

UNIVERSIDADE FEDERAL DE SANTA MARIA
COLÉGIO POLITÉCNICO
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRICULTURA DE
PRECISÃO

Marco Ivan Rodrigues Sampaio

**ÍNDICES DE VEGETAÇÃO POR DIFERENTES PLATAFORMAS E
SUAS RELAÇÕES COM PRODUTIVIDADE DO MILHO (*Zea mays* L.)
SOB VARIABILIDADE DE DOSES DE NITROGÊNIO A PARTIR DE
ANÁLISES MULTIVARIADAS**

Santa Maria, RS
2019

Marco Ivan Rodrigues Sampaio

**ÍNDICES DE VEGETAÇÃO POR DIFERENTES PLATAFORMAS E SUAS
RELAÇÕES COM PRODUTIVIDADE DO MILHO (*Zea mays* L.) SOB
VARIABILIDADE DE DOSES DE NITROGÊNIO A PARTIR DE ANÁLISES
MULTIVARIADAS**

Dissertação de mestrado apresentada ao Curso de Pós-Graduação Profissional em Agricultura de Precisão da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Mestre em Agricultura de Precisão**.

Orientador: Prof. Dr. Lúcio de Paula Amaral

Santa Maria, RS
2019

Sampaio, Marco Ivan Rodrigues
ÍNDICES DE VEGETAÇÃO POR DIFERENTES PLATAFORMAS E
SUAS RELAÇÕES COM PRODUTIVIDADE DO MILHO (Zea mays L.)
SOB VARIABILIDADE DE DOSES DE NITROGÊNIO A PARTIR DE
ANÁLISES MULTIVARIADAS / Marco Ivan Rodrigues Sampaio.-
2019.
95 p.; 30 cm

Orientador: Lúcio de Paula Amaral
Dissertação (mestrado) - Universidade Federal de Santa
Maria, Colégio Politécnico, Programa de Pós-Graduação em
Agricultura de Precisão, RS, 2019

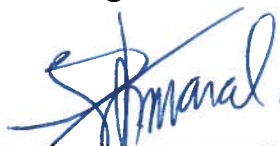
1. ACP 2. NDRE 3. Cluster I. Amaral, Lúcio de Paula
II. Título.

Marco Ivan Rodrigues Sampaio

**ÍNDICES DE VEGETAÇÃO POR DIFERENTES PLATAFORMAS E
SUAS RELAÇÕES COM PRODUTIVIDADE DO MILHO (*Zeamays L.*)
SOB VARIABILIDADE DE DOSES DE NITROGÊNIO A PARTIR DE
ANÁLISES MULTIVARIADAS**

Dissertação de mestrado apresentada ao
Curso de Pós-Graduação Profissional em
Agricultura de Precisão da Universidade
Federal de Santa Maria (UFSM, RS),
como requisito parcial para obtenção do
título de **Mestre em Agricultura de
Precisão**.

Aprovado em 30 de agosto de 2019:



Lúcio de Paula Amaral, Dr. (UFSM)
(Presidente/Orientador)



Telmo Jorge Carneiro Amado, Dr. (UFSM)



João Fernando Zamberlam, Dr. (UNICRUZ)

DEDICATÓRIA

Dedico aos meus pais (in memorium), que sempre lutaram para que seus filhos tivessem oportunidade de estudar e evoluir como pessoas.

À minha esposa e filho, pelo apoio incondicional em todos os momentos, principalmente nos difíceis, comuns nesta jornada de crescimento profissional.

Sem vocês nenhuma conquista valeria a pena.

AGRADECIMENTOS

Gostaria de agradecer a todas as pessoas que diretamente fizeram parte desta jornada de Pós-graduação e de alguma forma contribuíram para a realização desta dissertação, em especial:

À Deus, pela vida, saúde e por me guiar ao longo desta caminhada.

À minha família, em especial aos meus pais (in memoriam), Alice Rodrigues Sampaio e Ivan Motta Sampaio, meus irmãos(as), e esposa, Ediane Girardi Viera Sampaio e ao meu filho Joaquim Viera Sampaio que me incentivaram e apoiaram a todo momento. Aos meus sobrinhos e sobrinhas que sempre tiveram torcendo por mim.

À Universidade Federal de Santa Maria, ao Colégio Politécnico professores e colegas do Programa de Pós Graduação em Agricultura de Precisão, por ter me oportunizado a realização do mestrado. Agradecimentos especiais ao professor Luiz Felipe de Carvalho e aos colegas do mestrado que nos ajudaram na coleta dos dados a campo, sem vocês não teríamos conseguido.

Ao professor Lúcio de Paula Amaral, pela paciência e orientação para conclusão desta dissertação, ensinamentos e amizade.

Aos meus colegas e professores da Universidade de Cruz Alta (UNICRUZ) ao Laboratório de Floresta de Precisão, Agricultura de Precisão e Análises Espaciais – LAFLOPE, e o Projeto de Pesquisa 048066 “Uso de Geotecnologias em Floresta de Precisão, Agricultura de Precisão, Novas Áreas de Precisão e Análises Espaciais”, pelo entendimento, paciência e parceria, meu muito obrigado.

Enfim, a todos aqueles que, de uma forma ou de outra, contribuíram para a realização deste projeto.

Talvez não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito. Não sou o que deveria ser, mas Graças a Deus, não sou o que era antes

Marthin Luther King

RESUMO

USO DA ESTATÍSTICA MULTIVARIADA PARA A ANÁLISE DE ÍNDICES DE VEGETAÇÃO PARA A CULTURA DO MILHO (*Zea mays* L.)

AUTOR: Marco Ivan Rodrigues Sampaio

ORIENTADOR: Lúcio de Paula Amaral

Há necessidade do uso de ferramentas para estimativa do potencial produtivo durante o desenvolvimento da cultura do milho. Assim, o auxílio por meio de sensores ópticos ativos ou embarcado em ARPs para a geração de índices de vegetação, pode fornecer informações significativas para o conhecimento do comportamento e relação temporal destes índices com parâmetros produtivos das culturas agrícolas. Normalmente, no monitoramento do ciclo inteiro de uma lavoura, são gerados uma grande quantidade de dados que são difíceis de analisar e interpretar, pois as relações entre as variáveis são complexas. O Objetivo do trabalho foi utilizar técnicas de análise multivariada para melhor entender a relação da produtividade do milho, sob diferentes doses de nitrogênio, com uso de índices de vegetação obtidos a partir de dados de duas plataformas distintas de sensoriamento remoto, uma proximal e a outra a aeronave remotamente pilotada (ARP), em diferentes estágios fenológicos. O experimento foi realizado por Carvalho (2019) em uma área de lavoura da Universidade Federal de Santa Maria com a cultivar de milho. O delineamento utilizado foi blocos ao acaso com cinco blocos e 5 tratamentos com variações de doses de nitrogênio (N) após a emergência da cultura. O sensoriamento da vegetação foi realizado por duas plataformas distintas sensor sequoia embarcado em ARP e o sensor Optrx embarcada em uma bicicleta, obtendo-se os Índices de Vegetação (IVs) NDVI, GNDVI, EVI2 e NDRE com o sensor sequoia embarcada no ARP e NDVI e NDRE com o sensor sequoia embarcada na bicicleta nos estádios vegetativos V5, V7, V9, V11 e V12. Além dessas variáveis foram obtidos número de plantas, teores de N na planta e dados de produtividade. Nesse trabalho foram utilizados dados de quatro blocos, contendo 800 parcelas, porém foram utilizados somente dados de 451 parcelas, em função do descarte de 349 parcelas, que não apresentavam a variação de 14 a 18 plantas no momento da colheita e/ou não apresentavam leituras para alguma variável, ou seja, valor nulo. Foi realizado o teste de normalidade e os dados não apresentaram normalidade, foi realizado a padronização dos dados no software (Statistica 12). A análise dos dados foi realizada com a estatística multivariada com os métodos de Análise de Agrupamentos Hierárquicos (AAH), Análise Fatorial (AF) e Análise de Componentes Principais (ACP). Conclui-se que foi formado dois grupos distintos (Sequoia/ARP e Optrx), existindo um relação maior entre dados de produtividade com os IVs (NDRE, NDVI, GNDVI e EVI2) no estágio fenológico V9 e o IV NDRE no estágio fenológico V12.

Palavras-chave: ACP. NDRE. Cluster.

ABSTRACT

THE USE OF MULTIVARIATE STATISTICS IN THE ANALYSIS OF MAIZE CROP VEGETATION INDICES (*Zea mays L.*)

AUTHOR: Marco Ivan Rodrigues Sampaio

ADVISOR: Lúcio de Paula Amaral

Nowadays, there is a necessity for the use of tools in order to estimate yield potential during the development of corn crop. Thus, the aid of active optical sensors, or embedded in RPAS, in the generation of vegetation indices can provide significant information to the knowledge of the behavior and temporal relationship of these indices with yield parameters of agricultural crops. Normally, during the monitoring of the entire cycle of a crop, a large amount of data is generated, which is difficult to analyze and interpret because the relationships between variables are complex. The goal of this work was to use multivariate analysis techniques to better understand the relationship of corn yield under different nitrogen rates, using vegetation indices obtained from data from two distinct remote sensing platforms, one proximal and the other, the remotely piloted aircraft (RPA) at different phenological stages. The experiment was carried out by Carvalho (2019) in a crop area of the Federal University of Santa Maria with the corn cultivar. A randomized block design with five blocks and five treatments with nitrogen dose variations (N) after the culture emergence was used. Vegetation sensing was performed by two distinct platforms, sequoia sensor embedded in an RPA and Optrx sensor embedded in a bicycle, obtaining the NDVI, GNDVI, EVI2 and NDRE Vegetation Indices with the sequoia sensor embedded in the RPA, and NDVI and NDRE with the sequoia sensor embedded in the bicycle in the vegetative stages V5, V7, V9, V11 and V12. In addition to these variables, the number of plants, N levels in the plant, and yield data were obtained. In this work we used data from four blocks, containing 800 plots, but only data from 451 plots were used, due to the discarding of 349 plots, which did not vary from 14 to 18 plants at harvest and/or did not present readings for some variable, i.e., null value. The normality test was performed and the data did not present normality, the data was standardized in the software (Statistica 12). Data analysis was performed using multivariate statistics using Hierarchical Cluster Analysis (HCA), Factor Analysis (FA) and Principal Component Analysis (PCA) methods. It was concluded that two distinct groups were formed (Sequoia / ARP and Optrx), and there was a greater relationship between productivity data with IVs (NDRE, NDVI, GNDVI and EVI2) at phenological stage V9 and IV NDRE at phenological stage V12.

Keywords: PCA. NDRE. Cluster.

LISTA DE ABREVIATURAS E SIGLAS

ANAC	Agência Nacional de Aviação Civil
ANATEL	Agência Nacional de Telecomunicações
AP	Agricultura de Precisão
ARP	Aeronave Remotamente Pilotada
cm	Centímetro
CONAB	Companhia Nacional de Abastecimento
GNDVI	Índice de Vegetação por Diferença Normalizada do Verde
GNSS	Sistema de Navegação Global por Satélites
GPS	Sistema de Posicionamento Global
EVI	Índice de Vegetação Melhorado
EVI2	Índice de Vegetação Melhorado 2
ha	Hectare
IV	Índice de Vegetação
Kg	Quilograma
m ²	Metro Quadrado (área)
mm	Milímetro
Mp	Mega píxel
N	Nitrogênio
NDRE	Índice de Borda Vermelha da Diferença Normalizada
RGB	Red, Blue, Green

LISTA DE TABELAS

ARTIGO 1

Tabela 1. Estatística descritiva das variáveis utilizadas na pesquisa.	65
Tabela 2. Análise de componentes principais das variáveis que fizeram parte da pesquisa.	67
Tabela 3. Composição dos Fatores a partir da rotação Varimax.	68

APÊNDICES

Tabela 1 – Método de similaridade entre variáveis Distância Euclidiana e o Método de aglomeração Ward's.	84
Tabela 2 – Método de similaridade entre variáveis Distância Euclidiana ao Quadrado e o Método de aglomeração Ward's.	88
Tabela 3 – Distância variável a variável	92

LISTA DE QUADROS

APRESENTAÇÃO

Quadro 1 – Oferta e demanda de milho – Brasil – fev jan – mil t45

LISTA DE FIGURAS

APRESENTAÇÃO

Figura 1 – Diferença entre uso de aeronaves não tripuladas recreativo e não recreativo.....	21
Figura 2 – Resumo da regulamentação da ANAC.	21
Figura 3 – Interação da radiação eletromagnética entre o alvo e o sensor.....	24
Figura 4 – Comportamento da reflectância em relação ao comprimento de onda. ...	27
Figura 5 – Sensores RGB Canon S110 e Sony A6000.	31
Figura 6 – Sensor RGB Canon G9X e Phantom 4 K (Standard).....	32
Figura 7 – Comportamento espectral de folhas morta, estressada e sadia.....	34
Figura 8 – Sensor multiespectral Parrot Sequoia.	34
Figura 9 – Sensor multispectral RedEdge.	35
Figura 10 – Sensor multiespectral RedEdge MX.....	35
Figura 11 – Sensor Mapir Survey3.....	36
Figura 12 – Percentual dos principais grãos produzidos no mundo.	44
Figura 13 – Exportações brasileiras mensais de milho - toneladas - janeiro 2014 - julho 2017.....	45
Figura 14 – Esquema de aplicação de análise de componentes principais.	48
Figura 15 – Colheita manual do milho.....	55
Figura 16 – Equipamento utilizado para medir a umidade dos grãos.....	56
Figura 17 – Trator Massey Ferguson, utilizado para a debulha mecanizada do milho.	57
Figura 18 – Debulhadora utilizada para a separação do grão de milho da espiga....	58

ARTIGO 1

Figura 1. Divisão do experimento em blocos (20x20 m) em vermelho, repetições (4x4 m) – em amarelo, e parcelas (2x1 m) – em ciano.....	61
Figura 2. Gráfico da precipitação mensal total nos estádios fenológicos V5, V7, V9, V11 e V12 e as respectivas datas de sensoriamentos. Fonte: INMET, 2018.	62
Figura 3. Dendrograma vertical obtido para agrupamentos das variáveis utilizadas no presente estudo pelo método de similaridade distância euclidiana. Fonte: Autor, 2019.....	64
Figura 4. Dendrograma vertical obtido para agrupamentos das variáveis utilizadas no presente estudo pelo método de similaridade distância euclidiana ao quadrado. Fonte: Autor, 2019.....	66
Figura 5. Gráficos das distribuições da nuvem de variáveis, no círculo de correlações com CP1xCP2 (4a) e CP1xCP6 (4b). Fonte: Autor, 2019.....	69
Figura 6. Relação entre produtividade de milho e os índices de vegetação (NDRE, NDVI, GNDVI e EVI2) no estádio fenológico V9 e o índice de vegetação NDRE em V12. Fonte: Autor, 2019.	69

SUMÁRIO

1	APRESENTAÇÃO	14
1.1	INTRODUÇÃO.....	14
1.2	REFERENCIAL TEÓRICO	17
1.2.1	Agricultura de precisão	17
1.2.2	Aeronave remotamente pilotada (ARPs)	20
1.2.3	Sensoriamento remoto	22
1.2.3.1	<i>Sensoriamento remoto na agricultura de precisão</i>	25
1.2.3.1.1	Sensoriamento remoto com ARP	29
1.2.3.1.2	Sensores	30
1.2.3.1.3	Sensores RGB.....	31
1.2.3.1.4	Sensores multiespectrais	32
1.2.3.1.5	Sensoriamento remoto com sensores proximais	36
1.2.3.1.6	Sensor proximal OptRX ®	37
1.2.3.2	<i>Índices de vegetação</i>	38
1.2.3.2.1	NDVI.....	39
1.2.3.2.2	NDRE	40
1.2.3.2.3	EVI2.....	41
1.2.3.2.4	GNDVI	42
1.2.4	Cultura do Milho	43
1.2.5	Estatística Multivariada	46
1.2.5.1	<i>Análise dos Componentes Principais</i>	47
1.2.6	Análise de agrupamentos ou cluster	49
1.2.6.1	<i>Medidas de similaridades</i>	50
1.2.6.1.1	Distância euclidiana.....	51
1.2.6.1.2	Distância euclidiana quadrática	51
1.2.7	Análise fatorial	51
1.3	PROPOSIÇÃO	52
1.4	MATERIAL E MÉTODOS	53
2	ARTIGO 1	59
3	CONCLUSÃO	72
	REFERÊNCIAS	73
	APÊNDICE A	84
	APÊNDICE B	88
	APÊNDICE C	92

1 APRESENTAÇÃO

O uso de Sensoriamento Remoto (SR) na agricultura e também na Agricultura de Precisão (AP) é crescente, e uma das formas recentes é o sensoriamento das lavouras por sensores embarcados nas aeronaves remotamente pilotadas (ARP), que complementam as formas mais tradicionais de sensoriamento, orbital e proximal. Muitos dados podem ser obtidos com estas geotecnologias aplicadas à Agricultura de Precisão, e técnicas de análise multivariada podem auxiliar no melhor entendimento dos mesmos.

Outro ponto a ser considerado é a contribuição para o setor produtivo, neste caso o Setor Agrícola Nacional, sobre formas diferentes de utilizar os dados obtidos por sensores embarcado nas ARP na Agricultura de Precisão, uma vez que a falta de informação e de qualificação neste setor dificulta a adoção da tecnologia. Neste trabalho a contribuição vem para a cultura do milho e vem de encontro ao atendimento desta demanda, apresentando tratamento dos dados com análise multivariada. O presente trabalho de pesquisa está organizado/estruturado na forma de artigos científicos integrados, conforme estabelece o Manual de Dissertações e Teses da UFSM, versão 2015:

- Apresentação: contendo a introdução, o referencial teórico, proposição, objetivos, material e métodos, onde se tem descrições gerais para a elaboração da dissertação;
- Artigo: compreende os resultados da pesquisa, apresentados na forma de manuscrito, elaborado segundo as respectivas normas da Revista Biofix Scientific Journal, da Universidade Federal do Paraná (UFPR), para ser submetido posteriormente;
- Conclusão da dissertação: parte final do documento, constituída pela conclusão da pesquisa realizada, seguida das referências bibliográficas utilizadas na mesma, exceto as do manuscrito.

1.1 INTRODUÇÃO

A Agricultura de Precisão (AP) aumentou a eficiência de produção de alimentos através do uso de novas técnicas e tecnologias na gestão de processos que resultam na produção agrícola. A Comissão Brasileira de Agricultura de Precisão define AP,

como “um sistema de gerenciamento agrícola baseada na variação espacial e temporal da unidade produtiva e visa ao aumento de retorno econômico, à sustentabilidade e à minimização do efeito ao ambiente” (BRASIL, 2012). Desde os primórdios de sua concepção a AP tem evoluído constantemente e algumas tecnologias que recentemente surgiram tem sido ultimamente muito utilizadas. De acordo com Freitas (2011), são intensas as iniciativas para que se tenha em mãos a disponibilidade de imagens através de sensores orbitais que ajudam interferir de forma pontual sobre a dinâmica do espaço e do tempo em um determinado plantio. Ainda segundo Freitas (2011), em um passado bem recente, esse era o grande entrave, para uma análise mais detalhada de um sistema dinâmico como é o caso da agricultura, pois não eram periódicos, a passagem desses sensores orbitais sobre a superfície física da Terra (SFT).

Concomitantemente com o avanço da AP, surgem então os Sistemas Aéreos Não Tripulados (*Unmanned Aircraft Systems – UAS*), ou conforme a legislação brasileira Aeronave Remotamente Pilotada (ARP), que são ferramentas emergentes e relevantes capazes de estender os sistemas de sensoriamento tradicionais. As ARPs são capazes de detectar e fornecer informações com resoluções espaciais e temporais com escalas precisas devido sua maleabilidade de configuração e operação (DEPARTMENT OF DEFENSE, 2005).

O desenvolvimento dessas aeronaves surgiu como uma importante ferramenta e opção na agricultura de precisão. Sua aplicação na área agrícola e em missões de reconhecimento vem sendo favorecida e facilitada pelo atual estágio de desenvolvimento tecnológico, principalmente pela redução do custo e do tamanho dos equipamentos e pela necessidade de otimização da produção (INAMASU e JORGE, 2014).

Aliando-se ao sensoriamento remoto, ARPs podem ser aplicadas no monitoramento de safras, do pré-plantio até a colheita, logística, gestão, estimativa de produção, de produtividade, contagem de plantas, detecção de falhas de plantio, estresse hídrico, nutrição e detecção de pragas e doenças entre outras (NOVO, 2010).

Segundo Fernandes (2016), a utilização das ARPs na agricultura vem ao encontro das necessidades da agricultura de precisão, pois o ARPs é um equipamento portátil, capaz de realizar um voo automático além de dispor informações de relevância do vegetal e do solo, com a utilização de câmeras com sensores multiespectrais acoplados na sua carcaça, capazes de obter imagens de altíssima

resolução espacial e multibandas que podem ser capturadas em qualquer momento da safra. Com esses dados existe a possibilidade de inferir de forma antecipada, sobre a estimativa da produção e produtividade de uma determinada cultura de verão ou de inverno sem que tenha acontecido a sua colheita. É um fato bem conhecido que a estimativa de biomassa é crucial para previsão de rendimento das culturas (OERKE et al. (2010). Atributos ou variáveis mensurados em plantas, como biomassa, são freqüentemente utilizados para avaliar o estatus de suprimento de nutrientes e os efeitos das práticas de manejo agrícola (ADAMCHUK et al., 2010).

Conforme Formaggio e Sanches (2017) outra forma de obter informações sobre a lavoura é através de sensores proximais que objetivam, de modo geral, fornecer as informações sobre a variabilidade espacial das características das plantas e dos solos nas lavouras. Os sensores proximais de acordos com os mesmos autores, não entram em contato direto com os objetos de estudo, sendo de natureza óptica, uma vez que os fótons do espectro visível ou do infravermelho incidem no objeto ou são emitidos por ele e em seguida são direcionados para o sensor.

O monitoramento contínuo da lavoura é um dos principais instrumentos para que o produtor consiga alcançar grandes produções. Sendo assim, o uso das novas tecnologias no campo é um caminho para que isso aconteça. O uso de sensores proximais e embarcados em ARPs, possibilita o acompanhamento do processo desde a semeadura até a colheita. A aquisição de dados através desses sensores, inclui, em geral, coletas frequentes nos mesmos pontos amostragem e análise, acarretando em um grande número de observações de diferentes variáveis, resultando em uma matriz de grande dimensão e de uma difícil interpretação. Silva (2012) afirma que muitas vezes, um pequeno número dessas variáveis contém as informações mais relevantes enquanto a maioria das variáveis adiciona pouco ou nada à interpretação dos resultados, em termos qualitativos. Normalmente, no monitoramento do ciclo inteiro de uma lavoura, são gerados uma grande quantidades de dados que são difíceis de analisar e interpretar, pois as relações entre as variáveis são complexas (LIAO et al., 2008).

Deste modo, abordagens multivariadas, como Análise de Agrupamentos Hierárquicos (AAH), Análise Fatorial (AF) e Análise de Componentes Principais (ACP), têm sido utilizadas com sucesso na agricultura para extrair informações significativas a partir de uma coleta muito grande de dados (JÚNIOR et al., 2008; OLIVEIRA et al., 2002; GUARIENTI et al., 2003; ZIMBACK e MAZIONE, 2011; CORRÊA e

FIGUEIREDO, 2006). Os métodos de análise de dados multivariados são amplamente utilizados quando se deseja promover a redução do número de variáveis com o mínimo de perda de informação (ANDRADE et al., 2007a).

Deste modo, aplicou-se a análise estatística multivariada, AAH, AF, ACP e Clusters, com o objetivo de utilizar as potencialidades da estatística multivariada para poder entender um experimento grande e complexo, realizado a campo na cultura do milho, com a aplicação de diferentes doses de nitrogênio, caracterizado por índices de vegetação obtidos a partir de dados de duas plataformas distintas de sensoriamento remoto, em diferentes estágios fenológicos, somados ainda o teor de nitrogênio na planta e dados de produtividade.

1.2 REFERENCIAL TEÓRICO

1.2.1 Agricultura de precisão

De acordo com Molin, Amaral e Colaço (2016), ao mesmo tempo que há uma crescente demanda por alimentos, energia e demais produtos oriundos da agricultura, os recursos naturais estão cada vez mais escassos. Diante deste contexto, a produção agrícola precisa ser otimizada visando a sustentabilidade e a segurança alimentar. A gestão de cultivos deve buscar o máximo de rendimento das culturas com menor consumo de insumos possível, ou seja, com consumo racional e otimização desses. Neste contexto, a agricultura de precisão se mostra uma prática essencial e ganha cada vez mais adeptos.

Ainda, segundo os mesmos autores, o termo agricultura de precisão tem aproximadamente 25 anos, mas os fatos e as constatações que levaram o seu surgimento são de longa data. Desde o início do século XX, existem relatos de trabalhos que mostram a utilidade de se gerenciar as lavouras de forma detalhada e localizada, inclusive com aplicação de insumos, como o calcário, em taxas variáveis. Porém, a adoção real de práticas dessa natureza remonta aos anos de 1980, quando foram gerados os primeiros mapas de produtividade na Europa e foram feitas as primeiras adubações com doses variadas de forma automatizada nos Estados Unidos.

No Brasil, as primeiras atividades ligadas a Agricultura de Precisão ocorreram na década de 90 com a importação de máquinas colhedoras com monitor de produtividade de grãos e já no final dessa mesma década, com a importação de

máquinas para aplicação de taxas variáveis. No início dos anos 2000, surgiram as primeiras máquinas para aplicação de taxas variáveis brasileiras. Outras, datas importantes, no surgimento da agricultura de precisão, foi a elaboração do primeiro simpósio sobre AP na Universidade de São Paulo em 1996. Em 2000, a Universidade Federal de Viçosa realizava seu primeiro simpósio internacional de agricultura de precisão. Logo em 2004, a ESALQ/USP, realizava o primeiro Congresso Brasileiro de Agricultura de Precisão, surgindo posteriormente a criação da Comissão Brasileira de Agricultura de Precisão, órgão consultivo do Ministério da Agricultura, Pecuária e Abastecimento. Um marco na história da AP foi a realização no mês de Setembro de 2011 a primeira edição do APSul AMÉRICA, na cidade de Não me Toque RS. Nesta primeira edição o APSul já mostrava a sua força, recebendo um público de cinco mil pessoas e 26 expositores. O congresso promoveu palestras, oficinas, apresentação de trabalhos técnicos e científicos, contando ainda com a exposição da indústria de indústria de máquinas precisas.

Atualmente, as propriedades agrícolas brasileiras capazes de absorver as tecnologias da agricultura de precisão são de grande porte. Porém, a AP pode também ser praticada nas pequenas propriedades, uma vez que nessas, os campos também apresentam variabilidade espacial e temporal. Elas podem ser manejadas com precisão, sem ter que necessariamente utilizar as tecnologias de ponta oferecidas no mercado, mas sim fazer o uso do conhecimento da variabilidade dos fatores de produção, manejando esse conhecimento de acordo com os recursos disponíveis (GUEDES FILHO, 2009).

Existe ainda uma ideia equivocada de que para utilizar a AP são necessários máquinas e equipamentos caros e sofisticados. Estas máquinas e equipamentos podem, de fato, auxiliar muito o produtor e o técnico, porém o elemento essencial para adotar a AP é a constatação de que há variabilidade espacial e a sua intensidade é muito elevada para tratá-la como uniforme.

Segundo Manzatto et al. (1999), o principal conceito é aplicar os insumos no local correto, no momento adequado, as quantidades de insumos necessários à produção agrícola, para áreas cada vez menores e mais homogêneas, tanto quanto a tecnologia e os custos envolvidos o permitam.

Na AP, as técnicas diferenciam pelo seu nível de gerenciamento e conhecimento. O conhecimento adquirido com as informações fornecidas pela agricultura de precisão permite melhor suporte na tomada de decisão, tendo como

resultado final o aumento da produção e economia de insumos por hectare (MENEGATTI et al., 2006).

A agricultura de precisão engloba o uso de tecnologias atuais para o manejo do solo, insumos e culturas de modo adequado para as variações espaciais e temporais nos fatores que afetam a produtividade das mesmas. O que tem levado a esta nova filosofia de prática agrícola é o uso de três novas tecnologias: Sensoriamento Remoto, o uso de Sistemas de Informações Geográficas (SIG) e os Sistema Globais de Navegação por Satélite (GNSS). A agricultura de precisão é um conceito de sistema de produção agrícola que envolve o desenvolvimento e a adoção de técnicas de gestão, baseado no conhecimento com o objetivo principal de otimizar a rentabilidade. Este sistema permite práticas de gerenciamento com computador pessoal, que é a possibilidade de administrar cada local do campo adequadamente, sendo econômico e tecnicamente vantajoso administrá-lo a este nível (DALLMEYER e SCHLOSSER, 1999).

Amado et al. (2007) relataram que a AP se propõe a aumentar a eficiência e a rentabilidade da atividade agropecuária, com base no manejo localizado respeitando a variabilidade de solo, planta e microclima existente na área.

Segundo Shiratsuchi et al. (2014) a AP oferece uma infinidade de benefícios potenciais em rentabilidade, produtividade, sustentabilidade, dentre outros aspectos positivos. Utiliza abordagens científicas e modernas, combinadas com os conhecimentos tradicionais e tecnologias de informação para uma produção agrícola inteligente. Neste sentido, as técnicas de sensoriamento remoto, onde as informações da lavoura são obtidas de forma não destrutiva, rápida e por vezes à distância, tem se tornado de fundamental importância na obtenção e tratamento de dados de campo.

Um salto grande na agricultura de precisão ocorreu a partir de 1995, quando o primeiro sistema global de navegação por satélite (*Global Navigation Satellite Systems* – GNSS), desenvolvido pelos EUA e denominado de GPS (*Global Positioning System*), iniciou as primeiras operações em 1978, e considerado operacional em 1995. A disponibilização de sinal de satélites GPS, viabilizou a instalação de receptores em colhedoras, possibilitando armazenar dados de produção instantânea associada à coordenada geográfica. Em 1996, surge no mercado colhedoras com capacidade de mapeamento da produção, gerando o boom da Agricultura de Precisão no mundo, tornando possível a prática de mapeamento e aplicação de insumos à taxa variada por meio de máquinas (INAMASU e BERNARDI, 2014).

1.2.2 Aeronave remotamente pilotada (ARPs)

De acordo com Munaretto (2017), são várias as nomenclaturas que significam aeronaves remotamente pilotadas (ARP). Muitos outros termos equivalentes podem ser encontrados na literatura aeronáutica.

Conforme Fucci (2016), assim como em várias das tecnologias desenvolvidas pelo homem, a tecnologia dos Drones teve a sua origem na área militar, intitulados de Veículos Aéreos não tripulados – VANT ou RPAS, Remotely Piloted Aircraft Systems. O termo Veículo Aéreo Não Tripulado (VANT) utilizado no Brasil é uma adaptação do termo em inglês Unmanned Aerial Vehicle (UAV) e, segundo Eisenbeiss (2009), se refere a qualquer veículo que possa voar e ser controlado sem a necessidade de uma pessoa a bordo.

Segundo a Agencia Nacional de Aviação Civil (2017), o termo drone é usado popularmente para descrever qualquer aeronave com alto grau de automatismo. De forma geral, toda aeronave drone é considerada uma aeronave não tripulada categorizada como Aeromodelo, RPA ou Aeronave Não Tripulada Autônoma.

Pelo regulamento da ANAC (2017), Aeromodelos são aeronaves não tripuladas utilizadas para lazer. RPA são aeronaves não tripuladas usadas para outros fins, como corporativo ou comercial. Aeronaves Não Tripuladas Autônomas, nas quais não há interferência do piloto durante o voo, não estão contempladas na norma e sua utilização continua proibida no Brasil. A Figura 1 mostra o foco principal dessa regulamentação.

Figura 1 – Diferença entre uso de aeronaves não tripuladas recreativo e não recreativo.



Fonte: ANAC, 2017.

As RPA estão divididas em três classes, de acordo com o peso máximo de decolagem (PMD), no qual devem ser considerados os pesos do equipamento, da bateria ou combustível, e da carga eventualmente transportada.

Classe 1 – RPA: Peso máximo de decolagem maior que 150 kg;

Classe 2 – RPA: Peso máximo de decolagem maior que 25 kg e até 150 kg;

Classe 3 – RPA: Peso máximo de decolagem de até 25 kg.

Na Figura 2 se tem um resumo da regulamentação da ANAC em relação aos Drones.

Figura 2 – Resumo da regulamentação da ANAC.

	RPA Classe 1	RPA Classe 2	RPA Classe 3	Aeromodelos
Registro da aeronave?	Sim	Sim	BVLOS: Sim VLOS: Sim ¹	Sim ¹
Aprovação ou autorização do projeto?	Sim	Sim ²	Apenas BVLOS ou acima de 400 pés ²	Não
Limite de idade para operação?	Sim	Sim	Sim	Não
Certificado médico?	Sim	Sim	Não	Não
Licença e habilitação?	Sim	Sim	Apenas para operações acima de 400 pés	Apenas para operações acima de 400 pés
Local de operação	A distância da aeronave não tripulada NÃO poderá ser inferior a 30 metros horizontais de pessoas não envolvidas e não anuentes com a operação. O limite de 30 metros não precisa ser observado caso haja uma barreira mecânica suficientemente forte para isolar e proteger as pessoas não envolvidas e não anuentes. Esse limite não é aplicável para operações por órgão de segurança pública, de polícia, de fiscalização tributária e aduaneira, de combate a vetores de transmissão de doenças, de defesa civil e/ou do corpo de bombeiros, ou operador a serviço de um destes.			

¹ Todos os aeromodelos acima de 250 gramas e RPA entre 250 gramas e 25 kg que se destinem a operações na linha de visada visual (VLOS) até 400 pés acima do nível do solo, devem ser cadastrados por meio de ferramenta online disponível no endereço systemas.anac.gov.br/sisant.

² Para todos os sistemas de RPA Classe 2 e os de RPA Classe 3 que se destinam a operações além da linha de visada visual (BVLOS) ou acima de 400 pés, o fabricante pode optar pelo processo de certificação de tipo estabelecido no RBAC nº 21 ou pela autorização de projeto na Subparte E do RBAC-E nº 94.

Fonte: ANAC, 2017.

Além das diversas aplicações militares o uso dessas plataformas em aplicações civis está ficando cada vez mais diversificado. Para Sarris (2001), alguns dos possíveis usos civis dos VANTs ou ARPs são o patrulhamento de fronteiras, sensoriamento remoto, detecção e monitoramento de queimadas, auxílio em situações de emergência e desastre, monitoramento de estruturas lineares como gasodutos e linhas de transmissão, pesquisa, monitoramento ambiental, segurança pública e fotogrametria.

Segundo González et al. (2015), cada vez mais os agricultores estão confiando na implementação das ARPs devido a sua capacidade de obter informações precisas do seu cultivo ajudando assim a tomar uma decisão.

Segundo, os mesmos autores, na agricultura de precisão, com o uso das ARPs que captam imagens, através de imagens hiperespectrais, que obtém informações do espectro eletromagnético incluindo a faixa do visível com frequências de cada banda muito pequenas, as câmaras multiespectrais que obtém imagens na faixa do visível mais qualquer outra banda adicional a do visível, as câmaras infravermelhas ou térmicas que se usam para obter imagens de diferentes faixas do espectro, permitem adquirir dados dos cultivos e que desta forma, poderá interferir de modo pontual e localizado no andamento de determinada cultura. Enquanto, na agricultura convencional, se aplicam de maneira uniforme os insumos e os fertilizantes para a prevenção de doenças sem levar em conta a variabilidade espacial os diversos fatores que implicam em um bom desenvolvimento dos cultivos o que ocasiona em gastos desnecessários. Mediante as imagens com o uso das ARPs, são gerados diagnósticos que permitam a intervenção na gestão hídrica, uso de fertilizantes, detecção de doenças, entre outros (GONZÁLES et al., 2015).

1.2.3 Sensoriamento remoto

O surgimento do Sensoriamento Remoto está ligado ao descobrimento da fotografia em 1822, sendo utilizado como ferramenta de reconhecimento do terreno, e em 1859 foi tomada a primeira fotografia aérea a bordo de um balão contendo câmaras fotográficas da época. No início do século XX, com a invenção do avião, o aperfeiçoamento dos sistemas ópticos e dos mecanismos de exposição, inicia-se a fotografia tomada por aviões (NOVO, 1992).

A primeira fotografia orbital obteve-se no ano de 1961, a bordo da sonda espacial MA-4 Mercury, da *National Aeronautics and Space Administration* (NASA), dos Estados Unidos da América. Durante a Primeira e Segunda Guerra Mundial, o Sensoriamento Remoto foi amplamente utilizado para o planejamento de missões com fins militares (NOVO, 1992).

No ano de 1972, colocou-se em órbita, pelos Estados da América (EUA), o primeiro satélite de Sensoriamento Remoto com finalidade civil, e com o propósito de obter dados de forma rápida, confiável dos alvos terrestres, proporcionando, assim, um melhor conhecimento do nosso planeta através da enorme gama de informações fornecidas pelos sensores, sendo ferramentas indispensáveis ao inventário, mapeamento e monitoramento dos recursos naturais (ROSA, 2003).

A respeito da definição do termo Sensoriamento Remoto, surgem conceitos de diferentes autores, tornado, assim, de fundamental importância à compreensão dos mesmos.

Para Rocha (2000, p.115) o Sensoriamento Remoto caracteriza-se como sendo “...a aplicação de dispositivos que colocados em aeronaves ou satélites, nos permitem obter informações sobre objetos ou fenômenos na superfície da Terra, sem contato físico com eles”.

Neste sentido, Garcia (1982, p. 23), complementa a definição de Sensoriamento Remoto afirmando que:

...de uma maneira ampla como a detecção da natureza de um objeto sem que haja contato físico, em que aviões e satélites são as plataformas mais comuns. O termo Sensoriamento Remoto é restrito aos métodos que se utilizam da energia eletromagnética na detecção e medida das características de objetos, incluindo-se aqui as energias relativas a luz, calor e ondas de rádio.


De acordo com Rosa (2003), o Sensoriamento Remoto é a forma de obter informações de um objeto ou alvo, sem haver contato físico com o mesmo. As informações são obtidas utilizando-se a radiação eletromagnética, que é gerada por fontes naturais como o Sol e a Terra, e por fonte artificial, como o radar.

Conforme Novo (1992) Sensoriamento Remoto é a utilização conjunta de modernos sensores e equipamentos para a aquisição de dados ou informações, sem contato direto com eles, com o objetivo de estudar o ambiente terrestre, podendo ser dividido em dois subsistemas: o subsistema de coleta de dados e o subsistema de

análise de dados. O subsistema de coleta de dados, para funcionar, precisa ter uma fonte de radiação eletromagnética, esta deve se propagar pela atmosfera até atingir a superfície terrestre. O subsistema de análise dos dados inclui o processamento fotográfico, o processamento eletrônico do sinal, a modelagem.

O SR clássico é baseado principalmente em imagens adquiridas por câmeras acopladas em plataformas orbitais e aéreas, que pode ser definido como a arte ou a ciência para a obtenção de informações sobre uma área, fenômeno ou objeto (Figura 3), por intermédio de dados obtidos por um sistema sensor (equipamento), não havendo contato com o alvo (CREPANI, 1993).

Figura 3 – Interação da radiação eletromagnética entre o alvo e o sensor.



Fonte: Florenzano, (2011).

Segundo Jensen (2007), várias definições têm sido propostas, sendo a seguinte aquela que, embora curta, simples, geral e facilmente memorizável, consegue englobar a essência do termo, “Sensoriamento remoto é a aquisição de dados sobre um determinado objeto sem haver a necessidade de toca-lo diretamente”.

De acordo com o mesmo autor, outras definições procuram adicionar vários qualificadores, na tentativa de assegurar que apenas funções legitimamente conformes sejam incluídas. Com essa preocupação, o autor define sensoriamento remoto como registro da informação das regiões do ultravioleta, visível, infravermelho e micro-ondas do espectro eletromagnético, sem contato, por meio de instrumentos tais como câmeras, escâneres, lasers, dispositivos lineares e/ou matriciais localizados

em plataformas como aeronaves ou satélites, e a análise da informação adquirida por meio visual ou processamento digital de imagens (JENSEN, 2007).

Segundo Novo (2010), existem definições muito amplas de sensoriamento remoto, pois segundo o autor, a aquisição de informações sobre um determinado objeto sem que entre em contato físico com ele é muito genérico para conceituar sensoriamento remoto. Para Elachi (1987), sensoriamento remoto, implica na obtenção de informação a partir da detecção e mensuração das mudanças que um determinado objeto impõe aos campos de força que os circundam, sejam estes campos eletromagnéticos, acústicos ou potenciais. Assim sendo, Novo (2010), adota o seguinte conceito para sensoriamento remoto, como sendo, a aquisição de informações sobre objetos a partir da detecção e mensuração de mudanças que estes impõem ao campo eletromagnético.

Ainda, para Novo (2010), esse conceito de sensoriamento remoto, definido anteriormente, pode ser acrescido, de certas partes, podendo então, a partir de agora, definir Sensoriamento Remoto como sendo a utilização conjunta de sensores equipamentos para processamento de dados, equipamentos de transmissão de dados colocados a bordo de aeronaves, espaçonaves, ou outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta Terra a partir do registro e análise das interações entre a radiação eletromagnética e as substâncias que o compõem em suas mais diversas manifestações.

A fonte de energia eletromagnética mais importante para o sensoriamento remoto é a radiação solar para os sensores passivos, sendo estes normalmente orbitais. No entanto, há sensores ativos que possuem sua própria fonte de energia, e funcionam independentemente da radiação solar. O registro da informação se dá através da captura de ondas refletidas pelo alvo constituído por bandas do espectro eletromagnético, sendo que cada banda compreende uma faixa de comprimento de onda específico. O olho humano tem sensibilidade de capturar imagens que compreendem a faixa do espectro visível, relativamente estreito, entre 400 e 700 nm (CROSTA, 1993).

1.2.3.1 Sensoriamento remoto na agricultura de precisão


De acordo com Brandão (2009) existem várias aplicações do sensoriamento remoto na agricultura de precisão, aonde se destacam, entre elas, a estimativa da

produtividade, estimativa da biomassa, monitoramento do estresse hídrico, vigor da planta e avaliação dos estádios fenológicos. De acordo, com o mesmo autor, uma das primeiras aplicações dos dados obtidos remotamente tem sido a detecção de diferenças na refletância, relacionadas a cobertura vegetal. A refletância identifica a intensidade que cada material, reflete a radiação eletromagnética em diferentes comprimentos de onda do espectro eletromagnético.

Atzberger (2013) comenta que dados de refletância têm sido associados às características das plantas, como índice de área foliar, biomassa ou a fração radiativa interceptada fotossinteticamente. Na agricultura, as propriedades da refletância em cada faixa do espectro eletromagnético podem ser melhor avaliadas através de combinações matemáticas de diferentes bandas espectrais. Essas transformações são medidas da atividade da vegetação utilizam em especial as faixas do visível (azul, verde, vermelho, borda do vermelho) e infravermelho próximo (NIR – Near Infrared) e são denominados de índices de vegetação (IVs). Para entender como os IVs são criados, e preciso uma melhor compreensão da resposta espectral da vegetação. Na Figura 4, pode ser observado o comportamento da refletância para a vegetação verde saudável, sendo fundamentalmente determinado pela clorofila, que reflete em todo o espectro visível, mas tem seu ápice na faixa da luz verde (500-600 nm), e cuja absorção é máxima nas faixas espectrais da luz azul (400-500 nm) e da luz vermelha (600-700 nm) (BRANDAO et al., 2009).

Segundo Formaggio e Sanches (2017), o sensoriamento remoto na região espectral compreendida entre o visível e o infravermelho de ondas curtas (400 nm a 2500 nm) é baseado em medições remotas da radiação eletromagnética refletida pelos alvos da superfície terrestre. Assim, as informações coletadas pelos sensores necessitam ser interpretadas com base no pressuposto de que diferentes alvos apresentam comportamentos distintos de resposta espectral. Para Machado et al. (1985), a reflectância engloba os efeitos de muitos fatores biofísicos, tais como estrutura e geometria das plantas, tamanho, anatomia e idade das folhas, arranjo das plantas no campo, entre outros.

Figura 4 – Comportamento da reflectância em relação ao comprimento de onda.



Fonte: Adaptado de Novo, 2010.

Para Ponzoni et al. (2012), pensar no processo de interação entre a radiação eletromagnética e a vegetação faz recordar que para os vegetais a realização da fotossíntese é vital, que é um processo fundamentado na absorção da radiação eletromagnética por parte dos pigmentos fotossintetizantes como as clorofilas, xantofilas e carotenos. As regiões do espectro de luz fisiologicamente eficazes para a fotossíntese se localizam no espectro na faixa ultravioleta ao azul e na faixa do vermelho até próximo ao infravermelho (LARCHER, 1986).

Ainda de acordo com Ponzoni et al. (2012), sabe-se ainda que, de todos os órgãos existentes em uma planta, as folhas são aquelas que tem como função principal viabilizar a interação da radiação eletromagnética na região do visível. É possível observar que as folhas são constituídas por diferentes tecidos, sendo que a face ventral é aquela que está voltada para cima, recebendo então maior quantidade de radiação eletromagnética provinda do sol. Nessa face é que se encontram diferentes tipos de estruturas, como pelos e camadas de cera (cutícula) que exercem diferentes funções de proteção. Logo abaixo dessas estruturas, encontram-se a epiderme. Abaixo da epiderme localiza-se o parênquima paliçádico, o qual é

organizado por células ricas em cloroplastos, que são as organelas dentro das quais se encontram os pigmentos fotossintetizantes, principalmente as clorofilas.

Seguindo em direção a face dorsal da folha, encontra-se o mesófilo esponjoso, também conhecido como parênquima esponjoso, que se caracteriza por apresentar uma organização de células menos compacta do que o parênquima paliçádico, que lhe confere uma maior quantidade de lacunas entre as células, lacunas essas preenchidas com gases resultantes dos processos de respiração e de transpiração. Segue-se novamente a epiderme, com um número maior de estômatos em relação a ventral e logo uma nova camada de cera ou cutícula, na qual voltam a aparecer estruturas como pelos e ceras. É evidente, segundo o mesmo autor, que existem variações de estruturas de folhas entre espécies diferentes e até mesmo entre folhas de uma mesma espécie, mas o que é relevante compreender é que a folha em si pode ser considerada como um meio pela qual a radiação eletromagnética trafega, e dependendo do comprimento de onda dessa radiação, alguns componentes desse meio, bem como outros fatores relacionados a fisiologia da planta, vão exercer influência no processo de interação (PONZONI et al. 2012).

Moreira (2000), em um trabalho realizado sobre a resposta espectral de folhas verdes, verificou que no intervalo de comprimento de onda de 400 a 700 nm a reflectância é baixa, 10%, apresentando um aumento de resposta na região do verde (550 nm). Na faixa do infravermelho próximo (700 a 1300 nm) há um aumento nos valores de reflectância, atingindo cerca de 50%. Para Sanches e Formaggio (2017), considerando a reflectância de uma folha verde normal no intervalo de 400 nm e 2500 nm, ele pode ser dividido em três regiões espectrais: visível, infravermelho próximo e infravermelho de ondas curtas. No visível, ou seja, entre 400 nm (azul) e 700 nm (vermelho), a reflectância é muito baixa. Em 550 nm ocorre um pico, isto é, uma diminuição relativa de absorção, o qual explica por que a vegetação é percebida na cor verde. Este pico é causado por duas bandas de absorção da clorofila centradas em aproximadamente 450 nm (azul) e 650 nm (vermelho) (HOFFER, 1978).

A queda de reflectância na faixa do visível está associada à absorção pelos pigmentos foliares, principalmente pela clorofila, a qual se caracteriza como o fotorreceptor principal (65%), carotenos (6%) e xantofilas (29%), que são os fotorreceptores auxiliares (LARCHER, 1986; PONZONI, 2001).

Curran et al.(1991) diz que nas proximidades de 700 nm, na transição para região do infravermelho próximo começa um crescimento acentuado da reflectância.

Esse ponto é denominado de Red Edge ou ainda chamado de borda vermelha, sendo considerado o limite entre o processo de absorção pela clorofila no vermelho e o processo de espalhamento do infravermelho próximo devido à estrutura interna das folhas. Como explica Hoffer (1978), na região espectral do infravermelho próximo entre 1700 nm e 1300 nm, as folhas verdes saudáveis apresentam altos valores de reflectância, alta transmitância e baixa absorptância.

1.2.3.1.1 Sensoriamento remoto com ARP

Puscov (2002) relata que a primeira fotografia aérea em voo não tripulado foi feita por Arthur Batat em 1888, em que foi utilizada uma câmera instalada em uma pipa. No mesmo ano, o primeiro avião não tripulado – o Kettering Aerial Torpedo – foi projetado na França por Charles Kettering. Este veículo era guiado por um sistema de pré-pneumático e controles elétricos.

A algum tempo já existe o interesse do setor agrícola pelo uso das ARPs, como ferramenta de grande interesse, com novas alternativas para a agricultura e outras áreas que demandam imagens de alta resolução e em tempo quase real (HERWITZ et al., 2004). A Yamaha, empresa japonesa, foi a fabricante precursora no setor agrícola, ao desenvolver nos anos 80 um novo tipo de helicóptero não tripulado para fins de manejos na colheita e na pulverização, sendo o modelo RMAX considerado o marco inicial de desenvolvimento e concepção do uso de RPAs na agricultura (YAMAHA, 2002; DAMIAN et al., 2016).

Segundo, Molin et al. (2016), nos últimos anos, as aeronaves remotamente pilotadas, tem um grande destaque no âmbito da Agricultura de Precisão. A principal vantagem dessa tecnologia, segundo o mesmo autor, é a sua agilidade e flexibilidade o que permite a obtenção de dados na lavoura no tempo que o agricultor julgar necessário sem a dependência da resolução temporal dos sensores orbitais e do fretamento de voos com aviões tripulados. Esse tipo de sensoriamento, pode ser considerado de baixo custo, rápido e prático.

Crusiol et al. (2017), com a utilização de câmeras sensíveis à radiação do espectro visível e infravermelho próximo acopladas a uma Aeronave Remotamente Pilotada (ARP), relataram a rápida aquisição de informações em amplas extensões territoriais e uma boa geração de IVs com valores condizentes com aqueles obtidos pelo espectrorradiômetro de campo.

A utilização de aeronaves remotamente pilotadas no sensoriamento remoto vem sendo discutido por vários autores como (LONGHITANO, 2010; EVERAERTS, 2008; EISENBEISS et al., 2011; MOUTINHO 2015; MUNARETTO, 2017; CÂNDIDO et al., 2015).

1.2.3.1.2 Sensores

De acordo com Molin et al. (2016), atualmente, a área com maior potencial para desenvolvimento em Agricultura de Precisão é a de sensores, tanto em equipamentos como em aplicações. Os sensores são os sistemas responsáveis pela conversão da energia proveniente dos objetos em um registro na forma de imagem ou gráfico que permita associar a distribuição da radiância, emitância, ou retroespalhamento com suas propriedades físicas, químicas, biológicas ou geométricas. No processo de conversão e registro dessa energia, está se encontra sujeita a um conjunto de transformações radiométricas, geométricas e espaciais (NOVO, 2010).

Os sistemas de sensoriamento remoto são conjuntos compostos de plataformas e sensores e que captam a radiação eletromagnética (REM) emitida e/ou refletida pelos objetos da Superfície terrestre (FORMAGIO e SANCHES, 2017). Os sensores remotos são dispositivos capazes de detectar, em determinadas faixas do espectro eletromagnético, a energia eletromagnética proveniente de um objeto, transformá-la em um sinal elétrico e registrá-la, de tal forma que esse dado possa ser armazenado ou transmitido em tempo real, para posteriormente ser convertido em informações que descrevam as feições dos objetos que compõem a superfície terrestre (MORAES, 2015).

Segundo Molin et al. (2016), sensores são dispositivos que respondem a um estímulo físico/químico de maneira específica e mensurável. Eles são capazes de avaliar algum atributo de um alvo de interesse, normalmente de forma indireta. Assim, pode-se interpretar que o termo sensor refere-se ao dispositivo que efetivamente mede ou estima determinada propriedade do alvo. Os sensores não imageadores se caracterizam por não fornecerem uma imagem bidimensional do terreno. Destacam-se entre esses tipos de sensores os espectrorradiômetros que privilegia a informação espectral e os altímetros a laser que se caracterizam pela obtenção da altura da superfície. Já os sensores imageadores permitem que seja gerada imagens

bidimensionais e, em alguns casos, imagens tridimensionais da superfície imageada (NOVO, 2010).

1.2.3.1.3 Sensores RGB

De acordo com Inamasu e Jorge (2014) são sensores que operam no espectro do visível (0,4 a 0,7 μ m) sendo possível obter imagens que auxiliam o produtor a visualizar falha de plantio, alterações no dossel, variando resoluções de centímetros a metros, dependendo da altura de voo e lente utilizada.

Segundo Molin et al. (2016), é nessa região que os pigmentos existentes nas folhas dominam a reflectância. São eles, portanto, que definem a forma da curva dos fatores de reflectância nessa região espectral. Esses pigmentos, geralmente encontrados nos cloroplastos, são as clorofilas, carotenos e as xantofilas. Os valores percentuais desses pigmentos existentes nas folhas podem variar intensamente de espécie para espécie.

Munaretto (2015), comenta que os sensores na faixa do visível (RGB) muito usados para monitoramento de obras, agricultura e mineração e são também os mais utilizados nos ARPs.

Os sensores RGB são os mais comuns e acessíveis em termos de custo, alguns exemplos de sensores RGB (Figura 5 e 6) utilizados por ARPs na agricultura são câmeras (Figura 5) Sony RX100 MKIII; Canon S110; Canon G9x; Sony A6000, entre outras.

Figura 5 – Sensores RGB Canon S110 e Sony A6000.



Canon S110



Sony A6000

Fonte: Canon e Sony, 2019.

Figura 6 – Sensor RGB Canon G9X e Phantom 4 K (Standard).



Fonte: Canon e DJI, 2019.

Amaral et al. (2017) realizou um estudo caso com sensor RGB embarcado em ARPs obtendo fotografias verticais gerando um ortomosaico para que servisse de base cartográfica para a silvicultura. O sensor RGB utilizado no trabalho foi da marca Canon, modelo G9X que possui um sensor de 20.2 MP, 13.200 mm x 8.800 mm, de alta sensibilidade e uma lente grande angular com distância focal de 28-80 mm, para obtenção das fotografias aéreas.

1.2.3.1.4 Sensores multiespectrais

No início o SR era dependente de câmeras fotográficas e de seus filmes fotográficos. Em meados do século XX surgiram os satélites artificiais, sendo desenvolvida a tecnologia dos sensores imageadores, que não dependiam de filmes e podiam ter um maior número de bandas espectrais, sendo designados de sensores multiespectrais. Posteriormente, em meados da década de 1980, surgiu uma evolução da tecnologia multiespectral, possibilitando os sensores imageadores obter imagens em centenas de bandas estreitas, sendo denominados de sensores hiperespectrais (FORMAGIO e SANCHES, 2017).

Segundo Inamasu e Castro Jorge (2014), os sensores que operam no espectro do visível funcional como se fosse o olho do agricultor na lavoura, no entanto, algumas respostas de estresse nutricional, indicadores fisiológicos e estrutura do dossel são melhor verificados com imagens no infravermelho ou NIR (0,7 a 1,3 μm). Os sensores na faixa do Infravermelho ou NIR são usados geralmente em câmeras multiespectrais, que são câmeras alteradas trocando o filtro na região do azul, normalmente presente numa câmera no espectro visível (RGB) para a faixa do infravermelho. Assim


configurando uma câmera com bandas NIR + R + G. Com estas informações e possível criar índices de vegetação próprios para avaliar o dossel de plantas.

Os dados multiespectrais dos sensores ETM+ ou do OLI/Landsat, dentre outros, têm grande utilização para os objetivos do sensoriamento remoto em agricultura (FORMAGIO e SANCHES, 2017), assim como os sensores multiespectrais embarcados em ARPs. Furlanetto et al. (2017), a utilização de câmaras multiespectrais acopladas em ARPs minimizam o custo das operações e tornam-se um meio rápido e preciso para avaliar o ciclo de desenvolvimento agrícola.

Nos comprimentos de onda no NIR, a refletância da vegetação é influenciada pela estrutura interna das folhas, em particular, o tamanho, a forma e a distribuição de ar e água no interior da folha (CHUVIECO, 1996; KNOX, 1997; KUMAR, 1998; CASTRO JORGE E INAMASU, 2014).

Nos comprimentos de onda da região do infravermelho médio, a refletância da vegetação é determinada pela absorção de água (KAUFMAN; REMER, 1994), assim como pela presença de bioquímicos como lignina, celulose, amido, proteínas e nitrógenos (GUYOT; GUYON; RIOM, 1989; KUMAR et al., 2001; CASTRO JORGE E INAMASU, 2014). Pode-se observar na figura (7) a refletância da vegetação na região do espectro eletromagnético, correspondente ao infravermelho próximo (NIR) e do visível (RGB). As folhas mortas refletem a luz solar em níveis muito parecidos nos comprimentos de onda da região do RGB (entre 400 e 700 nm), e do comprimento de onda do NIR (700 e 1100 nm), ou seja, absorvem muito a energia eletromagnética nesses comprimentos de ondas. As folhas de plantas estressadas refletem muito na região do NIR ao verde (G), absorvendo na região espectral do azul (B) e do vermelho (R), já as plantas saudáveis diferem das plantas estressadas na refletância na região do NIR, refletindo muito mais neste comprimento de onda em relação ao RGB. Também, em relação a vegetação saudável, pode-se observar que na região do visível (RGB) há uma absorção da energia eletromagnética na região do azul (B) e do vermelho (R) e uma maior reflectância na região do verde (G), o qual explica porque a vegetação é percebida na cor verde (FORMAGIO e SANCHES, 2017).

Figura 7 – Comportamento espectral de folhas morta, estressada e sadia.



Fonte: Fernanda Lampert Batista, 2017.

Os sensores multiespectrais embarcados em ARPs mais utilizados em AP são a câmera MicaSense Parrot Sequoia (Figura 08), capaz de registrar a irradiância no comprimento de onda da região do verde (550 nm), vermelho (660 nm), borda do vermelho (735 nm) e infravermelho próximo (790 nm), com resolução 1,2 Mega pixel (Mp) e resolução RGB de 16 Mp.

Figura 8 – Sensor multiespectral Parrot Sequoia.



Fonte: MicaSense, 2019.

Outro sensor multiespectral utilizado é o sensor/câmera MicaSense RedEdge™ (figura 9) que é uma leve e avançada câmera multiespectral otimizada

para uso em ARPs. Seus sensores dedicados capturam dados em cinco bandas distintas do espectro eletromagnético na região do visível: azul, verde e vermelho, e na região do invisível: RedEdge, infravermelho próximo de forma precisa, para ser usado principalmente em aplicações de sensoriamento remoto agrícola.

Figura 9 – Sensor multispectral RedEdge.



Fonte: MicaSense, 2019.

A RedEdge-MX (Figura 10), segundo o seu fabricante MicaSense (2019), é um sensor multiespectral que captura bandas azul (centro de 475 nm, largura de banda de 20 nm), verde (centro de 560 nm, largura de banda de 20 nm), vermelho (centro de 668 nm, largura de banda de 10 nm), borda vermelha (centro de 717 nm, largura de banda de 10 nm), quase IR (840 centro de nm, largura de banda de 40 nm).

Figura 10 – Sensor multiespectral RedEdge MX.



Fonte: MicaSense, 2019.

Outro sensor multiespectral, que tem um menor custo, entre os sensores, vistos anteriormente, é a MAPIR Survey3 (Figura 11). Esse sensor Survey3 da Mapir é o mais nova da linha de câmeras multiespectrais simples de usar. Toda câmera Survey3 inclui um receptor GPS USB externo para geomarcar automaticamente cada imagem capturada. Seu sensor de 12MP e lentes afiadas não fisheye permitem que você capture facilmente a imagem aérea. O sensor tem condições de capturar dados das bandas vermelho, verde e infravermelho próximo (MAPIR, 2019).

Figura 11 – Sensor Mapir Survey3.



Fonte: Mapir, 2019.

1.2.3.1.5 Sensoriamento remoto com sensores proximais

Segundo Sanches e Formaggio (2017) os sensores proximais objetivam, de modo geral, fornecer informações sobre a variabilidade espacial das características das plantas e dos solos nas lavouras. Os sensores proximais de acordo com os mesmos autores, não entram em contato direto com os objetos de estudo, sendo de natureza óptica, uma vez que os fótons do espectro visível ou da infravermelho incidem no objeto ou são emitidos por ele e em seguida é direcionado para o sensor. Dessa forma, o princípio físico de funcionamento é o mesmo utilizado pelos sensores embarcados em aeronaves ou em satélites, sendo somente a distância do sensor em relação ao alvo a diferença. O Sensoriamento proximal destina-se a aplicações mais localizadas, sendo que o sensoriamento remoto convencional visa a áreas mais extensas.

De acordo com Vian (2015), atualmente, existem no mercado uma série de sensores de vegetação, tais como Crop Circle®, N-Sensor® e Greenseeker®. Esses sensores tem a mesma finalidade, ou seja, a determinação de um índice de vegetação específico para cada sensor para estimativa da dose de N em cobertura a ser aplicada em uma determinada cultura (FENG et al., 2008; SCHMIDT et al., 2009; ERDLE et al., 2011; RISSINI et al., 2015).

Estes tipos de sensores podem ser ferramentas de grande potencial para o manejo do nitrogênio, sendo realizados vários trabalhos em culturas como milho e trigo (POVH et al., 2008; BREDEMEIER et al., 2013). Povh et al. (2008), realizou uma pesquisa que teve o objetivo de avaliar as relações das leituras realizadas com um sensor ótico ativo (Greenseeker) com doses de N, concentração de N nas folhas, produção de matéria seca e produtividade de grãos nas culturas de trigo, triticale, cevada e milho. Já, Bredemeier et al. (2013), teve como objetivo na sua pesquisa avaliar a relação entre o NDVI em diferentes estádios do desenvolvimento e o rendimento de grãos de quatro cultivares de trigo, visando a desenvolver procedimentos mais precisos para a adubação nitrogenada em cobertura.

1.2.3.1.6 Sensor proximal OptRX ®

O OptRX® é um sensor proximal óptico ativo com frequência de leitura de 5 Hz (5 leituras por segundo). Segundo o fabricante (*Ag Leader*), nos Estados Unidos, onde o OptRx foi criado, normalmente são utilizadas em tempo real as leituras dos índices de vegetação em conjunto às aplicações de produtos, com sensor instalado em pulverizador possibilitando a realização simultânea entre essas operações. Além disso, a empresa *Ag Leader Technology* (Ag Leader Technology, 2011) menciona que o sensor emite uma luz própria e mede a reflectância de algumas ondas eletromagnéticas específicas, e essa luz medida se correlaciona com o teor de clorofila e a biomassa, permitindo ao sensor obter o índice de vegetação. Com esse sensor é possível obter os índices de vegetação NDRE e NDVI, que serão descritos mais adiante.

O OptRx, é um sensor óptico ativo, que emite radiação e coleta a refletância das ondas eletromagnéticas, especificamente, nas bandas 790 e 720 nm, que proporciona estimar o NDRE e o NDVI (FITZGERALD et al., 2006).

Existem diferentes sensores disponíveis no mercado, são comuns trabalhos que utilizam os sensores OptRx® e GreenSeeker® (GROHS et al., 2009; CARNEIRO et al., 2019; CARVALHO, 2019). Carneiro et al. (2019), utilizaram o sensor OptRx para obter os IVs NDVI, IRVI e NDRE em experimento com amendoim, Serrano et al. (2014) utilizaram para avaliar IVs em campo experimental com pastagem, Carvalho (2019) estudou a correlação entre os IVs distintos, obtidos em diferentes estádios fenológicos no milho e a sua produtividade usando entre outros sensores o proximal OptRx.

1.2.3.2 Índices de vegetação

Conforme Sanches e Formaggio (2017), entre as principais contribuições dos dados de sensoriamento remoto para objetivos e aplicações em agricultura, situam-se aquelas relacionadas com o monitoramento e a estimativa de parâmetros biofísicos das culturas agrícolas. De acordo, com os mesmos autores, os índices de vegetação (IVs) podem ser definidos como formulações matemáticas desenvolvidas a partir de dados espectrais obtidos por sensores remotos, principalmente nas bandas do vermelho e do infravermelho próximo, visando permitir avaliações e estimativas da cobertura vegetal de uma área, em termos de parâmetros como área foliar, fitomassa, percentagem de cobertura do solo e atividade fotossintética.

Essas transformações matemáticas podem ser interpretadas como medidas semianalíticas da atividade da vegetação e tem sido largamente utilizadas em razão de conseguirem representar com fidedignidade variações da folhagem verde não somente em termos sazonais, mas também ao longo da superfície terrestre, com o objetivo de detectar variabilidades especializadas (SANCHES E FORMAGGIO, 2017). Pode-se dizer que os índices de vegetação procuram realçar informações sobre a fitomassa verde contidas em dados de reflectância espectral, procurando minimizar efeitos indesejáveis causados por solos subjacentes a vegetação, os efeitos da atmosfera ao ser atravessada pela radiação eletromagnética e variações da geometria Sol-alvo-sensor.

As análises da vegetação e detecção de mudanças são realizadas com o intuito de avaliar os recursos naturais e monitorar a cobertura vegetal. Na sequência, a detecção qualitativa da vegetação verde é uma das principais aplicações do sensoriamento remoto na tomada de decisões e gerenciamento ambiental do alvo. Um índice espectral de vegetação é a integração de duas ou mais bandas espectrais,

segundo determinado procedimento, cuja finalidade é realçar característica da vegetação como biomassa, vigor vegetativo, índice de área foliar, dentre outras características (MOREIRA, 1997).

A determinação dos índices de vegetação demonstra o potencial de produtividade de grãos utilizando variados sistemas de manejo, que é uma relevante ferramenta para detectar os fatores limitantes e as estratégias adequadas de manejo da cultura (VILLALBA, 2012).

Segundo Dusseux et al. (2015), os índices de vegetação são indicadores da condição em que se encontra a vegetação de uma determinada parcela, como por exemplo os valores de NDVI próximos a 1, que significam maior cobertura do solo com vegetação fotossinteticamente ativa, já valores de NDVI próximos de 0, correspondem a zonas de solo descoberto.

Será apresentado nesse trabalho, com maiores detalhes, o NDVI (Índice de Vegetação por Diferença Normalizada), NDRE (Índice de RedEdge por Diferença Normalizada), GNDVI e EVI2, por serem os IVs utilizados na presente pesquisa.

1.2.3.2.1 NDVI

O índice de vegetação por diferença normalizada foi proposto por Rouse et al. (1973), e tem sido utilizado para mensurar a coloração verde e o tamanho do aparato fotossintético das culturas (PIETRAGALLA; VEJA, 2012). Entretanto, Silva (2004) aponta que Deering, em 1978, foi quem normalizou esta razão dentro de um intervalo que varia de -1 a 1, por intermédio da razão da diferença dividida pela soma das bandas do vermelho e infravermelho próximo, como pode ser visto na equação 1. Os valores de NDVI variam em uma escala de -1 a 1, sendo que quanto maior o seu valor, maiores são as diferenças entre a reflectância do infravermelho próximo com o vermelho, o que indica maior quantidade de clorofila e vigor de desenvolvimento e, conseqüentemente, maior o potencial produtivo das plantas (RISSINI, 2011).

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

Onde:

NIR: Reflectância no infravermelho próximo;

Red: Reflectância no vermelho.

Assim sendo, o NDVI fornece informações que remetem ao estado nutricional e/ou sanitário da planta de milho, é um indicador da quantidade e condição da vegetação verde, representando o vigor da cultura, sendo obtido através de combinações da refletância medidas nas faixas espectrais do vermelho e infravermelho próximo do espectro eletromagnético.

De acordo com Oliveira (2015) o NDVI tem sido correlacionado com o teor de nitrogênio nas plantas, conteúdo de clorofila, biomassa foliar verde, parâmetros agrônômicos (produtividade, massa de grãos, entre outros) e fitopatológicos (incidência e severidade de doenças, área abaixo da curva de progresso da doença, patologia de sementes, grãos ardidos, etc.) e ainda utilizado para aplicação de nitrogênio em taxas variáveis. Uma peculiaridade inerente ao NDVI é sua rápida saturação, o que o torna pouco sensível à detecção de variações no aumento da biomassa vegetal a partir de uma determinada fase de crescimento das plantas (ASRAR et al., 1984).

Vários são os trabalhos com o IV NDVI na cultura do milho (MONTOVANI et al., 2016; POVH et al., 2008; UEBEL, 2015; CRUSIOL, OLIVEIRA 2017; ORLANDO, 2019) entre outros.

1.2.3.2.2 NDRE

O NDRE (*Normalized Difference Red Edge*) é um índice interessante para avaliar o teor de clorofila nas plantas, assim como sua captação de nitrogênio e a demanda de fertilizantes. Esse índice é largamente utilizado na AP, principalmente em plantas de maior porte, ou seja, que estão muito próximo da maturação fisiológica. Taipale (2018), comenta que o IV NDRE é um índice capaz de fornecer uma melhor análise de estádios fenológicos mais avançados, pois consegue obter dados em profundidades maiores em um determinado dossel, além de ser menos propenso a saturação. Para o índice de vegetação NDRE (Equação 2), tem-se a seguinte equação matemática (BARNES, 2000):

$$NDRE = \frac{NIR - RedEdge}{NIR + RedEdge} \quad (2)$$

Onde:

NIR: Reflectância no infravermelho próximo;

RedEdge: Reflectância na borda do vermelho.

A diferença para o NDVI, é que o NDRE utiliza a banda na borda do vermelho (RedEdge). Conforme Carvalho (2019), a máxima absorção da clorofila se dá nas ondas vermelhas, sendo assim, a radiação vermelha não penetra muito além de algumas camadas de folhas. Por outro lado, a radiação na borda vermelha, pode penetrar na camada de folhas de forma muito mais profunda em relação a luz azul ou vermelha. Assim, uma faixa de onda da borda vermelha pura será mais sensível a níveis médios e altos de clorofila e biomassa, portanto, detectando com maior sensibilidade o N foliar, do que uma faixa de onda ampla, que engloba luz azul, vermelha ou ainda uma mistura de luz visível e infravermelho próximo.

1.2.3.2.3 EVI2

O índice de vegetação melhorado (EVI) foi desenvolvido para otimizar o sinal da vegetação, melhorando a sensibilidade de sua detecção em regiões com maiores densidades de biomassa, e para reduzir a influência do sinal do solo e da atmosfera sobre a resposta do dossel. Nesse sentido, o EVI é calculado por meio da equação 03 (JUSTICE et al., 1998).

O EVI-2 é um índice associado à biomassa e minimiza os efeitos do solo e da atmosfera (JIANG et al., 2008). Foi obtido a partir da seguinte equação:

$$2,5 \frac{(NIR - Red)}{(NIR + 2,4 Red + 1)} \quad (3)$$

Onde:

NIR: Reflectância no infravermelho próximo;

Red: Reflectância no vermelho.

Bolton e Friedl (2013) fizeram um trabalho de pesquisa nos EUA, com três IVs, que foram o NDVI, NDWI e EVI2 e obtiveram resultados relevantes para a relação dos IVs com a produtividade das culturas de milho e soja. De acordo com o trabalho, os autores, chegaram à conclusão para a pesquisa realizada, que o IV EVI2, que se trata

de uma modificação do NDVI, é mais efetivo para a estimativa da produtividade em milho do que o NDVI.

Albuquerque et al. (2010) trabalhando com gramíneas, solo exposto e floresta no estado do Rio de Janeiro, concluíram que o EVI2 deverá ser investigado com maior profundidade dada a sua aparente capacidade de não sofrer os efeitos da saturação, aos quais está sujeito o NDVI, o que faria desse índice sensível na distinção de formações vegetais com elevada biomassa

1.2.3.2.4 GNDVI

O Índice de Vegetação Verde da Diferença (GNDVI) foi proposto por Gitelson et al. (1996), utilizando imagens orbitais sobre áreas de vegetação adulta e sobre áreas ocupadas por vegetação sob estado de senescência, com objetivos de determinação de taxas de concentração de pigmentações fotossinteticamente ativos e deficiências das vegetações. O mesmo autor, diz ainda que, o GNDVI surge como um índice que substitui a banda do vermelho pelo verde e associado ao infravermelho, podendo dar indícios sobre a sanidade da vegetação e da quantidade de clorofila contida nas folhas. Sua fórmula é dada por (Equação 4):

$$GNDVI = \frac{NIR - Gren}{NIR + Gren} \quad (4)$$

Onde:

NIR: Reflectância no infravermelho próximo;

Gren: Reflectância no verde.

Diversos trabalhos de pesquisa têm sido realizados com o IV GNDVI para saber a sua eficiência para estimar a produção de grãos, deficiências de nitrogênios e de sanidade da vegetação. Osborne et al. (2002), trabalhando com doses de nitrogênio e fósforo em milho, encontraram o maior valor de R² para o índice GNDVI, obtido de dados de imagem multiespectral, quando analisado o rendimento de grãos, demonstrando a eficiência na utilização do índice para estimar a produção de grãos e deficiência de nutrientes. Shanahan et al. (2001) diz que é possível com a obtenção do GNDVI estabelecer relações entre respostas espectrais do solo, da cultura e com os parâmetros de crescimento das plantas. Neste sentido, o trabalho de pesquisa de

Groff et al. (2013), permitiu os autores identificarem, em quais os estádios fenológicos da cultura da soja, tinham relações entre o IV GNDVI e características agrônômicas desejáveis como produtividade de grãos e de matéria seca. Gasparotto et al. (2015), avaliou IV GNDVI para estimar estresse nutricional de N na cultura de milho.

1.2.4 Cultura do Milho

O milho (*Zea mays L.*) é uma planta que pertence à família Gramineae/Poaceae. É uma planta herbácea e monoica, o seu ciclo é bastante variado, mas nas condições brasileiras, as cultivares completam o seu ciclo entre 110 a 180 dias. Da emergência a colheita o ciclo pode ser descrito como: superprecoce, precoce e normal (FANCELLI e DOURADO-NETO, 2004).

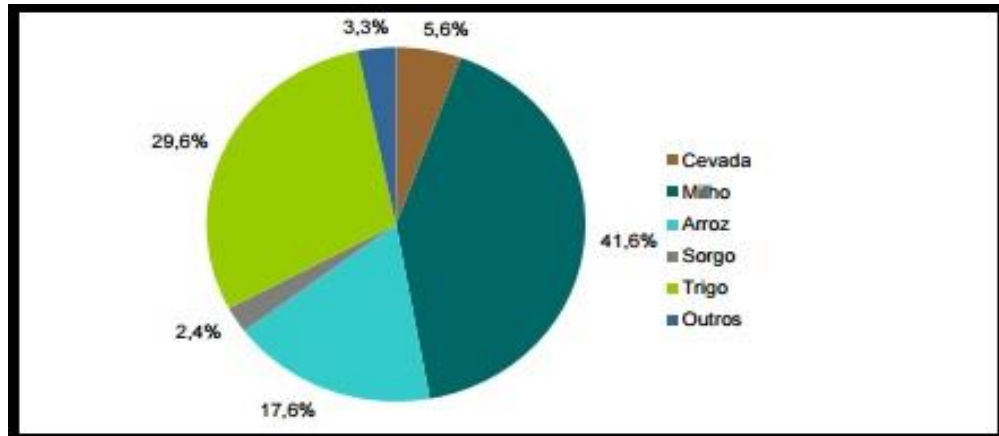
O milho possui raízes fasciculadas em que estão presentes raízes primárias e seminais, adventícias e de suporte. As folhas são longas e lanceoladas, com nervura central em forma de canaleta, bem vigorosa; as folhas são invaginantes e inserem-se por nós do colmo, apresentando pilosidades. O colmo suporta as folhas e partes florais, além de servir como órgão de reserva. Sendo o milho planta monóica, as flores masculinas se agrupam numa panícula no topo da planta, enquanto que as femininas são constituídas pelas espigas. O florescimento ocorre aproximadamente de 50 a 100 dias após semeadura e é afetado principalmente pela temperatura (EMBRAPA, 1996).

A produção a nível mundial do milho no ano de 2014, representava mais de 30% do total de grãos produzidos no mundo, sendo de destacada importância na alimentação humana e animal, produção de combustível etanol principalmente nos Estados Unidos, além de ser utilizado para fabricação dos mais diversos produtos como medicamentos e colas. O consumo mundial de milho vem crescendo em decorrência do aumento do consumo per capita de carnes, principalmente de frangos (EMBRAPA, 2014).

A cultura do milho é uma das mais importantes dentro do cenário da produção agropecuária no mundo, haja vista algumas utilizações deste cereal que justificam tal importância, como: principal fonte de energia dentro do processo de nutrição animal, sendo o cereal mais largamente consumido pelos setores de aves e suínos; pode ser utilizado na alimentação humana como flocos, farinha e óleo, além de fazer parte de vários processos da indústria alimentícia e de bebidas, é uma importante matriz energética na produção de biocombustíveis como o etanol. Por essa razão, a

produção deste cereal é importante na balança comercial de muitos países. Atualmente, é o grão mais produzido no mundo, sendo responsável por 42% de todos os grãos gerados, seguido pelo trigo (30%), e arroz (18%) como pode ser visto na Figura 12 (CONAB, 2017)

Figura 12 – Percentual dos principais grãos produzidos no mundo.



Fonte: USDA, 2017.

Além disso, pode-se afirmar que o milho é fundamental para a rotação de culturas, principalmente no binômio soja-milho, tornando-se o segundo grão mais plantado no Brasil (CONAB, 2017).

O aumento de produtividade da cultura do milho deve-se a importantes mudanças tecnológicas ocorridas recentemente, destacando-se os avanços no melhoramento genético, na qualificação da adubação, principalmente a nitrogenada, e na sua eficiência de aplicação e absorção, na qualidade do uso e manejo do solo, na irrigação e no aprimoramento na gestão dos recursos agrícolas, pela adoção das ferramentas da agricultura de precisão (AP) (SANTI, 2007).

A produção brasileira de milho, segundo a Conab, deve atingir seu maior volume, estimado em 97,2 milhões de toneladas. Este incremento significativo deu-se em função do aumento da área plantada do milho 1ª safra, do plantio do milho 2ª safra dentro do período ideal e das condições climáticas favoráveis às duas safras do grão, associando incremento na área com aumento de produtividade média como pode ser visto a baixo no Quadro 1 (CONAB, 2017).


Quadro 1 – Oferta e demanda de milho – Brasil – fev jan – mil t

SAFRA	ESTOQUE INICIAL	PRODUÇÃO	IMPORTAÇÃO	SUPRIMENTO	CONSUMO	EXPORTAÇÃO	ESTOQUE FINAL
2011/12	4.459,6	72.979,5	774,0	78.213,1	51.903,0	22.313,7	3.996,4
2012/13	3.996,4	81.505,7	911,4	86.413,5	53.287,9	26.174,1	6.951,5
2013/14	6.951,5	80.051,7	790,7	87.793,9	54.541,6	20.924,8	12.327,5
2014/15	12.327,5	84.672,4	316,1	97.316,0	56.742,4	30.172,3	10.401,3
2015/16	10.401,3	66.530,6	3.338,1	80.270,0	53.387,8	18.883,2	7.999,0
2016/17	7.999,0	97.191,2	500,0	105.690,2	56.100,0	28.000,0	21.590,2

Fonte: Conab, 2017.

Destaca-se o aumento da participação do Brasil (Figura 13) nas exportações mundiais de menos de nove milhões de toneladas na safra 09/10, para 28,0 milhões de toneladas em 2017/2018. Os maiores importadores são o Japão, com 15,1% e México e Coreia do Sul, com 6,8% cada (CONAB, 2017).

Figura 13 – Exportações brasileiras mensais de milho – toneladas - janeiro 2014 - julho 2017.



Fonte: Secex.

No entanto, o consumo (56,1 milhões de toneladas), apesar de maior que do ano anterior, trata-se apenas de uma recuperação do volume de demanda do setor animal (especialmente aves e suínos, que sofreu com a escassez do grão e com os elevados preços na safra 2015/16, forçando a diminuir seu plantel e investimentos) e do consumo do grão para a produção de etanol, com início de novas indústrias e a retomadas das mais antigas. Em relação às exportações do milho, há uma expectativa de embarque de 28,0 milhões de toneladas até o fim de janeiro de 2018. Contudo, é possível que, diante de alguns problemas de ordem logística, haja um comportamento semelhante ao ocorrido em 2016, quando se viu um grande volume de milho da safra

antiga sendo exportado em fevereiro e março de 2018, sendo contabilizado na oferta e demanda da safra 2017/18. Neste cenário, somando à produção o estoque inicial de quase 8,0 milhões de toneladas e tirando o consumo total estimado para a safra 2016/17, os estoques previstos tendem a ficar em 21,6 milhões de toneladas, ou seja, o maior estoque de passagem na história da produção de milho no país.

A cultura do milho para o Rio Grande do Sul apresenta significativa importância socioeconômica, ocupando aproximadamente 20% do total das áreas semeadas com cultivos de primavera-verão. Segundo Censo Agropecuário de 2006, o milho estava presente em 251.215 estabelecimentos rurais naquele ano e, destes, 90,1% são provenientes de agricultores familiares e 9,9% não familiares (EMBRAPA, 2014).

1.2.5 Estatística Multivariada

Muitas são as dificuldades em traduzir as informações obtidas em conhecimento, principalmente quando se trata da avaliação estatística das informações. Os métodos estatísticos, para analisar as variáveis, estão dispostos em dois grupos, um, que trata da estatística que olha as variáveis de forma isolada, a estatística univariada e outro grupo, que trata as variáveis de conjunta que é a estatística multivariada (VICINI, 2005).

Neto (2004) denomina a Análise Multivariada a um grande número de métodos e técnicas que utilizam, ao mesmo tempo, todas as variáveis da interpretação teórica do conjunto de dados obtidos.

Quando se deseja promover a redução do número de variáveis com um mínimo de perda possível, os métodos de análise de dados multivariados são muito utilizados (ANDRADE et al., 2007a; HELENA et al., 2000).

Os dados multivariados se parecem muito com os univariados consistem de uma ou mais variáveis independentes (preditoras) e duas ou mais variáveis dependentes (resposta). A distinção entre dados univariados e multivariados recai em grande parte sobre como os dados são organizados e analisados, e não como são coletados (GOTELLI e ELLISON, 2011).

1.2.5.1 *Análise dos Componentes Principais*

De acordo com Junior et al. (2015), a análise de componentes principais (ACP) é uma técnica multivariada de modelagem da estrutura de covariância. A técnica foi inicialmente descrita por Pearson (1901) e uma descrição de métodos computacionais práticos veio muito mais tarde com Hotelling (1933, 1936), que usou com o propósito determinado de analisar as estruturas de correlação. A ACP é uma técnica estatística de análise multivariada que transforma linearmente um conjunto original de variáveis, inicialmente correlacionadas entre si, num conjunto substancialmente menor de variáveis não correlacionadas que contém a maior parte da informação do conjunto original (VICINI, 2005).


A ACP é uma técnica da estatística multivariada que consiste em transformar um conjunto de variáveis originais em outro conjunto de variáveis de mesma dimensão denominadas de componentes principais. Os componentes principais apresentam propriedades importantes: cada componente principal é uma combinação linear de todas as variáveis originais, são independentes entre si e estimados com o propósito de reter, em ordem de estimação, o máximo de informação, em termos da variação total contida nos dados (JOHNSON; WICHERN, 1998; HONGYU, 2015).

Para Regazzi (2001), procura-se redistribuir a variação nas variáveis (eixos originais) de forma a obter o conjunto ortogonal de eixos não correlacionados. Essa redução é feita transformando-se o conjunto de variáveis originais em um novo conjunto de variáveis que mantém ao máximo, a variabilidade do conjunto, isto é, com menor perda possível de informação. Além disso, esta técnica permite o agrupamento de indivíduos similares mediante a exames visuais, em dispersões gráficas no espaço em duas dimensões ou em três dimensões, de fácil interpretação geométrica. A redução de dimensionalidade é chamada de Análise de Componentes Principal, no qual os autovalores são chamados de principal.

Para a determinação das componentes principais, é necessário calcular a matriz de variância-covariância, ou a matriz correlação, encontrar os autovalores e os autovetores e, por fim, escrever as combinações lineares, que serão as novas variáveis, denominadas de componentes principais, sendo que cada componente principal é uma combinação linear de todas as variáveis originais, independentes entre si e estimadas com o propósito de reter, em ordem de estimação e em termos de variação total, contida nos dados iniciais (REGAZZI, 2001). Souza (2000), descreve o

esquema da aplicação da análise dos componentes principais, sendo que pode ser visto (Figura 14).

Figura 14 – Esquema de aplicação de análise de componentes principais.



Fonte: Souza, (2000. p. 25).

Diversos trabalhos tem sido realizados na área das agrícola, utilizando técnicas multivariadas de ACP, entre esses trabalhos, cita-se Guarienti et al. (2003), verificaram quais as principais variáveis meteorológicas que afetavam a qualidade industrial e o rendimento de grãos de trigo através das ACPs, Montovani et al. (2002), na AP, verificaram a eficiência da técnica multivariada de componentes principais, aplicada sobre variáveis do solo, na validação de zonas de manejo estabelecidas, com base na condutividade elétrica e em um solo cultivado com a cultura do milho, Junior et al. (2008) agrupou os solos dos municípios do Estado do Amapá, utilizando a ACPs, utilizando amostras coletadas a campo, Pesini (2019), em seu trabalho de conclusão de mestrado avaliou a variabilidade da população e plantas da soja e seu impacto nos mapas de colheita, sendo que com a análise dos componentes principais foi possível identificar as medidas responsáveis pelas maiores variações entre os resultados, reduzindo o volume de atributos iniciais, Zamberlan et al. (2011 e 2013) em seus trabalhos determinando os índices de qualidade da água para a irrigação.

1.2.6 Análise de agrupamentos ou cluster

A análise de agrupamentos é o nome para um grupo de técnicas multivariadas cuja finalidade primária é agregar objetos com base nas características que eles possuem. A análise de agrupamentos classifica objetos de modo que cada objeto é muito semelhante aos outros no agrupamento em relação a algum critério de seleção predeterminado. Os agrupamentos resultantes de objetos devem então exibir elevada homogeneidade interna e elevada heterogeneidade externa entre os agrupamentos. Assim sendo, se a classificação for bem-sucedida, os objetos dentro dos agrupamentos estarão próximos quando representados graficamente e diferentes agrupamentos estarão distantes (HAIR et al., 2005).

Ainda, trata-se de uma análise que identifica grupos em objetos de dados multivariados. O objetivo é formar grupos com propriedades homogêneas de amostras heterogêneas grandes. Devem-se buscar grupos mais homogêneos possíveis e que as diferenças entre eles sejam as maiores possíveis (HÄRDLE e SIMAR, 2007).

O valor primário da análise de agrupamentos repousa na classificação de dados. A análise de agrupamentos se assemelha a análise fatorial em seu objetivo de avaliar a estrutura. Porém, diferem no sentido em que a primeira agrega objetos e a segunda está prioritariamente interessada em agregar variáveis (HAIR et al., 2005).

Muitos algoritmos existem para formar os agrupamentos. Devido a existência de vários critérios, para conceituar esses grupos, o pesquisador deve optar por aquele que for mais adequado a análise em estudo (VICINI, 2005).

Para Vicini (2005), para aplicar a análise de agrupamentos, entre várias análises, se apresenta os métodos de agrupamentos hierárquicos aglomerativos, que tem início com um grupo separado. Primeiro os objetos mais similares são agrupados formando um único grupo, sendo que eventualmente, o processo é repetido, e com o decréscimo da similaridade, todos os subgrupos são agrupados, formando um único grupo com todos os objetos.

Doni (2004) ressalta que “a análise de cluster é um processo de partição de uma população heterogênea em vários subgrupos mais homogêneos. No agrupamento não há classes pré-definidas, os elementos são agrupados de acordo com a semelhança, o que diferencia da tarefa de classificação”.

A análise de cluster agrupa os dados de acordo com a similaridade entre eles. Os grupos são formados de maneira que dentro deles existe homogeneidade e entre

os grupos heterogeneidade (DONI, 2004). Ainda conforme o mesmo autor, a análise de cluster exige métodos que apresentam as características de ser capaz de lidar com dados com alta dimensionalidade, ser escalável com número de dimensões e com a quantidade de elementos a serem agrupados, habilidade para lidar com diferentes tipos de dados, capacidade de definir agrupamentos de diferentes tamanhos e formas, exigir o mínimo de conhecimento para a determinação dos parâmetros de entrada, ser robusto a presença de ruído e apresentar resultado consistente independente da ordem em que os dados são apresentados.

Conforme Hair et al. (2005), o conceito de similaridade é fundamental na análise de agrupamentos. A similaridade entre objetos é uma medida de correspondência ou semelhança entre objetos a serem agrupados. A similaridade entre objetos pode ser medida de diversas maneiras, mas três métodos dominam as aplicações de análise de agrupamentos: medidas correlacionais, medidas de distância e medidas de associação. Cada um desses métodos representa uma perspectiva particular da similaridade, dependendo de seus objetivos ou do tipo de dados. Tanto as medidas correlacionais, quanto as medidas de distância requerem dados métricos, ao passo que as medidas de associação são para os dados não métricos.

1.2.6.1 Medidas de similaridades

A maioria dos métodos de análise de agrupamentos requer uma medida de similaridade entre os objetos a serem agrupados, normalmente como função da distância ou métrica (DONI, 2004).

De acordo com Hair et al. (2005) mesmo que as medidas correlacionais tenham um apelo intuitivo e sejam usadas em muitas outras técnicas multivariadas, elas não são a medida de similaridade mais comumente empregada em análise de agrupamentos. As medidas de similaridades baseadas em distância, as quais representam a similaridade como a proximidade entre observações ao longo das variáveis na variável estatística de agrupamento, são o método mais frequentemente usado. A distância euclidiana e suas variações são um exemplo (VICINI, 2005).

1.2.6.1.1 Distância euclidiana

A distância euclidiana é a distância geométrica no espaço multidimensional. A distância euclidiana entre dois elementos $X = [X_1, X_2, \dots, X_p]$ e $Y = [Y_1, Y_2, \dots, Y_p]$ é definida pela equação 5:

$$d_{x,y} = \sqrt{(X_2 - X_1)^2 + (Y_2 - Y_1)^2 + \dots + (X_p - Y_p)^2} \quad (5)$$

1.2.6.1.2 Distância euclidiana quadrática

A distância euclidiana quadrática é definida pela equação 6:

$$d_{x,y} = (X_2 - X_1)^2 + (Y_2 - Y_1)^2 + \dots + (X_p - Y_p)^2 \quad (6)$$

As medidas de similaridade são utilizadas na análise de cluster de forma a determinar a distância entre elementos. Essa distância, é normalmente representada na forma de matriz, ou seja, em uma matriz de similaridade. A matriz de similaridade é simétrica e utiliza, na maioria dos casos, a distância Euclidiana (DONI, 2004, p. 29).

Pesini (2019) utilizou em seu trabalho de pesquisa realizou a análise de cluster para objetos ou grupos relativamente homogêneos. Montibeller (2019), utilizou a análise de conglomerados para análise interespecífica com todos os talhões de soja, milho e cana-de-açúcar, com base em seis bandas espectrais.

1.2.7 Análise fatorial

A Análise Fatorial (AF) é um nome genérico dado a uma classe de métodos estatísticos multivariados cujo propósito principal é definir a estrutura subjacente em uma matriz de dados. Em termos gerais, a análise fatorial aborda o problema de analisar a estrutura das inter-relações entre um grande número de variáveis, definindo um conjunto de dimensões latentes comuns, chamadas de fatores. O pesquisador pode primeiro identificar as dimensões separadas da estrutura e então determinar o grau em cada variável é explicada por cada dimensão. Uma vez que essas dimensões e a explicação de cada variável estejam determinadas, os dois principais usos da

análise fatorial, isto é, o resumo e a redução de dados podem ser conseguidos (HAIR et al., 2005).

De acordo com Mingoti (2005) a análise fatorial é aplicada quando há um número grande de variáveis e correlacionadas entre si, com o objetivo de identificar um número menor de novas variáveis alternativas, não correlacionadas e que, de algum modo, sumarizem as informações principais das variáveis originais encontrando os fatores ou variáveis latentes.

A análise fatorial é uma técnica de interdependência que avalia todas as variáveis simultaneamente, cada uma relacionada com a outra, empregando o conceito da variável estatística. No entanto, segundo Hair et al. (2005), este conceito não é utilizado para prever uma variável dependente, mas sim para maximizar o poder de explicação do conjunto inteiro de variáveis. Dessa forma, o modelo de análise fatorial obtido através da matriz de correlação que relaciona linearmente as variáveis padronizadas e os fatores comuns inicialmente desconhecidos.

1.3 PROPOSIÇÃO

O presente estudo propõe o objetivo de utilizar as potencialidades da estatística multivariada para poder entender um experimento grande e complexo, realizado a campo na cultura do milho, com a aplicação de diferentes doses de nitrogênio, caracterizado por índices de vegetação obtidos a partir de dados de duas plataformas distintas de sensoriamento remoto, em diferentes estágios fenológicos, somados ainda o teor de nitrogênio na planta e dados de produtividade.

Neste sentido, o presente estudo tem como objetivos específicos:

- Reduzir a dimensionalidade de variáveis a partir da geração de variáveis sintéticas como fatores através do uso da análise fatorial e componentes principais;
- Verificar como os índices de vegetação obtidos de distintas plataformas de sensoriamento remoto contribuem na formação das variáveis sintéticas;
- Realizar o agrupamento das variáveis descritoras do experimento a partir de medidas de similaridade para evidenciar os efeitos dos distintos sensores na formação desses grupos;
- Determinar a relação das novas variáveis com a produção do milho.

1.4 MATERIAL E MÉTODOS

O estudo de campo na cultura do milho foi realizado na safra 2017/18 em uma área pertencente Universidade Federal de Santa Maria (UFSM), no município de Santa Maria, Rio Grande do Sul, localizado nas coordenadas 29° 43' 10" S e 53°44' 16" W. A área experimental apresenta uma dimensão aproximada de 1600 m².

O trabalho de pesquisa foi conduzido por Carvalho (2019), na qual em parceria, participamos, em diversas fases do desenvolvimento do estudo. O solo da área em questão, devido a sua formação, é classificado de acordo com a Embrapa (1999), como um Argissolo Vermelho distrófico arênico, que pertence a unidade de mapeamento São Pedro, este tipo de solo, é de cor avermelhada com a textura superficial franco arenoso, apresentando boa drenagem, sendo friável e com boa profundidade. O clima da região, segundo a classificação de Köppen (1931) é do tipo Cfa, subtropical úmido com verões quentes. A precipitação normal anual da região de Santa Maria/RS é de 1942,90 mm, geralmente bem distribuída, ao longo do ano, com uma temperatura média de 16°C (INMET, 2018).

Antes da implantação da cultura, foi realizada uma análise de solo na área, para saber qual era o seu estado nutricional. Essa coleta de solo foi realizada nas profundidades de 0-5 cm, 5-10 cm e 10-20 cm com o georreferenciamento da área com um receptor GNSS RTK de dupla frequência (L1/L2) da marca Topcon. Esse levantamento geodésico, serviu também, para delimitar os cinco blocos e as repetições do experimento. As coordenadas oriundas desse levantamento geodésico, também se mostrou útil, pois serviu como pontos de controle a campo, sendo fundamental para a geração e confecção de um mosaico ortorretificado.

O delineamento experimental utilizado foi o de blocos ao acaso (DBC), contendo cinco blocos, cada bloco com 20m x 20m, totalizando assim 400 m² cada bloco. Esses blocos foram localizados na lavoura de acordo com a sua topografia. Foram utilizados cinco tratamentos (T1, T2, T3, T4 e T5), contendo em cada bloco cinco repetições, de 4 m de comprimento por 4 m de largura equivalendo uma área de 16 m². Os tratamentos foram constituídos, por variações de doses de nitrogênio, com uso de ureia (45% N) como fonte de N na adubação de cobertura, aplicada manualmente sobre o solo, dez dias após a emergência (DAE). As doses de nitrogênio utilizadas, nos respectivos tratamentos, foram de 20, 60, 120, 180 e 240 kg.ha⁻¹.

A cultivar utilizada no estudo foi a variedade Pioneer 30F53VYH. Segundo, a empresa produtora (PIONEER, 2018), essa cultivar apresenta um elevado potencial produtivo, apresentando precocidade e estabilidade de população, ótima qualidade de grãos e responde muito bem ao manejo vegetativo e reprodutivo. Sendo, que a época de plantio, considerada ideal está preferencialmente entre os meses de Agosto e Novembro, com um estande de população entre 65 a 85.000 plantas por ha⁻¹.

A semeadura mecanizada da cultura foi realizada no dia 24 de Outubro de 2017, com espaçamento entre linhas de 0,50 m e entre plantas de 0,25 m, com uma densidade populacional de 80.000 plantas ha⁻¹, sendo assim, foram quatro sementes por metro. A adubação de base foi de 150 Kg ha⁻¹ com formulação de NPK 05-30-15.

A aeronave remotamente pilotada utilizada para o voo foi um modelo *Phantom 4 Standard*®, com uso de seu sensor RGB próprio e adaptado para embarcar concomitantemente a câmera multiespectral *MicaSense Parrot Sequoia*. As imagens oriundas do sensor multiespectral serviram para a geração e confecção do mosaico ortorretificado dos índices de vegetação. Esse sensor, segundo seu fabricante, tem a capacidade de coletar e registrar a reflectância nos comprimentos de onda na região espectral do verde (550 nm ± 5 nm), vermelho (660 nm ± 5 nm), borda do vermelho (735 ± 5 nm) e infravermelho próximo (790 ± 5 nm) com resolução de 1.2 Mp, e resolução RGB de 16 Mp, equipada com “*Sunshine sensor*”.

O tratamento das imagens geradas pela câmera RGB, foi realizado separadamente dos sensores multiespectrais. Anteriormente, a execução do voo, foi realizado um plano de voo no programa computacional *Dronedeploy* e posteriormente foi ortorretificadas e extraídos os mapas de interesse no programa *PIX4D*. Os voos foram realizados com uma altura de 15 metros, sendo que essa altura foi fixada por estar dentro do Plano Básico de Zona de Proteção de Aeródromo, pois a área do experimento ficava muito próxima da Base Aérea e do aeroporto de Santa Maria. De acordo com Carvalho (2019), após realizado os processamentos iniciais foram gerados o ortomosaico e no menu calculadora de índices no programa computacional *PIX4D*, foi calculado os seguintes índices: Índice de vegetação por diferença normalizada (NDVI), Índice de vegetação da borda do vermelho (NDRE), Índice de vegetação normalizada do verde (GNDVI) e o Índice de vegetação realçado 2 (EVI2).

Ressalta-se que os dados referentes ao estágio vegetativo V6 não foram utilizados nessa pesquisa, pois de acordo com Carvalho (2018) houveram, problemas

na aquisição dos dados durante a execução do voo, isto é, as fotos não foram georreferenciadas devido a um problema no Sunshine.

Também foi utilizado um sensor óptico proximal para a realização das observações a campo. Foram realizadas determinações da reflectância do dossel vegetativo com o sensor proximal *Optrx ACS 430 (Ag Leader)*, esse sensor trabalha com as bandas espectrais do vermelho (630 ± 5 nm) e infravermelho próximo (770 ± 5 nm) para geração índice de vegetação conhecido como NDVI. Adicionalmente, o sensor *Optrx* ainda registra a refletância na região da borda do vermelho (730 ± 5 nm) para geração do IV NDRE. O sensor proximal foi colocado em uma bicicleta especialmente preparada para o uso deste equipamento. Essa bicicleta foi idealizada e forjada por Carvalho (2019). As leituras foram realizadas com o equipamento posicionado paralelamente às linhas da cultura, em altura de 0,60 m acima do topo do dossel e com o deslocamento linear do equipamento sobre cada linha do plantio.

Convém ressaltar, que as leituras, realizadas tanto com os sensores multiespectrais embarcados em ARP, quanto o sensor proximal embarcado na bicicleta, foram feitas nos estádios fenológicos V5, V7, V9, V11 e V12, realizadas nas datas de 19/10, 01/12, 15/12/ 28/12 de 2017 e 04/01 de 2018 respectivamente.

No final do cultivo do milho, foi realizado o processo de colheita manual e beneficiamento, com espigas colhidas individualmente, condicionadas em sacos plásticos e rotuladas de acordo com o bloco, tratamento e parcela, numerados de 1 a 40.

Figura 15 – Colheita manual do milho.



Em um período antes da debulha do cereal, foi realizada a leitura da umidade dos grãos com o equipamento denominado agrologic AL-101 que mede o peso hectolítrico, esse aparelho foi calibrado pelo INMETRO. O mesmo possui uma balança incorporada e software para gravar os resultados de medição e opção de inclusão de mais de 60 grãos no aparelho, segundo o fabricante com uma precisão na leitura da umidade de 0,1%, (Figura 16).

Figura 16 – Equipamento utilizado para medir a umidade dos grãos.



Fonte: Autor, 2018.

Os grãos foram separados, pesados e os valores corrigidos para 13% de umidade e logo descontada a massa úmida para obter a massa seca de grãos em quilogramas por parcela. Com os dados de massa seca dos grãos foram estimadas a quantidade total de nitrogênio absorvida pelas plantas e a quantidade de nitrogênio exportada pelos grãos, com base no trabalho de Silva (2016). A partir dos teores médios descritos naquele trabalho, foram elaboradas as fórmulas para a estimativa da quantidade de Nitrogênio absorvido pelas plantas (N_{ABS_PLANTA}) e quantidade de Nitrogênio exportada pelos grãos ($N_{EXP_GR\tilde{A}OS}$), para o híbrido Pioneer 30F53 YH:

$$N_{ABS_PLANTAS} = MS_G * 26,35 \quad (7)$$

$$N_{EXP_GR\tilde{A}OS} = MS_G * 14,00 \quad (8)$$

Onde: N_{ABS_PLANTA} = nitrogênio absorvido pelas plantas em quilogramas por parcela; $N_{EXP_GR\tilde{A}OS}$ = nitrogênio exportado pelos grãos em quilogramas por parcela; MS_G = massa seca dos grãos em quilogramas por parcela; 26,35 e 14,00 = fatores de conversão, compostos por valores médios, obtidos do trabalho de Silva (2016). Os dados de massa seca dos grãos em quilogramas por parcela (2 m²), foram extrapolados para quilograma por hectare (10.000 m²).

Ainda, o presente trabalho considerou como fontes de variação as dosagens de nitrogênio aplicadas pelos tratamentos (20 a 240 kg N.ha⁻¹) e número de plantas por parcelas (14 a 18).

Logo após essa etapa, realizou-se a debulha mecanizada do milho feita por um debulhador que estava acoplado em um trator da marca *MASSEY FERGUSON* modelo *TURBO 4290* (Figuras 17 e 18) período esse que foi de 21 /05 a 21/07 de 2018.

Figura 17 – Trator Massey Ferguson, utilizado para a debulha mecanizada do milho.



Fonte: Autor, 2018.

Figura 18 – Debulhadora utilizada para a separação do grão de milho da espiga.



Fonte: Autor, 2018.

Após realizada a debulha, foi realizada a pesagem da massa de grãos em uma balança digital com aferição pelo IMETRO.

Logo terminada essa etapa, os dados foram tabulados e organizados em uma planilha Excel.

Os dados observados a campo foram submetidos ao Teste estatístico de Shapiro-Wilk ($p > 0,05$) para a avaliação da normalidade dos dados. Ao proceder os testes estatísticos para saber se havia ou não a normalidade dos dados, foi constatado que o dados não eram normais.

Foi realizado a padronização dos dados, antes de efetuar a análise estatística multivariada. A execução dessa padronização dos dados é para eliminar o efeito da presença de diferentes unidades e escalas de valores nos mesmos (OLIVEIRA et al., 2014).

Foram utilizados os métodos de Análise de Agrupamento Hierárquico (AAH), Análise Fatorial (AF) e Análise de Componentes Principais (ACP), para haver redução de dimensionalidade e obtenção de variáveis sintéticas, ou seja, as componentes principais - CPs (HAIR JR. et al., 2005; VICINI, 2005).

2 ARTIGO 1

RELAÇÕES DA PRODUTIVIDADE DE MILHO (*ZEA MAYS L.*) COM ÍNDICES DE VEGETAÇÃO A PARTIR DE ANÁLISES MULTIVARIADA

PRODUCTIVITY RELATIONS OF CORN (*ZEA MAYS L.*) WITH VEGETATION INDICES FROM MULTIVARIATE ANALYSES

Marco Ivan Rodrigues Sampaio¹, Lucio de Paula Amaral²

^{1, 2} Universidade Federal de Santa Maria (UFSM) - Programa de Pós-Graduação em Agricultura de Precisão, Colégio Politécnico da UFSM, Santa Maria, Rio Grande do Sul, Brasil –marcosampaio@politecnico.ufsm.br, amaralufsm@gmail.com

RESUMO

Na agricultura moderna, está cada vez mais sendo utilizado os índices de vegetação para estimar produtividade. O uso dos IVs acarreta na obtenção muito grande de dados (variáveis), priorizando assim, trabalhar com a análise estatística multivariada. O objetivo da pesquisa foi utilizar técnicas de análise multivariada para entender a relação da produtividade do milho, sob diferentes doses de nitrogênio, com uso de índices de vegetação obtidos a partir de dados de duas plataformas distintas de sensoriamento remoto, uma proximal e a outra a aeronave remotamente pilotada (ARP), em diferentes estágios fenológicos. O experimento foi realizado por Carvalho (2019) em uma área de lavoura da Universidade Federal de Santa Maria com a cultivar de milho. O delineamento utilizado foi blocos ao acaso com cinco blocos e cinco tratamentos com variações de doses de nitrogênio (N) após a emergência da cultura. O sensoriamento da vegetação foi realizado por duas plataformas distintas sensor sequoia embarcado em ARP e o sensor Optrx embarcada em uma bicicleta, obtendo-se os Índices de Vegetação (IVs) NDVI, GNDVI, EVI2 e NDRE com o sensor sequoia embarcada no ARP e NDVI e NDRE com o sensor sequoia embarcada na bicicleta nos estádios vegetativos V5, V7, V9, V11 e V12. Além dessas variáveis foram obtidos número de plantas, teores de N na planta, dados de produtividade. Nesse trabalho foram utilizados dados de quatro blocos, contendo 800 parcelas, porém foram utilizados somente dados de 451 parcelas, em função do descarte de 349 parcelas, que não apresentavam a variação de 14 a 18 plantas no momento da colheita e/ou não apresentavam leituras para alguma variável, ou seja, valor nulo. Foi realizado o teste de normalidade e os dados não apresentaram normalidade, foi realizado a padronização dos dados no software (Statistica 12). A análise dos dados foi realizada com a estatística multivariada com os métodos de Análise de Agrupamentos Hierárquicos (AAH), Análise Fatorial (AF) e Análise de Componentes Principais (ACP). Conclui-se que foi formado dois grupos distintos (Sequoia/ARP e Optrx), existindo uma relação maior entre dados de produtividade com os IVs (NDRE, NDVI, GNDVI e EVI2) no estágio fenológico V9 e o IV NDRE no estágio fenológico V12.

PALAVRAS-CHAVE: Análise fatorial, Cluster, NDVI.

ABSTRACT

In modern agriculture, vegetation indices are increasingly being used to estimate productivity. The use of VIs results in very large data collection (variables), thus prioritizing the work with multivariate statistical analysis. The goal of the research was to use multivariate analysis techniques to understand the relation of corn yield, under different nitrogen doses, using vegetation indices obtained from data from two different remote sensing platforms, one proximal and the other, a remotely piloted aircraft (RPA), along different phenological stages. The experiment was carried out by Carvalho (2019) in a farming area of the Federal University of Santa Maria destined to the cultivation of corn. A randomized block design with five blocks and five treatments with nitrogen dose variations (N) after crop emergence was used. The vegetation sensing was performed by two different platforms, sequoia sensor embedded in an RPA and the Optrx sensor embedded in a bicycle, obtaining the NDVI, GNDVI, EVI2 and NDRE Vegetation Indices (VIs) with the sequoia sensor embedded in the RPA and the NDVI and NDRE indices with the sequoia sensor embedded in the bicycle in the vegetative stages V5, V7, V9, V11 and V12. In addition to these variables, the number of plants, N levels in the plant, and yield data were obtained. In this work, data from four blocks were used, containing 800 plots, but only data from 451 plots were used, due to the discarding of 349 plots, which did not present a variation from 14 to 18 plants at the time of harvesting and/or did not present readings for any variable, i.e., null value. The normality test was performed and the data did not present normality, the standardization of data in the software was performed (Statistica 12). The data analysis was performed with multivariate statistics using the methods of Hierarchical Cluster Analysis (HCA), Factor Analysis (FA) and Principal Component Analysis (PCA). It was concluded that two distinct groups were formed (Sequoia / ARP and Optrx), and there was a greater relationship between productivity data with IVs (NDRE, NDVI, GNDVI and EVI2) at phenological stage V9 and IV NDRE at phenological stage V12.

KEYWORDS: Factor Analysis, Cluster, NDVI.

INTRODUÇÃO

A Agricultura de Precisão (AP) aumentou a eficiência de produção de alimentos através do uso de novas técnicas e tecnologias na gestão de produção agrícola. As inovações tecnológicas na agricultura brasileira têm sido apontadas como definidoras do grande incremento de produtividade do setor desde a década de 1970 (CORRÊA & FIGUEIREDO, 2006). Segundo Fernandes (2016), a utilização dos ARP (Aeronave Remotamente Pilotada), na agricultura vem ao encontro das necessidades da AP, pois o ARP é um equipamento portátil, capaz de realizar um voo automático, além de dispor informações de relevância do vegetal, com a utilização de câmeras com sensores multiespectrais acoplados na sua estrutura, capazes de obter imagens de altíssima resolução, que podem ser capturadas em qualquer momento da safra.

Conforme Formaggio & Sanches (2017) os sensores proximais objetivam, de modo geral, fornecer as informações sobre a variabilidade espacial das características das plantas e dos solos nas lavouras. Os sensores proximais de acordo com os mesmos autores, não entram em contato direto com os objetos de estudo, sendo de natureza óptica, uma vez que os fótons do espectro visível ou do infravermelho incidem no objeto ou são emitidos por ele e em seguida é direcionado para o sensor.

Os índices de vegetação (IVs) são insubstituíveis para Agricultura de Precisão (AP), uma vez que as reflectâncias obtidas por sensores, com as quais são calculados os IVs, podem ser utilizadas, por exemplo, para estimar a produtividade de culturas agrícolas (FORMAGGIO & SANCHES, 2017).

O monitoramento da lavoura em tempo real é um dos principais fatores, hoje em dia, para alcançar altas produtividades de grãos. O acompanhamento da cultura em diversas fases do seu desenvolvimento fisiológico, poderá trazer consequências positivas na qualidade e produtividade de grãos pois, pode-se interferir de forma imediata mitigando problemas de sanidade vegetal, deficiência nutricional, compactação de solos, emergência desuniforme de plantas, entre outros. Geralmente, quando é realizado o monitoramento em tempo real, de uma determinada cultura de grãos, acarreta normalmente, em uma grande quantidade de variáveis analisadas, pois é comum a coleta frequente nos mesmos pontos de amostragem, resultando assim em uma grande matriz de dados e uma complexa interpretação. Guedes et al. (2012), comenta, que muitas vezes, um pequeno número dessas variáveis contém as informações mais relevantes enquanto a maioria das variáveis adiciona pouco ou nada à interpretação dos resultados, termos qualitativos.

Com alguma frequência, quando é realizado o monitoramento de uma lavoura de grãos são gerados um volume muito grande de dados que são difíceis de analisar e interpretar (LIAO et al., 2008).

Sendo assim, análises multivariadas, como Análise Fatorial (AF), Análise de Agrupamentos Hierárquicos (AAH), Análise de Componentes Principais (ACP), tem sido utilizados de forma positiva na agricultura para extrair informações de uma grande quantidade de dados e quando a estatística univariada não consegue dar solução desejada, pois com o uso da estatística univariada para um grande volume de dados pode acarretar em perdas na qualidade da análise e na interpretação dos dados (OLIVEIRA et al., 2002; GUARIENTI et al., 2003; CORRÊA e FIGUEIREDO, 2006; FREDDI et al., 2008; JUNIOR et al., 2008 MONTIBELLER, 2018; PESINI, 2019).

Os métodos de análise de dados multivariados são muito utilizados quando se deseja uma redução de massa de dados, com o mínimo de perda possível da informação, procurando redistribuir a variação observada nos eixos originais de forma a se obter um conjunto de eixos ortogonais não correlacionados (MANLY, 1986; ALVARENGA & DAVIDE, 1999; HONGYU, 2015).

O objetivo desta pesquisa foi utilizar técnicas de análise multivariada para melhor entender a relação da produtividade do milho, sob diferentes doses de nitrogênio, com uso de índices de vegetação obtidos a partir de dados de duas plataformas distintas de sensoriamento remoto, uma proximal e a outra a aeronave remotamente pilotada (ARP), em diferentes estágios fenológicos. Os objetivos específicos foram reduzir o número de variáveis explicativas do experimento e da produtividade pelas técnicas de (ACP) e análise fatorial (AF), entender a relação entre as diversas variáveis e formar grupos homogêneos de variáveis explicativas, pela técnica de análise de agrupamento hierárquico (cluster).

MATERIAL E MÉTODOS

O experimento foi realizado por Carvalho (2019), em área de lavoura de milho irrigada por pivô central do Colégio Politécnico da UFSM, safra 2017/2018, localizada no Campus Sede da UFSM em Santa Maria-RS, com coordenadas 29° 43' 10" S e 53° 44' 16" W. A área experimental apresenta uma dimensão aproximada de 1600 m². O solo da área em questão, devido a sua formação, é classificado de acordo com a Embrapa (1999), como um Argissolo Vermelho distrófico arênico, que pertence a unidade de mapeamento São Pedro, este tipo de solo, é de cor avermelhada com a textura superficial franco arenoso, apresentando boa drenagem, sendo

friável e com boa profundidade. O clima da região, segundo a classificação de Köppen (1931) é do tipo Cfa, subtropical úmido com verões quentes. A precipitação normal anual da região de Santa Maria/RS é de 1942,90 mm, geralmente bem distribuída, ao longo do ano, com uma temperatura média de 16°C (INMET, 2018).

O plantio mecanizado foi realizado em 24 de outubro de 2017, com uso da cultivar de milho Pioneer 30F53YH, espaçamento de 50 x 25 cm, com uma densidade de 80.000 plantas por hectare (16 plantas por parcela no experimento), no entanto, houveram uma oscilação no número de plantas, por causas variadas. A cultivar 30F53YH é considerada precoce, possui elevado potencial produtivo, com ótima qualidade de grãos e responde muito bem ao manejo vegetativo e reprodutivo (PIONEER, 2018).

Foi utilizado o delineamento blocos ao acaso (DBC), com cinco blocos, dispersos na área ao longo de uma toposequência, no sentido declivoso, da parte mais alta para a de menor altitude. Foram utilizados cinco tratamentos (T1, T2, T3, T4 e T5), sendo variações de doses de nitrogênio (N) de 20, 60, 120, 180 e 240 kg.ha⁻¹, com uso de ureia (45% de N) na adubação de cobertura aplicada manualmente sobre o solo dez dias após a emergência de plantas (DAE). A adubação de base foi de 150 Kg ha⁻¹ com formulação de NPK 05-30-15. Cada bloco continha cinco repetições (4x4 m – 16 m²) (Figura 1).




Figura 1. Divisão do experimento em blocos (20x20 m) em vermelho, repetições (4x4 m) – em amarelo, e parcelas (2x1 m) – em ciano.

Neste trabalho foram utilizados dados de quatro blocos, cada bloco contendo 200 parcelas, porém foram utilizados somente dados de 142 parcelas, em função do descarte de 58 parcelas, que não apresentavam a variação de 14 a 18 plantas no momento da colheita e/ou não apresentavam leituras para alguma variável, ou seja, valor nulo.

Os limites dos blocos e repetições foram georreferenciados com receptor GNSS com função RTK (*Real Time Kinematic*). As coordenadas finais foram obtidas pela técnica de posicionamento relativo cinemático com

precisão na casa dos centímetros (MONICO, 2008). Estas coordenadas foram utilizadas como pontos de controle a campo para obtenção de mosaicos ortorretificados, a partir das fotografias obtidas com sensores embarcados na ARP, bem como para a obtenção dos limites das parcelas de 2m² e extração dos valores médios dos índices de vegetação em sistema de informação geográfica (SIG) chamado de Arc Map 10[®],

Ao final do cultivo foi realizada colheita manual das espigas (entre 02 de abril a 17 de maio de 2018), e as repetições de 16 m² foram subdivididas em parcelas menores de 2x1 m (2m²), contendo 16 plantas, sendo oito em cada linha. O milho foi debulhado entre 21 de maio a 21 de julho de 2018. Foi determinada a umidade dos grãos com o equipamento denominado agrologic AL-101 que realiza a estimativa do PH (peso hectolítrico), e possui balança incorporada, com software para gravar os resultados de medição e a massa dos mesmos por parcela foi determinada em balança com aferição pelo IMETRO. Os grãos foram separados, pesados e os valores corrigidos para 13% de umidade e logo descontada a massa úmida para obter a massa seca de grãos em quilogramas por parcela. Com os dados de massa seca dos grãos foram estimadas a quantidade total de nitrogênio absorvida pelas plantas e a quantidade de nitrogênio exportada pelos grãos, com base no trabalho de Silva (2016). A partir dos teores médios descritos naquele trabalho, foram elaboradas as fórmulas para a estimativa da quantidade de Nitrogênio absorvido pelas plantas (N_ABS_PLA) e quantidade de Nitrogênio exportada pelos grãos (N_EXP_G), para o híbrido Pioneer 30F53 YH:

$$N_ABS_PLA = MS_G * 26,35 \quad (9)$$

$$N_EXP_G = MS_G * 14,00 \quad (10)$$

onde: N_ABS_PLA = nitrogênio absorvido pelas plantas em quilogramas por parcela; N-EXP_G = nitrogênio exportado pelos grãos em quilogramas por parcela; MS_G = massa seca dos grãos em quilogramas por parcela; 26,35 e 14,00 = fatores de conversão, compostos por valores médios, obtidos do trabalho de Silva (2016). Os dados de massa seca dos grãos em quilogramas por parcela (2 m²), foram extrapolados para quilograma por hectare (10.000 m²).

Ainda, o presente trabalho considerou como fontes de variação as dosagens de nitrogênio aplicadas pelos tratamentos (20 a 240 kg N.ha⁻¹) e número de plantas por parcelas (14 a 18).

As doses de nitrogênio aplicada por hectare foram obtidas do delineamento experimental. Carvalho (2019) realizou voos com veículo aéreo remotamente pilotado

(ARP), com sensores RGB e multiespectral embarcados, bem como a utilização de sensores proximais, para a obtenção dos índices de vegetação previamente definidos, nos estádios fenológicos da cultura do milho V5, V6, V7, V9, V11 e V12, realizadas nas datas de 19/10, 01/12, 15/12/28/12 de 2017 e 04/01 de 2018 respectivamente, podendo ser observando também a precipitação total em milímetros (mm) em cada mês (Figura 2). Ressalta-se que os dados referentes ao estágio vegetativo V6 não foram utilizados nessa pesquisa, pois houve problemas na aquisição dos dados durante a execução do voo, limitando assim, a um reduzido número de parcelas que continham os dados. De acordo com Carvalho (2019), no estágio fenológico V8, os arquivos oriundos do sensor embarcado no ARP ficaram corrompidos e no estágio fenológico V10, não foi realizado o voo devido a condições meteorológicas adversas.

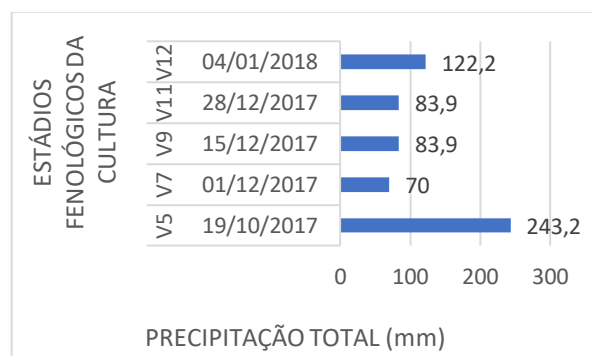


Figura 2. Gráfico da precipitação mensal total nos estádios fenológicos V5, V7, V9, V11 e V12 e as respectivas datas de sensoriamentos. Fonte: INMET, 2018.

A ARP utilizada foi o modelo *Phantom 4 Standart*[®], com uso de seu sensor RGB próprio e sensor adaptado embarcado concomitantemente, sendo a camera multiespectral *Sequóia*[®]. O planejamento de voo foi realizado no software Dronedeploy, com altura de 15 m, essa altura foi estabelecida devido à proximidade da área de pesquisa com o aeroporto e a base aérea, com recobrimento lateral de 80% e longitudinal de 80%. O voo foi realizado sempre as 15 hs quando o sol estava no seu zênite. O processamento das fotografias digitais foi realizado no software PIX4D, para obtenção dos mosaicos ortoretificados e índices de vegetação. O sensor proximal utilizado foi o Optrix[®], acoplado em bicicleta especialmente adaptada, com altura variável, sempre a 0,60 m acima do dossel da cultura, adaptado por Carvalho (2019).

Foram utilizados os índices de vegetação NDVI, GNDVI, EVI2 e NDRE, todos obtidos pelos sensores embarcados no ARP, e os índices NDVI e NDRE obtidos pelo sensor proximal.

Os valores de NDVI variam em uma escala de -1 a 1, sendo que quanto maior o seu valor, maiores são as diferenças entre a reflectância do infravermelho próximo com o vermelho (Equação 3), o que indica maior quantidade de clorofila e vigor de desenvolvimento e, consequentemente, maior o potencial produtivo das plantas (RISSINI, 2011).

$$NDVI = \frac{NIR - Red}{NIR + Red}, \quad (11)$$

onde:

NIR: Reflectância no infravermelho próximo;

Red: Reflectância no vermelho.

O NDRE (*Normalized Difference Red Edge*) é um índice interessante para avaliar o teor de clorofila nas plantas, assim como sua captação de nitrogênio e a demanda de fertilizantes. É dado pela Equação 4.

$$NDRE = \frac{NIR - RedEdge}{NIR + RedEdge}, \quad (12)$$

onde:

NIR: Reflectância no infravermelho próximo;

RedEdge: Reflectância na borda do vermelho.

O índice de vegetação melhorado (EVI) foi desenvolvido para otimizar o sinal da vegetação, melhorando a sensibilidade de sua detecção em regiões com maiores densidades de biomassa, para reduzir a influência do sinal do solo e da atmosfera sobre a resposta do dossel (JUSTICE et al., 1998).

O EVI-2 é um índice associado à biomassa e minimiza os efeitos do solo e da atmosfera (JIANG et al., 2008). Foi obtido a partir da seguinte Equação 5:

$$EVI = 2,5 \frac{(NIR - Red)}{(NIR + 2,4 Red + 1)}, \quad (13)$$

onde:

2,5: Constante.

NIR: Reflectância no infravermelho próximo;

Red: Reflectância no vermelho.

O índice de vegetação por diferença normalizada do verde (GNDVI) foi proposto por Gitelson et al. (1996), com o uso de imagens orbitais sobre áreas de vegetação adulta e sobre áreas ocupadas por vegetação sob estado de senescência, com objetivos de determinar taxas de concentração de pigmentações fotossinteticamente ativos e deficiências das vegetações (Equação 6).

$$GNDVI = \frac{NIR - Gren}{NIR + Gren}, \quad (14)$$

onde:

NIR: Reflectância no infravermelho próximo;

Gren: Reflectância no verde.

Foram também obtidos os teores de nitrogênio nas plantas de milho pelo método de Kjeldahl (1883), nos estádios V7, V11 e V12. Foram coletadas uma planta por parcela, secas em uma estufa com uma temperatura de 65º Celsius, depois foram trituradas para a extração do nitrogênio total. Nas parcelas de 2m², durante a colheita, foram obtidas as variáveis número de plantas e produção de milho (kg de matéria seca). Esta última foi extrapolada para quilos de matéria seca de grãos por hectare, para caracterizar a produtividade da cultura conforme os tratamentos.

Antes da realização da análise estatística os dados foram tabulados em planilha Excel. Os dados foram submetidos à análise de normalidade pelo Teste de Shapiro-Wilk ($p > 0,05$), e não apresentaram normalidade. Para análise multivariada os dados foram padronizados (com subtração da média de cada variável original para cada observação e divisão pelo respectivo desvio padrão) para eliminar o efeito da presença de diferentes unidades e escalas de valores nos mesmos (OLIVEIRA et al., 2014). Foram utilizados os métodos de Análise de Agrupamento Hierárquico (AAH), Análise Fatorial (AF) e Análise de Componentes Principais (ACP), para haver redução de dimensionalidade e obtenção de variáveis sintéticas, ou seja, as componentes principais - CPs (HAIR JR. et al., 2005; VICINI, 2005). O objetivo do uso destas análises foi reduzir dimensionalidade dos dados originais, capturando o máximo possível da variabilidade original com as CPs. As CPs são variáveis sintéticas, obtidas pela fusão das variáveis originais, que podem apresentar maior poder de predição para a Produção de Milho neste caso, em relação às variáveis originais.

Foram selecionadas as CPs significantes, utilizando como critérios a presença de autovalores $\geq 1,0$ e de variância explicada acumulada superior a 70% (HAIR JR. et al., 2005; VICINI, 2005). Na AAH foi utilizada a formação de dendrograma vertical para agrupamento das variáveis, com utilização do Método Ward para ligação e distância euclidiana e distância euclidiana ao quadrado como medida de similaridade. Na AF foi utilizado como método de extração dos fatores e para obter a contribuição das variáveis originais em cada fator significativo, foi realizada a rotação *Varimax Normalized* (LATTIN et al., 2011; FERREIRA, 2008; MARDIA et al., 1994). As análises multivariadas foram realizadas no software Statistica 12®.

RESULTADOS E DISCUSSÃO

Na Tabela 01 é mostrada a estatística descritiva das variáveis que fizeram parte do experimento, mostrando o seu comportamento estatístico. O coeficiente de variação é uma medida de dispersão empregada para estimar a precisão de experimentos e representa o desvio-padrão expresso como porcentagem da média (MOHALLEM et al., 2008). A maioria dos pesquisadores tem comparado os seus resultados com aqueles sugeridos por Gomes (1990). Essa classificação considera os coeficientes de variação como baixos quando inferiores a 10%, médios entre 10 e 20%, altos entre 20 e 30% e muito altos se superiores a 30% (GOMES, 1990). Observa-se que o coeficiente de variação maioria das variáveis em relação a classificação proposta por Gomes (1990) varia como sendo baixo (NDRE_D_V5, GNDVI_D_V5, NDVI_D_V9, entre outros) médios (NDVI_D_V5, NDVI_OP_V5, NDRE_OP_V5, NDVI_OP_V7, NDRE_OP_V7, entre outros) altos (EVI2_V5, NT_V7, NT_V11, entre outros) e muito altos (DN_ha, e os dados de produtividade). Coeficientes de variação altos indica muitas vezes a não normalidade dos dados, por apresentar uma maior variabilidade dos dados, essa variabilidade, muitas vezes, pode estar associada com própria natureza da variável. Salienta-se, que os dados foram submetidos à análise de normalidade pelo Teste de Shapiro-Wilk ($p > 0,05$), e não apresentaram normalidade. Porém, esse fato não impede que os dados sejam tratados pela Análise Estatística Multivariada.

Os dendrogramas verticais foram obtidos pela análise de agrupamentos hierárquico (AAH) sendo apresentados nas Figuras 2 e 3. Os primeiros cortes foram feitos nos dendrogramas nas distâncias 56,35 e 2026 respectivamente. Os primeiros cortes foram realizados nessas distâncias respectivamente porque são a metade da maior distância de ligação obtida na formação da matriz de aglomeração, sendo que essas distâncias são de 112,7145 e 4172,485 respectivamente (ANEXO A). Já o segundo corte a critério do pesquisador, para formar grupos gerenciáveis sem individualizar as variáveis originais (HAIR et al., 2005; VICINI, 2005). Em relação ao primeiro corte, no dendrograma formado com distância euclidiana, as variáveis se agruparam de acordo com suas semelhanças em cinco grupos (Figura 2), sendo três grupos formados no eixo do sensor sequoia embarcado no ARP e outros dois grupos formados no eixo do sensor proximal optrx. Já no dendrograma realizado com a distância euclidiana ao quadrado, formaram-se quatro grupos (Figura 3), sendo dois grupos pertencentes ao eixo do sensor proximal optrx

Tabela 1. Estatística descritiva das variáveis utilizadas na pesquisa.

MEDIDAS/VARIÁVEL	M	EP	MD	MDO	DP	VAR	Curtose	Assim	MIN	MAX	CV(%)
D_N_ha	126,87	3,77	120,00	240,00	80,16	6426,43	-1,40	0,08	20,00	240,00	63,18
NDVI_D_V5	0,47	0,00	0,45	AMODAL	0,07	0,01	1,74	1,41	0,35	0,74	15,58
NDRE_D_V5	0,17	0,00	0,17	AMODAL	0,01	0,00	0,48	0,63	0,14	0,22	7,48
NDVI_OP_V5	0,59	0,01	0,62	0,69	0,12	0,01	0,77	-0,90	0,21	0,83	19,68
NDRE_OP_V5	0,25	0,00	0,26	0,29	0,04	0,00	0,66	-0,73	0,11	0,35	16,76
GNDVI_V5	0,39	0,00	0,39	AMODAL	0,04	0,00	1,47	1,02	0,31	0,54	9,64
EVI2_V5	0,32	0,00	0,30	AMODAL	0,07	0,01	2,91	1,81	0,23	0,61	22,89
NT_V7	2,02	0,02	2,04	1,50	0,46	0,21	-0,59	-0,04	1,18	3,26	22,60
NDVI_D_V7	0,52	0,01	0,54	AMODAL	0,13	0,02	0,13	-0,78	0,10	0,72	25,00
NDRE_D_V7	0,12	0,01	0,19	AMODAL	0,15	0,02	-0,57	-0,93	-0,25	0,32	125,14
NDVI_OP_V7	0,71	0,01	0,76	0,84	0,14	0,02	2,01	-1,44	0,19	0,87	19,12
NDRE_OP_V7	0,32	0,00	0,34	0,26	0,06	0,00	0,81	-0,98	0,11	0,42	18,43
GNDVI_V7	0,31	0,00	0,33	AMODAL	0,10	0,01	-0,23	-0,60	0,01	0,48	31,90
EVI2_V7	0,95	0,01	0,97	AMODAL	0,27	0,07	-0,39	-0,52	0,15	1,43	28,70
NDVI_D_V9	0,67	0,00	0,68	AMODAL	0,06	0,00	0,15	-0,55	0,46	0,79	8,39
NDRE_D_V9	0,28	0,00	0,29	AMODAL	0,04	0,00	-0,07	-0,29	0,15	0,39	15,03
NDVI_OP_V9	0,73	0,01	0,77	0,77	0,12	0,02	2,56	-1,63	0,24	0,87	17,10
NDRE_OP_V9	0,31	0,00	0,32	0,33	0,06	0,00	0,78	-0,97	0,11	0,42	18,51
GNDVI_V9	0,57	0,00	0,57	AMODAL	0,05	0,00	-0,13	-0,50	0,42	0,67	8,30
EVI2_V9	0,46	0,00	0,46	AMODAL	0,05	0,00	-0,15	-0,29	0,32	0,59	9,97
NT_V11	1,42	0,02	1,48	1,20	0,40	0,16	-0,37	0,18	0,62	2,60	28,12
NDVI_D_V11	0,63	0,00	0,65	AMODAL	0,09	0,01	3,95	-1,71	0,19	0,75	13,66
NDRE_D_V11	0,20	0,00	0,21	AMODAL	0,04	0,00	-0,53	-0,48	0,10	0,29	18,41
NDVI_OP_V11	0,74	0,01	0,78	0,81	0,11	0,01	3,20	-1,76	0,17	0,88	15,33
NDRE_OP_V11	0,30	0,00	0,31	0,32	0,05	0,00	1,40	-0,89	0,04	0,42	17,09
GNDVI_V11	0,45	0,00	0,46	AMODAL	0,06	0,00	0,68	-0,89	0,21	0,56	13,92
EVI2_V11	1,24	0,01	1,29	AMODAL	0,20	0,04	2,27	-1,35	0,33	1,57	15,97
NT_V12	498,81	32,17	1,38	1360,00	683,10	466631,65	-1,31	0,73	0,50	1820,00	136,95
NDVI_D_V12	0,83	0,00	0,84	AMODAL	0,03	0,00	2,37	-1,46	0,71	0,87	3,20
NDRE_D_V12	0,33	0,00	0,34	AMODAL	0,03	0,00	-0,58	-0,42	0,24	0,41	10,58
NDVI_OP_V12	0,67	0,01	0,70	0,75	0,11	0,01	3,31	-1,74	0,20	0,81	16,04
NDRE_OP_V12	0,27	0,00	0,28	0,32	0,05	0,00	1,68	-0,92	0,06	0,40	18,01
GNDVI_V12	0,32	0,00	0,32	AMODAL	0,05	0,00	-0,26	-0,45	0,17	0,43	15,59
EVI2_V12	3,37	0,00	3,38	AMODAL	0,03	0,00	2,54	-1,50	3,21	3,41	0,96
PLA	79213	175	80000	80000	3711	13767923	3	-1	70000	90000	5
MS_G	5912,51	100,93	5768,00	7828,00	2143,49	4594556,70	-0,40	0,30	947,60	12183,50	36,25
N_ABS	155,79	2,66	151,99	206,27	56,48	3190,10	-0,40	0,30	24,97	321,04	36,25
N_EXPG	82,78	1,41	80,75	109,59	30,01	900,53	-0,40	0,30	13,27	170,57	36,25

Legenda: M=média; EP=Erro Padrão; MD=Mediana; MDO=Moda; DP=Desvio Padrão; VAR=Variância; Assim=Assimetria; MIN=Valor Mínimo; MAX=Valor Máximo e CV%=Coeficiente de Variação.

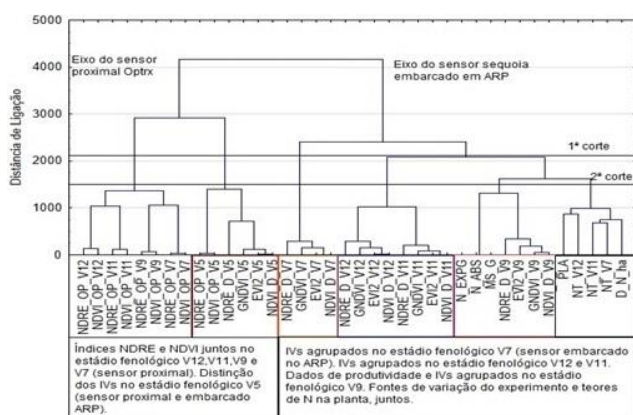


Figura 4. Dendrograma vertical obtido para agrupamentos das variáveis utilizadas no presente estudo pelo método de similaridade distância euclidiana ao quadrado. Fonte: Autor, 2019.

Já, no eixo do sensor sequoia embarcado em ARP (Figura 3), existe a distinção dos índices de vegetação NDVI, EVI2, GNDVI e NDRE nos estádios fenológicos V7, sendo que as menores distâncias encontradas na formação deste grupo, isto é, maior similaridade entre as variáveis estão nos índices NDVI e EVI2 (distância de 3,14). Nesse eixo, encontra-se a formação de um grupo com os IVs NDVI, EVI2, GNDVI e NDRE nos estádios fenológicos V11 e V12, sendo que os IVs NDVI e EVI2 que tem maior similaridade (distância de 3,75) e (distância de 10,65) em V11 e V12 respectivamente. Existe, a formação de um grupo, contendo os IVs NDVI, GNDVI, EVI2 e NDRE no estágio fenológico V9 (sensor sequoia embarcado em ARP) com os dados de produtividade. Percebeu-se que a maior similaridade (distância 0,00) entre os dados de produtividade (MS_G, N_ABS e N_EXP_G), seguidos dos IVs NDVI e GNDVI (distância 56,76) no estágio fenológico V9. No eixo sensor sequoia embarcado em ARP (Figura 3), encontra-se as fontes de variação do experimento e os teores de nitrogênio na planta. Após, a geração dos dendrogramas verticais pelos dois métodos de similaridade (distância euclidiana e distância euclidiana ao quadrado), observou-se que o método de similaridade por distância euclidiana ao quadrado, apresentou uma solução melhor, pois gerou uma menor quantidade de grupos (seis) vide (Figura 3) em relação ao método de similaridade distância euclidiana que gerou 10 grupos, separou melhor as plataformas (proximal e embarcado em ARP) e os dados de produtividade ficou muito próximo do estágio fenológico V9. Olhando a tabela (ANEXO C) de distância, variável a variável, percebe-se, que a maior similaridade, entre todos os índices vegetativos da pesquisa e os dados de produtividade foi observado com o IV NDRE no estágio V12 (distância de 18,7).

Na tabela 2 são mostradas as 38 variáveis originais que fizeram parte do experimento de campo, juntamente com

os autovalores, variância acumulada e as componentes principais, geradas na Análise de Componentes Principais, e a matriz de correlação das variáveis originais padronizadas em relação as CPs. Os valores que estão em destaque (cor vermelha) apresentam a correlação de cada variável para a formação da componente principal. Percebeu-se, conforme a tabela, que fica difícil de identificar quais as variáveis contribuíram significativamente para a formação de cada componente, pois existem um grupo grande de variáveis formando cada fator. Segundo Vicini (2005), quando essa identificação fica difícil, por apresentar um grupo grande de variáveis na formação de cada fator, trabalha-se com a realização de rotações dos eixos, possibilitando assim, uma melhor visualização das variáveis que contribuem para a formação dos fatores. A rotação utilizada no presente trabalho de pesquisa foi a rotação *varimax normalized*, por ser a mais utilizada.

Observou-se (Tabela 3), após a rotação *varimax normalized*, uma melhor visualização das variáveis que realmente contribuíram para a formação dos fatores, isto é, a proporção de variação das variáveis que melhor representam cada fator. Verificou-se, que os valores iguais ou maiores que 0,70 ficaram com uma coloração diferente (cor vermelha), por serem essas as variáveis que contribuíram significativamente para a formação de cada fator.

As 38 variáveis originais foram agrupados em 11 fatores, e o ajuste do modelo foi capaz de explicar aproximadamente 83,80% das variâncias das variáveis. Conforme Pereira (2001) essa é uma medida de ajuste do modelo a análise de dados. O primeiro componente principal explicou 28,96% da variabilidade total de todas as variáveis originais do experimento. O primeiro componente principal ou ainda chamado de fator, foi explicado pelos índices de vegetação NDVI, EVI2 e GNDVI no estágio vegetativo da cultura do milho em V9, com o sensor sequoia embarcado em ARP, com uma contribuição de aproximadamente 0,89, 0,86 e 0,81 de carga fatorial respectivamente na ordem decrescente de valores. Esses valores corroboram, com os trabalhos de Ma et al. (2001), Antuniassi et al. (2007), de acordo com eles, existem correlações positivas entre a reflectância do dossel das plantas, expressa em valores de IV NDVI com o estágio fenológico V9. De acordo com Groff et al. (2013), foi observado em sua pesquisa, uma correlação positiva entre o IV GNDVI e o estágio fenológico V9. Essa contribuição dos IVs NDVI, EVI2 e GNDVI, para a formação do fator 1, que é o principal componente, pois como visto anteriormente, explicou uma variabilidade total de todas as variáveis originais do experimento de 28,96%, corrobora com os

Tabela 2. Análise de componentes principais das variáveis que fizeram parte da pesquisa.

Componentes da Variância	Componentes Principais										
	1	2	3	4	5	6	7	8	9	10	11
Autovalores	11,00	5,12	3,92	2,46	1,85	1,66	1,36	1,22	1,14	1,11	1,01
Autovalores acumulados	11,00	16,12	20,04	22,50	24,35	26,02	27,37	28,59	29,73	30,84	31,84
Proporção (%)	28,96	13,47	10,31	6,48	4,87	4,37	3,58	3,21	3,00	2,91	2,65
Proporção acumulada (%)	28,96	42,43	52,74	59,22	64,09	68,46	72,04	75,25	78,24	81,15	83,80
Variáveis	Correlação das variáveis com as componentes principais sem a rotação										
DN	-0,27	0,09	0,08	0,08	0,15	0,26	0,09	-0,29	-0,24	0,50	0,11
NDVI_V5	0,19	0,75	0,39	0,36	0,13	-0,12	0,12	0,04	-0,12	0,05	-0,05
NDRE_V5	-0,10	0,35	0,33	-0,01	0,29	-0,42	0,05	0,16	-0,25	0,05	-0,28
NDVI_OP_V5	-0,05	0,65	-0,16	0,05	0,16	-0,22	-0,57	-0,19	0,27	-0,03	0,00
NDRE_OP_V5	-0,13	0,61	-0,18	0,02	0,15	-0,24	-0,59	-0,19	0,27	-0,03	0,00
GNDVI_V5	0,09	0,76	0,44	0,26	0,03	-0,11	0,09	0,03	-0,13	0,10	-0,04
EVI2_V5	0,25	0,72	0,39	0,35	0,16	-0,09	0,13	0,04	-0,11	0,02	-0,04
N%_V7	-0,38	0,16	0,23	0,00	0,22	0,17	0,05	-0,32	-0,01	0,04	0,14
NDVI_V7	-0,61	-0,60	-0,03	0,17	0,34	-0,23	-0,01	-0,01	-0,01	0,02	-0,10
NDRE_V7	-0,35	-0,55	-0,09	0,44	0,46	-0,13	-0,01	0,09	0,03	0,01	0,00
NDVI_OP_V7	-0,28	0,34	-0,49	-0,33	0,18	0,04	-0,22	0,33	-0,45	-0,05	0,12
NDRE_OP_V7	-0,36	0,30	-0,47	-0,34	0,20	0,07	-0,23	0,33	-0,43	-0,03	0,15
GNDVI_V7	-0,57	-0,51	0,07	0,28	0,32	-0,25	0,00	0,06	-0,03	0,07	-0,03
EVI2_V7	-0,61	-0,59	-0,01	0,16	0,34	-0,26	-0,01	-0,02	-0,02	0,01	-0,10
NDVI_V9	-0,72	0,12	0,30	-0,37	-0,16	-0,24	0,17	-0,09	-0,04	-0,20	0,04
NDRE_V9	-0,77	-0,07	0,00	-0,29	0,07	-0,13	0,08	-0,11	0,03	-0,25	0,10
NDVI_OP_V9	-0,40	0,30	-0,35	-0,45	0,11	-0,13	0,22	0,10	0,32	0,31	-0,15
NDRE_OP_V9	-0,46	0,24	-0,32	-0,45	0,13	-0,12	0,21	0,09	0,33	0,33	-0,13
GNDVI_V9	-0,70	0,13	0,26	-0,42	-0,22	-0,19	0,11	-0,08	-0,05	-0,14	0,00
EVI2_V9	-0,66	0,16	0,32	-0,28	0,07	-0,28	0,24	-0,11	-0,03	-0,28	0,06
N%_V11	-0,29	0,14	0,21	-0,11	0,40	0,17	0,08	-0,21	0,00	-0,19	0,29
NDVI_V11	-0,77	0,09	-0,25	0,19	-0,33	-0,05	-0,03	-0,22	-0,18	0,14	-0,14
NDRE_V11	-0,87	0,00	-0,11	0,05	-0,05	-0,01	-0,05	-0,20	-0,14	0,09	-0,04
NDVI_OP_V11	-0,29	0,05	-0,68	0,25	0,09	0,20	0,12	-0,13	-0,01	-0,24	-0,14
NDRE_OP_V11	-0,40	0,00	-0,61	0,21	0,10	0,20	0,04	-0,16	-0,04	-0,25	-0,08
GNDVI_V11	-0,83	0,14	-0,15	0,07	-0,30	0,03	-0,06	-0,20	-0,14	0,19	-0,06
EVI2_V11	-0,80	0,09	-0,22	0,17	-0,33	-0,05	-0,03	-0,21	-0,16	0,12	-0,13
N%_V12	0,21	0,39	0,02	0,12	0,08	0,15	0,11	-0,25	0,01	-0,34	-0,13
NDVI_V12	-0,74	0,20	0,00	0,38	-0,26	-0,02	0,01	0,26	0,10	-0,03	0,14
NDRE_V12	-0,79	0,15	0,14	0,27	0,01	0,12	-0,02	0,14	0,12	-0,03	0,24
NDVI_OP_V12	-0,09	0,50	-0,56	0,12	0,18	0,13	0,29	0,10	0,12	-0,05	-0,04
NDRE_OP_V12	-0,12	0,53	-0,41	0,14	0,23	0,20	0,37	0,07	0,13	-0,02	0,00
GNDVI_V12	-0,77	0,00	0,08	0,25	-0,27	-0,07	0,00	0,29	0,17	-0,08	0,14
EVI2_V12	-0,75	0,16	0,01	0,37	-0,29	-0,04	0,01	0,29	0,13	-0,05	0,14
PLA	-0,20	0,01	0,20	-0,04	-0,10	0,22	-0,12	0,18	-0,04	-0,24	-0,69
MS_G	-0,69	-0,01	0,47	-0,12	0,15	0,43	-0,14	0,08	0,09	0,05	-0,08
N_ABS_PLA	-0,69	-0,01	0,47	-0,12	0,15	0,43	-0,14	0,08	0,09	0,05	-0,08
N_EXP_G	-0,69	-0,01	0,47	-0,12	0,15	0,43	-0,14	0,08	0,09	0,05	-0,08

Tabela 3. Composição dos Fatores a partir da rotação Varimax.

Variáveis	Componentes Principais										
	1	2	3	4	5	6	7	8	9	10	11
DN	0,04	0,08	0,03	0,03	0,06	0,15	-0,01	0,97	0,03	0,02	0,00
NDVI_V5	-0,02	0,94	-0,05	0,05	-0,19	-0,01	0,15	0,03	-0,04	-0,07	0,01
NDRE_V5	0,15	0,37	0,06	-0,01	0,07	0,07	0,08	-0,03	0,05	-0,07	0,01
NDVI_OP_V5	0,00	0,22	0,08	0,04	-0,12	-0,03	0,94	0,00	0,11	0,04	-0,01
NDRE_OP_V5	0,04	0,14	0,09	0,05	-0,10	0,00	0,95	-0,01	0,12	0,05	-0,01
GNDVI_V5	0,07	0,88	-0,03	0,08	-0,24	0,06	0,15	0,06	-0,04	-0,10	-0,01
EVI2_V5	-0,04	0,93	-0,07	0,01	-0,19	-0,03	0,12	0,01	-0,05	-0,08	0,01
N%_V7	0,14	0,11	0,05	0,07	0,07	0,23	0,04	0,09	0,01	0,02	0,01
NDVI_V7	0,14	-0,26	0,03	0,11	0,89	0,15	-0,08	0,02	-0,01	0,06	0,02
NDRE_V7	-0,14	-0,10	-0,06	0,13	0,84	0,07	-0,08	0,00	-0,03	0,13	-0,03
NDVI_OP_V7	0,07	-0,03	0,15	0,03	-0,05	-0,01	0,12	0,00	0,94	0,12	0,02
NDRE_OP_V7	0,07	-0,07	0,17	0,07	-0,01	0,06	0,11	0,03	0,93	0,11	-0,01
GNDVI_V7	0,13	-0,10	0,00	0,18	0,87	0,13	-0,08	0,07	-0,03	0,03	0,02
EVI2_V7	0,16	-0,26	0,03	0,11	0,89	0,14	-0,07	0,02	-0,01	0,05	0,02
NDVI_V9	0,89	0,00	0,13	0,19	0,06	0,26	0,01	0,02	0,04	-0,04	0,03
NDRE_V9	0,60	-0,23	0,16	0,21	0,23	0,22	0,05	0,03	0,13	0,09	0,05
NDVI_OP_V9	0,16	-0,04	0,92	0,07	-0,02	0,04	0,10	0,01	0,18	0,06	0,01
NDRE_OP_V9	0,17	-0,09	0,91	0,08	0,03	0,10	0,08	0,03	0,16	0,07	-0,03
GNDVI_V9	0,81	-0,07	0,15	0,19	0,00	0,27	0,02	0,04	0,08	-0,06	0,05
EVI2_V9	0,86	0,13	0,11	0,13	0,17	0,22	0,02	0,00	0,04	-0,01	0,02
N%_V11	0,13	0,06	0,04	0,02	0,07	0,22	0,03	0,05	0,05	0,00	-0,03
NDVI_V11	0,16	-0,05	0,09	0,28	0,14	0,09	0,05	0,04	0,08	0,16	0,03
NDRE_V11	0,26	-0,09	0,13	0,23	0,29	0,27	0,06	0,12	0,14	0,13	0,03
NDVI_OP_V11	-0,07	-0,12	0,09	0,10	0,09	-0,07	0,04	0,00	0,12	0,89	-0,01
NDRE_OP_V11	0,01	-0,15	0,06	0,12	0,13	0,01	0,06	0,03	0,14	0,89	-0,02
GNDVI_V11	0,22	-0,05	0,14	0,27	0,10	0,24	0,08	0,09	0,12	0,11	0,01
EVI2_V11	0,19	-0,06	0,09	0,30	0,14	0,12	0,05	0,04	0,08	0,15	0,03
N%_V12	-0,06	0,22	-0,01	-0,05	-0,16	-0,06	0,07	-0,03	-0,01	0,03	0,04
NDVI_V12	0,13	0,10	0,07	0,86	0,13	0,17	0,05	0,02	0,07	0,08	0,03
NDRE_V12	0,21	0,14	0,05	0,56	0,23	0,41	0,07	0,05	0,07	0,10	-0,04
NDVI_OP_V12	-0,04	0,08	0,15	0,07	-0,08	-0,12	0,15	0,02	0,19	0,20	0,01
NDRE_OP_V12	-0,01	0,17	0,13	0,06	-0,09	-0,01	0,09	0,05	0,11	0,15	-0,03
GNDVI_V12	0,26	-0,05	0,05	0,80	0,21	0,24	0,01	0,00	0,01	0,07	0,05
EVI2_V12	0,15	0,06	0,06	0,89	0,15	0,17	0,04	0,02	0,05	0,08	0,05
PLA	0,07	0,01	-0,02	0,07	0,01	0,18	-0,02	0,00	0,01	-0,02	0,98
MS_G	0,20	0,00	0,05	0,17	0,13	0,93	-0,02	0,06	0,02	-0,02	0,08
N_ABS_PLA	0,20	0,00	0,05	0,17	0,13	0,93	-0,02	0,06	0,02	-0,02	0,08
N_EXP_G	0,20	0,00	0,05	0,17	0,13	0,93	-0,02	0,06	0,02	-0,02	0,08

resultados encontrados na AAH pelo método de similaridade da distância euclidiana ao quadrado mostrando que o estágio vegetativo fenológico V9

se mostra muito próximo dos dados de produtividade (MS_G, N_ABS_PLA e N_EXP_G).

Já o segundo componente principal, apresenta uma proporção acumulada de aproximadamente de 42,43% entre o primeiro e o segundo fator. Esse componente principal é explicado pelos índices de vegetação NDVI, GNDVI e EVI2 no estágio fenológico V5 com o sensor sequoia embarcado em ARP com uma contribuição de carga fatorial de aproximadamente de 0,94, 0,88 e 0,93 respectivamente, mostrando que a composição desse fator, pôr as variáveis (NDVI, GNDVI e EVI2) no estágio fenológico V5, mostrando a resposta espectral de solo e palha. O sexto componente principal apresenta uma proporção acumulada de aproximadamente 68,46% e é explicado através dos dados de produtividade, como matéria seca de grãos, nitrogênio absorvido pelas plantas e nitrogênio exportado para os grãos, com uma contribuição de carga fatorial de 0,92 de cada uma dessas três variáveis

Nas Figuras 4 e 5 são mostrados os círculos de correlações unitários das variáveis. Analisando as Figuras (4 e 5) observa-se que as variáveis que estão mais próximas ao círculo unitário, possuem uma maior contribuição para o CP em relação aquelas variáveis que estão mais afastadas. Também, deve ser observado o ângulo formado entre as variáveis, demonstrado, maior ou menor semelhança entre as variáveis (CATEN et al., 2011). Sendo assim, na Figura 4, observou-se, que no eixo da CP1 e CP2 os IVs NDVI, GNDVI e EVI2 no estágio fenológico V9 e os IVs NDVI, GNDVI e EVI2 no estágio fenológico V5 respectivamente (obtidos com o sensor embarco em ARP), contribuíram fortemente na análise e possuem correlações significativas, pois há um pequeno ângulo formado entre essas variáveis.

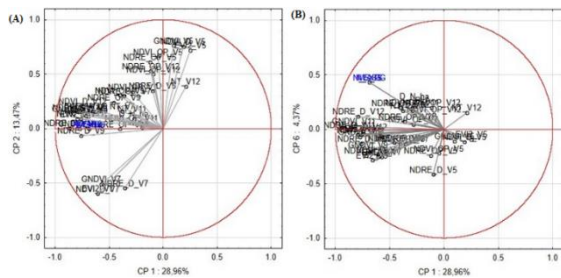


Figura 5. Gráficos das distribuições da nuvem de variáveis, no círculo de correlações com CP1xCP2 (4a) e CP1xCP6 (4b). Fonte: Autor, 2019.

Na Figura (4.B), da mesma forma, observou-se, que no eixo da CP1, os IVs NDVI, GNDVI e EVI2

(obtidos com o sensor embarco em ARP), no estágio fenológico V9 e no eixo da CP2 os dados de produtividade (MSG, N_ABS_PLA e N_EXP_G), contribuíram fortemente na análise, pois as variáveis estão próximas ao círculo unitário e possuem correlações significativas, porque há um pequeno ângulo formado entre essas variáveis.

Observa-se na Figura 5, que o maior coeficiente de determinação ($r^2=0,4004$) está relacionado com dados da produtividade (MSG) e com o índice de vegetação NDRE obtido com o sensor sequoia embarcado em ARP, no estágio fenológico V12, corroborando com a pesquisa de Carvalho (2019) e sugerindo que esta é a melhor variável para explicar a produtividade na cultura do milho. Percebe-se também, que os índices de vegetação GNDVI, NDVI, EVI2 e NDRE obtidos com o sensor sequoia embarcado em ARP no estágio fenológico V9, em relação ao dado de produtividade (MSG) tiveram coeficientes de correlação muito próximos ($r^2=0,2878$, $r^2=0,2851$, $r^2=0,2409$ e $0,2293$ respectivamente), porém esses coeficientes são considerados baixos mas muito próximos do dado de colheita (MSG), esse comportamento pode ser explicado pelo fato de que no estágio vegetativo V9, o milho teve um elevado índice de área foliar e vigoroso.

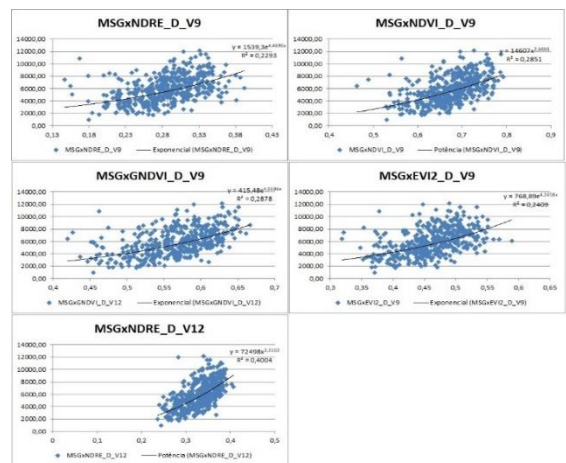


Figura 6. Relação entre produtividade de milho e os índices de vegetação (NDRE, NDVI, GNDVI e EVI2) no estágio fenológico V9 e o índice de vegetação NDRE em V12. Fonte: Autor, 2019.

CONCLUSÕES

O dendrograma vertical formado pelo método de similaridade da distância euclidiana ao

quadrado, mostrou melhor solução em relação ao dendrograma formado pelo método de similaridade da distância euclidiana, pois conseguiu separar melhor as plataformas do sensor multiespectral Sequóia embarcado em ARP e o sensor proximal Optrix, além de gerar um menor número de agrupamentos em ambos os cortes realizados.

Os sensores utilizados apresentaram resultados diferentes, e a princípio, não comparáveis.

Este dendrograma mostrou similaridade da variabilidade dos IVs obtidos no estágio fenológico V9 com a variabilidade dos dados de produtividade, pois houve a seleção de quatro IVs diferentes, ressaltando a influência deste estágio.

Os IVs obtidos com o sensor sequoia embarcado em ARP ficaram mais próximos dos dados de produtividade em relação aos obtidos pelo sensor proximal.

Existe influência de solo e palha em relação as plantas, nos dados obtidos no estágio fenológico V5, pois agrupou IVs distintos obtidos por ambas as plataformas.

Não é possível identificar claramente quais as variáveis que contribuem significativamente para a formação de um componente principal, somente pela matriz de correlação das variáveis originais padronizadas com os mesmos, sem que haja a rotação varimax normalizada dos eixos, proporcionada pela análise fatorial.

O índice NDRE no estágio fenológico V12 se mostrou mais próximo dos dados de produtividade.

REFERÊNCIAS

ANDRUS-GUIMARÃES, I. Análise de componentes principais aplicada à estimação de modelos de parâmetros nos modelos de regressão logística quadrática. **Trends in Applied and Computational Mathematics**, v. 14, n. 1, p. 57-68, 2013. DOI: 10.5540/tema.2013.014.01.0057

BARNES, E. M. T. R. et al. **Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data**. 2000. Disponível em: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.463.8007&rep=rep1&type=pdf>. Acesso em: 23 maio 2019.

CARVALHO, L. G. et al. Modelo de regressão para previsão de produtividade de cafeeiros no estado de Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 8, n. 2/3, p. 204-211, 2004.

CARVALHO, L. F. D. **Índices de vegetação obtidos por sensor proximal e embarcado em aeronave**

remotamente pilotada e sua relação com a produtividade do milho. 91 p. Tese (Doutorado em Ciências do Solo) – Universidade Federal de Santa Maria, Santa Maria, 2019.

CATEN, A. T. et al. Estatística multivariada aplicada à diminuição do número de preditores no mapeamento digital do solo. Pesquisa **Agropecuária Brasileira**, Brasília, v.46, n.5, p.554-562, 2011.

CONAB. Observatório Agrícola. Cultivos de verão, safra 2019/2020. **Acompanhamento brasileiro da safra de grãos**. v.7-safra 2019/20- N.3- Terceiro levantamento, 2019.

CORRÊA, A. M. C. J.; FIGUEIREDO, N. M. S. Modernização da agricultura brasileira no início dos anos 2000: Uma aplicação da análise fatorial. **Revista GEPEC**, vol. 10, n. 02, Jul/Dez, 2006. p. 82-99.

DILLON, W. R.; GOLDSTEIN, M. **Multivariate analysis methods and application**. New York: John Wiley. 1984. 587p.

FERNANDES, P. **Estimativa da produtividade de milho (zea mays l.) através de imagens multiespectrais obtidas por veículo aéreo não tripulado**. 2016. 78 p. (Dissertação de Mestrado).

FORMAGGIO, A. R.; SANCHES, I D. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de Textos, 2017, 284 p.

FRANCO, L. B. et al. Componentes principais e regressão múltipla na estimativa da produtividade de café com base em nutrientes foliares. **Revista Univap**, v. 22, n. 40, Edição Especial, p.290-xxx, 2016. DOI: 10.18066/revistaunivap.v22i40.749

FREDDI, O. da S. et al. Análise multivariada na compactação de um Latossolo Vermelho cultivado com milho. **Revista Brasileira de Ciência do Solo**, v.32, p.953-961, 2008.

GITELSON, A. A. et al. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v.58, n.3, p.289-298, 1996.

GUARIENTI, E. M. et al. Avaliação do efeito de variáveis meteorológicas na qualidade industrial e no rendimento de grãos de trigo pelo emprego de análise de componentes principais. **Cenc. Tecnol. Aliment.**, Campinas 23 (3): 500-510, set, dez. 2003.

GUEDES, H. A. S. et al. Aplicação da análise estatística multivariada no estudo da qualidade da água do Rio Pomba, MG. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.16, n.5, p. 558-563, 2012.

HAAN, C. T. **Statistical methods in hydrology**. 5 ed., Ames: The Iowa State University Press, 1977, 378 p.

HAIR JR., J. F. et al. **Análise multivariada de dados**. 5 ed., Porto Alegre: Editora Bookman, 2005, 593p.

- HONGYU, K. **Comparação do GGE-biplot ponderado e AMMI-ponderado com outros modelos de interação genótipo × ambiente**. 2015. 155p. (Tese de doutorado).
- JIANG, Z. et al. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v.112, p. 3833-3845, 2008.
- LIAO, S. W. et al. Identification of pollution of Tapeng Lagoon from neighbouring rivers using multivariate statistical method. **Journal of Environmental Management**, v.88, p.286-292, 2008
- MARQUES, J. M.; MARQUES, M. A. M. As componentes principais no descarte de variáveis em um modelo de regressão múltipla. **Revista da FAE**, v. 8, n. 1, p. 93-11, 2005.
- MONTGOMERY, D. C.; PECK, E. A. **Introduction to linear regression analysis**. 2 ed., New York: Jhon Wiley & Sons, Inc., 1992, 527 p.
- MONTIBELLER, B. **Análise espectro-temporal das culturas de milho, soja e cana-de-açúcar com dados do sensor oli/landsat-8**. 2018 (Dissertação de mestrado em Sensoriamento Remoto).
- PESINI, F. **Avaliação da população de plantas de Soja (Glycine mx L.) na variabilidade dos mapas de colheita**. 2019. (Dissertação. de mestrado).
- RENCHER, A. C. **Methods of multivariate analysis**. 2.ed. New York: Wiley Interscience, 2002. 738p.
- SCHNEIDER, P. R. et al. **Análise de regressão aplicada à Engenharia Florestal**. 2 ed., Santa Maria: Editora FACOS, 2009, 294 p.
- MOLIN. J. P. et al. **Agricultura de Precisão**. 1 ed., São Paulo: Oficina de Textos, 2015, 238 p.
- OLIVEIRA, A. C. et al. Análise de componentes principais para definição de zonas de manejo em agricultura de precisão. **XXIV Congresso Nacional de Milho e Sorgo - 01 a 05 de setembro de 2002**, Florianópolis, SC.
- ROUSE J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: **Proceedings of the 3rd. ERTS-1 Symposium; 1973**; Washington, DC. Washington, DC: NASA SP-351; 1973. p.309-17.
- PEREIRA, J. C. R. **Análise de dados qualitativos: estratégias metodológicas para as ciências da saúde, humanas e sociais**. São Paulo: Edusp, 2001.
- PIONEER. DUPONT PIONEER. Disponível em: <https://www.pioneersementes.com.br/milho>. Acesso em 20 de março de 2018.
- RISSINI, A. L. L. **NDVI, crescimento e produtividade de cultivares de trigo submetidas a doses de nitrogênio**. 2011. 53 p. (Dissertação de mestrado).
- SILVA, C. G. M. **Absorção e exportação de macronutrientes em milho transgênico sob dois níveis de investimento em adubação**. 2016. 52 p. (Dissertação de mestrado).
- TEDESCO, M. J. et al. **Análise de solo, plantas e outros materiais**. 2 ed., Porto Alegre: UFRGS – Departamento de Solos, 1995. 174p. (Boletim Técnico, 5).
- VICINI, L. **Análise Multivariada da teoria à prática**. Santa Maria: CCNE-UFSM, 2005, 215 p. Disponível em: <http://w3.ufsm.br/adriano/livro/Caderno%20dedatico%20multivariada%20-%20LIVRO%20FINAL%201.pdf>. Acesso em: 29 de ago. de 2019.
- X. ZHOU et al. Predicting grain yield in Rice using multi-temporal vegetation índices from UAV based multispectral and digital imagery. **Journal of Photogrammetry and Remote Sensing**, v. 130, p. 246-255, 2017.

3 CONCLUSÃO

A técnica estatística multivariada por meio da aplicação da (AAH) demonstrou que o dendograma vertical formado pelo método de similaridade da distância euclidiana ao quadrado, revelou melhor solução em relação ao dendograma formado pelo método de similaridade da distância euclidiana, pois conseguiu separar melhor as plataformas do sensor multiespectral Sequóia embarcado em ARP e o sensor proximal Optrix, além de gerar um menor número de agrupamentos em ambos os cortes realizados. Este dendograma, mostrou similaridade da variabilidade dos IVs obtidos no estádio fenológico V9 com a variabilidade dos dados de produtividade, pois houve a seleção de quatro IVs diferentes, ressaltando a influência deste estádio.

Os sensores utilizados apresentaram resultados diferentes, e a princípio não comparáveis. Os IVs obtidos com o sensor sequoia embarcado em ARP ficaram mais próximos dos dados de produtividade em relação aos obtidos pelo sensor proximal. Existe a influência de solo e palha em relação as plantas, nos dados obtidos no estádio fenológico V5, pois agrupou IVs distintos obtidos por ambas as plataformas.

Não é possível identificar claramente quais as variáveis que contribuem significativamente para a formação de um componente principal, somente pela matriz de correlação das variáveis originais padronizadas com os mesmos, sem que haja a rotação varimax normalizada dos eixos, proporcionada pela análise fatorial. O índice NDRE no estádio fenológico V12 se mostrou mais próximo dos dados de produtividade.

A técnica estatística multivariada por meio da aplicação da análise fatorial/análise de componentes principais promoveu a redução no número de variáveis sendo que o melhor comportamento das variáveis ocorreu com a inclusão de 11 das 38 variáveis analisadas.

REFERÊNCIAS

ADAMCHUK, V.I., FERGUSON, R.B., HERGERT, G.W. **Soil heterogeneity and crop growth.** , 2010.

AGROLINK. **Georreferenciamento – Agricultura de Precisão.** Disponível em: <https://www.agrolink.com.br/georreferenciamento/AgriculturaPrecisao.aspx>. Acesso em 23 de Outubro de 2018.

AG LEADER TECHNOLOGY. 2011. **Precision Point Blog.** Disponível em: <http://www.agleader.com/blog/optrx-crop-sensors-a-tech-support-perspective/>. Acesso em 6 de jan. 2019.

ALBUQUERQUE, C. K.; CRUZ, C. B. M.; BARROS, R. S. Comparação do Comportamento do NDVI e do EVI2- Um Novo Índice de Vegetação. In: III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação, 3., 2010, Recife. **Anais...** Recife: Decart, 2010. p. 001 - 004.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL – ANAC. **Drones.** Disponível em: . Acesso em: 20 de Set. de 2017.

AMARAL, L. de P. et al. **Uso de Aeronave Remotamente Pilotada (arp) para obtenção de fotografias aéreas e geração de ortomosaico para a silvicultura.** Congresso Sul-Americano de Agricultura de Precisão e Máquinas Precisas (4: 2017: Não - Me -Toque, RS), trabalhos completos (recurso eletrônico) / IV Congresso Sul Americano de Agricultura de Precisão e Maquinas Precisas, 26 a 27 de Setembro de 2017.

ANDRADE, E. M. de; ARAÚJO, L. de F. P.; ROSA, M. de F.; DISNEY, W. ALVES, A. B. Seleção dos indicadores da qualidade das águas superficiais pelo emprego da análise multivariada. **Engenharia Agrícola**, v.27, p.683-690, 2007a.

AMADO, T. J. C. et al. Variabilidade espacial e temporal da produtividade de culturas sob sistema plantio direto. **Pesq. agropec. bras.**, Brasília, v.42, n.8, p.1101-1110, ago. 2007

ATZBERGER, C. **Advances in remote sensing of agriculture: context description, existing operational monitoring systems and major information needs. Remote Sensing**, v. 5, n. 2, p. 949-981, 2013. <http://dx.doi.org/10.3390/rs5020949>.

ASRAR, G et al. Estimating absorbed photosynthetic radiation and leaf area index from spectral reflectance in wheat. **Agronomy Journal**. v.76, n. 2, p. 300-306, 1984.

BARNES, E. M. T. R.; CLARKE, S. E.; RICHARDS, P. D.; COLAIZZI, J.; HABERLAND, M.; KOSTRZEWSKI et al. **Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data.** 2000. Disponível em: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.463.8007&rep=rep1&type=pdf>. Acesso em: 23 maio 2019.

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.

BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. de V.; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de Precisão Resultados de um Novo Olhar**. Brasília, DF: EMBRAPA, 2014, p. 13-600.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Portaria nº 852 - Art. 1º Criar a Comissão Brasileira de Agricultura de Precisão – CBAP. **Diário Oficial da República Federativa do Brasil**, Brasília, DF, 21 set. 2012. Seção 1, n. 184.

BRANDAO, Z. N. **Estimativa da produtividade e estado nutricional da cultura do algodão irrigado via técnicas de sensoriamento remoto**. 2009. 152 f. Tese (Doutorado em Recursos Naturais) -Universidade Federal de Campina Grande, Campina Grande, 2009.

BREDEMEIER, C. et al. Estimativa do potencial produtivo em trigo utilizando sensor óptico ativo para adubação nitrogenada em taxa variável. **Ciência Rural**, v.43, n.7, p.1147-1154, 2013.

CÂNDIDO, A. K. A. A.; SILVA, N. M.; PARANHOS FILHO, A. C. Imagens de Alta Resolução Espacial de Veículos Aéreos Não Tripulados (VANT) no Planejamento do Uso e Ocupação do Solo. **Anuário do Instituto de Geociências - UFRJ**, v. 38, n. 1, p. 147-156, 2015.

CARNEIRO, F. M. et al. Correlations among vegetation indices and peanut traits during different crop development stages. **Engenharia Agrícola**, Jaboticabal, v.39, special issue, p.33-40, sep. 2019.

CARVALHO, L. F. D. **Índices de vegetação obtidos por sensor proximal e embarcado em aeronave remotamente pilotada e sua relação com a produtividade do milho**. 2019, 91 p. Tese (Doutorado em Ciências do Solo) – Universidade Federal de Santa Maria, Santa Maria, 2019.

CHUVIECO, E. **Fundamentos de teledetección espacial**. 3. ed. Madrid: Rialp, 1996. 568p.

COMPANHIA NACIONAL DE ABASTECIMENTO – CONAB. **Acompanhamento brasileira da safra de grãos**. v.7-safra 2017/18- n.3 - Terceiro levantamento, Dezembro 2017.

CORRÊA, A. M. C. J.; FIGUEIREDO, N. M. S. **Modernização da agricultura brasileira no início dos anos 2000: Uma aplicação da análise fatorial**. Revista GEPEC, vol. 10, n. 02, Jul/Dez, 2006. p. 82-99.

CREPANI, E. **Princípios básicos de sensoriamento remoto**. São José dos Campos: CNPq/INPE, 45p., 1993.

CRUSIOL, L. G. T. et al. Sensoriamento remoto aplicado ao monitoramento do déficit hídrico na cultura da soja. In: Jornada Acadêmica da Embrapa Soja, XII, 2017, Londrina. **Anais...** Londrina: Embrapa Soja, 2017. p. 119-127.

CROSTA, A. P. **Processamento digital de imagens e sensoriamento remoto.** Campinas, 1993, 170p.

CURRAN, P.J.; DUNGAN, J.L.; MACLER, B.A.; PLUMMER, S.E. The effect of a red leaf pigment on the relationship between red edge and chlorophyll concentration. **Remote Sensing of Environment**, v. 35, n. 1, p.69-76,1991.

DALLMEYER, A. U.; SCHLOSSER, J. F. **Mecanización para la Agricultura de Precisión.** 1999. Cap.3, p. 75-104.

DJI. **Phantom 4 – Características e Funcionalidades.** Disponível em: <http://aeromodelobrasil.com/drones/dji-phantom-4/>. Acesso em: 09 de jul. de 2018.

DONI, M. V. **Análise de cluster: métodos hierárquicos e de particionamento.** Trabalho de Graduação. Faculdade de Computação e Informática da Universidade Presbiteriana Mackenzie. São Paulo 2004.

DOURADO NETO, D.; SPAROVEK, G.; FIGUEREDO JUNIOR, L. G. M. de; et al. Modelo para estimação da produtividade de grãos de milho deplecionada com base no balanço hídrico no solo. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 12, n. 2, p. 359-367, 2004.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Sistema brasileiro de classificação de solos:** Embrapa Produção de Informações. Rio de Janeiro: Embrapa Solos, 1996. 412p.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. Centro Nacional de Pesquisa do Solo. **Sistema brasileiro de classificação de solos.** Brasília, Embrapa Produção de Informação; Rio de Janeiro, Embrapa Solos, 1999. 412p.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Manual de segurança e qualidade para a cultura do milho.** Brasília: Embrapa/Sede, 2004, 78 p.

ELACHI, C. **Introduction to the Physics and Techniques of Remote Sensing.** New York, Wiley, 1987.

ERDLE, K. et al. Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. **Field Crops Research**, v.124, p.74-84, 2011.

EISENBEISS, H. **UAV Photogrammetry.** Tese de doutorado. Alemanha: University of Technology Dresden, 2009.

EISENBEIS, H.; SAUERBIER, M. Investigation of UAV systems and flight modes for photogrammetric applications. **The Photogrammetric Record**, v. 26, n. 136, p. 400-421, 2011.

EVERAERTS, J. (2008). The Use Of Unmanned Aerial Vehicles (VANTS) For Remote Sensing And Mapping. **Remote Sensing and Spatial Information Sciences** . Beijing. Vol. XXXVII.

FENG, W. et al. Monitoring leaf nitrogen status with hyperspectral reflectance in wheat. **European Journal of Agronomy**, v.28, n.3, p.394-404, 2008. Disponível em: Acesso em: 09 abr. 2019. doi: 10.1016/j. eja.2007.11.005.

FERNANDES, P. **Estimativa da produtividade de milho (Zea mays L.) através de imagens multiespectrais obtidas por veículo aéreo não tripulado**. Dissertação (Mestrado em Agricultura de Precisão), Universidade Federal de Santa Maria, Colégio Politécnico, 78 p.,2016.

FITZGERALD, G. J. et al. Spectral and thermal sensing for nitrogen and water status in rainfed and irrigated wheat environments. **Precision Agriculture**, v. 7, p. 233–248, 2006.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento Remoto em Agricultura**. São José dos Campos - SP: Oficina de Textos. (2017).

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. 3 ed. ampl. e atual. São Paulo: Oficina de Textos, 128p. (2011).

FREDDI, O. da S.; FERRAUDO, A.S.; CENTURION, J.F. Análise multivariada na compactação de um Latossolo Vermelho cultivado com milho. **Revista Brasileira de Ciência do Solo**, v.32, p.953-961, 2008.

FUCCI, C. L. **Piloto de Drone, uma Profissão de Futuro! A Tecnologia dos Drones**. Editora clube de autores, 135 p., 2016.

FURLANETTO, R.H. et al. Potencial de utilização de sensores multiespectral e hiperespectral no estudo de diferentes alvos agrícolas. In: Jornada Acadêmica da Embrapa Soja, XII, 2017, Londrina, **Anais...** Londrina: Embrapa Soja, 2017, p. 146-154.

GARCIA, G. J. **Sensoriamento Remoto: Princípios de Interpretação de Imagens**. São Paulo: Nobel, 1982.

GASPAROTTO, A. C. et al. Diferentes doses de nitrogênio na cultura do milho e sua relação com GNDVI. **Anais...** XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE.

GITELSON, A.; KAUFMAN, Y.; MERZLYAK, M. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, p. 289-298, 1996.

GOTELLI, N. J.; ELLISON, A. M. **Princípios de estatística em ecologia**. Porto Alegre: Editora Artmed, 2011. 528 p.

GONZALES, R. C. e WOODS, R. E. **Processamento Digital de Imagens**. Pearson Prentice Hall, 3 ed., 624 p., 2015.

GROFF, E. C. et al. Características agronômicas associadas com índices de vegetação medidos por sensores ativos de dossel na cultura da soja. **Ciências Agrárias**, Londrina, v. 34, n. 2, p. 517-526, mar./abr. 2013.

GUARIENTI, E. M. et al. Avaliação do efeito de variáveis meteorológicas na qualidade industrial e no rendimento de grãos de trigo pelo emprego de análise de componentes principais. **Cenc. Technol. Aliment.**, Campinas, v. 23, p. 500-510, 2003.

GUYOT, G.; GUYON, D.; RIOM, J. Factors affecting the spectral response of forest canopies: a review. **Geocarto International**, v. 4, n. 3, p. 3-18, 1989. <http://dx.doi.org/10.1080/10106048909354217>.

GUEDES FILHO, O. **Variabilidade espacial e temporal de mapas de colheita e atributos do solo em um sistema de semeadura direta**. Dissertação (Mestrado em Agricultura Tropical e Subtropical). Campinas: Instituto Agronômico, 2009. 97 p.

HÄRDLE, W.; SIMAR, L. **Applied multivariate statistical analysis**. Berlin: Springer, 2 ed., 2007.

HAIR JUNIOR, J. F. et al. **Análise multivariada de dados**. 5. ed. Porto Alegre: Bookman, 2005.

HERWITZ, S. R. et al. Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. **Computers and Electronics in Agriculture**. v. 44, 2004, p. 49–61.

HOFFER, R.M. Biological and physical considerations in applying computer-aided analysis techniques to remote sensor data. In: SWAIN, P.H.; DAVIS, S.M. (Org.) **Remote Sensing: the Quantitative Approach**, McGraw-Hill, New York, 1978, p.228-289.

HONGYU, K. **Comparação do GGE-biplot ponderado e AMMI-ponderado com outros modelos de interação genótipo x ambiente**. 2015. 155p. Tese (Doutorado em Estatística e Experimentação Agronômica) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2015.

INAMASU, R. Y.; BERNARDI, A.C.C. Agricultura de Precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R.Y. (Org.) **Agricultura de Precisão: resultados de um novo olhar**. p. 21-33. Brasília, D. F.: Embrapa, 2014. 596 p. Disponível em <<https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1004023/1/Agriculturadeprecisaocap>>.12.pdf. Acesso em: 19 nov. 2018.

INAMASU, R. Y.; JORGE, L. A. de C. **Uso de Veículos Aéreos não tripulados (VANT) em Agricultura de Precisão**. Embrapa Instrumentação- São Carlos, SP. 2014.

INSTITUTO NACIONAL DE METEOROLOGIA – INMET. Dados de estações automáticas (s.d). Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=noticia/visualizarNoticia&id=222>>. Acesso em: 12 mar. 2019.

JACKSON, J.E. Principal components and factor analysis: Part I – principal componets. **Journal of Quality Technology**, v.12, n.4, p. 201-213, 2019.

JENSEN, J. R. **Remote Sensing of the Environment: Na Earth Resource Perspective**. Upper Saddle River, NJ: Prentice Hall, 2. ed., 592 p , 2007.

JIANG, Z., et al. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, 112: 3833–3845, 2008.

JOHNSON, R.A.; WICHERN, D.W. **Applied multivariate statistical analysis**. Madison: Prentice Hall International, 816p, 1998.

JUNIOR, W. de C. et al. **Análise multivariada de argissolos da faixa atlântica brasileira**, 2008.

JUSTICE, C. 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, p.1228-1249, 1998.

KAUFMAN, Y.J.; TANRE, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v.30, p.261-270, 1992.

KNOX, B.; LADIGES, P.; EVANS, B. **Biology**. Sydney: Mc Graw-Hill, 1997. 225 p.

KÖPPEN, W. **Climatologia. México**, Fundo de Cultura Econômica. 1931.

KUMAR, L.; SCHMIDT, K.; DURY, S.; SKIDMORE, A. Imaging spectrometry and vegetation science. *In*: VAN DER MEER, F. D.; JONG, S. M. **Imaging spectrometry: basic principles and prospective applications**. Dordrecht: Kluwer Academic Publishers, 2001, p. 11-155.

KUMAR, L. **Modeling forest resources using geographical information systems and hyperspectral remote sensing**. 1998. Tese (Doutorado) – University of New South Wales, Sydney, 256 p., 1998.

KUNAL, S. et al. **Application of GIS in precision agriculture. Conference National Seminar on “Precision Farming Technologies for high himalayas”**. **Proceedings...Precision Farming Development centre and High Mountain Arid Agriculture Research Insitute**, Leh, Ladakh, jammu and Kashmir, India. October 2015. DOI: 10.13140/RG.2.1.2221.3368. Disponível em:

<https://www.researchgate.net/publication/295858552_Application_of_GIS_in_precision_agriculture>. Acesso em 20 Dez. 2018.

LARCHER, W. **Ecofisiologia vegetal**. São Paulo: Editora E.P.U, 1986, 529p.

LIAO, S. W. et al. Identification of pollution of Tapeng Lagoon from neighbouring rivers using multivariate statistical method. **Journal of Environmental Management**, v.88, p.286-292, 2008

LONGHITANO, G. A. **Vants para sensoriamento remoto: aplicabilidade na avaliação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas**. Tese (Doutorado em Engenharia de Transportes) - Escola Politécnica da Universidade de São Paulo, São Paulo, São Paulo, Brasil, 2010. 163p.

MANTOVANI E. C. et al. **Estimativa do coeficiente de cultura do milho com base no ndvi**.

MACHADO, E. C. et al. **Relações radiométricas de uma cultura de cana-de-açúcar**. *Bragantia*, v. 44, p. 229-238, 1985.

MANUAL DO DJI PHANTOM 4. Disponível em: <<http://aeromodelobrasil.com/drones/dji-phantom-4/>>. Acesso em 09/07/2018.

MENEGATTI, L. A. A. et al. Benefícios econômicos e agrônômicos da adoção de agricultura de precisão em usinas de açúcar. **2º Congresso Brasileiro de Agricultura de Precisão** São Pedro, SP – ESALQ/USP, 2006.

MICASENSE. **MicaSense RedEdge™ 3 Multispectral Camera** - User Manual. 2016. Disponível em: <<https://www.micasense.com/rededge-mx>>. Acesso em 7.fev.2019.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Belo Horizonte: Editora UFMG, 2005.

MOLIN J. P. et al. Utilização de dados georreferenciados na determinação de parâmetros de desempenho em colheita mecanizada. **Eng. Agríc.**, Jabaticabal, v. 26, n. 3, 2006.

MONICO, J. F. G. **Posicionamento pelo GNSS – Descrição, Fundamentos e Aplicações**. São Paulo: Editora UNESP, 2 ed., 2008. 480 p.

MONTIBELLER, B. **Análise espectro-temporal das culturas de milho, soja e cana-de-açúcar com dados do sensor oli/landsat-8**. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

MORAES, E.C. **Fundamentos Do Sensoriamento Remoto**. Apostila. Instituto Nacional de Pesquisas Espaciais (INPE/MCTI). Disponível em: <http://www.dsr.inpe.br/vcsr/files/capitulo_1.pdf>. Acesso em: 15 nov. 2018.

MOREIRA, R. C. **Influência do posicionamento e da largura de bandas de sensores remotos e dos efeitos atmosféricos na determinação de índices de vegetação**. 2000. 79f. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2000.

MORENO, J.A. **Clima do Rio Grande do Sul**. Porto Alegre: Secretaria da Agricultura, 1961. 46p.

MOUTINHO, O. **Evaluation of Photogrammetric Solutions for RPAS: Commercial vs Open Source**. 2015. 120f. Dissertação (Mestrado) – Engenharia Geográfica, Universidade do Porto, Porto, 2015.

MUNARETTO, L. **VANT e drones: a aeronáutica ao alcance de todos**. São José dos Campos: Edição independente, 2015.

MUNARETTO, L. **Vant e drones. A aeronáutica ao alcance de todos**. São Paulo, 2ª ed, Edição independente, 2017. 176 p.

NETO, M. M. J. Estatística multivariada. **Revista de Filosofia e Ensino**. 12 setembro 2019. Disponível em: <http://www.criticanarede.com/cien_estatistica.html>. Acesso em: 12 setembro 2019.

NETO, F. N. **Variabilidade espacial da produtividade de milho em duas glebas na região de Guarapuava – PR**. Dissertação (Mestrado) – Universidade Federal do Paraná, 2007, 130p.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. São Paulo: Edgard Blucher, 2 ed., 1992.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Edgard Blucher, 3 ed., 2010.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. São Paulo: Edgard Blucher, 4 ed., 2010.

NTECH INDUSTRIES. Greenseeker Manuals. Disponível em: <http://www.ntechindustries.com/greenseeker-manual.html>. Acesso em: 22 de Jan. 2019.

OERKE, E.C et al. **Precision Crop Protection – The Challenge and Use of Heterogeneity**. Springer, Dordrecht, Netherlands, pp. 3–16. 2010.

OLIVEIRA, A. C. et al. Análise de componentes principais para definição de zonas de manejo em agricultura de precisão. XXIV Congresso Nacional de Milho e Sorgo - 01 a 05 de setembro de 2002, Florianópolis, SC.

OLIVEIRA, M. F. **Modelos de predição de produtividade da cultura do milho por meio de ndvi em arranjos espaciais**. Dissertação (Mestrado) - Universidade Estadual Paulista, Faculdade de Ciências e Veterinárias, 2017. 44p.

OSBORNE, S. L. et al. 2002a. Detection of phosphorus and nitrogen deficiencies in corn using spectral radiance measurements. **Agronomy Journal**, v. 94, n. 6, p. 1215-1221, 2002. DOI: 10.1186/1471-2229-12-63.

PESINI, F. **Avaliação da população de plantas de Soja (*Glycine mx L.*) na variabilidade dos mapas de colheita**. Dissertação. Programa de Pós-Graduação em Agricultura de Precisão da Universidade Federal de Santa Maria. Santa Maria, 2019.

PIETRAGALLA, J.; VEJA, A. M. **Normalized difference vegetation index**. In: PASK, A.; PIETRAGALLA, J.; MULLAN, D.; REYNOLDS, M. H. (Eds.) **Physiological Breeding II: a field guide to wheat phenotyping**. Mexico: CIMMYT, 2012. p. 37-40.

PIONEER. **DUPONT PIONEER**. Disponível em <https://www.pioneersementes.com.br/milho>. Acesso em 20 de março de 2018.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. atual. ampl. São Paulo: Oficina de Textos, 2012. 160 p.

POVH, F. P. et al. Comportamento do NDVI obtido por sensor ótico ativo em cereais. **Pesquisa Agropecuária Brasileira**, v. 43, n. 8, p.1075-1083, 2008.

PUSCOV, J. **Fligh system implementation in UAV**. Examensarbete utfört vid fysikinstitutionen, KTH, SCFAB. Somaren-Hosten, 2002. 51 f.

REGAZZI, A. J. **Análise multivariada**. Viçosa: Universidade Federal de Viçosa, Centro de Ciências Exatas e Tecnológicas, 2001, 166p.

RISSINI, A. L. L. **NDVI, crescimento e produtividade de cultivares de trigo submetidas a doses de nitrogênio**. 2011.53 p. Dissertação (Mestrado em Agronomia) – Universidade Estadual do Centro-Oeste, Guarapuava, 2011.

ROCHA, C. H. B. **Geoprocessamento: tecnologia transdisciplinar**. Juiz de Fora, Minas Gerais. Ed do Autor, 2000.

ROSA, R. **Introdução ao Sensoriamento Remoto**. Uberlândia: Ed. da Universidade Federal de Uberlândia, 5 ed., 2003.

ROUSE J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: **Proceedings of the 3rd. ERTS-1 Symposium**; 1973; Washington, DC. Washington, DC: NASA SP-351; 1973. p.309-17.

SARRIS, Z.; ATLAS, S. Survey of UAV applications in civil markets. In **IEEE Mediterranean Conference on Control and Automation**. 2001.

SCHMIDT, J.P. et al. Nitrogen recommendations for corn: an on-the-go sensor compared with current recommendation methods. **Agronomy Journal**, v.101, n.4, p.916-924, 2009.

SERRANO, J. et al. Avaliação de tecnologias para aplicação diferenciada de fertilizantes: novos conceitos de gestão em pastagens permanentes. **Revista de Ciências Agrárias**, 2014, p. 253-269.

SHANAHAN, J. F et al. Use of Remote sensig imagery to estimate corn grain yield. **Agronomy Faculty Publications**, 2001.

SHIRATSUCHI, L. S. et al. **Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão**. Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, 2014.

SILVA, C. G. M. **Absorção e exportação de macronutrientes em milho transgênico sob dois níveis de investimento em adubação**. 2016. 52 p. Dissertação (Mestrado em Ciências Agrárias) - Universidade Federal de São João Del-Rei, Sete Lagoas, 2016.

SILVA, A. M. M.; SACOMANI, L. B. Using chemical and physical parameters to define the quality of Pardo river water (Botucatu-SP-Brasil). **Water Research**, v.35, p.1609-1616, 2001.

SOUZA, A. M. **Monitoração e ajuste de realimentação em processos produtivos multivariados**. 2000. Tese (Doutorado Engenharia de Produção) – Universidade Federal Santa Catarina, 2000.

TAIPALE, E, Sentera. **NDVI vs. NDRE: What's the Difference?** 2018. Disponível em: <<https://sentera.com/ndvi-vs-ndre-whats-difference/>>. Acesso em: 28 de nov. de 2019.

TRIMBLE. **GreenSeeker 505 Hand Held Sensor User Guide**, 2010. Disponível em: <http://trl.trimble.com/docushare/dsweb/Get/Document-493091/GS505_HandheldSensor_UG_500-1-030_RevM_MD.pdf>. Acesso em: 21 nov. 2018.

UEBEL, J.D. **Avaliação de fungicidas no controle de doenças foliares, grãos ardidos e efeito no NDVI (Índice de Vegetação por Diferença Normalizada) em híbridos de milho**. Dissertação. (Mestrado), 2015, 119 p. Brasília: Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, 2015.

VIAN, A. L. **Sensores de vegetação para estimativa in situ do potencial produtivo na cultura do milho**. Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul, Faculdade de Agronomia, Programa de Pós-Graduação em Fitotecnia, Porto Alegre, 2015.

VICINI, L. **Análise Multivariada da teoria à prática**. Santa Maria: CCNE-UFSM, 2005, 215 p. Disponível em: <<http://w3.ufsm.br/adriano/livro/Caderno%20dedatico%20multivariada%20-%20LIVRO%20FINAL%201.pdf>>. Acesso em: 29 de ago. de 2019.

VILLALBA, E.O.H. **Nutritional status of corn evaluated by optical spectroscopy in Paraguay.** Tese (Doutorado em Engenharia Agrônômica). Universidade Federal de Santa Maria, pp 132. 2012. Disponível em: <<http://agrologic.com.br/medidor-de-umidade-de-graos-portatil-al-101/>>.

ZAMBERLAN, J. F. **Índice de qualidade e custos em função da variabilidade temporal da água de irrigação.** 2011. 147f. Tese. (Doutorado em Engenharia Agrícola), Universidade Federal de Santa Maria, 2011.

ZAMBERLAN, F. J. et al. Índices sazonais de qualidade da água de irrigação via análise multivariada na região central do Rio Grande do Sul. **Irriga**, Botucatu, v. 18, n. 3, p. 376-386, 2013.

ZIMBACK, C. R. L.; MANZIONE, R. L. Análise espacial multivariada aplicada na avaliação da fertilidade do solo. **Engenharia na agricultura**, Viçosa, v.19, n.3, 2011.

APÊNDICE A

Tabela 1 – Método de similaridade entre variáveis Distância Euclidiana e o Método de aglomeração Ward's.

Distância	Método de similaridade entre variáveis (distância Euclidiana)									
	1	2	3	4	5	6	7	8	9	10
,0000000	N_ABS	N_EXPG								
,0000000	MS_G	N_ABS	N_EXPG							
1,772379	NDVI_D_V7	EVI2_V7								
1,936877	NDVI_D_V11	EVI2_V11								
3,264503	NDVI_D_V12	EVI2_V12								
3,929080	NDVI_D_V5	EVI2_V5								
5,847713	NDVI_OP_V5	NDRE_OP_V5								
6,314705	NDVI_OP_V7	NDRE_OP_V7								
7,534544	NDVI_D_V9	GNDVI_V9								
8,070503	NDVI_OP_V9	NDRE_OP_V9								
10,56654	NDVI_D_V11	EVI2_V11	GNDVI_V11							
10,85310	NDVI_OP_V11	NDRE_OP_V11								
11,49894	NDVI_D_V5	EVI2_V5	GNDVI_V5							
11,,93139	NDVI_OP_V12	NDRE_OP_V12								
13,66497	NDVI_D_V12	EVI2_V12	GNDVI_V12							
13,66972	NDVI_D_V9	GNDVI_V9	EVI2_V9							
13,99026	NDVI_D_V7	EVI2_V7	GNDVI_V7							
15,34081	NDVI_D_V11	EVI2_V11	GNDVI_V11	NDRE_D_V11						
18,21031	NDVI_D_V12	EVI2_V12	GNDVI_V12	NDRE_D_V12						
18,44854	NDVI_D_V7	EVI2_V7	GNDVI_V7	NDRE_D_V7						
19,19008	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9						
26,07822	NT_V7	NT_V11								
27,26224	D_N_ha	NT_V7	NT_V11							
29,36595	NT_V12	PLA								
29,64384	NDRE_D_V5	NT_V12	PLA							
31,60003	D_N_ha	NT_V7	NT_V11	NDRE_D_V5	NT_V12	PLA				
36,93771	NDVI_OP_V11	NDRE_OP_V11	NDVI_OP_V12	NDRE_OP_V12						
39,98660	NDVI_OP_V7	NDRE_OP_V7	NDVI_OP_V9	NDRE_OP_V9						
43,60426	NDVI_D_V11	EVI2_V11	GNDVI_V11	NDRE_D_V11	NDVI_D_V12	EVI2_V12	GNDVI_V12	NDRE_D_V12		
44,91647	NDVI_OP_V7	NDRE_OP_V7	NDVI_OP_V9	NDRE_OP_V9	NDVI_OP_V11	NDRE_OP_V11	NDVI_OP_V12	NDRE_OP_V12		
45,79589	D_N_ha	NT_V7	NT_V11	NDRE_D_V5	NT_V12	PLA	NDVI_OP_V5	NDRE_OP_V5		
50,86510	D_N_ha	NT_V7	NT_V11	NDRE_D_V5	NT_V12	PLA	NDVI_OP_V5	NDRE_OP_V5	NDVI_D_V5	EVI2_V5
53,26213	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9	NDVI_D_V11	EVI2_V11	GNDVI_V11	NDRE_D_V11	NDVI_D_V12	EVI2_V12
65,53492	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9	NDVI_D_V11	EVI2_V11	GNDVI_V11	NDRE_D_V11	NDVI_D_V12	EVI2_V12
68,11760	D_N_ha	NT_V7	NT_V11	NDRE_D_V5	NT_V12	PLA	NDVI_OP_V5	NDRE_OP_V5	NDVI_D_V5	EVI2_V5
74,03628	NDVI_D_V7	EVI2_V7	GNDVI_V7	NDRE_D_V7	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9	NDVI_D_V11	EVI2_V11
112,7145	D_N_ha	NT_V7	NT_V11	NDRE_D_V5	NT_V12	PLA	NDVI_OP_V5	NDRE_OP_V5	NDVI_D_V5	EVI2_V5

continua...

continuação

Distância	Método de similaridade entre variáveis (distância Euclidiana)									
	11	12	13	14	15	16	17	18	19	20
,0000000										
,0000000										
1,772379										
1,936877										
3,264503										
3,929080										
5,847713										
6,314705										
7,534544										
8,070503										
10,56654										
10,85310										
11,49894										
11,,93139										
13,66497										
13,66972										
13,99026										
15,34081										
18,21031										
18,44854										
19,19008										
26,07822										
27,26224										
29,36595										
29,64384										
31,60003										
36,93771										
39,98660										
43,60426										
44,91647										
45,79589										
50,86510	GNDVI_V5									
53,26213	GNDVI_V12	NDRE_D_V12								
65,53492	GNDVI_V12	NDRE_D_V12	MS_G	N_ABS	N_EXPG					
68,11760	GNDVI_V5	NDVI_OP_V7	NDRE_OP_V7	NDVI_OP_V9	NDRE_OP_V9	NDVI_OP_V11	NDRE_OP_V11	NDVI_OP_V12	NDRE_OP_V12	
74,03628	GNDVI_V11	NDRE_D_V11	NDVI_D_V12	EVI2_V12	GNDVI_V12	NDRE_D_V12	MS_G	N_ABS	N_EXPG	
112,7145	GNDVI_V5	NDVI_OP_V7	NDRE_OP_V7	NDVI_OP_V9	NDRE_OP_V9	NDVI_OP_V11	NDRE_OP_V11	NDVI_OP_V12	NDRE_OP_V12	NDVI_D_V7

continua...

continuação

Distância	Método de similaridade entre variáveis (distância Euclidiana)									
	21	22	23	24	25	26	27	28	29	30
,0000000										
,0000000										
1,772379										
1,936877										
3,264503										
3,929080										
5,847713										
6,314705										
7,534544										
8,070503										
10,56654										
10,85310										
11,49894										
11,,93139										
13,66497										
13,66972										
13,99026										
15,34081										
18,21031										
18,44854										
19,19008										
26,07822										
27,26224										
29,36595										
29,64384										
31,60003										
36,93771										
39,98660										
43,60426										
44,91647										
45,79589										
50,86510										
53,26213										
65,53492										
68,11760										
74,03628										
112,7145	EVI2_V7	GNDVI_V7	NDRE_D_V7	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9	NDVI_D_V11	EVI2_V11	GNDVI_V11

continua,,,

Distância	Método de similaridade entre variáveis (distância Euclidiana)							
	31	32	33	34	35	36	37	38
,0000000								
,0000000								
1,772379								
1,936877								
3,264503								
3,929080								
5,847713								
6,314705								
7,534544								
8,070503								
10,56654								
10,85310								
11,49894								
11,,93139								
13,66497								
13,66972								
13,99026								
15,34081								
18,21031								
18,44854								
19,19008								
26,07822								
27,26224								
29,36595								
29,64384								
31,60003								
36,93771								
39,98660								
43,60426								
44,91647								
45,79589								
50,86510								
53,26213								
65,53492								
68,11760								
74,03628								
112,7145	NDRE_D_V11	NDVI_D_V12	EVI2_V12	GNDVI_V12	NDRE_D_V12	MS_G	N_ABS	N_EXPG

APÊNDICE B

Tabela 2 – Método de similaridade entre variáveis Distância Euclidiana ao Quadrado e o Método de aglomeração Ward's.

Distância	Método de similaridade entre variáveis (distância Euclidiana ao quadrado)									
	1	2	3	4	5	6	7	8	9	10
0,000000	N_ABS	N_EXPG								
0,000000	MS_G	N_ABS	N_EXPG							
3,141328	NDVI_D_V7	EVI2_V7								
3,751494	NDVI_D_V11	EVI2_V11								
10,65698	NDVI_D_V12	EVI2_V12								
15,43767	NDVI_D_V5	EVI2_V5								
34,19576	NDVI_OP_V5	NDRE_OP_V5								
39,87550	NDVI_OP_V7	NDRE_OP_V7								
56,76936	NDVI_D_V9	GNDVI_V9								
65,13302	NDVI_OP_V9	NDRE_OP_V9								
93,25973	NDVI_D_V11	EVI2_V11	GNDVI_V11							
117,7897	NDVI_OP_V11	NDRE_OP_V11								
119,1197	NDVI_D_V5	EVI2_V5	GNDVI_V5							
142,3581	NDVI_OP_V12	NDRE_OP_V12								
158,4835	NDVI_D_V7	EVI2_V7	GNDVI_V7							
161,6792	NDVI_D_V12	EVI2_V12	GNDVI_V12							
185,5749	NDVI_D_V9	GNDVI_V9	EVI2_V9							
205,5322	NDVI_D_V11	EVI2_V11	GNDVI_V11	NDRE_D_V11						
292,7371	NDVI_D_V12	EVI2_V12	GNDVI_V12	NDRE_D_V12						
293,9774	NDVI_D_V7	EVI2_V7	GNDVI_V7	NDRE_D_V7						
341,0911	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9						
680,0737	NT_V7	NT_V11								
723,1980	NDVI_D_V5	EVI2_V5	GNDVI_V5	NDRE_D_V5						
743,7852	D_N_ha	NT_V7	NT_V11							
862,3591	NT_V12	PLA								
990,1926	D_N_ha	NT_V7	NT_V11	NT_V12	PLA					
1030,175	NDVI_D_V11	EVI2_V11	GNDVI_V11	NDRE_D_V11	NDVI_D_V12	EVI2_V12	GNDVI_V12	NDRE_D_V12		
1040,088	NDVI_OP_V11	NDRE_OP_V11	NDVI_OP_V12	NDRE_OP_V12						
1060,699	NDVI_OP_V7	NDRE_OP_V7	NDVI_OP_V9	NDRE_OP_V9						
1318,444	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9	MS_G	N_ABS	N_EXPG			
1368,605	NDVI_OP_V7	NDRE_OP_V7	NDVI_OP_V9	NDRE_OP_V9	NDVI_OP_V11	NDRE_OP_V11	NDVI_OP_V12	NDRE_OP_V12		
1406,016	NDVI_D_V5	EVI2_V5	GNDVI_V5	NDRE_D_V5	NDVI_OP_V5	NDRE_OP_V5				
1615,346	D_N_ha	NT_V7	NT_V11	NT_V12	PLA	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9	MS_G
2084,271	D_N_ha	NT_V7	NT_V11	NT_V12	PLA	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9	MS_G
2407,388	D_N_ha	NT_V7	NT_V11	NT_V12	PLA	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9	MS_G
2910,998	NDVI_D_V5	EVI2_V5	GNDVI_V5	NDRE_D_V5	NDVI_OP_V5	NDRE_OP_V5	NDVI_OP_V7	NDRE_OP_V7	NDVI_OP_V9	NDRE_OP_V9
4172,485	D_N_ha	NT_V7	NT_V11	NT_V12	PLA	NDVI_D_V9	GNDVI_V9	EVI2_V9	NDRE_D_V9	MS_G

continua...

continuação

Distância	Método de similaridade entre variáveis (distância Euclidiana ao quadrado)										
	11	12	13	14	15	16	17	18	19	20	21
0,000000											
0,000000											
3,141328											
3,751494											
10,65698											
15,43767											
34,19576											
39,87550											
56,76936											
65,13302											
93,25973											
117,7897											
119,1197											
142,3581											
158,4835											
161,6792											
185,5749											
205,5322											
292,7371											
293,9774											
341,0911											
680,0737											
723,1980											
743,7852											
862,3591											
990,1926											
1030,175											
1040,088											
1060,699											
1318,444											
1368,605											
1406,016											
1615,346	N_ABS	N_EXPG									
2084,271	N_ABS	N_EXPG	NDVI_D_V11	EVI2_V11	GNDVI_V11	NDRE_D_V11	NDVI_D_V12	EVI2_V12	GNDVI_V12	NDRE_D_V12	
2407,388	N_ABS	N_EXPG	NDVI_D_V11	EVI2_V11	GNDVI_V11	NDRE_D_V11	NDVI_D_V12	EVI2_V12	GNDVI_V12	NDRE_D_V12	NDVI_D_V7
2910,998	NDVI_OP_V11	NDRE_OP_V11	NDVI_OP_V12	NDRE_OP_V12							
4172,485	N_ABS	N_EXPG	NDVI_D_V11	EVI2_V11	GNDVI_V11	NDRE_D_V11	NDVI_D_V12	EVI2_V12	GNDVI_V12	NDRE_D_V12	NDVI_D_V7

continua...

continuação

Distância	Método de similaridade entre variáveis (distância Euclidiana ao quadrado)								
	22	23	24	25	26	27	28	29	30
0,000000									
0,000000									
3,141328									
3,751494									
10,65698									
15,43767									
34,19576									
39,87550									
56,76936									
65,13302									
93,25973									
117,7897									
119,1197									
142,3581									
158,4835									
161,6792									
185,5749									
205,5322									
292,7371									
293,9774									
341,0911									
680,0737									
723,1980									
743,7852									
862,3591									
990,1926									
1030,175									
1040,088									
1060,699									
1318,444									
1368,605									
1406,016									
1615,346									
2084,271									
2407,388	EVI2_V7	GNDVI_V7	NDRE_D_V7						
2910,998									
4172,485	EVI2_V7	GNDVI_V7	NDRE_D_V7	NDVI_D_V5	EVI2_V5	GNDVI_V5	NDRE_D_V5	NDVI_OP_V5	NDRE_OP_V5

continua...

Distância	Método de similaridade entre variáveis (distância Euclidiana ao quadrado)							
	31	32	33	34	35	36	37	38
0,000000								
0,000000								
3,141328								
3,751494								
10,65698								
15,43767								
34,19576								
39,87550								
56,76936								
65,13302								
93,25973								
117,7897								
119,1197								
142,3581								
158,4835								
161,6792								
185,5749								
205,5322								
292,7371								
293,9774								
341,0911								
680,0737								
723,1980								
743,7852								
862,3591								
990,1926								
1030,175								
1040,088								
1060,699								
1318,444								
1368,605								
1406,016								
1615,346								
2084,271								
2407,388								
2910,998								
4172,485	NDVI_OP_V7	NDRE_OP_V7	NDVI_OP_V9	NDRE_OP_V9	NDVI_OP_V11	NDRE_OP_V11	NDVI_OP_V12	NDRE_OP_V12

APÊNDICE C

Tabela 3 – Distância variável a variável.

Variável	Método de similaridade de distância Euclidiana (variável a variável).											
	D_N_ha	NDVI_D_V5	NDRE_D_V5	NDVI_OP_V5	NDRE_OP_V5	GNDVI_V5	EVI2_V5	NT_V7	NDVI_D_V7	NDRE_D_V7		
D_N_ha	0.0	28.7	30.0	29.8	29.8	28.2	29.2	26.1	28.2	29.0		
NDVI_D_V5	28.7	0.0	22.5	23.8	25.2	8.6	3.9	27.8	36.0	33.7		
NDRE_D_V5	30.0	22.5	0.0	27.4	27.0	21.9	23.0	29.0	29.6	30.8		
NDVI_OP_V5	29.8	23.8	27.4	0.0	5.8	23.9	24.4	28.7	33.3	33.0		
NDRE_OP_V5	29.8	25.2	27.0	5.8	0.0	25.0	25.9	28.6	32.4	32.5		
GNDVI_V5	28.2	8.6	21.9	23.9	25.0	0.0	10.6	28.0	35.8	35.3		
EVI2_V5	29.2	3.9	23.0	24.4	25.9	10.6	0.0	27.9	36.3	33.5		
NT_V7	26.1	27.8	29.0	28.7	28.6	28.0	27.9	0.0	27.7	28.6		
NDVI_D_V7	28.2	36.0	29.6	33.3	32.4	35.8	36.3	27.7	0.0	14.5		
NDRE_D_V7	29.0	33.7	30.8	33.0	32.5	35.3	33.5	28.6	14.5	0.0		
NDVI_OP_V7	29.2	30.8	29.0	25.9	25.6	30.4	31.1	29.4	30.3	31.2		
NDRE_OP_V7	28.6	31.4	28.8	26.3	25.7	31.0	31.7	28.7	29.2	30.4		
GNDVI_V7	27.5	34.1	29.3	32.9	32.3	33.6	34.3	27.6	11.2	15.4		
EVI2_V7	28.3	35.9	29.3	33.2	32.4	35.7	36.2	27.7	1.8	14.8		
NDVI_D_V9	27.9	30.6	26.6	29.7	28.8	28.6	31.4	25.6	25.2	30.7		
NDRE_D_V9	27.8	33.9	28.8	29.9	28.5	33.4	34.3	24.3	21.9	25.8		
NDVI_OP_V9	28.8	31.0	28.6	26.7	26.3	30.4	31.5	28.1	29.0	31.2		
NDRE_OP_V9	28.5	31.8	28.3	27.5	26.7	31.0	32.3	27.6	27.8	30.4		
GNDVI_V9	27.7	31.4	26.7	29.5	28.6	28.8	32.3	26.0	26.0	32.4		
EVI2_V9	28.1	28.6	25.6	29.3	28.5	27.9	29.1	24.3	24.8	28.6		
NT_V11	27.8	28.9	27.9	28.9	28.9	28.4	28.7	26.1	27.8	29.2		
NDVI_D_V11	26.9	31.7	29.9	28.6	27.6	30.8	32.6	26.4	23.7	27.1		
NDRE_D_V11	25.2	32.6	29.3	29.0	27.9	31.5	33.3	25.5	20.8	24.5		
NDVI_OP_V11	29.3	32.5	31.9	28.5	28.3	33.1	32.7	29.9	27.3	26.7		
NDRE_OP_V11	28.4	33.2	31.9	28.6	28.0	33.3	33.5	28.8	26.0	25.8		
GNDVI_V11	25.7	31.7	30.0	28.1	27.0	29.8	32.8	25.7	24.1	28.6		
EVI2_V11	26.8	31.8	29.8	28.7	27.6	30.8	32.8	26.3	23.5	27.1		
NT_V12	30.9	24.4	29.8	26.9	28.1	25.3	24.0	29.1	34.0	33.2		
NDVI_D_V12	27.6	28.6	28.9	28.1	27.6	27.9	29.4	26.2	25.1	26.3		
NDRE_D_V12	26.4	28.7	29.7	28.2	27.7	27.8	29.2	24.2	24.1	24.8		
NDVI_OP_V12	29.0	27.2	30.2	25.0	25.1	27.9	27.6	30.0	32.2	31.1		
NDRE_OP_V12	28.2	25.8	29.5	25.8	26.0	26.6	26.0	29.2	32.2	31.2		
GNDVI_V12	28.3	31.2	29.4	29.9	29.0	29.9	32.2	27.1	22.9	25.9		
EVI2_V12	27.8	29.2	29.0	28.5	27.9	28.4	30.1	26.5	24.6	26.3		
PLA	29.6	29.9	29.4	30.4	30.3	29.8	29.9	28.8	28.8	30.2		
MS_G	26.1	30.6	27.9	30.7	29.9	29.1	31.0	23.8	24.3	27.4		
N_ABS	26.1	30.6	27.9	30.7	29.9	29.1	31.0	23.8	24.3	27.4		
N_EXPG	26.1	30.6	27.9	30.7	29.9	29.1	31.0	23.8	24.3	27.4		

continua...

continuação

Variável	Método de similaridade de distância Euclidiana (variável a variável).									
	NDVI_OP_V7	NDRE_OP_V7	GNDVI_V7	EVI2_V7	NDVI_D_V9	NDRE_D_V9	NDVI_OP_V9	NDRE_OP_V9	GNDVI_V9	EVI2_V9
D_N_ha	29.2	28.6	27.5	28.3	27.9	27.8	28.8	28.5	27.7	28.1
NDVI_D_V5	30.8	31.4	34.1	35.9	30.6	33.9	31.0	31.8	31.4	28.6
NDRE_D_V5	29.0	28.8	29.3	29.3	26.6	28.8	28.6	28.3	26.7	25.6
NDVI_OP_V5	25.9	26.3	32.9	33.2	29.7	29.9	26.7	27.5	29.5	29.3
NDRE_OP_V5	25.6	25.7	32.3	32.4	28.8	28.5	26.3	26.7	28.6	28.5
GNDVI_V5	30.4	31.0	33.6	35.7	28.6	33.4	30.4	31.0	28.8	27.9
EVI2_V5	31.1	31.7	34.3	36.2	31.4	34.3	31.5	32.3	32.3	29.1
NT_V7	29.4	28.7	27.6	27.7	25.6	24.3	28.1	27.6	26.0	24.3
NDVI_D_V7	30.3	29.2	11.2	1.8	25.2	21.9	29.0	27.8	26.0	24.8
NDRE_OP_V7	31.2	30.4	15.4	14.8	30.7	25.8	31.2	30.4	32.4	28.6
NDVI_OP_V7	0.0	6.3	30.7	30.3	27.8	26.3	23.5	24.2	27.1	28.2
NDRE_OP_V7	6.3	0.0	30.0	29.3	27.2	24.9	23.3	23.3	26.5	27.4
GNDVI_V7	30.7	30.0	0.0	10.7	25.3	23.9	29.7	28.8	25.7	25.3
EVI2_V7	30.3	29.3	10.7	0.0	24.9	21.9	29.0	27.8	25.6	24.6
NDVI_D_V9	27.8	27.2	25.3	24.9	0.0	16.3	24.9	24.3	7.5	9.7
NDRE_D_V9	26.3	24.9	23.9	21.9	16.3	0.0	24.2	23.3	17.7	15.0
NDVI_OP_V9	23.5	23.3	29.7	29.0	24.9	24.2	0.0	8.1	24.3	25.3
NDRE_OP_V9	24.2	23.3	28.8	27.8	24.3	23.3	8.1	0.0	23.8	24.9
GNDVI_V9	27.1	26.5	25.7	25.6	7.5	17.7	24.3	23.8	0.0	14.6
EVI2_V9	28.2	27.4	25.3	24.6	9.7	15.0	25.3	24.9	14.6	0.0
NT_V11	28.6	28.3	28.0	27.8	26.3	25.6	28.3	28.2	26.4	25.1
NDVI_D_V11	26.2	25.5	24.7	23.8	22.2	22.0	25.3	24.9	22.3	24.2
NDRE_D_V11	25.8	24.5	22.1	20.8	20.3	17.0	24.6	23.9	20.6	21.0
NDVI_OP_V11	25.3	25.4	28.3	27.5	30.7	27.4	26.5	26.4	30.7	30.4
NDRE_OP_V11	25.2	24.8	27.0	26.2	29.0	25.4	26.9	26.4	29.1	28.9
GNDVI_V11	25.6	24.7	24.3	24.0	20.3	21.1	24.3	23.7	19.2	23.1
EVI2_V11	26.2	25.5	24.4	23.5	21.4	21.4	25.2	24.7	21.4	23.6
NT_V12	29.9	30.5	34.1	34.0	32.1	32.5	30.3	30.8	31.8	31.1
NDVI_D_V12	27.4	26.5	24.5	25.3	22.8	22.6	26.4	26.1	23.0	23.8
NDRE_D_V12	27.7	26.4	22.3	24.2	21.5	20.6	26.8	26.0	22.5	21.1
NDVI_OP_V12	23.9	24.5	32.1	32.4	30.9	29.6	24.7	25.5	30.8	30.2
NDRE_OP_V12	25.6	25.6	32.4	32.4	30.2	29.3	25.4	25.7	30.4	29.3
GNDVI_V12	28.7	27.7	22.1	22.9	20.4	21.0	27.1	26.2	20.8	22.3
EVI2_V12	27.8	26.9	24.0	24.8	22.3	22.3	26.6	26.2	22.6	23.6
PLA	29.7	29.8	28.8	28.8	27.5	27.7	29.8	30.1	27.2	27.9
MS_G	29.4	28.0	24.6	24.4	20.8	22.0	27.8	26.8	20.9	21.9
N_ABS	29.4	28.0	24.6	24.4	20.8	22.0	27.8	26.8	20.9	21.9
N_EXPG	29.4	28.0	24.6	24.4	20.8	22.0	27.8	26.8	20.9	21.9

continua...

continuação

Variável	Método de similaridade de distância Euclidiana (variável a variável).									
	NT_V11	NDVI_D_V11	NDRE_D_V11	NDVI_OP_V11	NDRE_OP_V11	GNDVI_V11	EVI2_V11	NT_V12	NDVI_D_V12	NDRE_D_V12
D_N_ha	27.8	26.9	25.2	29.3	28.4	25.7	26.8	30.9	27.6	26.4
NDVI_D_V5	28.9	31.7	32.6	32.5	33.2	31.7	31.8	24.4	28.6	28.7
NDRE_D_V5	27.9	29.9	29.3	31.9	31.9	30.0	29.8	29.8	28.9	29.7
NDVI_OP_V5	28.9	28.6	29.0	28.5	28.6	28.1	28.7	26.9	28.1	28.2
NDRE_OP_V5	28.9	27.6	27.9	28.3	28.0	27.0	27.6	28.1	27.6	27.7
GNDVI_V5	28.4	30.8	31.5	33.1	33.3	29.8	30.8	25.3	27.9	27.8
EVI2_V5	28.7	32.6	33.3	32.7	33.5	32.8	32.8	24.0	29.4	29.2
NT_V7	26.1	26.4	25.5	29.9	28.8	25.7	26.3	29.1	26.2	24.2
NDVI_D_V7	27.8	23.7	20.8	27.3	26.0	24.1	23.5	34.0	25.1	24.1
NDRE_D_V7	29.2	27.1	24.5	26.7	25.8	28.6	27.1	33.2	26.3	24.8
NDVI_OP_V7	28.6	26.2	25.8	25.3	25.2	25.6	26.2	29.9	27.4	27.7
NDRE_OP_V7	28.3	25.5	24.5	25.4	24.8	24.7	25.5	30.5	26.5	26.4
GNDVI_V7	28.0	24.7	22.1	28.3	27.0	24.3	24.4	34.1	24.5	22.3
EVI2_V7	27.8	23.8	20.8	27.5	26.2	24.0	23.5	34.0	25.3	24.2
NDVI_D_V9	26.3	22.2	20.3	30.7	29.0	20.3	21.4	32.1	22.8	21.5
NDRE_D_V9	25.6	22.0	17.0	27.4	25.4	21.1	21.4	32.5	22.6	20.6
NDVI_OP_V9	28.3	25.3	24.6	26.5	26.9	24.3	25.2	30.3	26.4	26.8
NDRE_OP_V9	28.2	24.9	23.9	26.4	26.4	23.7	24.7	30.8	26.1	26.0
GNDVI_V9	26.4	22.3	20.6	30.7	29.1	19.2	21.4	31.8	23.0	22.5
EVI2_V9	25.1	24.2	21.0	30.4	28.9	23.1	23.6	31.1	23.8	21.1
NT_V11	0.0	29.1	26.3	30.0	29.6	27.7	28.8	27.9	28.0	25.6
NDVI_D_V11	29.1	0.0	13.6	23.6	22.9	8.8	1.9	31.5	17.8	20.8
NDRE_D_V11	26.3	13.6	0.0	25.2	23.3	10.6	12.8	31.8	19.2	17.3
NDVI_OP_V11	30.0	23.6	25.2	0.0	10.9	25.1	23.8	29.2	26.1	27.0
NDRE_OP_V11	29.6	22.9	23.3	10.9	0.0	23.8	23.0	30.6	25.4	25.5
GNDVI_V11	27.7	8.8	10.6	25.1	23.8	0.0	8.0	32.0	18.0	18.4
EVI2_V11	28.8	1.9	12.8	23.8	23.0	8.0	0.0	31.7	17.4	20.2
NT_V12	27.9	31.5	31.8	29.2	30.6	32.0	31.7	0.0	30.9	31.3
NDVI_D_V12	28.0	17.8	19.2	26.1	25.4	18.0	17.4	30.9	0.0	15.0
NDRE_D_V12	25.6	20.8	17.3	27.0	25.5	18.4	20.2	31.3	15.0	0.0
NDVI_OP_V12	29.7	27.2	28.8	22.5	24.6	27.6	27.4	27.6	27.4	28.5
NDRE_OP_V12	28.4	27.7	28.2	24.2	25.4	27.6	27.8	27.6	27.1	27.5
GNDVI_V12	28.5	20.0	19.7	27.3	25.9	18.9	19.2	32.9	12.3	14.8
EVI2_V12	28.3	18.2	19.4	26.3	25.5	18.3	17.6	31.3	3.3	15.1
PLA	30.1	28.2	27.9	30.4	30.3	28.3	28.1	29.4	27.8	28.5
MS_G	24.4	24.8	21.1	30.7	29.0	22.0	24.1	31.9	23.1	18.7
N_ABS	24.4	24.8	21.1	30.7	29.0	22.0	24.1	31.9	23.1	18.7
N_EXPG	24.4	24.8	21.1	30.7	29.0	22.0	24.1	31.9	23.1	18.7

continua....

Variável	Método de similaridade de distância Euclidiana (variável a variável).								
	NDVI_OP_V12	NDRE_OP_V12	GNDVI_V12	EVI2_V12	PLA	MS_G	N_ABS	N_EXPG	
D_N_ha	29.0	28.2	28.3	27.8	29.6	26.1	26.1	26.1	
NDVI_D_V5	27.2	25.8	31.2	29.2	29.9	30.6	30.6	30.6	
NDRE_D_V5	30.2	29.5	29.4	29.0	29.4	27.9	27.9	27.9	
NDVI_OP_V5	25.0	25.8	29.9	28.5	30.4	30.7	30.7	30.7	
NDRE_OP_V5	25.1	26.0	29.0	27.9	30.3	29.9	29.9	29.9	
GNDVI_V5	27.9	26.6	29.9	28.4	29.8	29.1	29.1	29.1	
EVI2_V5	27.6	26.0	32.2	30.1	29.9	31.0	31.0	31.0	
NT_V7	30.0	29.2	27.1	26.5	28.8	23.8	23.8	23.8	
NDVI_D_V7	32.2	32.2	22.9	24.6	28.8	24.3	24.3	24.3	
NDRE_D_V7	31.1	31.2	25.9	26.3	30.2	27.4	27.4	27.4	
NDVI_OP_V7	23.9	25.6	28.7	27.8	29.7	29.4	29.4	29.4	
NDRE_OP_V7	24.5	25.6	27.7	26.9	29.8	28.0	28.0	28.0	
GNDVI_V7	32.1	32.4	22.1	24.0	28.8	24.6	24.6	24.6	
EVI2_V7	32.4	32.4	22.9	24.8	28.8	24.4	24.4	24.4	
NDVI_D_V9	30.9	30.2	20.4	22.3	27.5	20.8	20.8	20.8	
NDRE_D_V9	29.6	29.3	21.0	22.3	27.7	22.0	22.0	22.0	
NDVI_OP_V9	24.7	25.4	27.1	26.6	29.8	27.8	27.8	27.8	
NDRE_OP_V9	25.5	25.7	26.2	26.2	30.1	26.8	26.8	26.8	
GNDVI_V9	30.8	30.4	20.8	22.6	27.2	20.9	20.9	20.9	
EVI2_V9	30.2	29.3	22.3	23.6	27.9	21.9	21.9	21.9	
NT_V11	29.7	28.4	28.5	28.3	30.1	24.4	24.4	24.4	
NDVI_D_V11	27.2	27.7	20.0	18.2	28.2	24.8	24.8	24.8	
NDRE_D_V11	28.8	28.2	19.7	19.4	27.9	21.1	21.1	21.1	
NDVI_OP_V11	22.5	24.2	27.3	26.3	30.4	30.7	30.7	30.7	
NDRE_OP_V11	24.6	25.4	25.9	25.5	30.3	29.0	29.0	29.0	
GNDVI_V11	27.6	27.6	18.9	18.3	28.3	22.0	22.0	22.0	
EVI2_V11	27.4	27.8	19.2	17.6	28.1	24.1	24.1	24.1	
NT_V12	27.6	27.6	32.9	31.3	29.4	31.9	31.9	31.9	
NDVI_D_V12	27.4	27.1	12.3	3.3	27.8	23.1	23.1	23.1	
NDRE_D_V12	28.5	27.5	14.8	15.1	28.5	18.7	18.7	18.7	
NDVI_OP_V12	0.0	11.9	29.4	27.9	30.5	32.1	32.1	32.1	
NDRE_OP_V12	11.9	0.0	29.6	27.8	30.7	30.5	30.5	30.5	
GNDVI_V12	29.4	29.6	0.0	9.8	27.4	21.7	21.7	21.7	
EVI2_V12	27.9	27.8	9.8	0.0	27.5	23.0	23.0	23.0	
PLA	30.5	30.7	27.4	27.5	0.0	25.5	25.5	25.5	
MS_G	32.1	30.5	21.7	23.0	25.5	0.0	0.0	0.0	
N_ABS	32.1	30.5	21.7	23.0	25.5	0.0	0.0	0.0	
N_EXPG	32.1	30.5	21.7	23.0	25.5	0.0	0.0	0.0	