como *Zea mays* L. A cultura do milho tem importância histórica devido aos primeiros registros de cultivo datarem de 7.300 anos atrás nas proximidades do litoral do México. Nas antiguidades, o milho era fonte de alimentação para várias civilizações, como Olmecas, Maias, Astecas e Incas, que na época reverenciavam o cereal (LERAYER, 2006).

Como diversas culturas do âmbito agrícola, o milho também tem passado por processos de evolução proporcionados pelo conhecimento humano. O homem tem trabalhado visando melhoras as características produtivas do milho, visando aumento de produtividade, resistências a pragas e doenças, adaptação para diversas regiões produtivas, que na grande maioria envolvem o melhoramento genético e que promovem o desenvolvimento de cultivares conhecidas (LERAYER, 2006).

O milho é uma planta monoica, ou seja, possui órgãos masculinos e femininos nas mesmas plantas em inflorescências diferentes, sendo que os órgãos masculinos ficam na panícula e os femininos na espiga. Uma outra característica também, é a protandria que a espécie apresenta, em que os órgãos masculinos aparecem primeiro do que os órgãos femininos. A planta apresenta raiz do tipo fasciculada, com caules podendo chegar a mais de 2 metros de altura e com folhas estreitas dispostas de forma alternada, com nervuras paralelinérveas (BARROS; CALADO, 2014). Outra característica relevante do milho, é que apresenta o metabolismo C4, que faz com que a cultura tenha uma alta eficiência na utilização da luz e do CO², o que está relacionado também à taxa fotossintética e a produtividade da cultura (CRUZ, 2006).

A cultura do milho tem se tornado cada vez mais influente no Produto Interno Bruto (PIB) brasileiro, visto que é o segundo grão mais produzido no país em 2022 (CONAB, 2022). A produção da cultura do milho apresenta crescimentos significativos ao longo dos anos, devido à surgimento de novas tecnologias que envolvem o campo produtivo e proporcionam aos produtores maiores capacidades de atingirem os tetos produtivos. Na safra 2021/22 o Brasil produziu em torno de 113,1 milhões de toneladas do grão, e estima-se que para a atual safra 2022/23, produzirá em torno de 125,8 milhões de toneladas, um crescimento em torno de 10,1% (CONAB, 2023). A forte influência no PIB brasileiro pode ser notada de acordo com o Boletim Logístico da Conab, em que mostra que no ano de 2022, de janeiro a setembro foram exportados 24,66 milhões de toneladas, que mostra um aumento em relação ao mesmo período

do ano anterior em 92,3%.

Segundo dados divulgados pela Conab em 2017, a produção brasileira do milho está presente em três principais regiões do país, no Sul, Centro-Oeste e Sudeste. Os maiores estados produtores, são, por ordem de grandeza, Paraná, Mato Grosso, Minas Gerais, Bahia e Pará.

No estado de Minas Gerais, a produção está mais concentrada no Sul de Minas, Triângulo Mineiro, Alto Paranaíba e Noroeste (IBGE, 2006). Estas altas concentrações em determinadas regiões do país estão correlacionadas com as condições agroecológicas de cada região, sendo mais favoráveis nestas regiões. Além disso, a localização favorece as atividades, devido à proximidade de mercado do escoamento das produções, da organização do comercial que possibilita com maior facilidade a introdução das novas tecnologias e o gerenciamento das lavouras.

Em relação à época do plantio do milho, não há muita interferência no custo de produção, porem seguramente afeta o rendimento e, conseqüentemente o lucro do agricultor. É importante conhecer os fatores de riscos para minimizar os riscos da lavoura, como os fatores que proporcionam a interceptação da radiação solar pelo dossel, eficiência metabólica, eficiência de translocação de fotoassimilados para os grãos e a capacidade de dreno. Todas essas relações são diretamente ligadas à relação genótipos e ambientes, sendo as de genótipos mais controláveis do que as variações edafoclimáticas. Dentre os fatores mais relevantes na interferência da produtividade, tem-se relacionado diretamente com estresses hídricos e variações na temperatura. (SANS; GUIMARAES, 2006). Portanto, a possibilidade de se produzir um milho irrigado na safrinha, reduz grandes chances de perdas na produtividade final, pois é uma tecnologia que pode minimizar até 20% das perdas esperadas quando comparado ao sequeiro (EMBRAPA, 2006).

2.2 Agricultura de Precisão

A agricultura de precisão (AP) é uma filosofia voltada ao gerenciamento agrícola, que utiliza diversas técnicas visando estudar a variabilidade temporal e espacial do local, partindo de informações exatas e precisas. É uma maneira de gerir um campo produtivo metro a metro, levando em conta que cada pedaço da fazenda tem propriedades diferentes (ROZA, 2000).

Com o aumento exponencial da população mundial, o setor agropecuário utilizou e ainda utiliza de forma intensiva os insumos agrícolas e os recursos naturais, que por sua vez, são utilizados – nas maiorias das vezes – de forma irresponsável, gerando degradação ambiental, esgotamento das águas subterrâneas e eutrofização. Dessa forma, as tecnologias

existentes são uma maneira de se iniciar o manejo racional dos insumos agrícolas, principalmente quando é adotada a agricultura de precisão maximizando a produção e reduzindo as perdas ambientais (RAY; SINGH; SISHODIA, 2020).

A agricultura de precisão é considerada uma das formas de otimizar e aumentar a eficiência do uso de insumos agrícolas, pois está é considerada uma estratégia de gestão que utiliza dados da lavoura, que são transformadas em informações que auxiliam no processo de tomada de decisão (SRINIVASAN, 2006). Estas estratégias de manejos ajudam na otimização das aplicações de água, fertilizantes, defensivos, sementes, combustíveis e até mão-de-obra, que refletem em manejos mais sustentáveis que são algumas das formas de conduzir uma agricultura sustentável que é almejado pela nação. Com certeza, na definição da resolução espaço-temporal a ser utilizada, deve-se considerar alguns fatores importantes como, tamanho do campo, capacidade de equipamento agrícola de várias as taxas de aplicação de insumos e a finalidade de uso da técnica (MULLA, 2013)

Dentro das estratégias da agricultura de precisão, tem-se diversas tecnologias agregadoras, como sensoriamento remoto, sistemas de posicionamento global (GPS), sistemas de informações geográficas (GIS), Internet das Coisas (IoT), análise de Big Data e inteligência artificial (IA), que são ferramentas promissoras utilizadas para otimizar as operações e insumos agrícolas, todas com o objetivo de aumentar a produção e reduzir insumos e perdas de rendimento (ELIJAH, 2018; JHA, 2019; DELGADO, 2019).

2.3 Sensoriamento Remoto

O sensoriamento remoto direcionado para uso na AP podem ser classificados com base na plataforma e o tipo de sensor (SRINIVASAN, 2006). Dentre os diversos tipos de sensores, há os sensores orbitais/espaciais e os terrestres, ou seja, que realizam seu trabalho mais próximo aos alvos, que inclusive podem ser chamados de proximais. No caso das imagens orbitais, são obtidas através de sensores colocados a bordo de aeronaves, como por exemplo os satélites, em que são captadas as reflectâncias dos objetos terrestres em forma de energia eletromagnéticas (PONZONI, 2015).

Os sensores usados para sensoriamentos remoto apresentam diferentes formas de resoluções, sendo resolução temporal que está relacionada à frequência de atividade, a resolução espacial que está correlaciona ao tamanho real de área no solo representada por cada pixel que compõe aquela imagem capturada pelo sensor, a resolução espectral que confere à diferentes comprimentos de ondas que consegue captar, ou seja, é um dado que é mensurado

por números de bandas espectrais que contem cada comprimento de onda específico, e por último não menos importante, a resolução radiométrica que está relacionada à sensibilidade do sensor em captar pequenas variações radiométricas, em outras palavras, capacidade de captar diferentes tons de cinza, que tem como resultado, as diferenças nos valores das radiâncias (SUNDARESAN, 2014).

O número de satélites disponíveis atualmente são bem altos, mas pensando nas aplicações da AP requerem satélites que contenham alta resolução espacial e temporal, pois está correlacionado com os objetivos de manejos, que na maioria das vezes visam identificar gerenciar as lavouras com maior precisão.

Nas práticas que visam manejar a biomassa da cultura, principalmente visando as estimativas de rendimento, normalmente há necessidade de se trabalhar com maiores resoluções espaciais. Na coleta dos dados, se dá grande importância para a qualidade de obtenção dos dados, pois estes serão dados utilizados para tomar decisões dos manejos adjacentes na lavoura. Isso porque, a biomassa é um parâmetro agrônomico estratégico utilizado para indicar o status de crescimento da cultura, por causa dos efeitos das práticas de manejo agrícola. A biomassa desempenha um papel importante na previsão do rendimento, pois está correlacionada com altura de planta, teor de nitrogênio na planta e no solo, índice de área foliar e, pode ser estimada por meio de medições de reflectância espectral do dossel das culturas (JENSEN et al., 1990; LI et al., 2010; KOPPE et al., 2012; GNYP et al., 2014).

Ainda que com todos os avanços, significativos, no sensoriamento remoto, há muitas limitações do uso para fins comerciais, principalmente devido à altos custos de direito de uso de imagens de alta resolução, restrições devido a presença de nuvens e falta de estruturas automatizadas para análises e aplicação de imagens, sendo fatores que afetam diretamente na adoção em larga escala de imagens de satélite (KATSIGIANNIS ,2016).

2.4 Correções atmosféricas

Quando se trabalha com imagens de satélite, os sensores ficam localizados a quilômetros de distância, o que pode fazer com que a radiação refletida pelo alvo encontre barreiras até sua chegada no sensor, pois atravessam a atmosfera terrestre, que há diversos constituintes presente que afetam na qualidade final do dado obtido. A radiação eletromagnética que é emitida através da luz solar, passa por diversas alterações causadas pelas interações com as partículas e moléculas de gás que estão em suspensão na atmosfera (HILKER, 2018). Todos esses constituintes afetam as medições de radiâncias pelos sensores acoplados nos satélites. Para

evitar que esses efeitos depreciem a qualidade das imagens na medição, é necessário que seja adotada a correção.

O procedimento de correção atmosférica visa reduzir ao máximo a influência resultante da interação com os componentes atmosféricos no sinal detectado por sensor acoplado à um satélite presente na atmosfera (MOGRANE, 2019). O método de correção utilizado e as especificações técnicas de cada sensor são fatores importantes de se considerar, pois irão refletir na eficiência do procedimento de correção (OKIN; GU, 2015).

Na literatura diversos métodos têm sido propostos para a correção atmosférica de imagens advindas do sensoriamento remoto (DOXANI, 2018). Os métodos podem ser divididos em três principais categorias. Essas três categorias podem ser classificadas de acordo com os tipos de abordagens, sendo métodos físicos, empíricos e híbridos.

Os métodos físicos são fundamentados na Teoria de Transferência Radiativa, que é conhecida como correção absoluta, realizada utilizando estimativas físicas de parâmetros atmosféricos. Os métodos empíricos são baseados em estimativas dos efeitos atmosféricos a partir de informações de alvos específicos contidos na própria imagem, sendo este método mais simples e com tendências a serem menos precisos. Os métodos híbridos nada mais são do que a junção dos dois métodos antes citados.

Método “*Dark Object Subtraction*” (DOS) descrito como empírico é um método que considera a respostas espectrais de alvos específicos contidos na imagem (CHAVEZ, 1988). Este método parte do pressuposto de que a imagem contenha alvos escuros, e que nos pixels correspondentes à esta área, assume-se que a radiância detectada pelo sensor possui valor igual a zero em todos os comprimentos de onda, tornando os efeitos do espelhamento atmosférico com medidas de radiância não nulas (GAIDA, 2020). Vale destacar que este método tem eficiência apenas para corrigir o efeito aditivo da atmosfera, sendo assim o efeito multiplicativo da atmosfera não é considerado durante a correção, em que este apresenta uma alternativa, que seria analisar o histograma de cada banda e subtrair os valores mínimos de cada uma delas.

O método “*Image correction for atmospheric effects*” (iCOR) considerado híbrido (VITO, 2017), sendo um algoritmo desenvolvido para corrigir imagens de sensores orbitais MultiSpectral Instrument (MSI) que está embarcado no satélite Sentinel-2. Este método possibilita que se corrija os efeitos de adjacência a partir da recuperação de informações da própria imagem por meio do algoritmo “*Similarity Environmental Correction*” (SIMEC), que utiliza procedimentos extremamente elaborados de tabelas baseadas no código de transferência radioativa “*Moderate resolution atmospheric Transmission*” (MODTRAN) (DE KEUKELAERE, 2018).

O método “*Sentinel-2 correction*” (Sen2Cor) foi desenvolvido com objetivo similar ao iCOR, porém o Sen2Cor apresenta aplicação exclusiva para correção do sensor MSI contido no satélite Sentinel-2 (GASCON et al, 2017). Este método contém um algoritmo que executa o processamento das imagens, convertendo a reflectância do topo da atmosfera para a reflectância de superfície, que converte o nível de processamento de 1C para 2A (MAIN-KNORN, 2017). O modelo considera estimativas de aerossol, gases atmosféricos e concentração de ozônio, que variam de acordo com a localização geográfica e condições climáticas do momento de captura do sensor.

2.5 Índices de vegetação

No sensoriamento remoto, a partir da combinação das bandas espectrais do sensor é possível realizar os cálculos dos índices de vegetação. Os índices apresentam como resultados valores de reflectância, com esses valores em mãos é possível diferenciar os alvos, visto que a reflectância de cada alvo é única. Nesse sentido, florestas, água, solo, culturas agrícolas apresentam variações de acordo com seus aspectos biológicos e fisiológicos (LIU, 2016). As características de reflexão da vegetação (reflectância espectral) é determinada por características químicas e morfológicas da superfície de órgãos ou folhas (KOVACS; ZHANG, 2012). Para fins agrícolas, são utilizados os seguintes espectros de luz: Região azul, que varia de 450 a 495 nm; Região verde, que varia de 495 a 570 nm; Região vermelha, que varia de 620 a 750 nm; e Região do infravermelho próximo e médio, que varia de 850 a 1700 nm (CRUDEN; PRABHU; MARTINEZ, 2012).

Para diversos índices de vegetação, os resultados variam entre 0 e 1, como por exemplo no NDVI, em que uma planta totalmente verde desenvolvida sem nenhum estresse, geralmente apresenta resultado entre 0,96 e 0,99. Em contrapartida, para plantas secas, a taxa fotossintética geralmente diminui e apresenta os valores do índice entre 0,88 e 0,94 (ARKEBAUER, 2005). Os comprimentos de onda do infravermelho próximo e médio tem sido bastante estudado, e dizem que poder ser atribuídos a quantificação do crescimento e vigor das plantas, relacionado ao teor de água, pigmentos, teor de açúcar e carboidratos, teor de proteínas e aromáticos e outras diversas características (BATTEN, 1998).

Com a grande aplicabilidade dos índices de vegetação e o aumento na resolução espectral, o número de bandas dos satélites tem aumentado, e as larguras das bandas se tornando mais estreita, que isso possibilita as aferições mais precisas de comportamentos da vegetação. Um dos índices mais utilizados é o NDVI (Índice de Vegetação por Diferença Normalizada),

em que utiliza os comprimentos de onda do vermelho e infravermelho próximo para caracterizar o crescimento ou vigor do dossel (KARNIELI, 2010). O NDVI tem sido o mais utilizado devido ao fato de ser um dos primeiros a serem estudados e identificado o potencial, porém há diversos estudos comprovando que há outros índices com maior relevância, devido ao fato de embarcarem outros comprimentos de ondas em seus cálculos. Há estudos que mostram que o NDVI também está correlacionado com as taxas de fotossíntese do dossel (GAMON, 1995), que para a cultura do milho pode ser promissor, devido a condições morfológicas da cultura, a fotossíntese é um fator primordial que poderá refletir em produtividade.

O NDVI apresenta algumas limitações em relação à discriminação do comportamento do solo, então Huete et al. (1998) propuseram o EVI (Índice de Vegetação Melhorado), que foi desenvolvido para otimizar o sinal da vegetação, com melhoria na sensibilidade em condições de elevada biomassa, o que reduz as influências do sinal de fundo do dossel e da atmosfera (JUSTICE et al, 1998). O EVI é mais sensível à estrutura do dossel (Huete et al., 2002), embora sofra maior influência do ângulo zenital solar (Galvão et al., 2011) em determinadas condições. Além disso, também foi desenvolvido uma versão modificada do NDVI, que é o “Green NDVI” (GNDVI), para fornecer informações da cobertura do solo e as tendências nas mudanças da cobertura, como degradações que irão refletir na qualidade e quantidade de produtividade (YENGOH, 2015). O GNDVI é análogo ao NDVI, em que troca o comprimento de onda do vermelho pelo verde, sendo o cálculo realizado com as bandas do verde e infravermelho próximo.

Com o avanço das tecnologias, outros índices foram surgindo e apresentando relevâncias nos trabalhos realizados, como o ARVI (Índice de Vegetação Resistente à Atmosfera) que corrige os efeitos dos aerossóis e parte do princípio de que a atmosfera afeta mais significativamente a radiação vermelha do que a radiação infravermelha (MARQUES, 2018). Já o VARI (Índice Resistente a Atmosfera na Região Visível) foi desenvolvido para levar em consideração a redução de possíveis influências dos constituintes atmosféricos por meio da subtração da banda espectral do azul (Gitelson et al., 2002).

3 MATERIAL E MÉTODOS

3.1 Área de estudo

A área de obtenção dos dados de produtividade fica localizada na região de Campo do Meio, na região do Sul de Minas Gerais (Figura 1). A região possui um clima caracterizado como subtropical de altitude Cwa (KOPPEN BRASIL, 2023), considerado

ameno durante o ano todo, com temperatura média anual de 19,6°C, com precipitação média anual em torno de 1592,7 mm (CPTEC/INPE, 2023). De acordo com dados do IBGE, o tipo de solo predominante na região é o tipo “Lê-latossolo Vermelho Escuro” com textura predominantemente argilosa.

Os dados foram obtidos da safrinha do ano de 2019, em uma área de pivô central contendo em torno de 55,7 hectares de milho irrigado. A cultivar plantada na safra foi o híbrido “AS 1633 PRO3” da empresa Bayer. A cultura foi semeada no dia 11 de março de 2019 e a colheita no dia 06 de agosto de 2019.

Figura 1. Localização da região e da área de cultivo.



Fonte: Google Earth (08/08/2021)

3.2 Obtenção das imagens

As imagens utilizadas no trabalho foram coletadas no site da Copernicus Open Access Hub, que fornece acesso completo e gratuito a imagens das missões da Sentinel, em especial a do Sentinel-2 utilizada no estudo. O Sentinel-2 compreende uma constelação de dois satélites de órbita polar colocados na mesma órbita síncrona do sol, com fases de 180° um do outro. Os satélites visam realizar o monitoramento do globo terrestre e possuem uma faixa de imageamento de 290 km e tempo de revisita de 5 dias.

O sentinel-2 contem sensores com capacidade de captar 13 diferentes comprimentos

de ondas e com resoluções diferentes, ou seja, 13 tipos de bandas. Para o presente trabalho, foram utilizadas apenas quatro tipos de bandas (Tabela 1).

Tabela 1 – Descrição das bandas espectrais imageadas pelo Sentinel-2

Banda	Comprimento de Onda Central (μm)	Resolução Espacial
2 – Azul	0,490	10 m
3 – Verde	0,560	10 m
4 – Vermelho	0,665	10 m
8 – NIR	0,842	10 m

Fonte: do autor, 2023

A coleta das imagens deveria ocorrer em 5 datas específicas do desenvolvimento da cultura, aos 30, 45, 60, 75 e 100 dias após a semeadura (DAS). Porém, no decorrer do download das imagens foi constatada a presença de nuvens, o que impediu a coleta das imagens nas datas estipuladas, passando então para as datas de 50, 60, 71 e 101 DAS.

3.3 Correções atmosféricas

3.3.1 Dark Object Subtration (DOS)

A correção atmosférica DOS, proposta pelo SCP Plugin (CONGEDO, 2016), envolve a transformação dos DN's (Digital Number) para a subtração da radiância do objeto escuro, que equivale a 1% da reflectância (CONGEDO, 2016). Nesse sentido, a radiância de subtração pode ser calculada através da equação:

$$Lp = Lb - L1\%$$

em que:

Lp = radiância de subtração

$L1\%$ = radiância do objeto escuro

Lb = radiância da banda

A radiância do objeto escuro é representada no SCP Plugin (CONGEDO, 2016) pela equação:

$$L1\% = (0,01 \times ESUN * \cos z) / (\pi \times d^2)$$

em que:

$ESUN$ = irradiância solar

d = distância Terra-Sol

O resultado final da imagem corrigida deve ser expresso em valores de reflectância na superfície terrestre pela seguinte equação (CONGEDO, 2016):

$$\rho = \pi \times (L_b - L_p) \times d^2 ESUN \times \cos z$$

em que:

ρ = valor de reflectância para a banda

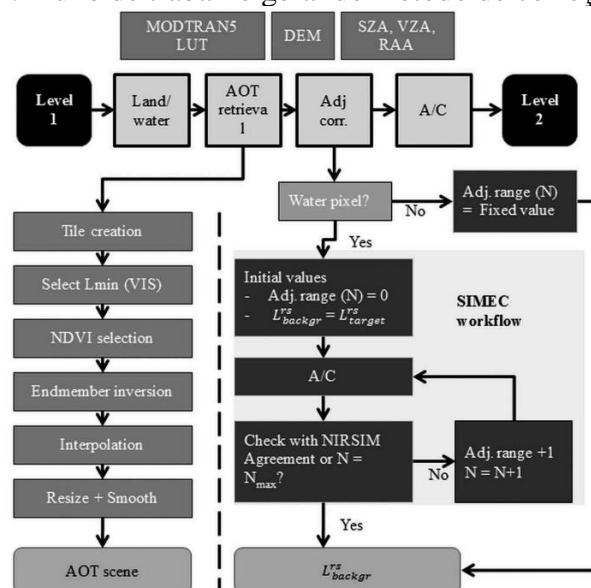
Para a imagem com correção atmosférica subtrai-se da radiância de cada banda (L_b) o valor da radiância de subtração (L_p). Na imagem sem correção não se subtrai o valor da radiância de subtração.

Todos os cálculos foram executados com a calculadora Raster do software livre QGIS.

3.3.2 Image correction for atmospheric effects (iCOR)

O fluxo de trabalho geral do iCOR é apresentado na Figura 2. Esse esquema pode ser resumido nos seguintes passos: (i) diferenciação de pixels de terra e água, (ii) utilização dos pixels de terra para derivar o AOT (espessura óptica do aerossol) com base em uma versão adaptada do método desenvolvido por Guanter (2007), (iii) realização de uma correção de adjacência usando o SIMEC (Sterckx et al., 2014) sobre a água e faixas de fundo fixas sobre alvos de terra (Berk et al., 2006), e (iv) resolução da equação de transferência radiativa. O iCOR utiliza o MODTRAN5 (Berk et al., 2006) para realizar a correção atmosférica e usa informações sobre os ângulos solares e de visualização (ângulo zenital do sol (SZA), ângulo zenital de visualização (VZA) e ângulo de azimute relativo (RAA)) e um MDE (Modelo de Elevação Digital).

Figura 2. Fluxo de trabalho geral do método de correção iCOR.

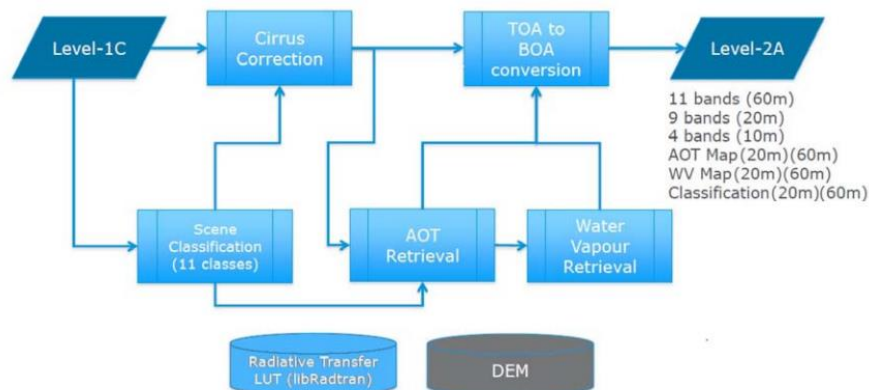


Na prática, o processamento da correção iCOR para as imagens foi feito no software SNAP (Sentinel Application Platform), que é um software gratuito e desenvolvido pela Agência Espacial Europeia (ESA). Para realizar o processamento, houve a necessidade de se instalar o plugin iCOR (que se encontra disponível no site da VITO Remote Sensing).

3.3.3 Sentinel-2 correction (Sen2Cor)

O Sen2Cor é um processador de Nível-2A, cujo principal objetivo é corrigir produtos Sentinel-2 de Nível-1C de uma única data dos efeitos da atmosfera, a fim de fornecer um produto de reflectância de Nível-2A na parte inferior da atmosfera (BOA). As saídas adicionais são um mapa de Espessura Óptica de Aerossol (AOT), um mapa de Vapor de Água (WV) e um mapa de Classificação de Cena (SCL) com Indicadores de Qualidade para probabilidades de nuvens e neve. A estrutura básica do processador Sen2Cor (Figura 3) consiste em cinco módulos que coordenam as interações dentro do fluxo de trabalho, leem e processam os dados, fornecem os parâmetros de configuração e convertem os produtos para o formato desejado. Dois módulos principais são projetados para processar os dados de entrada do Nível-1C do Sentinel-2, o módulo de Classificação de Cena (SCL) e o módulo de Correção Atmosférica (AC). O fluxo de trabalho principal consiste na leitura e processamento dos parâmetros e dados de entrada e na criação de um banco de dados temporário interno, que é usado pelos módulos SC e AC para recuperar e armazenar os dados e produtos intermediários. O processamento pode ocorrer em loop, dependendo do número de resoluções de produtos diferentes a serem geradas.

Figura 3. Processamento Sen2Cor



Fonte: Sen2Cor for Sentinel (MAIN-KNORN et al, 2017)

O algoritmo SCL permite detectar nuvens, suas sombras e neve, e gerar um mapa de

classificação. Este último consiste em 11 classes, incluindo 2 classes para probabilidades de nuvens (média e alta), uma classe para cirrus fino, vegetação, solos/desertos, água, neve, pixels de áreas escuras, sombras de nuvens e pixels não classificados, saturados ou defeituosos. Esse mapa é usado internamente no Sen2Cor no módulo AC para distinguir entre pixels nublados, claros e de água, e não realiza uma classificação de cobertura terrestre no sentido estrito (GASCON et al, 2017).

O algoritmo é baseado em uma série de testes de limiar que utilizam como entrada a reflectância de topo da atmosfera das bandas espectrais do Sentinel-2. O algoritmo utiliza as propriedades reflexivas das características da cena para estabelecer a presença ou ausência de nuvens em uma cena. A seleção de nuvens é aplicada aos dados a fim de recuperar parâmetros atmosféricos e de superfície precisos como entrada para etapas de processamento posteriores, seja as descritas abaixo ou processamentos de nível mais alto, como mosaico ou análise de séries temporais

3.4 Índices de vegetação e extração dos valores

Após as correções atmosféricas, as bandas utilizadas para os cálculos foram agrupadas em “band set”, visando otimizar o carregamento do processamento. Em seguida, foram calculados os índices de vegetação (Tabela 2), que foram previamente definidos para serem testados. A escolha destes índices se deu devido à popularidade de uso deles na agricultura, pois há diferentes autores discutindo sobre suas importâncias e aplicabilidades.

Tabela 2 – Índices de vegetação e suas equações

Índice de Vegetação	Equação	Autor
NDVI	$\frac{NIR - RED}{NIR + RED}$	Rouse et al (1974)
GNDVI	$\frac{NIR - GREEN}{NIR + GREEN}$	Gitelson et al. (1996)
EVI	$\frac{2,5 * (NIR - RED)}{(NIR + (C1 * RED) - (C2 * BLUE) + L)}$	Justice et al (1998)
VARI	$\frac{GREEN - RED}{GREEN + RED - BLUE}$	Gitelson et al (2002)
ARVI	$\frac{NIR - (2 * RED) + BLUE}{NIR + (2 * RED) + BLUE}$	Kaufman e Tanré (1992)

Legenda: **NDVI**: Normalized Difference Vegetation Index; **GNDVI**: Green Normalized Difference Vegetation; **EVI**: Enhanced Vegetation Index; **VARI**: Visible Atmospherically Resistant Index; **ARVI**: Atmospherically Resistant Vegetation Index.

Fonte: Autor (2023)

Após os cálculos de todos os índices de vegetação, utilizando novamente o QGIS, cada pixel foi transformado em polígonos individualmente, cada um contendo seu valor de índice de vegetação. Em seguida, foram convertidos para CSV para futuras análises estatísticas, visando a correlação com os mapas de produtividade.

3.5 Análise dos dados

Após a extração dos valores dos índices de vegetação de cada pixel foi realizada a análise de correlação de Pearson (r). Com a análise foi possível observar a correlação positiva ou negativa entre os índices de vegetação e a produtividade do milho nas diferentes datas. Além disso, com o intuito de calibrar um modelo foi realizada a análise de regressão linear. A variável dependente foi a produtividade e a independente os valores dos índices de vegetação.

O coeficiente de correlação de Pearson calcula-se segundo a seguinte fórmula:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

onde x_1, x_2, \dots, x_n e y_1, y_2, \dots, y_n são os valores medidos de ambas as variáveis. Para, além disso:

$$\bar{x} = \frac{1}{n} \cdot \sum_{i=1}^n x_i \quad \text{e} \quad \bar{y} = \frac{1}{n} \cdot \sum_{i=1}^n y_i$$

O modelo de regressão linear, é um dos modelos causais mais conhecidos e utilizados, que consiste de uma variável chamada de dependente estar relacionada a uma ou mais variáveis independentes por uma equação linear (KRAJEWSKI et al, 2009). Pode-se dizer em uma linguagem técnica que a linha de regressão minimiza os desvios quadrados dos dados reais. Para se obter o cálculo da equação da reta basta aplicar a seguinte equação:

$$y = a + bx$$


Todo o processo estatístico foi realizado utilizando o software Python, no ambiente Google Colab, utilizando as bibliotecas Pandas, Numpy, StasModels e Matplotlib. A biblioteca Pandas teve a função de preparar e organizar os dados de forma adequada para análise, como DataFrames, além de obter o coeficiente de correlação das variáveis. De modo a complementar, a biblioteca StasModels foi utilizada para ajustar o modelo de regressão linear aos dados.

Por final, agrupou-se os dados gerados em uma planilha do Excel para gerar os gráficos.

4 RESULTADOS E DISCUSSÃO

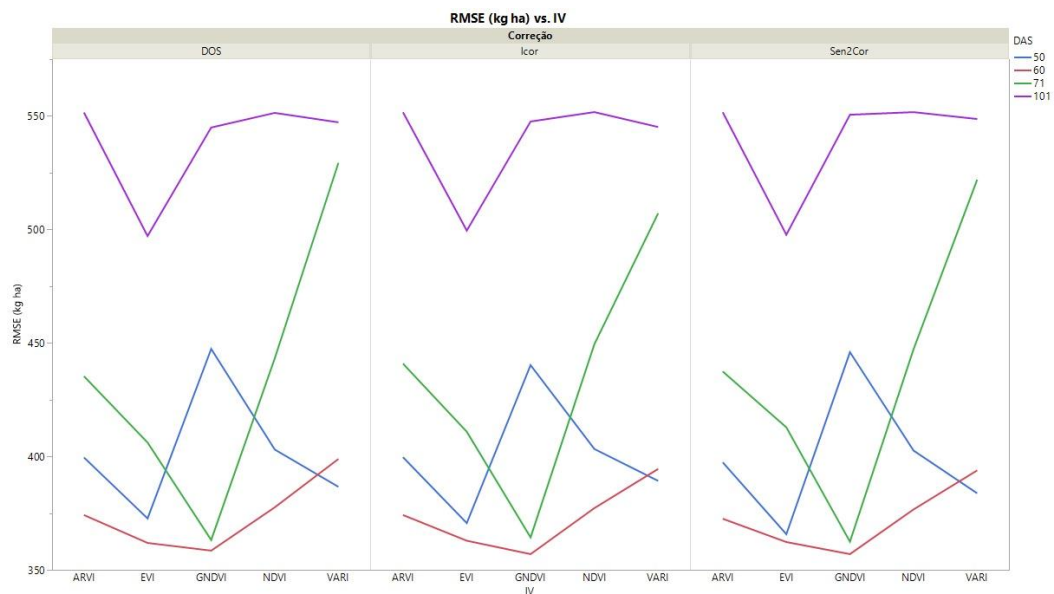
Diante dos três diferentes métodos de correção, foi observada pouca variação nos cálculos dos índices de vegetação. Abaixo se tem o resumo dos resultados dos gráficos de regressão linear expostos (Figura 4), para os valores dos índices de vegetação quase não houve alteração quando expostos à diferentes métodos de correção na maioria das datas, como por exemplo, para 50 DAS o valor de R^2 é igual a 0,47 no índice de NDVI para todas as correções. Para os outros índices de vegetação e outras datas também houve pouca variação, sendo que maior diferença foi aos 71 DAS, em que o R^2 do EVI foram 0,46 e 0,44, respectivamente, para as correções DOS e Sen2Cor. Estes resultados corroboram com um trabalho feito por Marcello et al. (2016), no qual ele fala que os índices de vegetação apresentam grandes diferenças se, calculados com uma imagem sem correção atmosférica comparado a uma imagem com correção atmosférica. Além disso, as diferenças entre reflectâncias corrigidas são relativamente baixas, sendo mais significativas quando há ajustes no modelo de adjacência e/ou no modelo de aerossol.

Figura 4 – Gráfico da regressão linear simples das correções atmosféricas DOS, iCOR e Sen2Cor.



Fonte: Autor, 2023

Figura 5 – Gráfico da raiz do erro quadrático médio das correções atmosféricas DOS, iCOR e Sen2Cor para estimativa de produtividade



Fonte: Autor, 2023

Nas diferentes datas de coleta é possível observar uma variação entre os melhores e os piores ajustes do modelo de regressão de acordo com o índice de vegetação. Aos 50 DAS o EVI foi o índice que apresentou os melhores ajustes de R^2 com uma média de 0,55 e o RMSE de 350. Na sequência os índices de vegetação VARI, ARVI, NDVI e GNDVI apresentaram os melhores descritos pelos valores médios de R^2 de 0,51, 0,48, 0,47 e 0,35 respectivamente. Aos 60 DAS os melhores resultados encontrados foram para o GNDVI e EVI com os valores de R^2 de 0,58 e 0,57, independente do método de correção. Já aos 71 DAS apenas o GNDVI apresentou os melhores resultados de R^2 (0,57) diferente do observado aos 101 DAS em que os melhores resultados de R^2 foram para o EVI (0,19). Nota-se também, que aos 101 DAS os erros são maiores (Figura 5), podendo estar correlacionado à maturidade fisiológica da cultura (ARAÚJO, 2016).

Apesar dessa diferenciação entre os valores dos IVs nas diferentes datas, Meirelles et al. (2022) encontrou bons ajustes dos modelos de regressão (R^2 de 0,81) entre a produtividade de milho e o NDVI, diferente do observado neste trabalho. Além disso, com esses resultados é possível inferir que os índices que apresentam fatores para correção do solo ou do ambiente como o EVI, VARI e ARVI são melhores para estimar a produtividade quando a cultura ainda apresenta uma baixa biomassa. Por outro lado, em alta biomassa os resultados encontrados com índices que não utilizam fatores de correção como o NDVI e o GNDVI os resultados são

melhores. Esses resultados diferem do que foi encontrado por Venâncio et al. (2019), em que ao analisar os resultados de 6 pivôs, concluíram que aos 100 dias após a semeadura, o NDVI apresenta uma alta relação de forma positiva com a produtividade do milho.

Além disso, um dos fatores que pode ter levado o GNDVI a obter bons resultados ao 71 DAS foi o fato do índice não utilizar a banda do vermelho, essa banda como observado no NDVI apresenta saturação dos seus valores, principalmente pelo fato da alta biomassa e nessa situação o índice não é capaz de captar a variabilidade na área (JENSEN; EPIPHANIO, 2009).

Por outro lado, o ambiente e o manejo adotado, com a cultura influenciam diretamente o seu ciclo e nos resultados com a produtividade. Como o relatado por Oliveira (2017), a predição de produtividade da cultura de milho por índice de vegetação apesar de muitas vezes correlacionar com a produtividade, pode ser um pouco complexa, pois o milho é cultivado sob espaçamentos e populações de plantas diferentes, fazendo com o que não se tenha um modelo único de predição de produtividade através do índice de vegetação.

Em relação à correlação dos índices de vegetação com a produtividade final, foram encontrados valores de correlações acima de 0,70 aos 50, 60 e 71 DAS, e acima de 0,60 para os 101 DAS (Tabela 4). Mas, vale destacar sobre alguns índices que apresentaram bons valores em mais de um período de avaliação, como o GNDVI, NDVI e EVI. O GNDVI se mostrou mais eficiente do que os demais em duas datas após plantios, sendo que apresentou um valor de correlação igual a 0,76 e 0,75, com 60 e 71 DAS respectivamente. De acordo Yamamoto e Landim (2013), correlações acima de 0,50 são satisfatórias, portanto afirma-se que os índices estudados podem ser utilizados para estimativa de produtividade do milho.

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 com GNDVI e EVI, o NDVI se correlacionou com menor intensidade com a produtividade. Esse fato, associado aos dados inerentes a este experimento, indicam que o NDVI devido a utilização do comprimento de onda vermelho em sua fórmula será menos indicado para a estimativa da produtividade na cultura do milho devido à probabilidade de saturação do índice diante de altas densidades de plantio.

Tabela 3 – Corelação de Pearson ($p>0.01$) entre os índices de vegetação e correções atmosféricas para estimar a produtividade aos 50, 60, 71 e 101 DAS.

DOS				
	50 DAS	60 DAS	71 DAS	101 DAS
NDVI	0,68	0,73	0,60	0,04
GNDVI	0,59	0,75*	0,75*	0,16
EVI	0,74	0,75*	0,68	0,43
VARI	0,71	0,69	0,28	-0,13
ARVI	0,69	0,73	0,61	0,03
Icor				
	50 DAS	60 DAS	71 DAS	101 DAS
NDVI	0,68	0,73	0,58	0,00
GNDVI	0,60	0,76*	0,75*	0,12
EVI	0,74	0,75*	0,67	0,42
VARI	0,71	0,70	0,39	-0,15
ARVI	0,69	0,73	0,60	-0,02
Sen2Cor				
NDVI	0,68	0,73	0,59	-0,01
GNDVI	0,59	0,76*	0,75*	0,06
EVI	0,75*	0,75*	0,66	0,43
VARI	0,72	0,70	0,32	-0,11
ARVI	0,69	0,74	0,61	-0,02

*= maiores correlações com produtividade

Fonte: Autor, 2023

Observa-se que os dias 60 e 71 DAS foram os dias em que os índices de vegetação mais apresentaram correlação com a produtividade. Principalmente no dia 12/04/2019 (60 DAS), porque é uma data esperada que esteja ocorrendo o pendoamento do milho e é justamente quando ocorre maior atividade metabólica e a planta se encontra com alto índice de área foliar, pois precisa de energia para encher os grãos. Em contrapartida, o que é observado no dia 22/05/2019 (101 DAS) a planta se encontra em etapas próximas da maturidade, tende a reduzir área foliar e sua atividade metabólica.

Para Araújo (2016) è possível observar que durante o desenvolvimento inicial da cultura do milho, entre o 1º e o 40º dia após o plantio, os valores de NDVI aumentam rapidamente, pois se trata de um período de elevadas taxas de crescimento da cultura, com

ligeira expansão da área foliar. Entre o 40° e o 100° dia após o plantio, nota-se a estagnação dos valores de NDVI. Sendo que a diminuição dos valores de NDVI ocorre após o 100° dia, sendo ocasionada pela maturidade das plantas.

5 CONCLUSÃO

Conclui-se que, não diferenças significativas nos índices de vegetação – NDVI, GNDVI, EVI, VARI e ARVI – se submetidos aos diferentes métodos de correção atmosférica – DOS, iCOR e Sen2Cor – visando a estimativa de produtividade.

Os três métodos de correção são eficientes para realizar trabalhos que utilizam o satélite da missão Sentinel-2.

O índice de vegetação “GNDVI” apresenta maior correlação com a produtividade do milho, associado ao período de desenvolvimento da planta de 60 dias após a semeadura. Porém, ressalta-se que com 60 DAS ainda é muito cedo para se estimar a produtividade, pois até a data de colheita a lavoura fica exposta a fatores externos que podem comprometer a produtividade final.

Por fim, o estudo foi realizado com base em uma safra, tendo assim, pouca variabilidade temporal para se afirmar os dados. Mas os resultados são bons indícios e mostram algum potencial de se analisar em mais safras recorrentes, principalmente se possível considerar outros fatores de interferência.

6 REFERÊNCIAS

ARAUJO, Glaucio Luciano. **Estimativas da evapotranspiração e produtividade do milho irrigado utilizando um modelo multiespectral e imagens do satélite Landsat 8**. 2016.

ARKEBAUER, Timothy J. Leaf radiative properties and the leaf energy budget. **Micrometeorology in Agricultural Systems**, v. 47, p. 93-103, 2005.

BARROS, José FC; CALADO, José G. **A cultura do milho**. 2014.

BATTEN, G. D. Plant analysis using near infrared reflectance spectroscopy: the potential and the limitations. **Australian Journal of Experimental Agriculture**, v. 38, n. 7, p. 697-706, 1998.

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.

BOLETIM Logístico. Companhia Nacional de Abastecimento (Conab), 2022. Disponível em: <<https://www.conab.gov.br/ultimas-noticias/4789-boletim-logistico-volume-acumulado-em-2022-das-exportacoes-de-milho-tem-aumento-de-92-3#:~:text=O%20volume%20acumulado%20das%20exporta%C3%A7%C3%B5es,12%2C82%20milh%C3%B5es%20de%20toneladas>>. Acesso em 05 de mar. de 2023.

CHAVEZ JR, Pat S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote sensing of environment**, v. 24, n. 3, p. 459-479, 1988.

CONAB - Companhia Nacional de Abastecimento. **Acompanhamento de safra brasileira: Grãos – Safra 2016/2017, Primeiro levantamento Outubro/2016** - Companhia Nacional de Abastecimento. - Brasília: Conab Brasília, v. 4. p. 1-164.

CONGEDO, Luca. **Semi-automatic classification plugin documentation**. Release, v. 4, n. 0.1, p. 29, 2016.

CRUDEN, Brett A.; PRABHU, Dinesh; MARTINEZ, Ramon. Absolute radiation measurement in venus and mars entry conditions. **Journal of Spacecraft and Rockets**, v. 49, n. 6, p. 1069-1079, 2012.

CRUZ, José Carlos et al. **Manejo da cultura do milho**. 2006.

DE KEUKELAERE, Liesbeth et al. Atmospheric correction of Landsat-8/OLI and Sentinel-2/MSI data using iCOR algorithm: validation for coastal and inland waters. **European Journal of Remote Sensing**, v. 51, n. 1, p. 525-542, 2018.

DELGADO, Jorge A. et al. Big data analysis for sustainable agriculture on a geospatial cloud framework. **Frontiers in Sustainable Food Systems**, v. 3, p. 54, 2019.

DOXANI, Georgia et al. Atmospheric correction inter-comparison exercise. **Remote Sensing**, v. 10, n. 2, p. 352, 2018.

ELIJAH, Olakunle et al. An overview of Internet of Things (IoT) and data analytics in agriculture: Benefits and challenges. **IEEE Internet of things Journal**, v. 5, n. 5, p. 3758-3773, 2018.

GAIDA, William et al. Correção atmosférica em sensoriamento remoto: uma revisão. **Revista Brasileira de Geografia Física**, v. 13, n. 01, p. 229-248, 2020.

GALVAO, Lenio Soares et al. On intra-annual EVI variability in the dry season of tropical forest: A case study with MODIS and hyperspectral data. **Remote Sensing of Environment**, v. 115, n. 9, p. 2350-2359, 2011.

GAMON, John A. et al. Relationships between NDVI, canopy structure, and photosynthesis in three Californian vegetation types. **Ecological applications**, v. 5, n. 1, p. 28-41, 1995.

GARCIA, João Carlos; MATTOSO, Marcos Joaquim; DUARTE, J. de O. **Importância do milho em Minas Gerais**. 2006.

GASCON, Ferran et al. Copernicus Sentinel-2A calibration and products validation

status. **Remote Sensing**, v. 9, n. 6, p. 584, 2017.

GITELSON, Anatoly A. et al. Novos algoritmos para estimativa remota da fração de vegetação. **Sensoriamento remoto do Meio Ambiente**, v. 80, n. 1, pág. 76-87, 2002.

GNYP, M. L.; BARETH, G.; LI, F.; LENZ-WIEDEMANN, V. I. S.; KOPPE, W.; MIAO, Y.; HENNIG, S. D.; JIA, L.; LAUDIEN, R.; CHEN, X.; ZHANG, F. Development and implementation of a multiscale biomass model using hyperspectral vegetation indices for winter wheat in the North China Plain. **International Journal of Applied Earth Observation and Geoinformation**, v. 33, p. 232-242, Dec. 2014

HILKER, T. Surface reflectance/bidirectional reflectance distribution function. 2018.

HUETE, Alfredo et al. 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.

HUETE, Alfredo R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.

JENSEN, John R.; EPIPHANIO, José Carlos Neves. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese Editora, 2009.

JHA, Kirtan et al. A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture**, v. 2, p. 1-12, 2019.

JENSEN, A.; LORENZEN, B.; ØSTERGAARD, H. S.; HVELPLUND, E. K. Radiometric estimation of biomass and nitrogen content of barley grown at different nitrogen levels. **Remote Sensing**, v. 11, n. 10, p. 1809-1820, 1990.

JUSTICE, Christopher O. et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): Land remote sensing for global change research. **IEEE transactions on geoscience and remote sensing**, v. 36, n. 4, p. 1228-1249, 1998.

KARNIELI, Arnon et al. Use of NDVI and land surface temperature for drought assessment: Merits and limitations. **Journal of climate**, v. 23, n. 3, p. 618-633, 2010.

KATSIKIANNIS, P. et al. Fusion of spatio-temporal UAV and proximal sensing data for an agricultural decision support system. In: **Fourth International Conference on Remote Sensing and Geoinformation of the Environment (RSCy2016)**. SPIE, 2016. p. 564-574.

KOPPE, W.; GNYP, M. L.; HENNIG, S. D.; LI, F.; MIAO, Y.; CHEN, X.; JIA, L.; BARETH, G. Multi-temporal hyperspectral and radar remote sensing for estimating winter wheat biomass in the North China Plain. **Photogrammetrie, Fernerkundung, Geoinformation**, v. 3, p. 281-298, Jun. 2012

KOPPEN BRASIL. **Classificação Climática de Koppen para os municípios brasileiros**. Disponível em: < <https://koppenbrasil.github.io/> >. Acesso em: 10 de abr. 2023.

KRAJEWSKI, L. J.; RITZMAN, L. P.; MALHOTRA, M. **Administração da produção e operações**. 8. ed. São Paulo: Pearson Prentice Hall, 2009.

LERAYER, Alda. Guia do milho: tecnologia do campo a mesa. **Conselho de Informações sobre Biotecnologia**, p. 16, 2006.

LI, F.; MIAO, Y.; HENNIG, S. D.; GNYP, M. L.; CHEN, X.; JIA, L.; BARETH, G. Evaluating hyperspectral vegetation indices for estimating nitrogen concentration of winter wheat at different growth stages. **Precision Agriculture**, v. 11, n. 4, p. 335-357, 2010.

LIU, Chang et al. A review of plant spectral reflectance response to water physiological changes. **Chinese Journal of Plant Ecology**, v. 40, n. 1, p. 80, 2016.

MAIN-KNORN, Magdalena et al. Sen2Cor for sentinel-2. In: **Image and Signal Processing for Remote Sensing XXIII**. SPIE, 2017. p. 37-48.

MARQUES, Francisco José Mendonça. **Utilidade agronômica dos índices NDVI e NDWI obtidos por imagem dos satélites Sentinel-2: estudos de caso nas culturas de trigo, brócolo e arroz**. 2018. Dissertação de Mestrado. Universidade de Évora.

MEIRELLES, Luara Franciane de. **Predição da produtividade de milho (zea mays l) por meio da interpretação temporal de índices de vegetação**. 2022.

MELO, R. W.; FONTANA, D. C.; BERLATO, M. A.; DUCATI, J. R. An agrometeorological-spectral model to estimate soybean yield, applied to southern Brazil. **International Journal Of Remote Sensing**. v. 29. n. 14. p.4013-4028. 2008.

MOGRANE, Mohamed Abdelillah et al. Evaluation of five atmospheric correction algorithms over French optically-complex waters for the Sentinel-3A OLCI Ocean Color Sensor. **Remote Sensing**, v. 11, n. 6, p. 668, 2019.

MOREIRA, M.A. Fundamentos de Sensoriamento Remoto e metodologias de Aplicação. São José dos Campos, 2001. Instituto Nacional de Pesquisas Espaciais (INPE), 2008, 208p.

MULLA, David J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems engineering**, v. 114, n. 4, p. 358-371, 2013.

OKIN, Gregory S.; GU, Juan. The impact of atmospheric conditions and instrument noise on atmospheric correction and spectral mixture analysis of multispectral imagery. **Remote Sensing of Environment**, v. 164, p. 130-141, 2015.

OLIVEIRA, M. F de. **Modelos de predição de produtividade da cultura do milho por meio de NDVI em arranjos espaciais**. Universidade Estadual Paulista – UNESP Câmpus de Jaboticabal, 2017.

PONZONI, Flávio Jorge et al. **Calibração de sensores orbitais**. Oficina de Textos, 2015.

RAMOS, M. C. A. **Estimativa de Produtividade de cana-de-açúcar por meio de imagens do satélite Landsat-5/ TM em áreas de pivôs centrais na região de Jaíba - MG**. 2013. 59 p. TCC (Graduação) - Curso de Engenharia Agrícola e Ambiental, Universidade Federal de Minas Gerais, Montes Claros, 2013.

RIZZI, R.; RUDORFF, B. F. T. Imagens do sensor MODIS associadas a um modelo agrônômico para estimar a produtividade de soja. **Pesquisa Agropecuária Brasileira**. v. 42. n. 1. p.73-80. 2007.

- RODRIGUES, V. N.; von PINHO, R. G.; PAGLIS, C. M.; BUENO FILHO, J. S. de S.; BRITO, A. H. de. Comparação entre métodos para estimar a produtividade de grãos de milho. **Ciência e Agrotecnologia**. v. 29. n. 1. p.34-42. 2005.
- 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. Proceedings. Washington, 1973, v.1, Sec. A, p. 309-317.
- ROSA, V. G. C. da; MOREIRA, M. A.; RUDOFF, B. F. T.; ADAMI, M. Estimativa da produtividade de café com base em um modelo agrometeorológico-espectral. **Pesquisa Agropecuária Brasileira**, Brasília, v. 24, n. 12, p.1478-1488, dez. 2010.
- ROZA, D. Novidade no campo: **Geotecnologias renovam a agricultura**. Revista InfoGEO, v. 11, 2000.
- RUDORFF, B. F. T.; MOREIRA, M. A. **Sensoriamento Remoto Aplicado a Agricultura, Capítulo 9**. 2002, INPE, São José dos Campos. INPE-8984-PUD/62
- SANS, Luiz Marcelo Aguiar; GUIMARAES, Daniel Pereira. **Zoneamento agrícola de riscos climáticos para a cultura do milho**. 2006.
- SISHODIA, Rajendra P.; RAY, Ram L.; SINGH, Sudhir K. Applications of remote sensing in precision agriculture: A review. **Remote Sensing**, v. 12, n. 19, p. 3136, 2020.
- SRINIVASAN, A. (Ed.) Manual de Agricultura de Precisão: Princípios e Aplicações; Food Products Press, Haworth Press Inc.: Nova York, NY, EUA, 2006; ISBN 13:978-1-56022-955-1.
- SUNDARESAN, Janardhanan et al. (Ed.). **Geospatial Technologies and Climate Change**. Springer International Publishing, 2014.
- VARELLA, C. A. A.; MEDEIROS, R.; GLERIANI, J. M. Agricultura de Precisão e Sensoriamento Remoto. In: SANTOS, F.; BORÉM, A.; CALDAS, C. **Cana-deaçúcar: bioenergia, açúcar e etanol: 58 tecnologias e perspectivas**. 2ed.rev e ampl. Viçosa, MG: Os editores, 2011. Cap. 9, p. 258.
- VENANCIO, L. P. et al. **Biomassa e produtividade de grãos na cultura do milho irrigado por meio do NDVI acumulado**. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto ISBN: 978-85-17- 00097-3. Vol 19, 2019 – 96307
- 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.
- VITO. Vlaams Instituut voor Technologisch Onderzoek. 2017. iCOR plugin for SNAP toolbox: software user manual. Version 1. Mol: VITO Remote Sensing Unit. Wang, J., Wu, C., Zhang, C., Ju, W
- YENGOH, Genesis T. et al. **Use of the Normalized Difference Vegetation Index (NDVI) to assess Land degradation at multiple scales: current status, future trends, and practical considerations**. Springer, 2015.
- ZHANG, Chunhua; KOVACS, John M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision agriculture**, v. 13, p. 693-712, 2012.