

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MIRAYR RAUL QUADROS DE SOUZA

**ESTIMATIVA DE BIOMASSA DE TRIGO  
USANDO IMAGENS DE ALTA  
RESOLUÇÃO ESPACIAL A PARTIR DE  
VEÍCULO AÉREO NÃO TRIPULADO**

Porto Alegre

2018



**MIRAYR RAUL QUADROS DE SOUZA**

**ESTIMATIVA DE BIOMASSA DE TRIGO  
USANDO IMAGENS DE ALTA  
RESOLUÇÃO ESPACIAL A PARTIR DE  
VEÍCULO AÉREO NÃO TRIPULADO**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Engenharia de Computação

ORIENTADOR: Prof. Dr. Altamiro Amadeu Susin

Porto Alegre

2018



**MIRAYR RAUL QUADROS DE SOUZA**

**ESTIMATIVA DE BIOMASSA DE TRIGO  
USANDO IMAGENS DE ALTA  
RESOLUÇÃO ESPACIAL A PARTIR DE  
VEÍCULO AÉREO NÃO TRIPULADO**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: \_\_\_\_\_

Prof. Dr. Altamiro Amadeu Susin, UFRGS

Doutor pela Institut National Polytechnique – Grenoble, FR

Banca Examinadora:

Prof. Dr. Valner Brusamarello, UFRGS

Doutor pela Universidade Federal de Santa Catarina – Santa Catarina, Brasil

Prof. Dr. Tiago Balen, UFRGS

Doutor em Engenharia Elétrica pela Universidade Federal do Rio Grande do Sul  
– Porto Alegre, Brasil

Prof. Dr. Christian Bredemeier, UFRGS

Doutor pela Universidade Técnica de Munique – Munique, Alemanha

Coordenador do PPGEE: \_\_\_\_\_

Prof. Dr. Joao Manoel Gomes da Silva Jr.

Porto Alegre, Novembro de 2018.



## **DEDICATÓRIA**

Dedico este trabalho a minha família, a minha mãe Flair e minhas irmãs Aline e Queila, que apesar da distância sempre me apoiaram. Dedico aos meus tios Flania e Nelson pelo apoio e dedicação e aos meus avós Jorge e Arcelina.





## AGRADECIMENTOS

Gostaria de agradecer a coordenação do Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul (PPGEE - UFRGS) pela oportunidade de cursar o Mestrado. Gostaria de agradecer aos Professores e funcionários, sobretudo ao meu orientador Dr. Altamiro Amadeu Susin. A minha coorientadora *Dr.<sup>a</sup> Adriane Parraga* pela orientação, ajuda e oportunidade de participar do projeto de pesquisa AgroDrones, onde pude compartilhar experiências durante a orientação dos alunos de graduação da Universidade Estadual do Rio Grande do Sul (UERGS), e adquirir mais experiências durante todo o projeto. Aos alunos que participaram do projeto, sobretudo ao aluno João Gustavo Atkinson Amorim.

Agradeço aos professores e funcionários da UERGS pela atenção e dedicação enquanto estive envolvido nas atividades do projeto de pesquisa na unidade do curso de Engenharia de Computação. Agradeço a Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS) pela provisão da bolsa de mestrado. Agradeço ao Dr. Agradeço ao Dr. Thiago Bertani, que durante a sua participação no projeto, me proporcionou uma ampla visão deste trabalho tendo em vista as necessidades de um trabalho interdisciplinar.

Por fim, gostaria de agradecer ao Professor Dr. Christian Bredemeier e sua aluna de Mestrado *Eng.<sup>a</sup> Agrônoma Carolina Trentin* pela colaboração e dedicação, sobretudo por ter nos proporcionado monitorar o experimento Agrônomico na EEA – UFRGS. A todos, muito obrigado!



## RESUMO

A Agricultura de Precisão contribui para melhorar a qualidade e a produtividade da produção vegetal, com redução de custos e impacto ambiental. A incorporação de tecnologia em equipamentos de cultivo, associada à melhoria genética, permite monitoramento, desenvolvimento das espécies e a aplicação correta, espacial e temporalmente, de nutrientes e defensivos. Neste trabalho são utilizadas imagens aéreas RGB de alta resolução espacial, obtidas por um VANT (Veículo Aéreo Não Tripulado) em vôo sobre um cultivar de trigo, para avaliar a biomassa de duas variedades de trigo brasileiras (TBIO Toruk e BRS Parrudo) através dos índices de vegetação (IVs). Foram utilizados dez índices de vegetação, entre os quais: NGRDI (Índice de Diferença Verde-Vermelho Normalizado), CIVE (Índice de Cor da Extração de Vegetação), ExG (Excesso Verde) SCOM (Índice Combinado Simplificado) e um novo índice proposto denominado ExRM (Excesso vermelho modificado). Os dados foram obtidos de um experimento contendo 120 parcelas de trigo projetado para avaliar o crescimento do trigo e testar o desempenho dos índices de vegetação, correlacionando-os com a biomassa seca medida da parte aérea. A variabilidade no crescimento da cultura foi provocada pela dosagem de nitrogênio aplicada. Para determinar a biomassa da parte aérea, as plantas foram amostradas em dois estágios diferentes de crescimento da cultura: V6 (estádio da sexta folha completamente expandida) e florescimento. Essas medidas foram consideradas como referência para os estimadores de biomassa. Foi criado um mosaico com as imagens capturadas a 50 metros acima do solo e foi realizado a segmentação das parcelas de trigo, de forma automática. Uma Rede Neural Artificial (RNA) foi treinada para prever a biomassa usando os índices de vegetação como entrada da rede. A precisão do modelo estimado foi avaliada com base no coeficiente de determinação ( $R^2$ ). O melhor resultado para a cultivar Parrudo foi  $R^2 = 0,81$  obtido usando RNA e todas os IV como características versus biomassa. Para a cultivar Toruk, o melhor resultado foi  $R^2 = 0,86$ . Os resultados indicam que o modelo de estimação proposto, baseado em imagens RGB e RNA, pode ser utilizado na agricultura de precisão para prever a variabilidade espacial da biomassa da parte aérea, considerando os dois cultivares de trigo testados. Os resultados também foram comparados com

uma regressão linear para estimar a biomassa da parte aérea dos IVs.

**Palavras-chave: Avaliação de Biomassa, Índice de Vegetação, Rede Neural Artificial, Segmentação de Parcelas de trigo.**

## ABSTRACT

Precision Agriculture contributes to improving the quality and productivity of plant production, with reduced costs and environmental impact. The incorporation of technology in crop equipment, associated with genetic improvement, allows for monitoring, species development and the correct, spatial and temporal application of nutrients and pesticides. In this work, high-resolution RGB aerial images obtained by an unmanned aerial vehicle (UAV) in flight on a wheat cultivar are used to evaluate the biomass of two Brazilian wheat varieties (TBIO Toruk and BRS Parrudo) through the indices of vegetation (IVs). Ten vegetation indexes were used, among which: NGRDI (Standard Green-Red Difference Index), CIVE (Extractive Color Index), ExG (Green Excess) SCOM (Simplified Combined Index) and a new porpoise index ExRM (Modified Red Excess). The data were obtained from an experiment containing 120 plots of wheat designed to evaluate wheat growth and to test the performance of vegetation indices, correlating them with the dry biomass measured of the aerial part. The variability in the growth of the crop was created by the applied nitrogen dosage. To determine shoot biomass, the plants were sampled at two different growth stages: V6 (stage of six fully developed leaves) and flowering. These measures were considered as reference for the biomass estimators. A mosaic was created with the images captured 50 meters above the ground and the regions of interest were automatically segmented. An ANN was trained to predict biomass using vegetation indices as input from the network. The accuracy of the estimated model was evaluated based on the coefficient of determination ( $R^2$ ). The best result for the Parrudo cultivar was  $R^2 = 0.81$  obtained using RNA and all IV as characteristics versus biomass. For cultivar Toruk, the best result was  $R^2 = 0.86$ . The results indicate that the proposed estimation model, based on RGB and RNA images, can be used in precision agriculture to predict the spatial variability of shoot biomass, considering the two wheat cultivars tested. The results were also compared with a linear regression to estimate the shoot biomass of the IVs.

**Keywords:** Wheat Plot Segmentation, Biomass Prediction, Artificial Neural Network.



## LISTA DE ILUSTRAÇÕES

Figura 1:	Descrição geométrica simples de um único elemento detector no plano focal de um sensor óptico. . . . .	40
Figura 2:	Diagramas ilustrando a amostragem da superfície. . . . .	40
Figura 3:	Exemplo de um histograma Bimodal com o Limiar $T$ indicando a separação de duas classes. . . . .	42
Figura 4:	Exemplo de elementos estruturantes. . . . .	43
Figura 5:	Espectro eletromagnético: destaque do comprimento de onda de luz visível. . . . .	46
Figura 6:	Refletância eletromagnética para a vegetação saudável, senescente e solo. (RA, 2018) . . . . .	47
Figura 7:	Relação entre índice de vegetação e características fisiológicas. . . . .	48
Figura 8:	Exemplo de um neurônio biológico e os componentes que o constituem. Dendrito: Zona receptiva, Soma: Corpo celular, Axônio: As linhas de transmissão, Terminações Sinápticas. . . . .	54
Figura 9:	Diagrama do modelo matemático de neurônio artificial. . . . .	55
Figura 10:	Exemplo de uma função limiar. . . . .	56
Figura 11:	Exemplo de uma função linear por partes. . . . .	57
Figura 12:	Curvas sigmóides para diferentes valores de $a$ , ou seja, com diferentes inclinações. . . . .	57
Figura 13:	Função Rectified Linear Unit (RELU). . . . .	58
Figura 14:	Arquitetura de rede neural artificial de camada única. . . . .	59
Figura 15:	Arquitetura de uma rede neural artificial multicamadas, totalmente conectada com camadas ocultas. . . . .	60
Figura 16:	Exemplo de gráfico de erro usando dois valores de pesos. . . . .	63
Figura 17:	Cultura monitorada de trigo e seus cultivares. . . . .	66
Figura 18:	Imagem ortorretificada a 50m de altura de todo o experimento monitorado. . . . .	67

Figura 19:	Imagem adquirida a partir do VANT de todo o experimento com ângulo de 70° . . . . .	68
Figura 20:	Veículo Aéreo Não Tripulado Matrice 100 usado neste trabalho. . . . .	70
Figura 21:	Câmera RGB usada no VANT. . . . .	71
Figura 22:	Câmera Sequoia juntamente com o sensor de radiação solar. . . . .	72
Figura 23:	Fluxo do Algoritmo de Segmentação proposto. . . . .	74
Figura 24:	Exemplo de mosaico de uma Imagem RGB das parcelas de trigo. . . . .	80
Figura 25:	Exemplo de imagem multiespectral (bandas NIR, Red e RedEdge) das parcelas de trigo. . . . .	80
Figura 26:	Resultado do processo de binarização da Imagem RGB. . . . .	80
Figura 27:	Resultado do processo de binarização da Imagem multiespectral. . . . .	81
Figura 28:	Resultado do processo morfológico aplicado na imagem binária. . . . .	82
Figura 29:	Criação de mapa ROI intermediário - grade binária com linhas encontradas para a criação do mapa. . . . .	83
Figura 30:	Criação de mapa ROI intermediário - mapa com as regiões criadas. . . . .	83
Figura 31:	Imagem da primeira versão do $I_{map}$ . . . . .	83
Figura 32:	Imagem do $I_{map}$ sobre a imagem RGB para fins de visualização. . . . .	84
Figura 33:	Operação Lógica AND do Passo 4. . . . .	84
Figura 34:	Exemplo da imagem do $I_{map}$ com algumas parcelas erroneamente removidas, destacadas por círculos vermelhos. . . . .	85
Figura 35:	Mapa final da Segmentação $I_{map}$ . . . . .	85
Figura 36:	Mapa de segmentação final $I_{map}$ sobreposta na imagem original. . . . .	86
Figura 37:	Relação entre o índice de vegetação exRM e a biomassa do cultivar Toruk . . . . .	87
Figura 38:	Relação entre amostras medidas e preditas de biomassa do Cultivar Parrudo referentes ao modelo da tabela 9 linha um. . . . .	89
Figura 39:	Relação entre amostras medidas e preditas de biomassa do Cultivar Toruk referentes ao modelo da tabela 9 linha dois. . . . .	90



## LISTA DE TABELAS

Tabela 1:	Índices de Vegetação extraídos das imagens utilizados para caracterização da biomassa. . . . .	69
Tabela 2:	Resolução Espacial das ortofotos em função dos sensores . . . . .	73
Tabela 3:	Resolução Espectral dos sensores da câmera sequoia . . . . .	73
Tabela 4:	Coefficiente de determinação para cada um dos índices de vegetação versus biomassa no modelo de regressão linear . . . . .	86
Tabela 5:	Coefficiente de determinação do modelo linear para os dois estádios . . . . .	87
Tabela 6:	Resultados do modelo de regressão múltipla para um cultivar em uma única data . . . . .	87
Tabela 7:	Coefficiente de determinação do modelo de regressão múltipla para cada um dos cultivares nos dois estádios . . . . .	88
Tabela 8:	Coefficiente de determinação usando RNA com amostras de um cultivar para cada estádio de biomassa . . . . .	89
Tabela 9:	Coefficiente de determinação usando ANN para modelagem da Biomassa com amostras nos dois estádios do Trigo para cada Cultivar . . . . .	89
Tabela 10:	Todos os índices de vegetação padronizados usados para modelar a biomassa com RNA . . . . .	91
Tabela 11:	Coefficiente de determinação dos modelos com índices no modo Raw e padronizados . . . . .	91
Tabela 12:	Coefficiente de determinação dos modelos com índices de vegetação (exG, SCOM, exGR) padronizados . . . . .	91
Tabela 13:	Resultado da predição de biomassa sem as parcelas que tiveram valores de biomassa medida acima de 20% do desvio padrão percentual . . . . .	92
Tabela 14:	Coefficiente de determinação entre o NDVI medido a partir da sequoia e o NDVI medido a partir do Greenseeker . . . . .	92
Tabela 15:	Coefficiente de determinação entre o NDVI medido a partir de imagens multiespectrais e o Greenseeker para cada um dos cultivares Toruk e Parrudo . . . . .	93



## LISTA DE ABREVIATURAS

AP	Agricultura de Precisão
ANN	Artificial Neural Network
CHM	Canopy Height Model
CRI	Carotenoid Reflectance Index
EVI	Enhanced Vegetation Index
V6	Estádio fenológico de seis folhas completamente expandida do Trigo
ExG+CHM	Excess Green combined with CHM
ExG	Excess Green Index
ExGR	Excess Green Red Index
ExR	Excess Red Index
Flor	Fase de florescimento do Trigo
GrassI	Grassland Index
GNDVI	Green-NDVI
GRVI	Green Red Vegetation Index
GSD	Ground Sample Distance
IV	Índice de Vegetação
MDS	Modelo Digital de Superfície
MGRVI	Modified Green Red Vegetation Index
MSAVI	Modified Soil Adjusted Vegetation Index
MSR	Modified Simple Ratio Index
MTVI2	Modified Triangular Vegetation Index 2

NRI	Nitrogen Reflectance Index
NDVI	Normalized Difference Vegetation Index
NLI	Nonlinear Vegetation Index
OSAVI	Optimized Soil-Adjusted Vegetation Index
PSRI	Plant Senescence Reflectance Index
RF	Random Forest
RVI	Ratio Vegetation Index
RDVI	Re-normalized Difference Vegetation Index
REM	Refletância Eletromagnética
RGBVI	Red Green Blue Vegetation Index
(RNA)	Redes Neurais Artificiais
RMSE	Root Mean Square Error
SR	Sensoriamento Remoto
SAVI	Soil-Adjusted Vegetation Index
SIPI	Structure Insensitive Pigment Index
SVR	Support Vector Regression
TVI	Transformational Vegetation Index
VANT	Veículo Aéreo Não Tripulado

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	21
<b>1.1</b>	<b>Imageamento Remoto</b>	22
1.1.1	A Biomassa Como Indicativo de Produtividade	24
<b>1.2</b>	<b>Contexto</b>	24
<b>1.3</b>	<b>Objetivos</b>	25
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	27
<b>2.1</b>	<b>Fenologia da Vegetação</b>	27
<b>2.2</b>	<b>Índices de Vegetação</b>	28
<b>2.3</b>	<b>Uso de <i>Machine Learning</i> em Sensoriamento Remoto</b>	31
<b>2.4</b>	<b>Predição de Biomassa</b>	33
<b>2.5</b>	<b>Considerações Finais</b>	35
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	37
<b>3.1</b>	<b>Processamento de Imagens</b>	38
3.1.1	Resolução espacial	39
3.1.2	Limiarização por Histograma	41
3.1.3	Morfologia	42
3.1.4	Erosão	44
3.1.5	Dilatação	44
3.1.6	Abertura e Fechamento	44
<b>3.2</b>	<b>Caracterização da Vegetação</b>	45
3.2.1	Radiação Eletromagnética	45
3.2.2	Refletância Eletromagnética	46
3.2.3	Índices de Vegetação	47
<b>3.3</b>	<b>Modelos de regressão</b>	52
3.3.1	Modelo de Regressão Linear	52
3.3.2	Redes Neurais Artificiais	53

3.3.3	Definição . . . . .	54
3.3.4	Funções de Ativação . . . . .	56
3.3.5	Arquitetura da Rede Neural . . . . .	58
3.3.6	Paradigmas de Aprendizagem . . . . .	60
3.3.7	<b>O Algoritmo Backpropagation</b> . . . . .	61
<b>4</b>	<b>METODOLOGIA</b> . . . . .	<b>65</b>
<b>4.1</b>	<b>Caracterização dos Experimentos</b> . . . . .	<b>65</b>
4.1.1	Cultivares de Trigo . . . . .	65
4.1.2	Tratamentos . . . . .	66
<b>4.2</b>	<b>Aquisição de Imagens</b> . . . . .	<b>67</b>
4.2.1	Índice de Vegetação . . . . .	68
4.2.2	Veículo Aéreo Não Tripulado . . . . .	68
4.2.3	Sensor de Banda Visível . . . . .	71
4.2.4	Sensores Multiespectrais . . . . .	71
<b>4.3</b>	<b>Segmentação das Parcelas</b> . . . . .	<b>73</b>
<b>4.4</b>	<b>Redes Neurais Artificiais (RNA)</b> . . . . .	<b>77</b>
<b>5</b>	<b>RESULTADOS</b> . . . . .	<b>79</b>
<b>5.1</b>	<b>Segmentação das Parcelas de Trigo</b> . . . . .	<b>79</b>
<b>5.2</b>	<b>Modelo de Predição de Biomassa</b> . . . . .	<b>84</b>
5.2.1	Modelo de Predição de Biomassa usando Regressão Linear . . . . .	86
5.2.2	Modelo de Predição de Biomassa Usando Regressão Não Linear . . . . .	88
<b>5.3</b>	<b>Validação dos índices de vegetação obtidos através do Greenseeker e da Sequoia</b> . . . . .	<b>92</b>
<b>6</b>	<b>CONCLUSÃO E TRABALHOS FUTUROS</b> . . . . .	<b>95</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>99</b>
	<b>APÊNDICE A CROQUI DO EXPERIMENTO</b> . . . . .	<b>107</b>

## 1 INTRODUÇÃO

O Brasil é um dos maiores produtores de alimentos do mundo. Os fatores que contribuem para este fato são a grande área disponível para agricultura e a abundância de recursos naturais. Segundo o IBGE - Instituto Brasileiro de Geografia e Estatística, em seu periódico anual chamado Produção Agrícola Municipal - PAM (IBGE/SIDRA, 2016), em 2016 o valor da produção agrícola foi de R\$ 317,5 Bilhões. Com relação ao trigo, foram produzidos 6 milhões de toneladas com um rendimento médio de 3.155 *kg/ha*, cuja área destinada para plantio foi de 56.990,61 ha. Já os resultados preliminares com relação a produção no ano de 2017 foi de 5.146.718,835 toneladas no Brasil, sendo que deste total, 2.170.964,246 toneladas foram produzidas no Rio Grande do Sul.

Segundo o Levantamento Sistemático da Produção Agrícola - LSPA (IBGE/SIDRA, 2018), até o mês de junho de 2018, no Brasil produziu-se 116.405,751 toneladas de soja comparadas com 114.982,993 toneladas referentes ao mesmo período no ano de 2017. Isso faz com que o Brasil fique em terceiro lugar como produtor mundial de soja (USDA/2018).

Com o intuito de gerenciar melhor a cultura e, conseqüentemente, obter maior produtividade, é necessário ter acesso às informações nutricionais da cultura o mais cedo possível. Saber qual a área da cultura está necessitando mais irrigação, nutrientes ou quais os nutrientes, fertilizante ou, saber ainda, qual vegetação invasora não desejada está presente na cultura, estas são informações que ajudam a melhorar a produtividade (BEDUTTI, 2009). Entretanto, ter acesso a essas informações normalmente necessita uma análise manual diretamente no local.

Atualmente, novas tecnologias e métodos têm sido amplamente utilizados para contribuir com o aumento da produção, principalmente em grande escala. Não apenas para aumentar a relação custo benefício, mas também para aliar a produção e qualidade com bom gerenciamento dos recursos naturais e, dessa maneira, diminuir os impactos ambientais (BERNARDI et al., 2014).

A Agricultura de Precisão (AP) procura gerenciar, de maneira inteligente e precisa, os recursos para diminuir os custos e elevar a produção (BERNARDI et al., 2014). A AP

leva em consideração a variabilidade espacial e temporal, aplicando recursos a partir de tecnologia de taxa variável (ZHANG; KOVACS, 2012). O manejo da cultura de forma manual, normalmente em pequena escala, propicia ao agricultor a noção das necessidades da lavoura. No entanto, com o surgimento de máquinas agrícolas que proporcionam o plantio de grandes áreas de maneira uniforme, o produtor perdeu a noção de variabilidade da lavoura. Portanto a AP é associada ao gerenciamento da cultura que, por sua vez, faz uso de tecnologias para identificar a variabilidade destas áreas (MOLIN; AMARAL; COLAÇO, 2015).

Com o intuito de alcançar a máxima produção, redução no uso de defensivos agrícolas e uso correto de nutrientes é importante ter acesso às informações antecipadamente, para que possam auxiliar na tomada de decisão. Informação nutricional da vegetação, do estresse hídrico, falha no crescimento ou até mesmo detecção de pragas na cultura são exemplos de informações que, quando previstas antecipadamente, podem auxiliar a gerenciar os recursos e as tomadas de decisões no manejo da cultura.

Uma das formas de avaliar a produtividade, qualidade e o desenvolvimento da cultura é através da sua produção biológica. A biomassa ou massa biológica é medida em peso por área, por exemplo kg/ha. A biomassa está relacionada diretamente com a produtividade, logo a medida da biomassa resulta em uma medida da produtividade da cultura.

## 1.1 Imageamento Remoto

Sensoriamento remoto (SR) visa obter informações de um objeto sem a necessidade de existir um contato físico com o mesmo. Técnicas de SR consistem em usar recursos de imagem, luz visível, ultrassom ou infravermelho para obter medidas agronômicas e avaliar a cultura (MOECKEL et al., 2017).

Tradicionalmente, a avaliação da vegetação vem sendo realizada através de imageamento por satélite. Contudo, o uso de imagens a partir de satélites é dependente da periodicidade de aquisição. Além disso, imagens de satélite têm resolução espacial na ordem de alguns metros por pixel (CAMPOS et al., fev. 2018; MYNENI et al., 1998). Imagens com resolução maior pode ser adquiridas a partir de sensores orbitais, como é o exemplo do satélite GeoEye-1 (FRASER; RAVANBAKSH, 2009). No entanto, imagens com maior resolução o acesso é restritivo ou pago.

Com surgimento recente dos Veículos Aéreo Não Tripulados (VANTs), surge um novo paradigma para as aquisições de imagens da cultura. Imagens a partir de VANTs podem fornecer resoluções espaciais na ordem de centímetros. Outra vantagem importante com relação ao uso de VANTs é a resolução temporal, ou seja, a aquisição de imagens a partir de VANTs pode ser programada em função da hora, do dia e das condições do tempo no



qual seja mais adequada a aquisição de imagens.

Estas novas tecnologias de aquisição de dados remotamente têm sido cada vez mais usadas em agricultura de precisão, porém a análise destes dados de forma automatizada ainda é um grande desafio. Portanto, o mapeamento entre os dados coletados e a tomada de decisão que vise otimizar a produtividade e a relação custo-benefício é um tema que necessita ser amplamente pesquisado e validado. O uso de VANTS, aliado ao uso de técnicas de processamento de imagem e inteligência artificial para avaliar a vegetação, vem sendo amplamente estudados para obter informações de maneira remota. (ZHANG; KOVACS, 2012; BENDIG et al., 2015; MESSINGER; ASNER; SILMAN, 2016).

Uma forma muito comum de segmentar, avaliar a quantidade de vegetação e condições fisiológicas a partir de imagens digitais é através do uso de índices de vegetação (IV). Os IV são combinações de duas ou mais bandas das imagens com o intuito de salientar alguma informação de interesse, a saber: estresse hídrico, senescência, biomassa, conteúdo de clorofila. Os IV podem auxiliar no estudo da estrutura de dosséis florestais, vigor e conteúdo de clorofila, sendo este último um índice que pode indicar atividade fotossintética. Além disso, os IV podem ser usados para segmentar alvos de interesse, como solo exposto, água e a própria vegetação (BERNARDI et al., 2014).

A cobertura vegetal também é usada para analisar a biomassa da vegetação. O índice de área foliar (IAF) (WATSON, 1947) é uma relação entre área das folhas e a área total ocupadas pelas plantas, portanto, não usa características espectrais da vegetação. O IAF também pode ser analisado como uma função de outro índice de vegetação, que por sua vez usa refletância eletromagnética (XAVIER; VETTORAZZI, 2004). A relação entre o IAF é alta como pode ser observado em (SERPA, 2011) onde a relação foi de 99% com a densidade de plantas de milho.

Muitos trabalhos associados ao monitoramento da vegetação têm sido conduzidos, levando em consideração a relação entre as bandas do espectro visível e, sobretudo, bandas que fazem parte do espectro de luz não visível, devido à alta refletância da vegetação nesses comprimentos de onda. Cada comprimento de onda dado em nanômetro (nm) recebe um nome como é o exemplo do sensor a bordo do satélite sentinel 2 (SENTINEL, 2018): Infravermelho Próximo (*Near Infra Red* - NIR) 842 nm, borda do vermelho (Red Edge) 705 a 865 nm, verde (GREEN) 560 nm, azul (BLUE) 490 nm, vermelho (RED) 665nm.

Um exemplo de relação entre essas bandas é o índice de vegetação por diferença normalizada NDVI (Normalized Difference Vegetation Index) (TUCKER, 1979; ROUSE JR et al., 1974) que leva em consideração as refletâncias dois comprimentos de onda NIR e RED, dada pela seguinte equação  $NDVI = \frac{NIR - RED}{NIR + RED}$ . O índice de vegetação é calculado a partir de refletância em um comprimento de onda específica, cada faixa tem um valor central e uma largura de banda dado pelas características do sensor projetado para a leitura

da refletância.

A fim de que estes métodos sejam usados na prática, auxiliando no gerenciamento da cultura, planejamento da lavoura, os algoritmos ainda devem ser exaustivamente testados e melhorados para que sejam mais precisos, rápidos e automáticos, sobretudo quando há a necessidade de processamento *on-the-fly*. O desenvolvimento de um único algoritmo ou método que atenda a qualquer tipo de imagem é provavelmente uma utopia, devido à complexidade inerente das imagens adquiridas em campo e da cultura investigada. Portanto, os métodos devem ser avaliados para cada modalidade e para cada cultura.

### **1.1.1 A Biomassa Como Indicativo de Produtividade**

A medida de biomassa ou a produção biológica está relacionada com a capacidade da vegetação de produzir. A biomassa da parte aérea da vegetação é medida em termos de vegetação seca, ou seja, a biomassa de uma porção de vegetação acima da superfície da terra é o peso da vegetação que quando levada ao forno é seca até o peso ficar constante (LIANG; LI; WANG, 2012; WENG, 2011). Dessa maneira, a biomassa é medida de maneira manual. Essa forma de medir a biomassa é completamente destrutiva. Logo, a estimativa de biomassa usando técnicas não destrutivas e automatizadas são desejadas para avaliar a quantidade e a qualidade da vegetação. Uma forma alternativa de se medir a biomassa indiretamente é a partir de índices de vegetação (IV) e muitos trabalhos na literatura têm sido propostos para medir ou modelar a Biomassa de forma indireta através de imageamento aéreo.

Medir a biomassa de maneira automatizada usando técnicas de imageamento remoto e *machine learning* permite que a biomassa não seja destruída, a medida automatizada permite analisar grandes áreas de plantio, conhecer as áreas que necessitam mais insumos, permite aplicá-los apenas nas áreas de interesse e conseqüentemente diminuindo a região que recebe defensivos agrícolas e insumos industrializados. Este último item corrobora com o desenvolvimento sustentável e a manutenção da fauna, fazendo com que as técnicas de AP, juntamente com imageamento remoto, formem uma plataforma extremamente importante, sobretudo frente aos elevados custos dos insumos e da necessidade da redução dos impactos ambientais gerados pela atividade agropecuária.

## **1.2 Contexto**

Este trabalho é o resultado da pesquisa realizada durante o curso de mestrado na Universidade Federal do Rio Grande do Sul UFRGS entre o período de Fevereiro/2017 a Agosto/2018 no contexto do projeto AgroDrones da Universidade Estadual do Rio Grande do Sul (UERGS). O projeto AgroDrones é Financiado pela FAPERGS (Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul) que tem o objetivo de criar um banco de

dados de imagens compartilhado, desenvolver uma ferramenta que possa ser usado pelo Agrônomo ou agricultor que possa fornecer informações sobre a saúde ou qualidade da vegetação e auxiliar no aumento da produtividade.

O projeto é de caráter interdisciplinar e acontece em parceria com o Programa de Pós-Graduação em Fitotecnia da UFRGS e Universidade Federal de Santa Maria (UFSM). Experimentos foram monitorados na Estação Experimental Agronômica (EEA) da UFRGS que fica localizada na cidade de Eldorado do Sul - RS localizado nas coordenadas geográficas: 30°06'41.7"S 51°40'34.0"W (EEA, 2018).

### 1.3 Objetivos

A análise da cultura através de imagens digitais a partir de VANTs é uma técnica de Sensoriamento Remoto que pode auxiliar na avaliação da cultura e, conseqüentemente, da produtividade. Diferentemente do que ocorre com análise de imagens a partir de plataformas orbitais, onde a resolução espacial e temporal é limitada, o uso de VANTs na Agricultura possibilita o acesso à informação rápida e com resolução espacial na ordem de centímetros por pixel. O imageamento na agricultura desempenha um papel importante no planejamento e manejo da cultura, pois, através deste método de análise, pode-se obter informações importantes de maneira remota e automatizada; juntamente com o avanço de tecnologias que permitem o uso de aeronaves cada vez menores, estáveis e autônomas, sensores cada vez mais dedicados; necessitam, portanto, o desenvolvimento de algoritmos que possam auxiliar na avaliação da cultura.

Este trabalho tem, portanto, o objetivo de avaliar o uso de imagens aéreas digitais RGB adquiridas com um veículo aéreo não tripulado para predição de biomassa usando inteligência artificial. Para alcançar este objetivo, será analisado o uso de índices de vegetação do espectro visível a partir de imagens aéreas digitais adquiridas à 50 metros de altitude em relação ao solo para caracterizar a biomassa de duas cultivares de trigo TBIO Toruk e BRS Parrudo. Para alcançar o objetivo, foram traçados alguns objetivos específicos listados abaixo:

1. Avaliar diversos índices de vegetação para estimativa de biomassa de trigo.
2. Determinar se um novo índice pode aumentar a correlação dos modelos.
3. Avaliar o potencial das imagens RGB para a estimativa da biomassa.
4. Avaliar o uso de uma rede neural artificial (RNA) para modelar a biomassa para cada uma das duas variedades de trigo usadas no presente estudo.
5. Segmentar automaticamente as parcelas de trigo para extração de IV utilizado na modelagem da biomassa.

Dos objetivos específicos, foram publicados 2 artigos em conferências internacionais. O primeiro apresenta os resultados de algoritmo de segmentação das parcelas de trigo (PARRAGA et al., 2018). No artigo (SOUZA et al., 2018) foi publicado os resultados de modelagem não-linear da biomassa da mesma cultura a partir de imagens RGB, usando diversos índices de vegetação.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo serão apresentados o estado da arte e os trabalhos relacionados com processamento de imagens para extração de informações aplicados à Agricultura de Precisão. Entre os trabalhos encontrados na literatura, primeiramente será abordados alguns conceitos básicos sobre a vegetação como escala fenológica e índice de vegetação. Em seguida, é apresentado uma revisão de artigos relacionados aos índices de vegetação e sua aplicação na agricultura. Posteriormente, serão apresentados trabalhos que utilizam *Machine Learning* em sensoriamento remoto e, por fim, trabalhos relacionados com a estimativa de Biomassa.

### 2.1 Fenologia da Vegetação

A Fenologia é a parte da botânica que estuda as diferentes fases de crescimento e desenvolvimento da vegetação, tanto a vegetativa (germinação, emergência, crescimento da parte aérea e das raízes) quanto a reprodutiva, estabelecendo as épocas e ocorrências e suas características. A Fenologia, tem um papel importante no manejo, por meio de suas características morfológicas, possibilita identificar o momento fisiológico ao qual encontram-se associadas as necessidades do vegetal, que quando atendidas, possibilitam desenvolvimento da cultura e, por conseguinte, melhor rendimento da mesma (BREDEMEIER; MUNDSTOCK, 2001).

As tomadas de decisões, e suas respectivas recomendações técnicas, estão fundamentadas com os diferentes estágios da vegetação. O acompanhamento da fenologia de uma espécie ocorre através de um sistema de números ou letras, ou ainda da combinação dos dois, de maneira a estabelecer o estágio que identifica cada fase de desenvolvimento da vegetação ou status de desenvolvimento. Este sistema é chamado de escala fenológica que estabelece o estágio de desenvolvimento da planta (CÂMARA, 2006).

O acompanhamento da evolução de uma determinada espécie, ocorre principalmente levando em conta a sua idade fenológica, e não apenas a sua idade cronológica. O acompanhamento da cultura a partir da linha do tempo só é útil quando as condições ambien-

tais (temperatura, umidade, fonte de nutrientes) são favoráveis para a cultura (SPIERTZ, 1974). No entanto, na prática normalmente estes eventos ou fontes de energia não estão alinhados no tempo e, conseqüentemente a observação de alguma fase fenológica, como por exemplo o surgimento do primeiro nó, no caso do trigo) poderá acontecer antes ou depois do tempo estimado.

Algumas escalas fenológicas foram desenvolvidas para o trigo como intuito de identificar as fases de interesse (FEEKES, 1941). No entanto, estas escalas fenológicas não são facilmente subdivididas nem contínuas, ou seja, linear, com respeito ao desenvolvimento a partes específicas da planta. A escala de Haun (HAUN, 1973) leva em consideração uma medida numérica que avalia o crescimento de cada folha do trigo em um universo contínuo com uma resolução decimal.

## 2.2 Índices de Vegetação

Nesta seção, apresentamos uma revisão dos índices de vegetação usados na literatura e propomos um novo índice de vegetação. Segundo (HUETE et al., 2002; H.FANG; S.LIANG, 2014), os índices de vegetação (VI) são transformações espectrais de duas ou mais bandas projetadas para aumentar a contribuição das propriedades da vegetação e permitir intercomparações espaciais e temporais confiáveis da atividade fotossintética terrestre e variações estruturais do dossel. Os índices de vegetação podem ser considerados como a base do sensoriamento remoto na análise agrícola da vegetação. É necessário um índice de vegetação preciso para identificar a biomassa da planta versus solo e resíduos para aplicações automatizadas de sensoriamento remoto e visão computacional, avaliações ecológicas de plantas, gerenciamento de culturas de precisão e controle de plantas daninhas (MEYER; NETO, 2008). Os índices de vegetação podem ser divididos em duas categorias: referentes às características estruturais da vegetação e referentes às informações bioquímicas (BERNARDI et al., 2014).

Alguns índices de vegetação foram desenvolvidos com o intuito de encontrar uma relação entre a parte estrutural da vegetação como: biomassa, quantidade de vegetação, relação entre a quantidade de vegetação e o solo. O índice de área foliar, por exemplo, evidencia a relação entre a área da folha e a área do solo (MUKHERJEE et al., 2013; WILHELM; RUWE; SCHLEMMER, 2000; CHEN; BLACK, 1992).

A necessidade de encontrar alvos de interesse nas imagens com o intuito de contar, classificar ou caracterizar deve começar pelo processo de segmentação (IOVAN; BOLDO; CORD, 2008). Reconhecimento da vegetação a partir do formato, perímetro, taxa entre o perímetro e o comprimento da folha são informações que podem ser usados nesta tarefa, para isso é necessário encontrar o objeto de interesse. Portanto, a segmentação é o

processo de dividir com o intuito de encontrar algum objeto de interesse (GONZALEZ; WOODS, 2010). O objeto de interesse, nesse caso, pode ser o solo, vegetação, folhas ou copas de árvores e os índices de vegetação auxiliam nesta tarefa como uma etapa de pré-processamento.

O processo de separação da vegetação e do solo, por exemplo, pode ser realizado levando em consideração a classificação da refletância de cada porção. O índice de vegetação *Excess Green Index (ExG)* foi desenvolvido com o intuito de separar a vegetação do solo exposto baseado na diferença que existe entre a intensidade das componentes verde e vermelho que se comportam de maneira diferente para a vegetação ou para o solo (WOEBBECKE et al., 1992; HAMUDA; GLAVIN; JONES, 2016). Outros índices de vegetação como *Excess Green menos Excess Red Index (ExGR)* (MEYER et al., 2004), *Excess Red Index* (MEYER; HINDMAN; LAKSMI, 1999) também foram desenvolvidos com o intuito de separar a vegetação de outros objetos.

O índice de vegetação *Colour Index of Vegetation Extraction (CIVE)* (KATAOKA et al., 2003) foi desenvolvido para segmentar a imagem separando a vegetação do solo. Em (HUETE, 1988) foi desenvolvido o *Soil-Adjusted Vegetation Index (SAVI)*, este índice de vegetação é ajustado visando diminuir os efeitos de refletância do solo. Baseado no NDVI este índice de vegetação usa uma constante (L) acrescentada ao índice que pode variar de [0,1]. Quando a constante tem o valor zero iguala-se ao NDVI. Em (RONDEAUX; STEVEN; BARET, 1996) o *Optimized Soil-Adjusted Vegetation Index (OSAVI)* foi desenvolvido com o intuito de otimizar o SAVI com relação aos ruídos de refletância pelo solo a partir de 26 amostras de solo.

A análise de condições nutricionais da cultura de milho foi realizado por (HUNT et al., 2005), onde o índice de vegetação *Normalized Green-Red Difference Index (NGRDI)* foi desenvolvido para estimar as condições de nutrientes de milho e biomassa das culturas alfafa, soja e do próprio milho. Este índice de vegetação também é algumas vezes referenciado como NDI (MEYER; NETO, 2008)

O comprimento de onda do espectro infra vermelho próximo foi analisado em (BIRTH; MCVEY, 1968) onde o índice de vegetação *Simple Ratio (SR)* foi desenvolvido a partir do quociente entre o comprimento de onda infravermelho próximo (740 nm) com o vermelho (675nm) e foram testados para três amostras de grama. O índice foi desenvolvido com a premissa de que deveria ser sensível à variação de vegetação (BIRTH; MCVEY, 1968). Em seguida este índice de vegetação foi aprimorado e normalizado surgindo o *Normalized Difference Vegetation Index (NDVI)*, dado pela equação  $NDVI = \frac{NIR-RED}{NIR+RED}$  (ROUSE JR et al., 1973).

Os índices de vegetação podem ser usados para avaliar a capacidade fotossintética da vegetação (VINCINI; FRAZZI; D'ALESSIO, 2008). O teor de clorofila (ch), usado

para análise bioquímica da vegetação, está associado diretamente com a atividade fotossintética e pode ser obtido através da refletância da vegetação causada pela clorofila ou pigmentos fotossintéticos presentes (GITELSON; GRITZ; MERZLYAK, 2003). Medidas de clorofila e índices de vegetação a partir de sensores ativos da cultura da videira (Cabernet Sauvignon e Xinomavro) foram adquiridos por (TASKOS et al., 2015) durante dois anos. Os resultados mostraram que o índice de vegetação *Normalized Difference Red Edge* (NDRE) =  $\frac{NIR-RE}{NIRRE}$ , teve relação melhor com a atividades fotossintéticas e a biomassa do que o índice de vegetação NDVI.

A clorofila pode ser determinada a partir de um processo químico com o uso de solventes e espectrofotometria, no entanto em (GITELSON; GRITZ; MERZLYAK, 2003) o índice de vegetação *Green Chlorophyll Index* (CGI) foi desenvolvido com o intuito de medir a atividade fotossintética a partir da refletância sem a necessidade de destruir a vegetação.

Os trabalhos encontrados na literatura usam índices de vegetação para desenvolver modelos que melhor se correlacionam com informações de interesse. A forma de medir esta correlação é através do coeficiente de correlação R, também chamado de coeficiente de Pearson, ou o coeficiente de determinação. O coeficiente de correlação varia entre [-1,1], onde o menor valor é uma correlação perfeita inversamente proporcional e o outro extremo indica que existe uma correlação perfeita direta. É comum definir um intervalo de R para classificar a correlação por exemplo, muito alta (0,9 a 1), alta (0,7 a 0,9), moderada (0,5 a 0,7), correlação fraca (0,3 a 0,5) ou sem correlação (<0,3) (MUKAKA, 2012).

O uso do coeficiente de determinação é bastante usado e ele é definido como sendo o coeficiente de correlação ao quadrado  $R^2$  e seus valores estão agora [0,1], onde o menor valor significa que não existe uma correlação entre as variáveis e o maior valor indica uma correlação direta (DEVORE, 2011).

Os índices de vegetação *First Modified Chlorophyll Absorption Ratio Index*(MCARI1) e *Second Modified Chlorophyll Absorption Ratio Index*(MCARI2) foram usados em (HA-BOUDANE et al., 2004) para desenvolver um modelo de estimativa de área foliar que tem menos variação com relação ao conteúdo de clorofila e linearmente relacionado com o índice de área foliar (LAI). Os dados foram coletados a partir imagens aéreas das culturas de trigo, milho e soja. A avaliação foi realizada a partir do coeficiente de determinação e a raiz do erro médio quadrático percentual  $RMSE\% = \frac{1}{\bar{y}} \sqrt{\frac{\sum_{i=1}^n (p_i - y_i)^2}{n}}$  onde  $\bar{y}$  é a médias das amostras,  $p_i$  são os valores preditos e  $y_i$  são os valores medidos, para os valores observados e preditos de LAI. Os valores de coeficiente de determinação ( $R^2$ ) foram de 0.98 para soja, 0.89 para milho, e 0.74 para trigo, e com valores correspondentes de RMSE de 0.28, 0.46, e 0.85, respectivamente.

A análise do estado nutricional durante o manejo é importante para melhorar o de-



envolvimento e produção da cultura (JENSEN et al., 1990). Além disso, o nível de concentração de clorofila foliar e nitrogênio na biomassa são indicadores da condição nutricional da vegetação (HANSEN; SCHJOERRING, 2003). Os modelos de predição de nutrientes podem ser desenvolvidos a partir destas informações para alcançar maior rendimento. Como pode ser observado em (SRIPADA et al., 2005) o índice de vegetação *Green Ratio Vegetation Index*(GRVI) foi usado com o intuito de desenvolver um modelo de predição de aplicação de nitrogênio na cultura do milho.

### 2.3 Uso de *Machine Learning* em Sensoriamento Remoto

A previsão de parâmetros agronômicos, como citado anteriormente, pode ser útil em agricultura de precisão para o melhor gerenciamento da cultura. A relação entre a biomassa da parte aérea da vegetação e o índice de vegetação por diferença normalizada não é linear para todo o ciclo de desenvolvimento da cultura (WENG, 2011). No entanto, em (TURRA, 2016) observa-se uma relação linear entre a biomassa da parte aérea e o índice de vegetação por diferença normalizada entre os estádio V5 e V6 de folhas completamente expandidas para o cultivar Toruk. Portanto, se faz necessário uma relação não linear quando leva-se em consideração todo o ciclo de desenvolvimento da cultura (YUE et al., 2018). Alguns trabalhos usam algoritmos de *Machine Learning* como modelo regressor. Exemplos de algoritmos usados em trabalhos na área de agricultura de precisão são: Redes Neurais Artificiais (ANN), SVR *Support Vector Regression*, RF *Random Forest* e RT *Regression Trees* (WANG et al., 2016). Nesta seção, serão apresentados alguns resultados da revisão bibliográfica dos trabalhos publicados com assuntos relacionados a esta dissertação que usam algoritmos de *machine learning*.

Em (WANG et al., 2016) foi estudado a viabilidade de usar *Random Forest* (RF), *Support Vector Regression* (SVR) e Redes Neurais Artificiais (RNA) para a estimação de biomassa de trigo de inverno remotamente. Foram escolhidas 15 parcelas com tamanho de 30x30m a partir de imagens do satélite *Huan Jing-1: Environmental Protection and Disaster Monitoring Constellation* (HJ1) (HJ1, 2018). A resolução espacial é de 30m abrangendo uma área de 720Km<sup>2</sup>. Já as bandas espectrais foram azul (430-520 nm), verde (520-600 nm), vermelho (630-690 nm) e infravermelho próximo (760-900 nm). Foram usados 15 índices de vegetação mostrados a seguir: NDVI, SAVI, OSAVI, NRI, GNDVI, SIPI, PSRI, RVI, CRI, EVI, MSR, NLI, RDVI, TVI, MTVI2, apenas um deles usa somente componentes do espectro visível o NRI. Amostras de biomassa foram coletadas nas mesmas datas de aquisição de imagem. Cada amostra de biomassa foi levada ao laboratório e submetida a secagem à 80 °C por 48h para o cálculo da biomassa seca. Em seguida, a medida do peso é dividida pela área de coleta da amostra e convertida para Kg

$ha^{-1}$ . As amostras foram divididas de maneira que 75% delas foram usadas para treinamento e 25% usadas para teste, sendo que 75 amostras nas fases de alongamento, emborrachamento e florescimento. O número de amostras para teste foi de 58 para alongamento e emborrachamento e 49 para florescimento. Os melhores resultados foram alcançados usando Random Forest (RF) com  $R^2 = 0,533, 0,721$  e  $0,79$  nos três estágios, respectivamente. Os valores correspondentes de RMSE foram 477, 1126,2, e 1808,2  $Kg\ ha^{-1}$ . O erro relativo RMSE usando os modelos baseados em RF e SVR foram de 8% e 20% no treinamento. Os valores relativos de RMSE para a ANN foi de 4% no treinamento de cada estágio, enquanto que os valores de RMSE no treinamento foram de 35% na fase alongamento, 45% no emborrachamento e 30% no florescimento.

Em (VILJANEN et al., 2018), é proposto o uso de índices de vegetação e uma nova técnica de aprendizado de máquina para modelar a predição de biomassa de Pastagem (*grass swards*), usando imagens adquiridas a partir de um Veículo Aéreo não Tripulado (VANT). Foi realizado o ortomosaico gerando uma ortofoto com resolução espacial de 1cm. O sensor utilizado gerou imagens em RGB e infravermelho próximo, em seguida foi realizado o modelo digital de superfície e *canopy model height* (CMH). Foram usados 12 índices de vegetação, sendo que, apenas 4 usam componentes espectrais *near infrared* e um deles foi desenvolvido pelos autores. Os índices utilizados foram: GRVI, MGRVI, RGBVI, ExG, ExR, ExGR, GrassI, NDVI, RVI, MSAVI, OSAVI, sendo que, ExG + CHM foi desenvolvido neste trabalho. Os resultados foram comparados usando regressão múltipla linear (MLR) e *Random Forest* (RF). O método de avaliação foi o coeficiente de determinação  $R^2$  e a Raiz do Erro Médio Quadrático (RMSE). O experimento foi conduzido de maneira que a área de plantio foi dividida em 24 parcelas de tamanho 12m x 3m com 5 aplicações de nitrogênio (0  $Kg/ha, 50\ Kg/ha, 75\ Kg/ha, 100\ Kg/ha, 125\ Kg/ha, 150\ Kg/ha$ ). A biomassa seca foi medida em laboratório após 17h secando à 100 °C. Os índices de vegetação saturaram no final do ciclo da cultura, no entanto, a avaliação a partir dessa informação tem correlação no início da cultura. Por outro lado, o modelo digital de superfície tem alta correlação com a biomassa conforme vai avançando no ciclo de vida da cultura. Os melhores resultados de estimação com ambos os métodos foram obtidos combinando as características CHM e VI e todas as três classes de características (características CHM, RGB e VI). A avaliação da sensibilidade do método em relação a diferentes estágios de desenvolvimento e diferentes quantidades de biomassa mostrou que o uso da técnica de aprendizado de máquina que integrou múltiplas características melhorou os resultados em comparação com as regressões lineares simples. Os resultados foram extremamente promissores, mostrando que a abordagem fotogramétrica multiespectral proposta pode fornecer estimativas precisas de biomassa de pastos de capim e pode ser desenvolvida como uma ferramenta de baixo custo para aplicações agrícolas

práticas.

## 2.4 Predição de Biomassa

Os trabalhos abaixo relacionados, nesta seção, sobre predição de biomassa, foram conduzidos, na sua grande maioria, a partir de dados extraídos de sensores orbitais, Veículo Aéreo Não Tripulado (VANTs), veículos automotores ou, até mesmo, de câmeras posicionadas ao longo da cultura a partir de estruturas fixas (HRUŠKA et al., 2017; KATAOKA et al., 2003; BROCKS; BARETH, 2018).

A produção, qualidade e uso de insumos no manejo de uma cultura estão associadas com a capacidade de gerenciamento dos nutrientes e capacidade e habilidade de prever onde e quando aplicar esses recursos. A predição de biomassa pode ajudar no monitoramento da produção. O intuito de usar modelo de predição de biomassa a partir do conceito de sensoriamento remoto é automatizar a avaliação da cultura de maneira que não precise destruir as amostras e, no caso de identificação de regiões com pouca biomassa por área, tomadas de decisões possam ser realizadas para evitar a falha no crescimento.

A biomassa está relacionada com a refletância da radiação eletromagnética e com a altura da vegetação (ROUSE JR et al., 1973; DE SOUZA et al., 2017). A partir de imagens, pode-se inferir a altura da vegetação através de Structure-from-Motion (SFM) que é uma técnica que consiste em recriar o modelo 3D a partir de imagens bidimensionais usando nuvens de pontos (SHALABY; ELMOGY; EL-FETOUH, 2017).

A partir do (SFM) pode-se gerar o Modelo Digital de Superfície (MDS) e o Modelo Digital de Elevação (MDE). O MDS leva em consideração tudo que está acima do solo, por outro lado o MDE leva em consideração a elevação do terreno (DE SOUZA et al., 2017). Em (BENDIG et al., 2015), imagens foram usadas para a construção de Structure-from-Motion (SFM) que fornece os dados necessários para a realização de Digital Surface Model (MDS) a partir de imagens RGB ou multiespectral ortoretificadas. Essas ortofotos foram usadas para a extração de índices de vegetação e a informação da altura da vegetação a partir de MDS é usada para construir o modelo de predição. Os trabalhos relacionados a predição de biomassa usam, como método de avaliação do modelo, coeficiente de determinação ( $R^2$ ) e raiz do erro médio quadrático ( $RMSE$ ), usando tanto modelo linear ou não linear (BROCKS; BARETH, 2018).

Os sensores utilizados para aquisição de imagem podem estar posicionados em satélites; existe inúmeros satélites orbitais que possuem sensores capazes de realizar aquisições de dados periódicos (WANG et al., 2016; ZHENG; ZHANG; WU, 2016). Exemplos de satélites que podem adquirir imagens digitais são: Série Landsat (ROY et al., 2014), Terra, Acqua, Sentinel (SENTINEL, 2018) e Aura (NASA, 2018).

Em (ZHENG; ZHANG; WU, 2016) foi realizada a aquisição de dados para predição de biomassa em milho a partir de satélite com dados de SPOT-5 (Systeme Probatoire d'Observation de la Terre-5) e MODIS (Moderate Resolution Imaging Spectroradiometer) que estão a bordo do satélite Terra. Um Modelo de Fusão de Refletância Adaptativo Temporal e Espacial - Spatial and Temporal Adaptive Reflectance Fusion Model (STARFM) foi desenvolvido levando em consideração os índices de vegetação NDVI e LSWI (land surface water index) com o intuito de desenvolver a predição de biomassa com dados com maior resolução espacial. A resolução espacial dos sensores são: 10m para o canal verde e 20m para a banda SWIR cujo comprimento de onda é (2,1  $\mu\text{m}$ ). Já as imagens dos sensores do MODIS são de 250 e 500 m, respectivamente. O método de avaliação desse sistema foi o coeficiente de determinação  $R^2$  e a raiz do erro médio quadrático - RMSE. Primeiramente, a segmentação da área de interesse foi realizada. Os resultados foram  $R^2$  0.66, 0.71, 0.75,  $RMSE$  23.5, 59.9, 163.4  $\text{g} * \text{m}^{-2}$ ), respectivamente, que são resultados melhores quando usando dados dos sensores do MODIS  $R^2$  0.51, 0.63 e 0.66,  $RMSE$  27.1, 61.4, 174.4  $\text{g} * \text{m}^{-2}$ , respectivamente.

O uso de VANT para estimativa de biomassa na Amazônia foi realizado em (MESSINGER; ASNER; SILMAN, 2016). Um modelo digital de superfície, MDS, foi realizado com imagens georreferenciadas com uma tolerância de +/- 2,5m. As informações de altura dos topos das copas foram preditas usando informações do MDS. Em (BENDIG et al., 2015) um modelo de predição de biomassa para cultura de cevada foi desenvolvido levando em consideração oito índices de vegetação, sendo que apenas três eram RGB, além da altura da vegetação a partir de *crop surface model* (CSM) gerado a partir das imagens. Os autores usaram modelos de regressão linear e exponencial para desenvolver o modelo de predição de biomassa, sendo que os melhores resultados foram combinando índice de vegetação com informação de altura da vegetação ( $R^2$  0.82).

Em (BROCKS; BARETH, 2018) foi desenvolvido um modelo de predição de biomassa seca e fresca a partir de dados de imagens de câmeras digitais instaladas próximas a cultura. Um modelo de superfície de cultura Crop Surface Models (CSMs) foi usado para estimar a altura da vegetação. Tanto o coeficiente de determinação  $R^2$  quanto a raiz do erro médio quadrado foram usados para avaliar o modelo resultando em 0,55  $R^2$  0,79 e 97  $RMSE$  234  $\text{g} * \text{m}^{-2}$  para biomassa seca. Além disso, foi usado o índice refinado de Willmott (WILLMOTT; ROBESON; MATSUURA, 2012) cujo valor varia entre -1 e 1 e que "indica a soma das magnitudes das diferenças entre o modelo predito e o desvio observado sobre a média observada em relação à soma das magnitudes do modelo predito e o desvio observado sobre a média observada". Os melhores resultados encontrados neste trabalho foram com o modelo de predição para biomassa seca.

## 2.5 Considerações Finais

Este capítulo apresentou alguns artigos atuais encontrados na literatura relacionados a este trabalho. Esta revisão bibliográfica não tem a intensão de esgotar o assunto nem os trabalhos publicados relacionados a este tema. Até o presente momento, muitos trabalhos aqui apresentados não incluem as cultivares de trigo, como proposto neste trabalho. Isso porque o cultivar BRS Parrudo foi lançado em 2012, apesar do TBIO Toruk ter sido lançado a mais tempo. Além disso, a modelagem de biomassa usando apenas imagens de VANTs combinando IVs com *machine learning* é um tema atual e que ainda precisa ser exaustivamente pesquisado. Portanto, este trabalho propõe a investigação da viabilidade de se usar IV no espectro visível como parâmetro para estimar a Biomassa de trigo usando uma ANN.



### 3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo será abordada a teoria das principais ferramentas utilizadas neste trabalho. A análise a partir do processamento de imagens consiste em etapas bem definidas como: aquisição e armazenamento das imagens, pré-processamento, segmentação e extração de características. Em seguida os dados extraídos a partir de imagens digitais podem ser usados para tomadas de decisão de forma automática. Portanto neste trabalho as atividades ocorreram da mesma forma, sendo que a aquisição de imagens e os equipamentos utilizados são descritos com mais detalhes na seção 4.2 do próximo capítulo. Realizada a aquisição das imagens digitais, a preparação, a remoção dos ruídos e a equalização são feitas pela etapa de pré-processamento. As ferramentas utilizadas nesta etapa serão abordadas na seção 3.1, bem como a utilização dos filtros digitais para suavizar os ruídos em imagens. Ainda, nesta seção, é discutido sobre a relação entre a distância do sensor de aquisição de imagem e o alvo de interesse e como isso está relacionado com a resolução espacial, com o sensor e o tamanho do alvo monitorado. Feito o pré-processamento, segue a etapa de segmentação, que consiste em achar os objetos de interesse, ou seja consiste em separar os objetos em uma ou mais classes. Portanto, nesta seção é discutida a segmentação por limiarização por densidade de probabilidade e também a segmentação usando morfologia matemática. A morfologia foi utilizada para auxiliar a encontrar as parcelas e, com isso, auxiliar na extração dos índices de vegetação de forma automática. Já na seção 3.2 é discutida a refletância da vegetação e como os dados biofísicos e estruturais da vegetação podem ser monitorados remotamente a partir de índices de vegetação. Ainda nesta seção, o índice de vegetação ExRM, proposto neste trabalho, que mostrou uma boa correlação inversamente proporcional com a biomassa, é apresentado. Por último, na seção 3.3, os modelos de regressão linear usando o método de mínimos quadrados e o modelo de regressão não linear usando Redes Neurais Artificiais usados como regressores para modelar a biomassa são descritos.

### 3.1 Processamento de Imagens

O processamento de imagens como uma área de Processamento Digital de Sinais visa melhorar a informação para que se possa armazenar, transmitir e extrair informações para que os sistemas de visão computacional possam de forma automática tomar decisões. Para isso é necessário que em processamento de imagens digitais sejam realizadas etapas como: aquisição de imagens, pré-processamento e caracterização ou extração de dados de interesse. Uma imagem digital pode ser descrita como uma função espacial bidimensional  $f(x, y)$ , onde  $x$  e  $y$  são as coordenadas espaciais no plano e a amplitude de  $f$  em qualquer par de coordenadas  $(x, y)$  é chamada de intensidade ou nível de cinza da imagem nesse ponto. As imagens são constituídas pelo seu elemento fundamental que é o pixel que pode conter um valor representado em escala de cinza como por exemplo  $f(x, y) : Y|Y \in [0, 255]$  onde 0 representa o preto e 255 o branco e um valor intermediário representa uma intensidade em escala de cinza (GONZALEZ; WOODS, 2010).

Imagens coloridas são obtidas a partir de uma combinação entre três valores em cada pixel  $f(x, y)$  ( $f(x_1, y_2), f(x_2, y_2), f(x_3, y_3)$ ) onde ( $f(x_1, y_2), f(x_2, y_2), f(x_3, y_3)$ ) representam a composição de canais monocromáticos vermelho, verde e azul. O processamento de imagens pode ser realizado em imagens coloridas através de transformações de imagens no espaço RGB em escala de cinza ou as operações podem ser realizadas no espaço de cores RGB como a segmentação por cores, por exemplo (BURGER; BURGE, 2016).

#### 3.1.0.1 Filtragem Espacial

A filtragem pode ser realizada no domínio da frequência ou no domínio do espaço (GONZALEZ; WOODS, 2010). O filtro no domínio da frequência aceita ou rejeita certas componentes de frequência. Portanto, em imagens digitais, análogo a filtros no domínio da frequência, pode-se usar filtros de aguçamento ou passa-altas e filtros passa-baixas que vão salientar bordas ou suavizá-las, respectivamente. A filtragem espacial linear de uma imagem de dimensões  $M \times N$  com um filtro  $w$  de dimensões  $m \times n$  é dada pela expressão:

$$g(x, y) = \sum_{x_0}^M \sum_{y_0}^N \sum_{s=-m}^m \sum_{t=-n}^n w(s, t) f(x - s, y - t) \quad (1)$$

onde  $g(x, y)$  é a imagem resultante e  $x$  e  $y$  variam de forma que cada pixel em  $w$  percorre todos os pixels em  $f$ . Em qualquer ponto  $(x, y)$  da imagem, a resposta,  $g(x, y)$ , do filtro é a soma dos produtos dos coeficientes do filtro com os pixels da imagem englobados pelo filtro. A remoção de ruídos em imagens pode ser realizada através de filtros lineares passa-baixas. Um filtro passa baixas pode ser descrito pela integração dos pixels vizinhos ou através da média.



$$g(x,y) \frac{\sum_{s-a}^a \sum_{t-b}^b w(s,t) f(x-s, y-t)}{\sum_{s-a}^a \sum_{t-b}^b w(s,t)} \quad (2)$$

$$h(x,y) \frac{1}{\sigma\sqrt{2\pi}} e^{-(x^2+y^2)/2\sigma^2} \quad (3)$$

O filtro passa-baixas linear pode ser descrito pela equação 2, onde a e b são as dimensões do filtro, x e y são as dimensões da imagem e o somatório no denominador se torna uma constante uma vez definido os coeficientes do filtro  $w(s,t)$ . Outro exemplo de filtro passa-baixas é o filtro gaussiano bidimensional descrito na equação 3 que tem a forma de um sino e a largura do sino pode ser determinada pelo desvio padrão  $\sigma$ . O filtro gaussiano é gerado realizando uma amostragem com o centro do sino no meio da mascara. De maneira análoga, se o filtro passa-baixas é expresso pela integração ou pela média o filtro passa-altas é definido pela derivada e, no domínio digital pode ser implementado pela equação de diferenças (GONZALEZ; WOODS, 2010).

$$\nabla^2 \frac{\partial^2 f}{\partial x^2} \frac{\partial^2 f}{\partial y^2} \quad (4)$$

$$\frac{\partial^2 f}{\partial x^2} f(x+1,y) f(x-1,y) - 2f(x,y) \quad (5)$$

$$\frac{\partial^2 f}{\partial y^2} f(x,y+1) f(x,y-1) - 2f(x,y) \quad (6)$$

$$\nabla^2 f(x+1,y) f(x-1,y) f(x,y+1) f(x,y-1) - 4f(x,y) \quad (7)$$

Dada uma imagem representada pela função  $f(x,y)$ , onde x e y são as coordenadas de cada pixel na imagem, o operador derivativo mais simples é o laplaciano e pode ser observada nas equações 4. Como as derivadas de qualquer ordem são operações lineares, o laplaciano é um operador linear. Para expressar essa equação na forma discreta, utilizamos a definição das equações 5 e 6 para as variáveis x e y, respectivamente. O laplaciano discreto de duas variáveis pode ser descrito pela equação 7. O filtro passa-altas salienta informações de altas frequências na imagem como bordas ou linhas.

### 3.1.1 Resolução espacial

A relação entre a distância entre os objetos na imagem e a distância real é dada pelo Ground Sample Distance (GSD) que é a distância que existe entre o centro de dois pixels adjacentes a partir de uma unidade de média de distância no solo (SCHOWENGERDT, 2006). Esta informação é importante para saber qual o tamanho de um objeto de inte-




Figura 1: Descrição geométrica simples de um único elemento detector no plano focal de um sensor óptico.




Figura 2: Diagramas ilustrando a amostragem da superfície.

resse a partir da imagem. O tamanho de uma unidade de imagem é chamado de Ground-projected Instantaneous Field of View (GIFOV) e pode ser visualizada na figura 1. Na figura 2 pode-se observar o diagrama ilustrando o GSD.

Na figura 1 os tamanhos de  $w$  e  $f$  não estão em escala em relação a  $H$ . Da mesma forma, para a óptica (que, na maioria das vezes, seria uma série de espelhos curvos, possivelmente com múltiplos caminhos ópticos dobrados). Os parâmetros angulares, como o Instantaneous Field of View (IFOV), são os mesmos no espaço de imagem e objeto neste modelo, mas as dimensões lineares são relacionadas pela ampliação  $\frac{f}{H}$  entre os dois espaços. Neste diagrama, assume-se que tudo está estacionário e com o ângulo de  $90^\circ$  com

relação ao solo.

$$IFOV \approx 2 \arctan\left(\frac{w}{2f}\right) \sim \frac{w}{f} \quad (8)$$

$$GIOF \approx 2H \tan\left(\frac{IFOV}{2}\right) \approx w \frac{H}{f} \frac{w}{m} \quad (9)$$

Na equação 8 podemos observar a relação entre o IFOV e a largura do sensor  $w$  e a distância focal  $f$ , nota-se que IFOV não é dependente da altura. Já na equação 9 podemos observar a relação entre  $w$ ,  $f$ , e a altura  $H$ , onde  $m$  é a ampliação geométrica (SCHOWENGERDT, 2006).

### 3.1.2 Limiarização por Histograma

A segmentação por limiarização tem uma posição central nas aplicações de segmentação de imagem pois trata-se de um método bastante simples de implementação e possui velocidade computacional, e com resultados normalmente bastante satisfatórios (GONZALEZ; WOODS, 2010). A segmentação global por limiarização pode ser definida conforme a equação 10, onde  $T$  é um limiar, e  $g(x, y)$  é uma imagem binária resultante da segmentação.

$$g(x, y) = \begin{cases} 1 & \text{if } f(x, y) > T \\ 0 & \text{if } f(x, y) \leq T \end{cases} \quad (10)$$

O histograma de uma imagem é muito utilizado para se encontrar um limiar  $T$  que separa um objeto de seu fundo numa imagem, representando duas classes, conforme pode ser visto na figura 3. Porém em muitos casos o histograma não se encontra neste formato bimodal, devido a diversos fatores como: nível de ruído da imagem (os modos ampliam com o aumento do ruído); tamanho relativo dos objetos e do fundo; e/ou uniformidade da fonte de iluminação (GONZALEZ; WOODS, 2010).

Otsu (OTSU, 1979) propôs um método de limiarização global ótima considerando a limiarização como um problema teórico de decisão estatística cujo objetivo é minimizar o erro médio incorrido na atribuição de pixels para dois ou mais grupos (também chamados de classes). O método de Otsu é ótimo no sentido de que maximiza a variância entre classes. A ideia é que as classes com limiares bem estabelecidos devem ser distintas em relação aos valores de intensidade de seus pixels e, inversamente, que um limiar que oferece a melhor separação entre as classes em termos de valores de intensidade seria o melhor limiar (limiar ótimo). Além do componente ótimo, o método de Otsu tem a importante peculiaridade de se basear inteiramente em cálculos realizados no histograma de uma imagem, um arranjo 1-D.




Figura 3: Exemplo de um histograma Bimodal com o Limiar  $T$  indicando a separação de duas classes.

O Método do Otsu consiste, portanto, na procura exaustiva do limiar  $T$  que minimiza a variância intra-classe  $\sigma_{\omega}^2$ , definida como a soma de pesos conforme equação 11

$$\sigma_{\omega}^2(T) = \omega_0 \sigma_0^2(T) + \omega_1 \sigma_1^2(T) \quad (11)$$

onde os pesos  $\omega_0$  e  $\omega_1$  são as probabilidades de duas classes separadas por um limiar  $T$ , e  $\sigma_0^2$  e  $\sigma_1^2$  são as variâncias das duas classes. Os pesos são calculados de acordo com as equações abaixo, onde  $L$  é número de níveis de cinza de uma imagem ou número de bins:

$$\omega_0(T) = \sum_{i=0}^{T-1} p(i) \quad (12)$$

$$\omega_1(T) = \sum_{i=T}^{L-1} p(i) \quad (13)$$

Otsu mostra que minimizar a variância intra-classe é igual a maximizar a variância inter-classe  $\sigma_B^2$ , e pode ser calculada da seguinte forma:

$$\sigma_B^2 = \sigma^2 - \sigma_{\omega}^2 = \omega_0(\mu_0 - \mu)^2 + \omega_1(\mu_1 - \mu)^2 = \omega_0 \omega_1 (\mu_0 - \mu_1)^2 \quad (14)$$

onde  $\mu = \omega_0 \mu_0 + \omega_1 \mu_1$

### 3.1.3 Morfologia

A morfologia é uma ferramenta muito utilizada para filtragem de imagens e, neste trabalho, a morfologia será aplicada em imagens binárias. Em imagens binárias, os conjuntos em questão são membros do espaço 2-D de números inteiros  $Z^2$ , em que cada

elemento de um conjunto é um vetor bidimensional, cujas coordenadas são  $(x, y)$  de um pixel branco (ou preto, dependendo da convenção) de uma imagem. A linguagem da morfologia é descrita pela teoria dos conjuntos, dessa maneira levando em consideração além das operações básicas, também as descritas a seguir (GONZALEZ; WOODS, 2010).

A inversão de uma imagem pode ser realizada usando a operação da equação 15.

$$\mathcal{B} \{w | w = b, \text{ para } b \in B\} \quad (15)$$

Se  $B$  é o conjunto de pixels (pontos bidimensionais) que representa um objeto em uma imagem, então  $B$  é simplesmente o conjunto dos pontos em  $B$  cujas coordenadas  $(x, y)$  foram substituídas por  $(-x, -y)$ . A translação do conjunto  $B$  no ponto  $z = (z_1, z_2)$ , indicada por  $(B)_z$  é definida como

$$(B)_z \{c | c = b + z, \text{ para } b \in B\} \quad (16)$$

Se  $B$  é o conjunto de pixels que representa um objeto em uma imagem, então  $(B)_z$  é o conjunto de pontos em  $B$ , cujas coordenadas  $(x, y)$  foram substituídas por  $(x + z_1, y + z_2)$ .

As operações descritas até agora são amplamente utilizadas na morfologia para formular operações baseadas nos chamados elementos estruturantes (ES): pequenos conjuntos ou subimagens usadas para examinar uma imagem buscando propriedades de interesse. A primeira linha da Figura 4 mostra vários exemplos de elementos estruturantes, nos quais cada quadrado sombreado indica um membro do ES. Além de uma definição de quais elementos são membros do ES, a origem de um elemento estruturante também deve ser especificada. As origens dos diversos ESs na Figura 4 são indicadas por um ponto preto.




Figura 4: Exemplo de elementos estruturantes.

É necessário que os elementos estruturantes sejam arranjos matriciais retangulares.

Isso é feito acrescentando o menor número possível de elementos de fundo (que são mostrados sem sombreamento na Figura 4) necessários para formar um arranjo matricial retangular. O primeiro e o último ES na segunda linha da Figura 4 ilustram o procedimento. Os outros elementos estruturantes nessa linha já estão na forma retangular.

### 3.1.4 Erosão

Com  $A$  e  $B$  como conjunto de  $\mathbb{Z}^2$ , a erosão de  $A$  por  $B$ , indicada por  $A \ominus B$ , é definida como:

$$A \ominus B = \{z | (B)_z \subseteq A\} \quad (17)$$

A erosão de  $A$  por  $B$  é o conjunto de todos os pontos  $z$  de forma que  $B$ , transladado por  $z$ , está contido em  $A$ . Na equação o elemento estruturante é representado por  $B$ .

### 3.1.5 Dilatação

Com  $A$  e  $B$  como conjunto de  $\mathbb{Z}^2$ , a dilatação de  $A$  por  $B$ , indicada por  $A \oplus B$ , é definida como

$$A \oplus B = \{z | \mathbb{B}_z \cap A \neq \emptyset\} \quad (18)$$

Essa equação baseia-se na reflexão de  $B$  em torno de sua origem, seguida da translação dessa reflexão por  $z$ . A dilatação de  $A$  por  $B$  é, então, o conjunto de todos os deslocamentos,  $z$ , de forma que  $B$  e  $A$  se sobreponham pelo menos por um elemento. Essas equações têm uma vantagem sobre as outras formulações, já que são mais intuitivas ao considerar o elemento estruturante  $B$  como uma máscara de convolução. O processo básico de inversão (rotação) de  $B$  em torno de sua origem, seguido de seu deslocamento sucessivo para que se deslize sobre o conjunto (imagem)  $A$ , é análogo à convolução espacial.

Ao contrário da erosão, que é uma operação de diminuição ou afinamento, a dilatação “aumenta” ou “engrossa” os objetos em uma imagem binária. A forma específica e a extensão desse espessamento são controladas pelo formato do elemento estruturante utilizado.

### 3.1.6 Abertura e Fechamento

A abertura geralmente suaviza o contorno de um objeto, rompe os istmos e elimina as saliências finas. O fechamento também tende a suavizar contornos, mas, ao contrário da abertura, geralmente funde as discontinuidades estreitas e alonga os golfos finos, elimina pequenos buracos e preenche as lacunas em um contorno.

A abertura do conjunto  $A$  pelo elemento estruturante  $B$ , indicado por  $A \circ B$  é definida

como:

$$A \circ B = (A \ominus B) \oplus B \quad (19)$$

Assim, a abertura de A por B é a erosão de A por B, seguida de uma dilatação do resultado por B. Da mesma forma, o fechamento do conjunto A pelo elemento estruturante B, indicado por  $A \bullet B$ , é definido na equação 20 como

$$A \bullet B = (A \oplus B) \ominus B \quad (20)$$

que mostra que o fechamento de A por B é simplesmente a dilatação de A por B, seguida pela erosão do resultado por B.

## 3.2 Caracterização da Vegetação

A análise da vegetação, usando técnicas de sensoriamento remoto visa analisar o desempenho vegetativo através de respostas bioquímicas ou estruturais. Dessa maneira, pode-se analisar, através da resposta da refletância usando recurso de imagem ou a refletância a partir de sensores ativos diretamente sobre a superfície da cultura (KATAOKA et al., 2003; WOEBBECKE et al., 1992; HUETE et al., 2002; ROUSE JR et al., 1973). A seguir são abordados itens que estão ligados diretamente com a caracterização da vegetação usando estes sensores.

### 3.2.1 Radiação Eletromagnética

A Radiação Eletromagnética (REM) está presente quando os átomos estão interagindo entre si, resultado das suas oscilações atômicas e moleculares (HALLIDAY; RESNICK; WALKER, 2012). Consequentemente, a REM é emitida por corpos que tem sua temperatura acima de zero absoluto. A radiação eletromagnética estende-se desde ondas de rádio até raios gama. Juntas, todos os tipos de radiação formam o espectro eletromagnético onde podemos observar na figura 5.

A REM não necessita de meio material para se propagar, de maneira que sua velocidade é a velocidade da luz  $c = 299792458 \text{ms}^{-1}$ . A relação entre as características fundamentais da REM está descrito na equação 21 onde a velocidade (c) é proporcional a frequência (f) multiplicado pelo comprimento de onda ( $\lambda$ ). O Sol é a principal fonte de energia no sistema solar, desta maneira a radiação emitida pelo sol atinge a superfície da terra onde é usada, entre outras coisas, como fonte de energia para a fotossíntese da vegetação. Ainda na figura 5 podemos observar em destaque o comprimento de onda da luz visível que vai aproximadamente de 400 a 700 nm.

$$c = f \cdot \lambda \quad (21)$$




Figura 5: Espectro eletromagnético: destaque do comprimento de onda de luz visível.

Esta radiação, quando atinge outros objetos são, por sua vez, absorvidas, refletidas ou transmitidas. Desta maneira, cada objeto, tem a sua assinatura espectral.

### 3.2.2 Refletância Eletromagnética

A vegetação usa a luz do sol como fonte de energia para a realização da fotossíntese. A energia do sol é convertida em energia química por organismos fotossintéticos. No entanto, de todos os comprimentos de onda que chegam a vegetação, apenas alguns são usados para este fim. Os organismos fotossintéticos são compostos de moléculas que absorvem luz, chamados de pigmentos. Dessa maneira, os comprimentos de onda que não são absorvidos por estes pigmentos são refletidos ou transmitidos.

Entre os pigmentos, a clorofila é a constituinte mais importante no que diz respeito a absorção de comprimento de onda no espectro vermelho e azul. Enquanto que o pigmento é o responsável por absorber o comprimento de onda no espectro visível, a estrutura molecular da vegetação é o responsável por refletir a maior parte da energia incidente na vegetação no comprimento de onda do infravermelho próximo (790 - 900 nm). Por isso, muitos trabalhos têm sido largamente desenvolvido levando em consideração sensores de aquisição de imagens e sensores de superfície com o intuito de medir a refletância da vegetação neste comprimento de onda (YUE et al., 2017; SERRANO; FILELLA; PENU-ELAS, 2000; HARDERS et al., 2018).

A partir da figura 6 podemos observar a curva de refletância ou assinatura espectral para a vegetação saudável, vegetação senescente, e solo exposto. Podemos concluir, levando em consideração apenas o espectro de luz visível, que a vegetação saudável absorve a REM cujo comprimento de onda é vermelho (560nm) e azul (450nm), e reflete mais os comprimentos de onda verde (550nm). Já a REM nos comprimentos de onda do infraver-



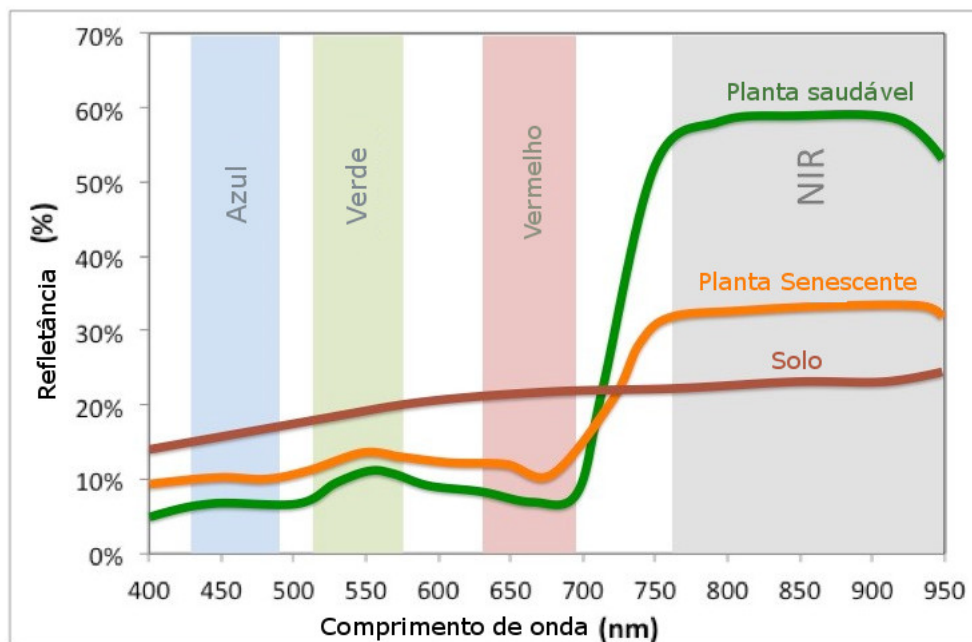


Figura 6: Refletância eletromagnética para a vegetação saudável, senescente e solo. (RA, 2018)

melho próximo (770 - 810 nm) são amplamente refletidos.

### 3.2.3 Índices de Vegetação

Os índices de vegetação são caracterizados por uma transformação espectral de duas ou mais bandas de sensores que retornam um valor proporcional a alguma característica fisiológica de interesse: estresse hídrico, teor de clorofila, biomassa. Alguns índices de vegetação estão associados a quantidade de vegetação como índice de área foliar. Os índices podem levar em consideração, no caso de imagens digitais, as bandas dos canais visíveis ou não. Na figura 7 podemos observar uma ilustração onde o índice de vegetação NDVI está associado a saúde da vegetação, vegetação com saúde tem um índice maior associado que vegetação com estresse. De acordo com (HUETE et al., 2002) os índices de vegetação permitem que seja avaliada, de forma confiável, as atividades fotossintética e a estruturas do dossel da vegetação.

Os índices de vegetação podem ser considerados a base do SR na análise da vegetação. Um índice preciso de vegetação é necessário para identificar a biomassa da vegetação em comparação com os resíduos de solo de forma automática em SR para a aplicação em visão computacional, avaliação ecológica da vegetação, gerenciamento preciso da cultura e controle de ervas daninha (MEYER; NETO, 2008).

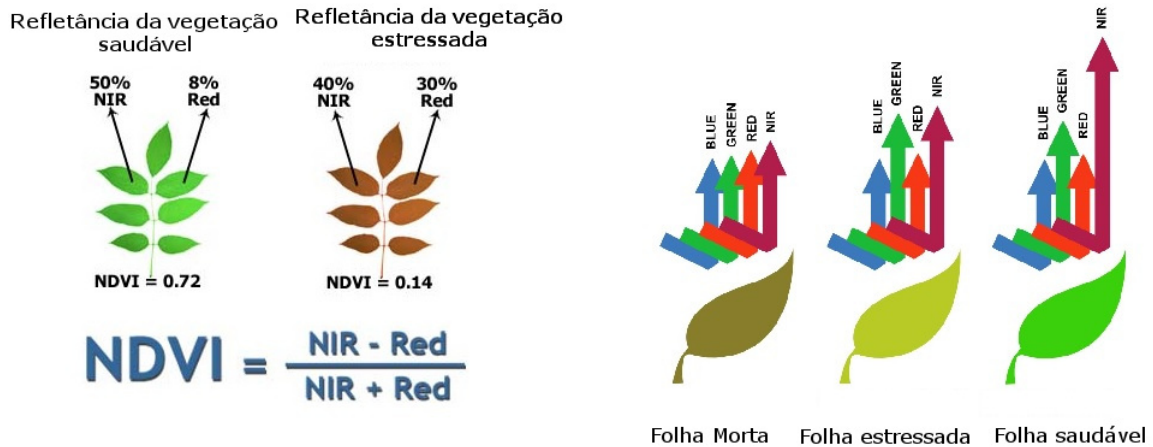


Figura 7: Relação entre índice de vegetação e características fisiológicas.

### 3.2.3.1 Normalização dos Índices de Vegetação

Os índices de vegetação calculados a partir de imagens digitais ocorrem através de um pré-processamento em cada canal individualmente. Introduzido por (WOEBBECKE et al., 1992) as coordenadas cromáticas são normalizadas na avaliação de índice de vegetação de cor.

$$r \frac{R^*}{R^* G^* B^*}, g \frac{G^*}{R^* G^* B^*}, b \frac{B^*}{R^* G^* B^*} \quad (22)$$

Onde,

$$R^* \frac{R}{R_{max}}, G^* \frac{G}{G_{max}}, B^* \frac{B}{B_{max}} \quad (23)$$

e R,G,B são os números digitais da imagem RGB dos canais *red*, *green* e *blue*, respectivamente.  $R_{max}$ ,  $G_{max}$ , e  $B_{max}$  são os valores máximos de cada canal. Quando usa-se 24-bits (8-bits por canal), o valor máximo de cada canal é o mesmo que  $R_{max} G_{max} B_{max} 255$ , logo a equação 22 pode ser reescrita como:

$$r \frac{R}{R G B}, g \frac{G}{R G B}, b \frac{B}{R G B} \quad (24)$$

Alguns autores não aplicam normalização e usam os números digitais de cada imagem diretamente quando avaliam os índices de vegetação, tais como (MEYER; NETO, 2008; KATAOKA et al., 2003). Os índices de vegetação usados neste trabalho que não usam esta normalização são indicados pelo sufixo RAW.

### 3.2.3.2 Excess Green Index (ExG)

O índice de vegetação *Excess Green Index* ou ExG (WOEBBECKE et al., 1992; HAMUDA; GLAVIN; JONES, 2016) é definido na equação 25 e foi usado para separar a

vegetação do solo exposto.

$$ExG = 2 * g - r - b \frac{2 * G - R - B}{R * G * B} \quad (25)$$

A versão não normalizada do índice exG é dado pela próxima equação 26.

$$exGRaw = 2 * G - R - B \quad (26)$$

### 3.2.3.3 Excess Red Index (ExR)

O índice de vegetação *Excess Red Index* ou exR (MEYER; HINDMAN; LAKSMI, 1999) também foi usado para separar pixel que pertence a plantas de pixels que pertence ao solo, no entanto pode não ser tão eficiente (HAMUDA; GLAVIN; JONES, 2016). No artigo original um coeficiente, cujo valor é 1,3, foi usado (MEYER; HINDMAN; LAKSMI, 1999; HAMUDA; GLAVIN; JONES, 2016), entretanto publicações recentes tem usado o valor 1,4 (MEYER; NETO, 2008; MEYER et al., 2004). A equação 27 usada neste trabalho é mostrada a seguir.

$$ExR = 1,4 * r - g \frac{1,4 * R - G}{R * G * B} \quad (27)$$

A versão da equação não normalizada é apresentada na equação 28 a seguir.

$$ExRRaw = 1,4 * R - G \quad (28)$$

### 3.2.3.4 Excess Green (ExGR)

O índice *Excess Green* menos *Excess Red Index* ou ExGR (MEYER et al., 2004; HAMUDA; GLAVIN; JONES, 2016) também foi usado para separar plantas do solo, o índice é definido conforme equação 29, a seguir.

$$ExGR = ExG - ExR \frac{3 * G - 2,4 * R - B}{R * G * B} \quad (29)$$

A versão não normalizada da equação é apresentada na equação 30, logo abaixo.

$$ExGRRaw = ExGRaw - ExRaw = 3 * G - 2,4 * R - B \quad (30)$$

### 3.2.3.5 Colour Index of Vegetation Extraction (CIVE)

O índice de vegetação *Colour Index of Vegetation Extraction* ou CIVE foi proposto por (KATAOKA et al., 2003) com o intuito separar as plantas do solo exposto. A versão normalizada é usada por (GUIJARRO et al., 2011) como pode ser visto na equação 31.

$$CIVE = 0,441 * r - 0,811 * g + 0,385 * b + 18,78745 \frac{0,441 * R - 0,811 * G + 0,385 * B}{RGB} + 18,78745 \quad (31)$$

A versão não normalizada é apresentada na equação 32:

$$CIVERaw = 0,441 * R - 0,811 * G + 0,385 * B + 18,78745 \quad (32)$$

### 3.2.3.6 Normalized Green-Red Difference Index (NGRDI)

O *Normalized Green-Red Difference Index* ou NGRDI (HUNT et al., 2005; HAMUDA; GLAVIN; JONES, 2016) foi usado em (HUNT et al., 2005) para estimar as condições de nutrientes do milho, biomassa da cultura de milho, alfafa e soja. Este índice de vegetação é algumas vezes referenciado como NDI (MEYER; NETO, 2008).

$$NGRDI = \frac{G - R}{G + R} \quad (33)$$

Neste trabalho, uma versão simplificada do índice combinado usado em (GUIJARRO et al., 2011) é usada, como pela equação a seguir.

$$SCOM = 0,25 * ExG + 0,30 * ExGR + 0,33 * CIVE \quad (34)$$

A versão não normalizada do *Simplified Combined Index* é apresentada em 35:

$$SCOMRaw = 0,25 * ExGRaw + 0,30 * ExGRRaw + 0,33 * CIVERaw \quad (35)$$

### 3.2.3.7 Excess Red Modified index (ExRM)

Neste trabalho, um novo índice de vegetação é proposto, chamado *Excess Red Modified index* (ExRM). Este índice foi desenvolvido levando em consideração a característica da vegetação de absorver a REM no comprimento de onda do vermelho. Sua equação é mostrada a seguir:

$$ExRM = 2 * r - g - b \frac{2 * R - G - B}{R + G + B} \quad (36)$$

Este índice de vegetação mostrou ter uma relação inversa e linear com as amostras de biomassa (SOUZA et al., 2018). Os índices de vegetação baseados no espectro de luz visível serão usados com o propósito de modelar a biomassa de trigo das diferentes parcelas.

### 3.2.3.8 Normalized Difference Vegetation Index (NDVI)

O índice Normalized Difference Vegetation Index NDVI (ROUSE JR et al., 1973) leva em consideração os comprimentos e onda do vermelho (650nm) e do infravermelho próximo (760nm). A equação 61 que define o NDVI segue abaixo:

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (37)$$

O índice de vegetação NDVI é amplamente utilizado para a predição de biomassa, avaliação de atividade fotossintética, os valores deste índice podem ocorrer entre [-1,1] e quanto mais próximo de 1 maior é a biomassa, e a quantidade de clorofila por áreas. O NDVI é um índice agrônômico eficiente podendo auxiliar na avaliação da deficiência nutricional da vegetação.

### 3.2.3.9 Soil-Adjusted Vegetation Index (SAVI)

Diferentes índices de vegetação são usados com o intuito de mensurar diferentes informações com relação a quantidade ou a saúde da vegetação. No entanto, medir o índice de vegetação a partir de imagens pode sofrer influencias do meio como efeitos atmosféricos. Portanto, alguns modelos matemáticos devem ser considerados de maneira a diminuir estes efeitos, principalmente quando as imagens são de satélite. Outro fator levado em consideração é o efeito da refletância com relação ao solo.

O solo em diferentes condições (seco, molhado ou coberto com vegetação) ou em diferentes tipos (claro ou escuro) pode refletir de maneira diferente a luz. Portanto, em (HUETE, 1988) foi desenvolvido um índice de vegetação que leva em consideração um fator de correção de refletância do solo, cujo nome é Soil-Adjusted Vegetation Index (SAVI) e a sua definição pode ser vista na equação 38.

$$SAVI = \frac{NIR - RED}{NIR + RED + L} \quad (38)$$

Na equação 38 NIR é a componente correspondente ao comprimento de onda Near Infrared, RED é correspondente a componente ao comprimento de onda vermelho visível e L é uma constante que pode variar entre [0,1] e tem o objetivo de minimizar os efeitos de refletância do solo. Quando L é zero o índice de vegetação SAVI fica exatamente o mesmo que o NDVI, de maneira que quando L tende a 1 diminui o valor do índice com o intuito de minimizar os efeitos de refletância do solo.

### 3.2.3.10 Optimized Soil-Adjusted Vegetation Index (OSAVI)

Pelos mesmos motivos no qual o índice de vegetação SAVI foi desenvolvido, ou seja, para diminuir os efeitos de refletância dos diferentes solos e suas composições, o índice

de vegetação Optimized Soil-Adjusted Vegetation Index (OSAVI) foi desenvolvido por (RONDEAUX; STEVEN; BARET, 1996) com o intuito de otimiza-lo.

$$OSAVI = \frac{(NIR - RED)}{(NIR + RED + 0,16)} \quad (39)$$

O índice de vegetação OSAVI foi otimizado a partir da análise do desvio padrão normalizado e o índice de cobertura de solo para 26 amostras de solo, onde a constante 0,16 foi encontrada resultando em redução dos ruídos com relação ao conjunto de amostras de solo.

### 3.3 Modelos de regressão

O modelo de regressão tem como objetivo ajustar uma função matemática a partir de um conjunto de dados (variáveis independentes) com o objetivo de estimar o valor da variável dependente. Este é precisamente o objetivo da análise de regressão: explorar a relação entre duas (ou mais) variáveis, de modo que possamos obter informações sobre uma delas, por meio dos valores conhecidos da(s) outra(s) (DEVORE, 2011).

Portanto, a análise de regressão é a parte da estatística que investiga a relação entre duas ou mais variáveis relacionadas de maneira não-determinística. A seguir são abordados os conceitos de dois modelos de regressão: linear e não linear.

#### 3.3.1 Modelo de Regressão Linear

Um conjunto de dados amostrais, compreendidos em  $n$  pares  $(x_1, y_1), \dots, (x_n, y_n)$  nos quais os parâmetros de modelo e a própria reta de regressão real podem ser estimados para uma equação  $(y = ax + b + e)$  onde  $x$  é a variável independente e  $y$  a variável dependente e  $e$  é o erro associado. No entanto os valores de  $a$ ,  $b$  e  $e$  nunca são conhecidos. A estimativa dos coeficientes da equação deve ser de tal maneira que minimize os erros dos dados e a curva estimada. De acordo com esse princípio, uma reta oferece uma boa aderência aos dados, se as distâncias verticais (desvios) dos pontos observados em relação à reta são pequenas. A medida da aderência é a soma dos quadrados desses desvios. A reta de melhor aderência é, portanto, aquela que tem a menor soma possível de desvios quadrados (CORREA, 2003).

A curva pode ser ajustada a partir das amostras usando o método de mínimos quadrados onde o objetivo é ajustar o coeficiente da função de maneira a diminuir os resíduos. A inclinação da curva e o ponto de interseção no eixo da abscissa pode ser obtida através das equações 40 e 41, respectivamente (CORREA, 2003).

$$a = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i * \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \quad (40)$$

$$b \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (41)$$

Dada a função ajustada pode-se avaliar os dados preditos pelo método de correlação que é a forma de medir o quão fortemente os dados (x e y) estão relacionados a partir do coeficiente de correlação ou coeficiente de Pearson (DEVORE, 2011). O coeficiente de correlação linear é dado pela equação 44, onde  $\bar{x}\bar{y}$  são a média de x e y e está definido na equação 42 e 43 respectivamente.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (42)$$

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i \quad (43)$$

$$r = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sqrt{(\sum_{i=1}^n x_i - n\bar{x}^2)(\sum_{i=1}^n y_i - n\bar{y}^2)}} \quad (44)$$

Outra forma de avaliar um conjunto de dados preditos com relação ao conjunto de dados desejado é a Raiz do Erro Médio Quadrático. O RMSE mostra o quanto os dados estão próximos da curva ajustada, ou seja, mostra o comportamento dos resíduos. O RMSE retorna o valor na mesma unidade das amostras, a equação pode ser observada em 45.

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (y_i - \bar{y}_i)^2}{n}} \quad (45)$$

### 3.3.2 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) surgiram nos anos 1940 e foram propostas com o intuito de analisarem dados e reconhecerem padrões, usado para classificação e análise de regressão (GONZALEZ; WOODS, 2010). Segundo HAYKIN (2001) são denominadas máquinas inteligentes e de maneira mais geral, denota-se que uma (RNA) é projetada para modelar a maneira como o cérebro realiza uma tarefa ou função de interesse. Os resultados são alcançados por componentes intrínsecos de uma (RNA) chamados de *neurônios* ou *unidades de processamento*. Portas lógicas de circuitos integrados tem um tempo de transição na ordem de nanossegundos ( $10^{-9}s$ ) e neurônios biológicos um tempo de sinapse na ordem de milissegundos ( $10^{-3}s$ ). No entanto, o poder de reconhecimento humano é considerado superior ao de um computador. Isso só é possível graças a quantidade de neurônios que o cérebro humano tem. Estima-se que contenha aproximadamente 10 bilhões de neurônios no córtex cerebral e 60 trilhões de sinapses ou conexões. Na figura

8, é mostrado um exemplo de neurônio biológico e os componentes que o constituem e a associação como o neurônio artificial foi inspirado.




Figura 8: Exemplo de um neurônio biológico e os componentes que o constituem. Dentrito: Zona receptiva, Soma: Corpo celular, Axônio: As linhas de transmissão, Terminações Sinápticas.

As redes neurais atuais, com seus neurônios não-lineares e com suas funções de ativação, redes em configurações multicamadas como a *multilayer perceptron* juntamente com o algoritmo de treinamento back-propagation, trouxeram um avanço retumbante na área de aprendizado de máquina. Todos estes elementos da rede serão descritos a seguir.

### 3.3.3 Definição

Segundo HAYKIN (2001) o neurônio artificial é a unidade de processamento fundamental de uma (RNA) - Rede Neural Artificial. Essa unidade é constituída de três elementos básicos: um conjunto de sinapses, a junção somadora para somar os sinais de entrada e uma função de ativação. O modelo de neurônio artificial pode ser observado na figura 9.

Historicamente, o primeiro modelo de neurônio artificial foi conhecido como Perceptron de Rosenblatt's ((HAYKIN, 2008). Uma rede com este neurônio era capaz de classificar padrões de classes ditas linearmente separáveis. Em relação a figura 9, o Perceptron era definido conforme a equação 46:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b \quad (46)$$

onde  $x_j$  são as variáveis de entrada da rede e  $w_j$  são os pesos sinápticos da rede, e o subscrito  $k$  indica o número do neurônio e  $m$  é o número de neurônios.

No modelo de neurônio mostrado também pode-se observar o bias  $b_k$ , que é um elemento que tem o objetivo de influenciar no valor de entrada, podendo ser positivo ou



negativo.

O *bias* tem um efeito de aplicar uma transformação afim na saída  $v$  da figura 9. Desta forma, os hiperplanos gerados para separar as classes não passam mais pela origem.

Contudo, classes de problemas linearmente separáveis são poucas e não é possível classificar ou modelar a maior parte dos problemas reais. McCulloch-Pitts então propuseram um modelo de perceptron não-linear, que permite modelar e classificar uma gama muito maior de problemas reais, que não são linearmente separáveis. Este novo neurônio artificial pode ser matematicamente descrito como a equação 47 e está apresentado na figura 9.

$$y_k = \varphi\left(\sum_{j=1}^m w_{kj}x_j + b_k\right) \quad (47)$$

onde  $y_k$  é a saída do neurônio;  $x_1, x_2, \dots, x_m$  são as entradas,  $w_{k1}, w_{k2}, \dots, w_{km}$  são os pesos do neurônio  $k$ ;  $b_k$  é o bias e  $\varphi(\cdot)$  é a função de ativação.

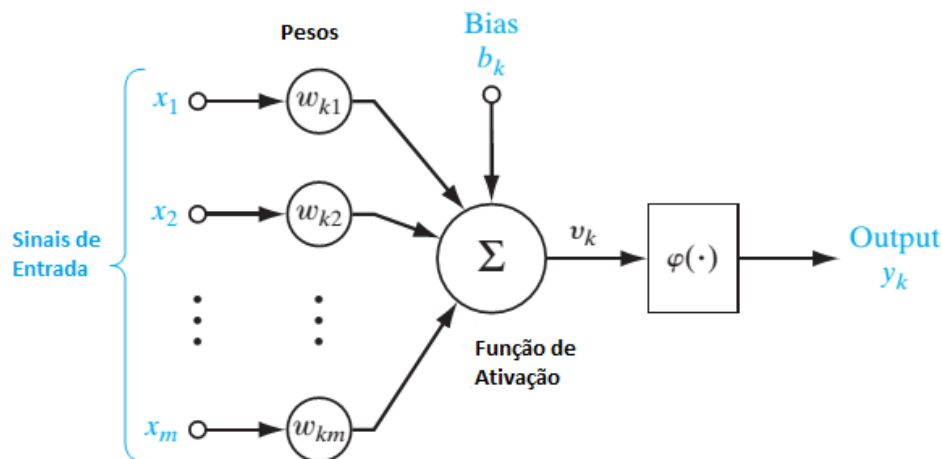


Figura 9: Diagrama do modelo matemático de neurônio artificial.  
Fonte: HAYKIN (2008)

O conjunto de sinapse pode ser caracterizado por um peso ou força  $w_{kj}$  onde o subscrito  $k$  indica o neurônio e  $j$  indica a sinapse do neurônio em questão. Uma entrada representado por  $x_j$  conectada a uma sinapse  $j$  é multiplicada pelo seu respectivo peso sináptico  $w_{kj}$ .

A Função de ativação presente em cada neurônio tem o objetivo de restringir a saída do neurônio, normalmente esse valor é normalizado entre o intervalo  $[0,1]$  ou  $[-1,1]$ . Exemplos de funções de ativação são descritas a seguir.

### 3.3.4 Funções de Ativação

A função de ativação define a saída de um neurônio em termos de potencial de ativação  $v$  como mostrado na figura 9 sendo que  $\varphi(v)$  é a função de ativação e alguns exemplos podem ser: limiar, linear por partes ou sigmoide.

#### 3.3.4.1 Função Limiar

Função limiar ou função degrau tem como função de transferência mostrada na figura 10. Representa a propriedade tudo-ou-nada de um neurônio. Essa função, equação 48, de limiar abrupto é normalmente usada quando se deseja classificar dados linearmente separáveis.

$$\varphi(v) \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (48)$$




Figura 10: Exemplo de uma função limiar.

Fonte: Autor

Onde  $v$  é o campo local induzido, essa função também é reconhecida como função de Heaviside.

#### 3.3.4.2 Funções lineares por partes

Essa função assume uma resposta linear se a operação for restrita a região linear. Se o fator de amplificação  $a$  tender ao infinito a função se restringe a função limiar. A função linear por partes é mostrada na equação 49.

$$\varphi(v) \begin{cases} 1, & v \geq \frac{0,5}{a} \\ a \cdot v - 0,5, & -\frac{0,5}{a} < v < \frac{0,5}{a} \\ 0, & v \leq -\frac{0,5}{a} \end{cases} \quad (49)$$

Se a região linear é mantida sem entrar em saturação, então surge o combinador linear. Do contrário a função limita-se a uma função limiar como pode ser observado na figura 11.




Figura 11: Exemplo de uma função linear por partes.

Fonte: Autor

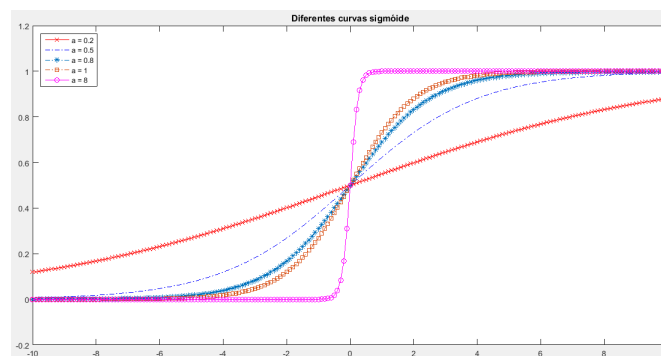
### 3.3.4.3 Função Sigmóide

A função sigmóide é normalmente a função mais usada em redes neurais. Essa função exibe um balanceamento adequado entre um comportamento linear e não-linear. Um exemplo de função sigmóide é a função logística denotada pela equação 50 e mostrada na figura 12:

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (50)$$

onde  $a$  é o parâmetro de inclinação da função. Quanto maior for o valor de  $a$  mais essa função se aproxima da função limiar.

Figura 12: Curvas sigmóides para diferentes valores de  $a$ , ou seja, com diferentes inclinações.



Fonte: Autor

Uma característica importante dessa função é que ela é diferenciável, diferentemente da função limiar. Isso é uma característica importante em aplicações de redes neurais, pois no treinamento da rede uma das condições de parada do treinamento é a derivada do **mse** - *Mean Square Error* - erro quadrático médio.

### 3.3.4.4 Função Rectified Linear Unit (RELU)

A função de ativação relu é uma das funções de ativação mais utilizadas atualmente em algoritmos de *machine learning*. A função de ativação RELU pode ser descrita conforme a equação 51.

$$R(z) = \max(0, z) \quad (51)$$

$$R(z) = \begin{cases} 0 & \text{if } z \leq 0 \\ z & \text{if } z > 0 \end{cases}$$

Um dos motivos que torna esta função de ativação mais atrativa atualmente é que a derivada da função é no mínimo zero e no máximo 1, para os valores negativos de entrada a função retorna zero. Isso faz com que alguns neurônios estejam desativados durante o treinamento tornando o algoritmo e treinamento mais rápido. Outro motivo é que a derivada desta função se mantém constante quando a entrada aumenta, em contraste da função sigmoide que tende a zero, nesse caso. (XU et al., 2015). A curva da função RELU pode ser observado na figura 13




Figura 13: Função Rectified Linear Unit (RELU).

Fonte: Autor

### 3.3.5 Arquitetura da Rede Neural

Algumas necessidades a serem supridas por redes neurais, exigem que a mesma passe por um processo de aprendizagem ou treinamento. Segundo HAYKIN (2001) a arquitetura da rede está ligada intimamente com o algoritmo de aprendizagem. Sendo assim, é necessário entender a arquitetura das redes neurais e isso está relacionado com a forma como os neurônios estão estruturados.

### 3.3.5.1 Redes Alimentadas Adiante de Camada Única

Redes alimentadas adiante de camada única ou (*Single-Layer Feedforward Networks*) é uma arquitetura de rede onde os nós de entradas se projetam sobre a camada de saída de neurônios (nós computacionais). Na figura 14 é possível notar quatro nós de entrada e o mesmo número de neurônios.




Figura 14: Arquitetura de rede neural artificial de camada única.  
Fonte: HAYKIN (2001)

Essa arquitetura de rede é chamada de camada única porque são levados em consideração apenas os nós *computacionais*, nesse caso de uma única camada.

### 3.3.5.2 Redes Neurais *feedforward* com Múltiplas Camadas

As *Multilayer Feedforward Networks* - Redes Alimentadas Diretamente com Múltiplas Camadas, são consideradas redes com uma capacidade maior de aprendizagem. Essa arquitetura difere-se da anterior porque pode ter uma ou mais camadas de nós computacionais (*neurônios*) entre a camada de nós de entrada e os nós de saída. As camadas intermediárias chamadas de camadas *ocultas* podem ser uma ou mais. Segundo HAYKIN (2001), a habilidade de os neurônios ocultos extraírem estatísticas de ordens elevadas é valiosa quando maior for a quantidade do vetor da camada de entrada. Na figura 15 pode ser observada uma rede neural artificial *feedforward* totalmente conectada com múltiplas camadas ocultas.

Os nós da fonte de entrada ou vetor de características de entrada da rede são conectados à entrada da primeira camada de neurônios, chamada de primeira camada oculta. As saídas dos nós da primeira camada oculta vão conectados a entrada dos nós da segunda camada oculta, se essa rede for constituída de mais de uma camada escondida, e assim por diante. Segundo HAYKIN (2001) "os nós da camada de saída constituem a resposta global da rede para o padrão de ativação fornecido pelo nós da fonte da camada de entrada". Quando todos os neurônios estão conectados à todos os nós da camada adjacente diz-se que essa rede é totalmente conectada (15). Caso contrário, se uma sinapse estivesse




Figura 15: Arquitetura de uma rede neural artificial multicamadas, totalmente conectada com camadas ocultas.

Fonte: (HAYKIN, 2008)

faltando a rede seria considerada parcialmente conectada.

### 3.3.6 Paradigmas de Aprendizagem

Como dito no início deste capítulo, uma (RNA) *rede neural artificial* foi estudada com o intuito de modelar a maneira como um cérebro realiza uma tarefa, nada mais natural então concluir que uma (RNA) deve ser treinada para realizar uma determinada tarefa. Talvez a capacidade de treinamento de uma (RNA) seja uma das propriedades mais importantes. É através do processo de treinamento que uma rede pode definir os seus parâmetros livres, ou seja, os pesos das sinapses. O treinamento de uma (RNA) pode ocorrer de duas maneiras: supervisionado ou não supervisionado.

No treinamento supervisionado ou aprendizagem com um professor, o treinamento se dá de maneira que são fornecidos à (RNA) os vetores de entrada e o vetor de saída ou resposta desejada. Os pesos das sinapses são ajustados em função do erro que é calculado como sendo a diferença entre o valor desejado e a resposta (*saída*) da rede. Para analisar a eficiência da (RNA), uma relação do erro quadrático médio e os parâmetros livres (pesos) são relacionados durante o treinamento. Sendo assim uma superfície pode ser visualizada como sendo uma superfície multidimensional de desempenho de erro. Para que o sistema aprenda com o professor um ponto na superfície de erro deve ser movido para baixo sucessivamente em direção ao ponto mínimo. O gradiente do erro médio quadrático em relação aos parâmetros livres da (RNA) fornece um vetor que aponta para a direção mais

íngreme na superfície. O objetivo é sempre procurar pelo ponto mais abaixo na superfície, ou seja, o menor erro.

Segundo HAYKIN (2001) em um treinamento não supervisionado, diferentemente do anterior, não há um professor que possa fornecer os dados de saída e comparar. Em vez disso são dadas as condições para realizar uma medida independente da tarefa da qualidade de representação que a rede deve aprender e os parâmetros livres são otimizados em relação a essa medida. Será abordado apenas o algoritmo de treinamento para redes supervisionadas, tendo em vista que foi usado apenas esse tipo de treinamento nesse trabalho.

### 3.3.7 O Algoritmo Backpropagation

As redes neurais multicamadas podem ser treinadas com o algoritmo *back-propagation* (BP) juntamente como o método de gradiente decrescente do erro quadrático médio como critério de parada.

O algoritmo *Back-Propagation* ((HAYKIN, 2008)) consiste em ajustar os pesos de suas unidades para que a classificação desejada seja obtida. Quando um padrão é inicialmente apresentado à rede, ela produz uma saída. A diferença entre a resposta atual e a resposta desejada é medida e são realizados os ajustes apropriados nos pesos das conexões de modo a minimizar o erro entre o valor desejado e o valor calculado.

O algoritmo *back-propagation* é iterativo e ocorre em duas passagens pela (RNA): primeiramente as instâncias são fornecidas à rede e então os valores são propagados de camada para camada, no sentido *forward*, sendo que normalmente os pesos  $\omega$  da rede são inicialmente escolhidos aleatoriamente e são fixos. No final da primeira passagem é calculado um erro com base na subtração do valor calculado ou saída da rede com o valor desejado. Isso encerra uma iteração do algoritmo. Na segunda fase, na volta ou na etapa de *backward* o erro calculado é então usado para atualizar os pesos das sinapses de cada neurônio, fazendo com isso que a (RNA) tenha a capacidade de se tornar uma função que relacione os valores de entrada com os valores de saída.

Matematicamente o processo de aprendizagem supervisionada é formalizado como uma aprendizagem por correção de erro. Seja então  $y_k(n)$  a saída do neurônio  $k$  para o sinal de entrada  $x(n)$ . A equação 52 representa o sinal de erro observado na saída do neurônio  $k$  no instante  $n$ .

$$e_k(n) = d_k(n) - y_k(n) \quad (52)$$

onde  $d_k(n)$  é o  $k$ -ésimo elemento do vetor de resposta desejada  $d(n)$ . O processo de aprendizagem tem como objetivo minimizar o erro observado (em todos os neurônios), e para tanto busca minimizar um critério, também conhecido como função objetivo, base-

ado na equação 52.

Um critério muito utilizado é a minimização de uma *função custo* baseada nos mínimos quadrados, como mostrado na equação 53.

$$J(\omega) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad (53)$$

onde  $C$  é o conjunto de todos os neurônios na camada de saída. A função custo  $J$  depende do vetor de pesos sinápticos  $\omega$ . O processo de aprendizagem por correção do erro, mais particularmente a minimização de  $J(\omega)$  resulta na *regra delta* de aprendizagem (WIDROW; LEHR, 1990).

O Método de *Back-Propagation* é um processo iterativo que consiste na atualização do o vetor de pesos  $\omega$  em cada iteração conforme a Equação 54.

$$\omega(\mathbf{n}+1) = \omega(\mathbf{n}) - \eta \frac{\partial J}{\partial \omega} \quad (54)$$

Onde  $\eta$  é uma constante que determina a taxa de aprendizagem quando um passo é avançado no processo de aprendizagem. Nota-se que a regra delta pressupõe que o sinal de erro seja diretamente mensurável, ou seja, para que a medida seja realizável, é necessário claramente que a resposta desejada seja fornecida por alguma fonte externa, que seja diretamente acessível ao neurônio  $k$ .

Considerando a função custo  $J(\omega)$  que seja uma função *continuamente diferenciável* de um vetor de pesos desconhecidos  $\omega$ . O problema irrestrito de otimização se refere a minimização da função custo  $J(\omega)$  em relação ao vetor de pesos  $\omega$ . É necessário, portanto, encontrar a solução ótima  $\omega^*$  que satisfaça a condição da Equação 55.

$$J(\omega^*) \leq J(\omega), \forall \omega \quad (55)$$

A condição necessária para a otimização é:

$$\nabla J(\omega^*) = 0 \quad (56)$$

onde  $\nabla$  é o *operador gradiente* e  $\nabla J$  é o vetor gradiente da função custo:

$$\nabla J(\omega) = \left[ \frac{\delta J}{\delta \omega_1}, \frac{\delta J}{\delta \omega_2}, \dots, \frac{\delta J}{\delta \omega_n} \right] \quad (57)$$

### Método da descida mais íngreme

Nesse método de otimização os ajustes sucessivos aplicados ao vetor  $w$  são a favor da descida mais íngreme, ou seja, no vetor gradiente com sentido contrário  $\nabla J(\omega)$ . Assim,



é descrito o valor de atualização do pesos como na Equação 58.

$$w(n+1) = w(n) - \eta \nabla J(w) \quad (58)$$

onde  $\eta$  é uma constante positiva denominada *tamanho do passo* ou *parâmetro de taxa de aprendizagem*. Passando a primeira iteração  $n$ , a seguinte  $n+1$  gera a correção para:

$$\Delta w(n) = w(n+1) - w(n) = -\eta \nabla J(w) \quad (59)$$

O método de descida mais íngreme converge para a solução ótima  $w^*$ . Além disso, o parâmetro  $\eta$  tem grande influência no comportamento quanto à convergência. Quando o parâmetro de taxa de aprendizagem é pequeno, a resposta transitória traçada por  $w(t)$  segue um caminho suave no plano  $w$ . Por outro lado, quando  $\eta$  possui um valor grande, a resposta do algoritmo é subamortecida, e dessa forma a trajetória segue um caminho oscilatório.

Uma maneira de examinar o comportamento de convergência do algoritmo ou de um filtro adaptativo em geral é traçar a curva de aprendizagem. Esse curva é o gráfico do valor médio quadrado do erro de estimação  $J_{med}(n)$  em função do número de iterações  $n$ . Assumindo que o sistema é estável é constato que a curva de aprendizagem média começa com um valor alto em  $J_{med}(0)$ , determinado pelas condições iniciais, e então, decresce a uma taxa determinado pelos parâmetros do sistema até finalmente convergir para um valor estável.

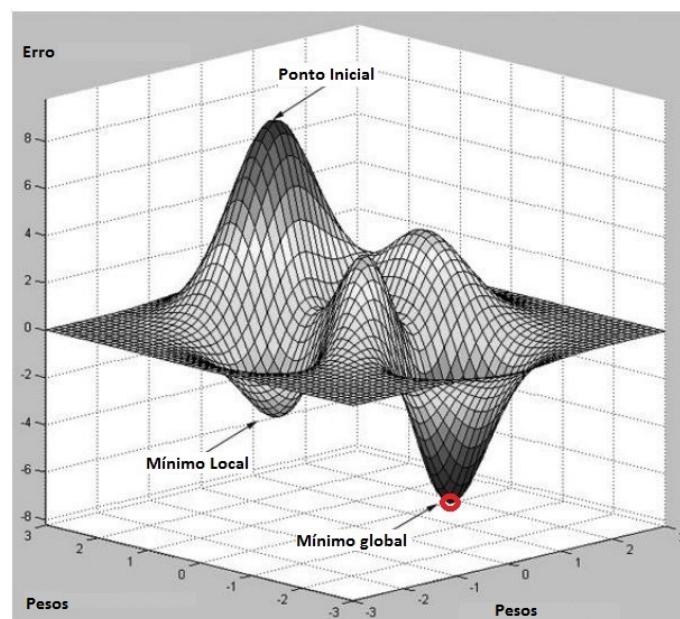


Figura 16: Exemplo de gráfico de erro usando dois valores de pesos.

Para solucionar a questão do mínimo local deve-se levar em conta o valor utilizado na taxa de aprendizagem. Sabe-se que a taxa de aprendizado não deve ser nem muito

grande (pois gera oscilações durante o treinamento prejudicando a convergência) e nem muito pequena (para não tornar o treinamento lento). Logo, se  $\eta$  é pequeno e o algoritmo está preso em um mínimo local, qualquer mudança nos pesos faz o erro aumentar. Se não for possível calcular um  $\Delta w$  que faça a rede neural sair do mínimo local, a rede não conseguirá aprender com a precisão especificada (considerando um erro mínimo).

A Figura 16 apresenta um exemplo de um gráfico de erro para dois pesos. O gráfico foi plotado em 3D para mostrar que a função peso  $J$  é, para problemas mais complexos, uma matriz multidimensional. O algoritmo começa com o maior erro, já que os pesos são iniciados com valores aleatórios. Em cada iteração o algoritmo de otimização diminui o erro e assim acontece a adaptação dos pesos. A escolha de um parâmetro  $\eta$  tem influência no algoritmo geral de forma que evita que a função de otimização encontre um mínimo global, como mostrado na figura. O valor de erro otimizado encontra-se no círculo vermelho da Figura, ou seja, o mínimo global da função erro em relação aos pesos.

## 4 METODOLOGIA

Neste capítulo é apresentada a metodologia usada para realizar os experimentos, os equipamentos utilizados bem como o local onde foi monitorado a cultura e qual foram os tratamentos recebidos pela cultura. O capítulo está dividido de maneira que na seção 4.1 é detalhada a localização do experimento, informações sobre os cultivares como a forma como ele foi conduzido e os tratamentos para gerar uma variabilidade no crescimento. Na seção 4.2 é abordada a questão de aquisição de imagens, informações sobre os equipamentos utilizados tais como o Veículo Aéreo Não Tripulado e suas características e restrições de uso, os sensores de banda visível e os sensores multiespectrais, de forma que, é detalhada todas as características de cada sensor. Na seção 4.3 é abordado o algoritmo de segmentação que foi dividido em 4 passos para melhor entendimento antecedido pelo diagrama de fluxo explicando o processo de segmentação. Por último na seção 4.4 estão os detalhes de como foram divididas as amostras para o treinamento do algoritmo de *Machine Learning*, ou seja, a Redes Neurais Artificiais (RNA). Ainda nesta seção são apresentados os detalhes da configuração da RNA e como foram conduzidos os testes.

### 4.1 Caracterização dos Experimentos

Os experimentos monitorados neste trabalho foram cultivados na Estação Experimental Agrônômica da Universidade Federal do Rio Grande do Sul (EEA/UFRGS), que ocupa uma área de 1.576 hectares entre o km 38,0 e o km 41,3 da rodovia BR-290, em ambas as margens, no município de Eldorado do Sul, RS. Ela está situada na região climática da Depressão Central, entre as latitudes de 30° 04' 30" S e 30° 07' 30" S e as longitudes de 51° 39' 18" W e 51° 42' 18" W (Datum SIRGAS2000) a 46m de altitude. A cultura monitorada durante este experimento pode ser visualizada na figura 17.

#### 4.1.1 Cultivares de Trigo

Neste trabalho foram monitorados experimentos de dois cultivares de Trigo: TBIO-Toruk e BRS-Parrudo durante o período de junho de 2017 a outubro de 2017. O TBIO

- Toruk (*Triticum aestivum* L) é um cultivar criado em 2013 com estatura considerada baixa, o grão é classificado como duro. O peso de mil sementes é de aproximadamente 33g. O ciclo é de aproximadamente 77 dias até o espigamento e 145 dias até a maturação. O BRS - Parrudo (*Triticum aestivum* L) é um cultivar criado no ano de 2012 e tem uma estatura média de aproximadamente 85cm o grão é classificado como muito duro e a produtividade é de aproximadamente de 7.700 Kg/ha. Ciclo de aproximadamente 85 dias até o espigamento e até 135 dias até a maturação.




Figura 17: Cultura monitorada de trigo e seus cultivares.

O experimento foi delineado a partir de parcelas  $2,5m \times 1,80m$ . Cada parcela é constituída de 10 linhas de 2,5m de comprimento e estão distantes entre si de 0,18m, formando uma área de aproximadamente  $4,5m^2$ .

Na figura 17 pode-se observar os cultivares de trigo separados em parcelas. O cultivar Parrudo está delimitado por uma linha tracejada azul e situado entre as linhas 1 e 3 e colunas 1 a 20. O cultivar Toruk está delimitado por uma linha vermelha contínua e encontra-se entre as linhas 8 a 10 e colunas 1 a 21. Os dois cultivares somam um total de 120 parcelas.

#### 4.1.2 Tratamentos

Os tratamentos foram conduzidos em quatro grupos de quatro variações de Nitrogênio (N) para cada cultivar. Os cultivares receberam tratamento em dois estádios de crescimento da vegetação: na emergência (0, 15, 30, e  $45 Kgha^{-1}$ ) e na cobertura (0, 20, 40, 60 e  $80 Kgha^{-1}$ ). A adubação é realizada neste período porque são os estádios mais críticos com relação a absorção de N, ou seja entre a emergência e o estádio de seis folhas expandidas (BREDEMEIER; MUNDSTOCK, 2001). O tratamento foi aplicado a partir de fertilizante em pontos estratégicos, definido pela fenologia do desenvolvimento

da cultura. O tratamento recebido por parcela pode ser visualizado no croqui da figura 40 em anexo, onde as parcelas monitoradas estão enumeradas pelas linhas 1 a 3 e 8 a 10.

Os cultivares receberam tratamento por fertilizantes em duas etapas do ciclo de crescimento da cultura. A primeira dose do tratamento foi na fase de emergência V6, enquanto que a segunda dose de tratamento foi aplicada na fase V6 (estádio da sexta folha completamente expandida).

## 4.2 Aquisição de Imagens

A aplicação de processamento de imagem em agricultura de precisão, com o intuito de monitorar o desenvolvimento ou a quantidade de vegetação associada através da imagem, se dá pela medida de refletância, obtida através da conversão dos valores digitais, cuja a fonte de luz é o sol. Dessa maneira é importante levar em consideração o comportamento espectral do alvo de interesse, nesse caso a vegetação. A refletância da vegetação em função do comprimento de onda, referente ao espectro visível, absorve no comprimento de onda do vermelho (668nm), reflete mais no comprimento de onda verde (560nm) do que no azul (475nm), devido a características intrínsecas da vegetação. No entanto, a refletância eletromagnética (REM) é maior em 717nm (Red Edge) e maior ainda em 840nm (Near Infrared). As curva da refletância da vegetação pode ser vista na figura 6 (VARSHNEY; ARORA, 2004).




Figura 18: Imagem ortorretificada a 50m de altura de todo o experimento monitorado.



Figura 19: Imagem adquirida a partir do VANT de todo o experimento com ângulo de 70°

As imagens foram adquiridas semanalmente entre o ciclo da cultura que foi do dia 14 de junho de 2017 (semeadura) até o dia 24 de outubro de 2017 (colheita) com um total de 19 semanas. As imagens começaram a ser adquiridas a partir da data 29 de junho de 2017 gerando um total de 13 aquisições. As imagens multiespectrais adquiridas com a Sequoia começaram a ser adquiridas a partir do dia 04 de agosto de 2017. Na figura 18 pode-se visualizar um ortomosaico de todo o experimento. Já na figura 19 pode-se observar o experimento, a partir de uma imagem adquirida com a câmera Zenmuse X3 com um ângulo de 70°. A câmera sequoia é composta de quatro canais de banda estreita, verde (GREEN), vermelho (RED), infravermelho próximo (NIR) e borda do vermelho (Red Edge) e um canal de banda visível RGB, este sensor está definido na seção 4.2.4.

#### 4.2.1 Índice de Vegetação

Neste trabalho foram usados 10 índices de vegetação que usam o espectro de radiação visível para a análise dos modelos de predição de biomassa. Os índices usados estão descritos na seção 3.2.3 e estão listados na tabela 1. Os modelos foram comparados com a biomassa medida em campo.

#### 4.2.2 Veículo Aéreo Não Tripulado

Os dados usados neste trabalho foram adquiridos com o uso de alguns equipamentos que serão descritos nesta seção. Foram usadas para aquisição em campo um Veículo Aéreo Não Tripulado VANT, uma câmera cujo sensor faz aquisição no espectro visível e

Tabela 1: Índices de Vegetação extraídos das imagens utilizados para caracterização da biomassa.

Índice de Vegetação	Equação	Aplicação	Autor
ExG Excess Green Index	$2 * G - R - B / (R + G + B)$ $\frac{2 * G - R - B}{R + G + B}$	Separar a Vegetação do Solo	Woebbecke et al. 1993; Hamuda, Glavin, and Jones 2016
NGRDI Normalized Green-Red Difference Index	$\frac{G - R}{G + R}$	Biomassa	Hunt et al. 2005; Hamuda, Glavin, and Jones 2016
ExGR Excess Green menos Excess Red Index	$\frac{3 * G - 2,4 * R - B}{R + G + B}$	Separar a Vegetação do Solo	Meyer et al. 2004; Hamuda, Glavin, and Jones 2016
CIVE Colour Index of Vegetation Extraction	$0,441 * r - 0,811 * g$ $0,385 * b + 18,78745$	Separar a Vegetação do Solo	Kataoka et al. 2003
SCOM Simplified Common	$0,25 * ExG$ $0,30 * ExGR +$ $0,33 * CIVE$	Separar a Vegetação do Solo	Guijarro et al. 2011
exGRaw Excess Green Index	$2 * G - R - B$	Separar a Vegetação do Solo	Woebbecke et al. 1993; Hamuda, Glavin, and Jones 2016
ExGRRaw Excess Green menos Excess Red Index	$3 * G - 2,4 * R - B$	Separar a Vegetação do Solo	Meyer et al. 2004; Hamuda, Glavin, and Jones 2016
CIVERaw Colour Index of Vegetation Extraction	$0,441 * R - 0,811 * G$ $0,385 * B + 18,78745$	Separar a Vegetação do Solo	Kataoka et al. 2003
SCOMRaw Simplified Common	$0,25 * ExGRaw$ $0,30 * ExGRRaw +$ $0,33 * CIVERaw$	Separar a Vegetação do Solo	Guijarro et al. 2011
ExRM Excess Red Modified index	$\frac{2 * R - G - B}{R + G + B}$	Biomassa	SOUZA et al. 2018

um uma câmera multiespectral que faz aquisição de imagens em cinco sensores diferentes.

O Veículo Aéreo não Tripulado usado neste projeto é um quadricóptero modelo Matrice 100 desenvolvido pela empresa DJI no qual foi projetado para desenvolvedores. Uma das características que se distingue de outros modelos do mercado é justamente a alta capacidade de instrumentação. Uma característica importante deste Drone com relação a outros modelos sendo comercializados atualmente no mercado é o chassi que através de suas aletas proporciona uma grande possibilidade de adaptar sensores. Abaixo são listadas as principais características deste Drone.

- Barômetro
- Magnetômetro
- Distância máxima de transmissão 2km
- Velocidade máxima 22m/s sem vento
- Autonomia de 22min sem *pyload*
- Peso máximo de *Takeoff Weight* 3600g
- Altitude máxima de voo 500m



Figura 20: Veículo Aéreo Não Tripulado Matrice 100 usado neste trabalho.

A autonomia está relacionada a capacidade da bateria e ao *payload* no VANT. Com uma bateria de 4500mA/h ele pode realizar voos de até 20min com *payload* nulo. O VANT pode ser visualizado na figura 20.



### 4.2.3 Sensor de Banda Visível

Juntamente com o VANT foi utilizado uma câmera RGB modelo Zenmuse X3 que é acoplada através de um equipamento de estabilização GIMBAL que faz as correções automáticas de pitch e roll. As imagens têm resolução 4K e a descrição do sensor está listada abaixo. A câmera pode ser visualizada na figura 21.

- Distância focal real 3,6mm
- Sensor tipo CMOS
- Resolução 4000x3000 px /12Mpx
- Resolução radiométrica 8 bits
- Armazenamento dos dados em *SDCard*



Figura 21: Câmera RGB usada no VANT.

### 4.2.4 Sensores Multiespectrais

Alguns índices de vegetação, como o NDVI (TUCKER, 1979), foram desenvolvidos de maneira a relacionar a maior refletância da vegetação nos comprimentos de onda no infravermelho próximo. Esse comprimento de onda emitido pela luz do sol, que não é visível, normalmente é analisado a partir de sensores orbitais. No entanto, alguns equipamentos estão sendo projetados com o intuito de realizar aquisição de dados nestes comprimentos de onda. Neste trabalho foram usados os sensores da câmera multiespectral

sequoia. Na figura 22 pode-se observar a câmera multiespectral Sequoia, que é composta de cinco sensores, acompanhada do *Sunshine Sensor*.



Figura 22: Câmera Sequoia juntamente com o sensor de radiação solar.

A câmera sequoia tem resolução radiométrica de 10 ou 8 bits/px. Abaixo é listada algumas características desse equipamento.

- Sensor Green, resolução 1,2 Mpx,
- Sensor Near Infrared 1,2 Mpx
- Sensor RED 1,2 Mpx
- Sensor Red Edge 1,2 Mpx
- Sensor RGB resolução 12 Mpx
- Sunshine Sensor
- Armazenamento interno de 64GB/SDCard
- Magnetômetro.
- Interface de comunicação via WiFi
- Alimentada com fonte externa, não tem bateria. Consumo de 5 - 12 w alimentado com 5 V e consome até 2 A.

Esta câmera usa a forma de aquisição de dados *Global Shutter* e tem uma resolução de 1280 x 960 pixels para os canais monocromáticos, enquanto que para o sensor RGB a resolução é de 4608 x 3456 pixels. Na tabela 2 podemos observar a resolução espacial tanto para os sensores da sequoia quanto para o sensor RGB da câmera Zenmuse X3.

Ainda na tabela 2 os acrônimos (GRE,NIR,RED,REG) fazem referência aos canais da câmera sequoia *Green* (550nm), *Near Infrared* (790nm), *Red* (660nm) e *Red Edge* (735nm), respectivamente.

Tabela 2: Resolução Espacial das ortofotos em função dos sensores

Altura de Aquisição	Resolução Espacial	
	Sequoia(GRE,NIR,RED,REG)	Zenmuse X3 (RGB)
100m	7,92 cm/px	4cm/px
50m	4,18 cm/px	2cm/px
10m	0,94 cm/px	0,33 cm/px

Na tabela 3 estão listados os comprimentos centrais de cada sensor e a largura de banda dos sensores monocromáticos. Todos os sensores monocromáticos tem um largura de banda de 40nm exceto pelo sensor Red Edge porque se trata de um espectro cuja resposta tem uma inclinação muito elevada como pode ser visto na figura 6 o sensor Red Edge faz aquisição de imagens no comprimento de onda 730 até 740 nm respectivamente.

Tabela 3: Resolução Espectral dos sensores da câmera sequoia

	Sensor Monocromático	RGB sensor
shutter	global	rolling (**)
Pixel size	3.75 $\mu m$	1.34 $\mu m$
Focal length	3.98 mm	4.88 mm
Resolution	1280 $\times$ 960 (10 bits)	4608 $\times$ 3456
Green	530-570 nm ou 550 largura de banda 40 nm	
Red	640-680 nm ou 660 largura de banda 40 nm	
Red Edge	730-740 nm ou 735 largura de banda 10 nm	
Near Infrared	770-810 nm ou 790 largura de banda 40 nm	
Focal Lengt h(***)	4.0 [mm]	4.9 [mm]
Sensor Size (***)	4.8 [mm] x 3.6 [mm]	6.2 [mm] x 4.6 [mm]

### 4.3 Segmentação das Parcelas

O algoritmo de segmentação proposto possui 4 etapas e seu fluxograma é apresentado na Figura 23. O Resultado final da segmentação é um Mapa binário contendo parte das parcelas, onde cada parcela é chamada de Região de Interesse (ROI). As 4 etapas consistem em:

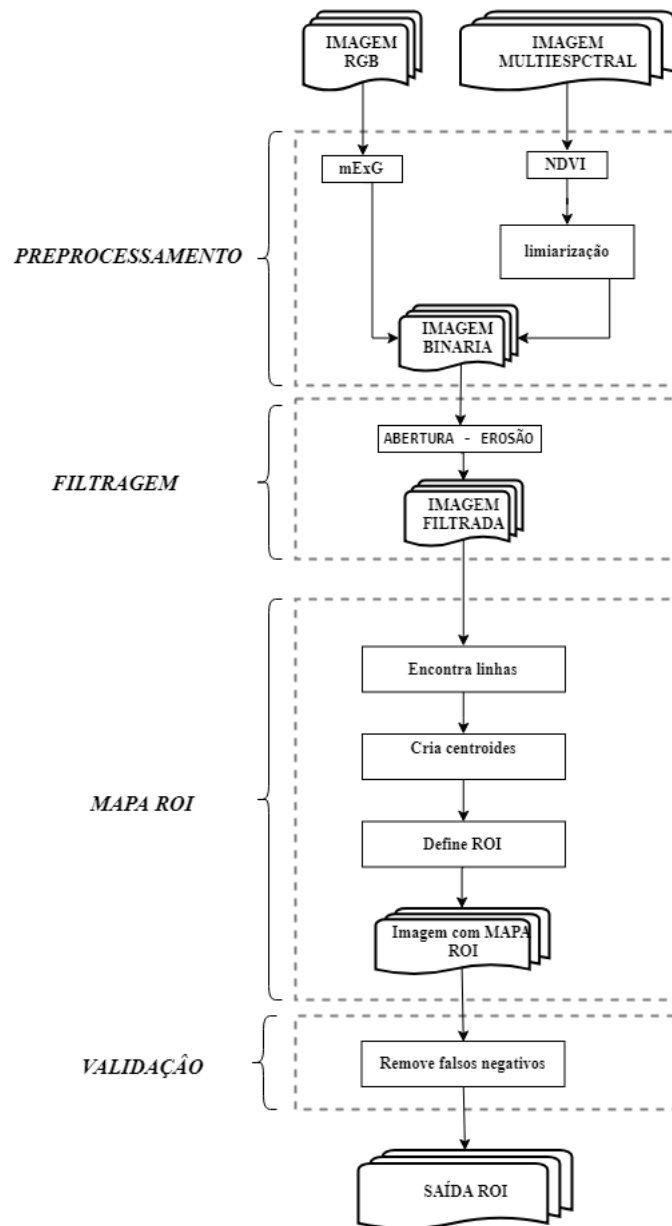


Figura 23: Fluxo do Algoritmo de Segmentação proposto.

1. Preprocessamento
2. Filtragem: Operação Morfológica
3. Geração do Mapa ROI de segmentação
4. Validação das ROIs

**Step 1 - Preprocessamento**

O pré-processamento consiste no cálculo de dois índices das bandas de imagem, a fim de diminuir o efeito de fundo e melhorar a informação espectral relacionada à atividade fotossintética. Para as imagens RGB, um índice personalizado é proposto (índice 1) e é dado pela equação 60. Nesta equação,  $I_G$  e  $I_B$  são os valores de pixel reais dos canais Verde e Azul da imagem RGB original, respectivamente. Então, a imagem de saída  $I_{BIN}$  da equação 60 é uma imagem binária. Esta equação foi gerada de forma empírica, ou seja, outros valores foram testados e este foi o que evidenciou mais as parcelas do solo.

$$I_{BIN} \begin{cases} 1 & \text{if } I_G \leq I_B \text{ or } I_G \leq 0.85 \cdot I_R \\ 0 & \text{otherwise} \end{cases} \quad (60)$$

Um segundo índice, (índice 2) foi utilizado para as imagens multiespectrais usando as bandas espectrais Vermelho e NIR. Esse índice é dado pela seguinte equação 61, em que  $NIR$  é a faixa do infravermelho próximo do espectro e  $I_R$  pixels do canal Vermelho. Após o cálculo de  $I_{NDVI}$ , os valores são reescalados de 0 a 255 conforme pode ser observado na equação 62.

$$I_{NDVI} = \frac{I_{NIR} - I_R}{I_{NIR} + I_R} \quad (61)$$

$$I_{NDVI_{norm}} = 255 * \frac{I_{NDVI} - \min(I_{NDVI})}{(\max(I_{NDVI}) - \min(I_{NDVI}))} \quad (62)$$

Na equação 62, as componentes  $I_{NDVI}$  é o índice NDVI calculado a partir da equação 61,  $\min(I_{NDVI})$  é o valor mínimo do NDVI e  $\max(I_{NDVI})$  é o valor máximo do NDVI. As imagens resultantes do índice 2 foram, então, convertidas em imagens binárias usando um limite definido pelo algoritmo OTSU (OTSU, 1979).

### **Step 2 - Filtragem**

A etapa de Filtragem consiste em aplicar operadores morfológicos às imagens binárias resultantes da Etapa 1 para melhorar a detecção das parcelas. O objetivo é remover a vegetação de fundo excessiva que está além da borda de cada parcela. Um filtro de erosão (abertura) e dois kernels foram selecionados. Ambos os núcleos de tamanho 9x9 e o primeiro é em forma de quadrado, enquanto o segundo é triangular ou em forma de diamante. Todo o procedimento é repetido algumas vezes.

### **Step 3 - Geração do Mapa ROI de segmentação**

Esta etapa consiste em gerar um mapa de segmentação  $I_{Map}$ . A partir das imagens filtradas geradas na etapa anterior e com base na geometria das plotagens, o algoritmo rotaciona a imagem de  $-45^\circ$  para  $45^\circ$  é usado para identificar linhas verticais e horizontais que se encontram ortogonalmente. Para cada vez que a imagem é girada, o número de pixels identificados como uma linha horizontal ou vertical é contado para cada linha ou

coluna. Se o número de pixels em uma linha ou coluna for maior que um limite predefinido, isso será considerado uma linha. As linhas são então desenhadas para gerar um mapa das parcelas. A seguir, um centróide para cada parcela é criado e a partir do qual os ROIs serão construídos usando uma área predefinida.

#### ***Step 4 - Validação do Mapa ROI***

Como etapa final, um processo de validação é realizado com o objetivo de reduzir os erros de inclusão. Esse processo funciona usando os valores médios dos Índices 1 e 2 para todos os pixels em cada parcela e um limite. Assim, parcelas com baixa cobertura vegetal podem ser eliminadas usando um simples operador lógico. Como este primeiro processo tem como objetivo identificar parcelas falsas perto das bordas da área de estudo apenas, uma segunda regra foi criada para garantir que as parcelas com pelo menos duas parcelas vizinhas válidas sejam mantidas.

Esta etapa é realizada em dois estágios: eliminação de falsos positivos usando a área de cada parcela e seu número de vizinhos.

**Estágio 1:** Uma operação lógica AND é executada entre o  $I_{Map}$  com a saída da imagem binária,  $I_{BIN}$  (da etapa 1, como na equação 63). Em seguida, o Algoritmo é aplicado para cada parcela na imagem  $I_{Map}$ .

$$I_{Map} \ I_{Bin} \wedge I_{Map} \quad (63)$$

---



---

#### **Algorithm Map Refine**

---



---

1. IF  
     Plot Area  $\leq$  Area\_Threshold  
     THEN  
     Discard Plot  
     ELSE  
     Keep the Plot
  2. Update  $I_{Map}$
- 

Depois de procurar por falsos positivos com base no tamanho dos objetos detectados, a próxima etapa é percorrer cada lote de mapa atualizado, procurando se as parcelas restantes tiverem pelo menos dois lotes próximos. Se uma parcela tiver menos de 2 vizinhos, ela será descartada. Há alguns casos em que a vegetação baixa (grama / arbusto) era um pouco grande e acabou não sendo removida como deveria. O contrário também acontece, em alguns casos objetos foram erroneamente removidos por causa da baixa vegetação da

parcela. Estes dois problemas foram resolvidos com o seguinte procedimento.

**Estágio 2:** O Mapa  $I_{map}$  é percorrido e, cada vez que um novo objeto é encontrado na imagem, a quantidade de vizinhos desse objeto na imagem resultante da Operação AND é pesquisada e contada. Se uma parcela tiver menos de 2 vizinhos, a parcela será descartada. Além disso, se uma parcela foi descartada por área, mas tem 3 ou 4 vizinhos, ela é incluída novamente. Isso é feito de tal forma que a adição de um novo objeto pode ser feita mais de uma vez.

#### 4.4 Redes Neurais Artificiais (RNA)

Neste trabalho foi usado o algoritmo de Redes Neurais Artificiais como modelo de regressão não linear para a estimativa de biomassa. Foi escolhido para a estrutura da rede uma camada de entrada, três camadas escondidas e uma camada de saída. O número de neurônios e as funções de ativação foram testados de maneira a escolher a melhor configuração para a predição.

Foram usados índices de vegetação para caracterizar a biomassa dos cultivares de trigo conforme citados na seção 3.2.3. Os dados foram divididos de maneira que 67% das amostras foram usadas para o treinamento da RNA e 33% foram reservadas para a validação do modelo. As amostras foram organizadas de maneira que  $\mathbf{x}$  é o vetor de dimensão  $n$  que contém o valor dos índices  $x_i$  de vegetação de  $n$  parcelas onde  $x = x_1, x_2, x_3 \dots x_n$  e  $i \in \mathbb{R}(1, 2, 3 \dots n)$ .

Dessa forma, a entrada da RNA é dada por um conjunto de vetores colunas  $x^T$  formando a matriz  $X(n \times m)$  onde  $n$  é o número de parcelas de um mesmo índice e  $m$  é o número de índices de vegetação. Cada linha da matriz  $X(n \times m)$  é associada a uma saída desejada ou *target*  $t_i$  de  $n$  dimensões onde  $t = t_1, t_2, t_3 \dots t_n$  e  $i \in \mathbb{R}(1, 2, 3 \dots n)$  que contém os valores de biomassa medida manualmente. Os modelos de regressão não linear foram desenvolvidos levando em consideração os índices de vegetação na forma como eles foram extraídos e também na forma padronizada conforme (HAYKIN, 2001; NAYAK; MISRA; BEHERA, 2014). Os dados na forma padronizada fazem com que cada linha da matriz, ou seja, para cada parcela, os valores de índice de vegetação tenha a média zero e desvio padrão unitário.

Na grande maioria dos testes foram usados 10,15,15 e 1 para as camadas de entradas, escondidas e de saída respectivamente. As funções de ativação usadas foram tangente hiperbólica, sigmoide, RELU. O algoritmo de treinamento foi o *backpropagation* usando como função custo o erro médio quadrático e função de otimização Adadelta.

As ferramentas computacionais usadas neste trabalho foram python como linguagem de programação principal, disponível através do sistema de gerenciamento de pacotes

CONDA (CONDA, 2018), com o auxílio do IDE spyder. Os algoritmos de *machine learning* usados neste trabalho estão disponíveis nas bibliotecas SCIKIT (PEDREGOSA et al., 2011; BUITINCK et al., 2013) e KERAS (CHOLLET et al., 2015)



## 5 RESULTADOS

Neste capítulo serão apresentados os resultados obtidos neste trabalho. Como descrito no capítulo 4 as imagens foram adquiridas no ano de 2017 e os resultados foram gerados a partir de imagens adquiridas a altitude de 50m em relação ao solo, no período de cinco semanas. Com o objetivo de prever a biomassa, foram desenvolvidos modelos a partir de índices de vegetação extraídos das imagens. Para isso, um algoritmo de segmentação foi proposto para encontrar a vegetação de interesse de forma automática, e na seção 5.1 é apresentado os resultados com relação à segmentação das parcelas. Em seguida, na seção 5.2, são mostrados os resultados dos modelos de predição de biomassa. Primeiramente, são desenvolvidos modelos de regressão linear simples e, em seguida, um modelo de regressão linear múltipla. Posteriormente, um modelo de regressão não linear baseado no algoritmo de Redes Neurais Artificiais foi implementado. Por último, na seção 5.3 é realizada uma comparação entre o índice de vegetação obtido a partir do sensor Greenseeker e o índice de vegetação calculado a partir de imagens multiespectrais da câmera sequoia para fins de validação.

### 5.1 Segmentação das Parcelas de Trigo

O algoritmo proposto foi aplicado em 10 imagens, 5 imagens RGB e 5 multiespectrais, durante algumas semanas do ciclo do trigo. Aqui será exposto apenas um exemplo de imagem RGB e multiespectral, para fins de simplificação. O objetivo é encontrar a coordenada central de cada parcela e, a partir daí, delimitar uma área dentro da parcela para extrair os dados digitais de cada canal da imagem.

Exemplos de imagens RGB e multiespectrais a serem segmentadas estão nas Figuras 24 e 25, respectivamente. Os resultados são apresentados para cada etapa descrita na seção de segmentação no capítulo de metodologia.

**Resultado - Step 1** A Figura 26 é o  $I_{BIN}$  para a imagem RGB original, que significa imagem binarizada. A binarização de imagem multiespectral está na figura 27.

**Resultados - Step 2**



Figura 24: Exemplo de mosaico de uma Imagem RGB das parcelas de trigo.




Figura 25: Exemplo de imagem multiespectral (bandas NIR, Red e RedEdge) das parcelas de trigo.




Figura 26: Resultado do processo de binarização da Imagem RGB.




Figura 27: Resultado do processo de binarização da Imagem multiespectral.

Como pode ser observado nas figuras 26 e 27 a primeira etapa que consiste na binarização não é suficiente para definir regiões de maneira bem delimitadas, isso porque a binarização gera muitas regiões menores que não são de interesse, que, conseqüentemente, são consideradas ruídos. Portanto a etapa 2 é aplicada para melhorar a separação dessas parcelas. O resultado está na Figura 28. Para isso, nas imagens RGB foram realizadas operações morfológicas de abertura com dois filtros constituídos de kernels de tamanhos 9x9: um quadrado 7 vezes seguido de um em forma de diamante 5 vezes. Já para as imagens multiespectrais, a mesma operação morfológica foi realizada com kernels 9x9, porém a operação de abertura com o kernel quadrado foi realizada 2 vezes e com o diamante 3 vezes.

Nesta etapa de segmentação podemos perceber que o ruído foi removido completamente, no entanto muitas parcelas que eram de interesse também foram removidas das imagens. Isso acontece porque algumas parcelas receberam quantidade menor de fertilizante com o propósito variar a biomassa, sendo assim é natural que algumas parcelas tenham pouca vegetação e sejam consideradas ruídos. Portanto, o próximo passo tenta minimizar estas perdas.

### **Resultados - Step 3**

Após a conclusão do passo 2, o passo 3 começa com a criação do mapa. A criação do mapa inicia-se inserindo parcelas que foram removidas, para isso foi inserido linhas horizontais e verticais na imagem binarizada 28. Para esta etapa as seguintes premissas foram adotadas: a linha tem tamanho de um pixel, a linha não pode coincidir com os pixels de parcelas já existentes.

O resultado desta etapa pode ser visualizado na imagem 29 onde as linhas inseridas estão representadas pela cor vermelha, os pixels brancos são representados pelas parcelas




Figura 28: Resultado do processo morfológico aplicado na imagem binária.

existente na etapa anterior, os pixels pretos é onde as linhas não passaram e consequentemente considerada uma parcela recuperada e por último os pixels verdes são onde as linhas coincidiram com a parcela existente. O resultado parcial do mapa é apresentado na figura 30, mostrando o formato de grade necessário para encontrar os centroides de cada parcela.

Depois que o Mapa é criado, o algoritmo localiza os centroides dos objetos, usando o método *findContours* do OpenCV, para selecionar uma área de tamanho igual predefinida. O tamanho da área definida para ser selecionada em cada objeto para a imagem RGB foi de 900 pixels e para a imagem multiespectral foi de 500 pixels. Na Figura 31 está o mapa com o tamanho da área definida, e na Figura 32 o mapa sobrepõe a imagem original.

Como pode ser observado na Figura 32, o Mapa encontra parcelas em toda a área da imagem, embora no topo do mosaico não haja parcelas. Assim, a próxima etapa é realizada para detectar falsos positivos e removê-los do mapa final de segmentação.

#### **Resultados - Step 4**

Usando o Mapa da Figura 31, o algoritmo faz uma operação lógica AND entre as Figuras 31 e 26. O resultado está na Figura 33. A partir da Figura 33 é feita a contagem de pixels que permaneceram em cada objeto, estágio descrito na seção Metodologia. Posteriormente, a Figura 31 é percorrida removendo os objetos com uma quantidade de pixels por objeto abaixo do limite desejado. Neste caso, foi usado um limite de 10% da área predefinida. Assim, removendo a maioria dos falsos positivos obtidos na Figura 32. No entanto, em alguns casos, os objetos foram removidos incorretamente, os quais podem ser vistos na Figura 34, destacados por círculos vermelhos.

Para resolver este problema e encontrar o mapa de segmentação final, foi aplicado o estágio 2 da etapa 4. Neste estágio, calcula-se a distância entre o centroide de cada




Figura 29: Criação de mapa ROI intermediário - grade binária com linhas encontradas para a criação do mapa.




Figura 30: Criação de mapa ROI intermediário - mapa com as regiões criadas.




Figura 31: Imagem da primeira versão do  $I_{map}$ .




Figura 32: Imagem do  $I_{map}$  sobre a imagem RGB para fins de visualização.

parcela e seu vizinho, depois a média destas distâncias. A distância entre cada centroide e seu vizinho é testada, se esta distância for maior que a média verifica-se a necessidade de inserir uma nova parcela neste intervalo.




Figura 33: Operação Lógica AND do Passo 4.

## 5.2 Modelo de Predição de Biomassa

Com o intuito de desenvolver um modelo de predição de biomassa, inicialmente foi analisado a relação linear entre os índices de vegetação e a Biomassa. Os resultados da regressão linear simples e múltipla estão na seção 5.2.1. Para isso, foram extraídos 12 índices de vegetação predefinida dentro de cada parcela da cultura, como descrito na seção 3.2.3. Para o modelo não-linear de predição de Biomassa foi utilizado o algoritmo de Redes Neurais Artificiais (RNA) e os vetores de entrada e saída da RNA estão descritos na seção 4.4. A amostragem de biomassa realizada no estádio V6 e Florescimento geraram 72 e 120 amostras, respectivamente. Metade destas amostras foram realizadas para cada um dos cultivares.




Figura 34: Exemplo da imagem do  $I_{map}$  com algumas parcelas erroneamente removidas, destacadas por círculos vermelhos.




Figura 35: Mapa final da Segmentação  $I_{map}$ .




Figura 36: Mapa de segmentação final  $I_{map}$  sobreposta na imagem original.

### 5.2.1 Modelo de Predição de Biomassa usando Regressão Linear

O modelo de regressão linear proposto aqui consiste em estimar a biomassa a partir de uma função linear onde a entrada é um índice de vegetação e a saída é o valor de biomassa. Na tabela 4, estão listados os coeficientes de determinação para os modelos de regressão linear para cada um dos índices de vegetação. São 40 coeficientes de determinação, para cada cultivar foi calculado a regressão no estágio V6 e Florescimento.

Tabela 4: Coeficiente de determinação para cada um dos índices de vegetação versus biomassa no modelo de regressão linear

Cultivar	estádio	ExRM	ExGRaw	ExGRRaw	SCOMRaw	CIVERaw	CIVE	SCOM	ExGR	ExG	NGDRI
Toruk	V6	0,17	0,21	0,22	0,22	0,21	0,21	0,21	0,21	0,20	0,21
Toruk	Flor	0,26	0,12	0,26	0,24	0,16	0,23	0,24	0,25	0,22	0,26
Parrudo	V6	0,59	0,63	0,67	0,67	0,64	0,69	0,68	0,68	0,69	0,66
Parrudo	Flor	0,33	0,30	0,36	0,36	0,33	0,33	0,36	0,36	0,32	0,35

A tabela acima citada mostra que para o cultivar, Parrudo no estágio V6, os modelos tem um coeficiente de determinação  $R^2 \geq 0,6$  exceto pelo índice de vegetação ExRM. Para todos os outros modelos, o coeficiente de determinação foi abaixo de  $R^2 0,6$ .

O próximo teste realizado com o modelo de regressão linear simples foi usando como entrada um vetor com índices de vegetação contendo amostras da cultura em ambos os estádios de desenvolvimento, ou seja, os estádios V6 e Florescimento. Na tabela 5 estão apresentados os coeficientes de determinação. Neste modelo de regressão, pode-se observar que o índice de vegetação no qual o modelo foi mais explicativo foi o ExRM com  $R^2 0,76$  e  $R^2 0,73$  para os cultivares Toruk e Parrudo, respectivamente.



Tabela 5: Coeficiente de determinação do modelo linear para os dois estádios

Cultivar	estádio	ExRM	ExGRaw	ExGRRaw	SCOMRaw	CIVERaw	CIVE	SCOM	ExGR	ExG	NGDRI
Toruk	V6+Flor	0,76	0,70	0,21	0,37	0,66	0,46	0,24	0,14	0,50	0,16
Parrudo	V6+Flor	0,73	0,31	0,14	0,03	0,21	0,00	0,11	0,20	0,02	0,55

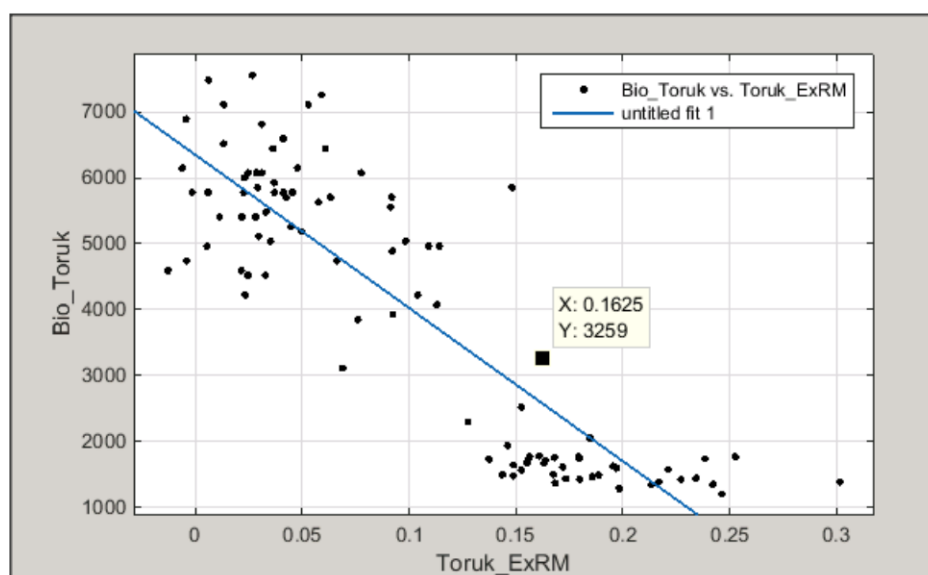


Figura 37: Relação entre o índice de vegetação exRM e a biomassa do cultivar Toruk

Com o intuito de aumentar a correlação entre os índices de vegetação e a biomassa, ou seja, obter um modelo mais preciso, foi analisado a predição usando um modelo de regressão múltipla com todos os 12 índices de vegetação. Os resultados podem ser observados na tabela 6. O Cultivar Parrudo foi bem explicado pelos regressores do modelo para o estágio V6 com  $R^2$  0,70 com uma medida de erro de RMSE = 92,29 Kg/ha e um erro percentual de 5,18%. No entanto, o modelo de regressão múltipla para o estágio Florescimento e para o cultivar Parrudo nos dois estádios resultaram em um coeficiente de determinação  $R^2$  0,6.

Tabela 6: Resultados do modelo de regressão múltipla para um cultivar em uma única data

Cultivar	estádio	$R^2$	RMSE (Kg/ha)	Erro (%)	Biomassa Máxima (kg)
Parrudo	V6	0,70	95,29	5,18	1838,88
	Flor	0,42	855,72	13,43	6370,37
Toruk	V6	0,24	162,87	7,94	2048,88
	Flor	0,43	835,20	11,05	7555,55

O próximo modelo foi implementado usando índices de vegetação das parcelas do

mesmo cultivar usando amostras em ambos os períodos v6 e Florescimento. Os resultados estão na tabela 7, onde a cultivar Parrudo o modelo é explicado pelos regressores por um coeficiente de determinação  $R^2$  0,77 para um  $RMSE$  745,22Kg/ha associado a um erro percentual de 11,69%. Por outro lado, o modelo de regressão para a cultivar Toruk teve um coeficiente de determinação  $R^2$  0,88 com um  $RMSE$  707,65kg/ha e um erro percentual associado de 9,36%.

Tabela 7: Coeficiente de determinação do modelo de regressão múltipla para cada um dos cultivares nos dois estádios

Cultivar	Estádio	$R^2$	RMSE (Kg/ha)	Erro (%)	Biomassa Máxima (kg)
Parrudo	V6+Flor	0,77	745,22	11,69	6370,37
Toruk	V6+Flor	0,88	707,65	9,36	7555,55

Como visto, os resultados apresentados usando modelos de regressão linear simples e múltipla apresentaram uma boa correlação levando em consideração as medidas de índice de vegetação nos dois estádios. Contudo, para uma modelagem mais robusta, será investigado o uso de modelos não-lineares, com intuito de melhorar a correlação entre os índices de vegetação e a biomassa. Na próxima seção, são apresentados, portanto, os resultados usando o algoritmo de Redes Neurais Artificiais.

### 5.2.2 Modelo de Predição de Biomassa Usando Regressão Não Linear

Neste trabalho usou-se como modelo de predição não linear de biomassa uma RNA que foi treinada com algoritmos de *Back-Propagation* descritos anteriormente na seção 3.3.2.

Na tabela 8, pode-se observar os valores de coeficiente de determinação para o primeiro modelo projetado usando RNA quando treinado com amostras coletadas no estádio V6 (27/07/2018) e Florescimento (13/09/2018) para cada um dos cultivares. Pode-se observar que o modelo desenvolvido para o cultivar Parrudo na fase V6 teve um coeficiente de determinação  $R^2$  0.74, para os outros modelos os coeficientes de determinação foi menor. Por outro lado, o coeficiente de determinação para os modelos desenvolvidos na Florescimento não são aceitáveis porque os valores de  $R^2$  são muito baixos, isso significa que as variáveis dependentes desse modelo não são explicáveis pelos regressores do modelo.

Posteriormente, a RNA foi treinada usando os dados de cultivar de Trigo levando em consideração as amostras de biomassa e índice de vegetação para um cultivar nas duas datas (V6 e Flor). Os resultados estão apresentados na tabela 9. Neste caso, quando todas as amostras do mesmo cultivar são levadas em consideração, o coeficiente de determina-

Tabela 8: Coeficiente de determinação usando RNA com amostras de um cultivar para cada estágio de biomassa

Cultivar	Estádio	Número de Amostras	$R^2$	RMSE (Kg/ha)	Erro (%)	Biomassa Máxima (Kg/ha)
Parrudo	V6	36	0,74	90,45	5,14	1759,25
Toruk	V6	36	0,38	147,8	7,62	1938,88
Parrudo	Flor	60	0,43	949,19	14,9	6370,37
Toruk	Flor	60	0,47	912,49	13,24	6888,88

ção aumentou significativamente com relação aos coeficientes de determinação da tabela 8. O cultivar Parrudo obteve um coeficiente de determinação ( $R^2$ ) 0,81 e para o Toruk o coeficiente de determinação ( $R^2$ ) 0,86.

Tabela 9: Coeficiente de determinação usando ANN para modelagem da Biomassa com amostras nos dois estádios do Trigo para cada Cultivar

Cultivar	estádio	Número de Amostras	$R^2$	RMSE (Kg/ha)	Erro %	Biomassa Máxima (kg/ha)
Parrudo	V6 + Florescimento	96	0,81	618,71	12,28	5037,03
Toruk	V6 + Florescimento	96	0,86	767,14	10,25	7481,48




Figura 38: Relação entre amostras medidas e preditas de biomassa do Cultivar Parrudo referentes ao modelo da tabela 9 linha um.




Figura 39: Relação entre amostras medidas e preditas de biomassa do Cultivar Toruk referentes ao modelo da tabela 9 linha dois.

A correlação entre os dados medidos e preditos mostrados nas linhas um e dois da tabela 9 pode ser visualizados nas figuras 38 e 39, respectivamente.

Conforme pode ser observado na tabela 9, o coeficiente de determinação foi maior do que os testes realizados para gerar a tabela 8. Portanto, o próximo resultado foi gerado levando em consideração os índices de vegetação e a biomassa medida em dois estágios para a mesma cultivar.

Neste teste, os índices de vegetação foram padronizados, ou seja, cada índice de vegetação passa a ter média nula e desvio padrão unitário conforme sugerido em (HAYKIN, 2001; NAYAK; MISRA; BEHERA, 2014). Os dados de entrada foram padronizados usando o método de Z-score conforme equação 64, onde cada índice de vegetação ( $a$ ) é subtraído de sua média ( $\mu(a)$ ), e dividido pelo seu desvio padrão, resultando em um índice padronizado ( $A$ ). Conforme pode ser observado na tabela 10, os coeficientes de determinação para os cultivares Parrudo e Toruk são  $R^2$  0,82 e  $R^2$  0,86, respectivamente.

$$A = \frac{a - \mu(a)}{\sigma(a)} \quad (64)$$

Os índices de vegetação são implementados de forma que o valor associado a cada pixel da imagem é normalizado. Na seção 3.2.3, são listados os índices de vegetação normalizados e não normalizados (Raw). Portanto, foi avaliado o uso de índices de vegetação no formato Raw. Na tabela 11 e 12, pode-se observar os coeficientes de determinação para o modelo de predição de biomassa para os índices de vegetação no formato Raw e normalizado. Além disso, os índices usados neste teste foram padronizados conforme a equação

Tabela 10: Todos os índices de vegetação padronizados usados para modelar a biomassa com RNA

Cultivar	Estádio	R <sup>2</sup>	RMSE (Kg/ha)	Erro (%)	Biomassa Máxima (Kg/ha)
Parrudo	V6+Flor	0,82	1168,32	18,34	6370,37
Toruk	Flor+Flor	0.85	963,33	12.75	7555,55

64.

Tabela 11: Coeficiente de determinação dos modelos com índices no modo Raw e padronizados

	índice de vegetação (exGRaw, SCOMRaw, exGRRaw)			
Cultivar	R <sup>2</sup>	RMSE (Kg/ha)	Erro (%)	Biomassa Máxima (Kg/ha)
Parrudo	0.81	1097,61	17,23	6370,37
Toruk	0.87	896,84	11,87	7555,55

Tabela 12: Coeficiente de determinação dos modelos com índices de vegetação (exG, SCOM, exGR) padronizados

	índice de vegetação (exG, SCOM, exGR)			
Cultivar	R <sup>2</sup>	RMSE (kg/ha)	Erro (%)	Biomassa Máxima (Kg/ha)
Parrudo	0,76	1323,12	20,77	6370,37
Toruk	0,84	979,19	12,96	7555,55

O modelo de predição usando os índices de vegetação no formato Raw e padronizados, mostrados na tabela 11, tem uma determinação de  $R^2$  0,81 e  $R^2$  0,87 para os cultivares Parrudo e Toruk, respectivamente. O modelo usando os mesmos índices de vegetação, no entanto normalizados, mostrados na tabela 12, obtiveram uma correlação menor de  $R^2$  0,76 e  $R^2$  0,84 para os cultivares Parrudo e Touk, respectivamente.

Para as repetições de doses de tratamento foi calculada a média e o desvio padrão da biomassa medida manualmente para as parcelas que receberam o mesmo tratamento. Foram desconsideradas, apenas para este teste, as parcelas que tiveram o desvio padrão percentual acima de 20%. Estas amostras foram classificadas como outliers. Neste teste apenas amostras de biomassa medidas no estágio Florescimento apresentaram acima do limiar estabelecido. Após a remoção das amostras consideradas outliers restaram 45 amostras para o cultivar Toruk e 34 amostras para o Cultivar Parrudo. Os resultados podem ser

observados na tabela 13.

Tabela 13: Resultado da predição de biomassa sem as parcelas que tiveram valores de biomassa medida acima de 20% do desvio padrão percentual

Cultivar	estádio	Número de Amostras	R <sup>2</sup>	RMSE (kg/ha)	Erro (%)	Biomassa Máxima (kg/ha)
Parrudo	V6+Flor	70	0,83	714,13	11,90	6000
Toruk	V6+Flor	81	0,93	577,86	7,64	6592,59

### 5.3 Validação dos índices de vegetação obtidos através do Greenseeker e da Sequoia

Foram medidos NDVI de superfície usando o equipamento Greenseeker. Na tabela 14, pode-se observar o coeficiente de determinação entre o NDVI calculado a partir da sequoia e o NDVI medido a partir do Greenseeker. Os resultados mostrados na tabela 5.3 foram obtidos através da correlação entre intra classe, ou seja, a determinação foi calculada entre as parcelas. Na tabela 15, o mesmo procedimento foi realizado, no entanto a determinação foi calculada entre as parcelas do mesmo cultivar.

Tabela 14: Coeficiente de determinação entre o NDVI medido a partir da sequoia e o NDVI medido a partir do Greenseeker

R <sup>2</sup>	Data	
	Sequoia	Greenseeker
0,77	05/08/17	04/08/17
0,66	16/08/17	18/08/17
0,79	31/08/17	01/09/17
0,86	13/09/17	12/09/17

Por outro lado, em uma avaliação inter classe, ou seja a determinação entre o NDVI medido a partir da sequoia e o NDVI medido a partir do Greenseeker para a mesma parcela ao longo do tempo foram iguais a R<sup>2</sup> 0,99 associados a um RMSE médio 0.00858 com um desvio padrão de  $\sigma$  0.0163.

Tabela 15: Coeficiente de determinação entre o NDVI medido a partir de imagens multi-espectrais e o Greenseeker para cada um dos cultivares Toruk e Parrudo

Parrudo			Toruk		
$R^2$	Data		$R^2$	Data	
	sequoia	Greenseeker		sequoia	Greenseeker
0,83	05/08/17	04/08/17	0,71	05/08/17	04/08/17
0,65	16/08/17	18/08/17	0,77	16/08/17	18/08/17
0,80	31/08/17	01/09/17	0,78	31/08/17	01/09/17
0,84	13/09/17	12/09/17	0,91	13/09/17	12/09/17





## 6 CONCLUSÃO E TRABALHOS FUTUROS

Neste trabalho foram apresentados os resultados da aquisição e segmentação de imagens aéreas de dois cultivares de Trigo BRS Parrudo e TBIO Toruk. Também foi implementado um modelo de predição de biomassa a partir de informações extraídas destas imagens usando um modelo de regressão linear simples e múltipla, e um modelo de regressão não linear usando RNA. As imagens foram adquiridas durante o período de junho de 2017 a outubro de 2017 em 10, 50 e 100m e as imagens foram adquiridas em 50 metros de altura. Foi possível gerar um banco de dados de imagens adquiridas destes dois cultivares a partir de dois sensores RGB e multiespectral.

O algoritmo proposto para segmentar automaticamente as parcelas de trigo durante todo o estágio de crescimento foi satisfatório. Este método explora uma maneira viável e simples de segmentar imagens de parcelas de trigo capturadas em condições reais de campo, usando informações de cor e soluciona os problemas de variação de iluminação assimetria das parcelas, o que é de grande valor teórico. A principal contribuição desta aplicação é fornecer uma ferramenta para fins de pesquisa agrônômica e sensoriamento remoto, que realizam essa segmentação manualmente e é fundamental para análises da vegetação. Embora o método consista em ajustar diversas variáveis, uma vez que isto seja feito, funciona adequadamente para todas as imagens adquiridas durante todo o ciclo do trigo. Isso é importante, pois cada semana tem uma mudança significativa no campo. A segmentação realizada nas imagens aqui neste trabalho encontrou todas as parcelas. Tendo as coordenadas dos centros de cada parcela foi possível extrair os índices de vegetação.

Após a segmentação automática, das parcelas de trigo, iniciou-se a investigação de características e métodos para a modelagem de Biomassa. A primeira tentativa de prever a biomassa usando índices de vegetação foi buscar uma relação linear entre a biomassa e cada índice de vegetação individual. A Tabela 4 apresenta os valores de  $R^2$  para as duas cultivares e para cada estágio de crescimento. Os resultados mostraram que os índices de vegetação para cada cultivar em um estágio produziram um bom ajuste entre o índice de vegetação versus biomassa da parte aérea apenas para o Cultivar Parrudo.

No entanto, ao combinar os dados para ambas as fases de crescimento, como apresentado na tabela 5, fica evidente que existe uma relação entre alguns índices de vegetação e a biomassa da parte aérea. Além disso, constatou-se que o Índice Excesso de Vermelho Modificado foi o melhor índice neste modelo linear. Na Figura 37 a biomassa da parte aérea versus ExRM foi apresentada. O declive negativo na plotagem é porque o Índice de Excesso de Vermelho Modificado é baseado no canal vermelho. Isso pode ser explicado pelo fato de que níveis mais altos de biomassa terão maior conteúdo de clorofila foliar por área e menor refletância (maior absorção) na faixa espectral do vermelho visível.

Um modelo de predição usando regressão múltipla linear foi usado com os 12 índices de vegetação. Na tabela 6 podemos observar correlação entre os índices de vegetação e a biomassa. No entanto, apenas o cultivar Parrudo no estágio V6 teve uma correlação  $R^2 = 0,70$ . Já o modelo de regressão múltipla provou correlacionar os índices de vegetação com a biomassa em  $R^2 = 0,77$  e  $R^2 = 0,88$  para os cultivares Parrudo e Toruk, respectivamente.

Como pode ser observado na Tabela 8 e 9, ao utilizar a RNA para modelar a biomassa, foi possível atingir um coeficiente de determinação  $R^2 = 0,81$  para a cultivar BRS Parrudo quando todos os índices de vegetação foram utilizados para o treinamento do modelo. O modelo usando ANN para o cultivar Toruk obteve um  $R^2 = 0,86$ .

A produção de trigo em condições experimentais pode chegar até  $5000\text{Kg/ha}$ , conforme pode ser observado por (GROHS et al., 2007) nos experimentos conduzidos em (2008) na Estação Experimental da UFRGS (Eldorado do Sul, RS). Existe uma relação monotônica crescente não linear entre a produção de grão e o índice de vegetação NDVI conforme observou (GROHS et al., 2009) e consequentemente com a biomassa tendo em vista que a biomassa e o índice NDVI tem a mesma relação. Os modelos não lineares apresentados neste trabalho, usando índices de vegetação do espectro visível, estão associados a um erro RMSE  $618,71\text{ Kg/ha}$  conforme tabela 9 para o cultivar Parrudo. Por outro lado, usando apenas três índices de vegetação obteve-se um erro de RMSE =  $1323,12\text{Kg/ha}$ , como pode ser observado na tabela 12.

Apesar do menor erro RMSE =  $95,29\text{Kg/ha}$  associado ao modelo de regressão múltipla, só foi possível para o cultivar Parrudo no estágio de desenvolvimento V6. O mesmo modelo usando regressão múltipla não teve os seus regressores explicáveis pelos índices de vegetação para o outro estágio de crescimento. O mesmo pode-se concluir para o cultivar Toruk onde o coeficiente e determinação foi  $R^2 = 0,43$ .

Os resultados apresentados nesta dissertação demonstraram que é possível estimar a Biomassa usando imagens RGB e índices de vegetação. Portanto, este trabalho evidencia que mais análises são necessárias para o desenvolvimento de um modelo de predição de forma remota. Ainda, como citado em (BENDIG et al., 2015) a altura da vegetação combinado com o índice de vegetação mostrou correlação maior com a biomassa que

somente o índice de vegetação. Como mencionado neste trabalho, se faz necessário a análise da cultura ao longo do tempo com imagens multimodais. Portanto, técnicas de registro de imagens são sugeridas para análise do desenvolvimento da cultura ao longo do tempo. (PANDIT; TSUYUKI; DUBE, 2018)



## REFERÊNCIAS

- BEDUTTI, A. D. **Um modelo espaço-temporal aplicado à agricultura de precisão**. 2009. 44–79 p. Dissertação de Mestrado PPG em Matemática — Universidade Estadual Paulista (UNESP), São Paulo, 2009.
- BENDIG, J. et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, Amsterdam, NL, v.39, p.79–87, 2015.
- BERNARDI, A. d. C. et al. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 596 p., 2014.
- BIRTH, G. S.; MCVEY, G. R. Measuring the Color of Growing Turf with a Reflectance Spectrophotometer. **Agronomy Journal**, Madison, WI, v.60, n.6, p.640–643, 1968.
- BREDEMEIER, C.; MUNDSTOCK, C. M. Estádios fenológicos do trigo para a adubação nitrogenada em cobertura. **Revista brasileira de ciência do solo**, Campinas, v.25, n.2, p.317–323, 2001.
- BROCKS, S.; BARETH, G. Estimating barley biomass with crop surface models from oblique rgb imagery. **Remote Sensing**, Basel, Switzerland, v.10, n.2, p.268, 2018.
- BUITINCK, L. et al. API design for machine learning software: experiences from the scikit-learn project. In: ECML PKDD WORKSHOP: LANGUAGES FOR DATA MINING AND MACHINE LEARNING, 2013, Prague. **Anais...** Springer, 2013. v.23, p.108–122.
- BURGER, W.; BURGE, M. J. **Digital image processing: an algorithmic introduction using java**. New York, USA: Springer, 2016.
- CÂMARA, G. d. S. Fenologia é ferramenta auxiliar de técnicas de produção. **Visão Agrícola**, [S.l.], v.5, p.63–66, 2006.

CAMPOS, I. et al. Remote sensing-based crop biomass with water or light-driven crop growth models in wheat commercial fields. **Field Crops Research**, New Jersey, USA, v.216, p.175–188, fev. fev. 2018.

CHEN, J. M.; BLACK, T. **Defining leaf area index for non-flat leaves**. Plant, Cell & Environment. Hoboken, New Jersey: Wiley Online Library, 1992. 421–429 p. v.15, n.4.

CHOLLET, F. et al. **Keras**. Disponível em: <<https://keras.io>>.

CONDA. **Anaconda CCloud**. Disponível em: <<https://anaconda.org/>>.

CORREA, S. M. B. B. **Probabilidade e estatística**. Minas Gerais: PUC Minas, 2003.

DE SOUZA, C. H. W. et al. Height estimation of sugarcane using an unmanned aerial system (UAS) based on structure from motion (SfM) point clouds. **International journal of remote sensing**, Philadelphia, PA, v.38, n.8-10, p.2218–2230, 2017.

DEVORE, J. L. **Probability and Statistics for Engineering and the Sciences**. Boston: Cengage learning, 2011.

EEA. **Estação Experimental Agrônômica da Universidade Federal do Rio Grande do Sul**. Disponível em: <<https://www.ufrgs.br/agronomia/joomla/index.php/estacao-experimental-agronomica>>, Acessado: 2018-07-30.

FEEKES, W. De tarwe en haar milieu P. 560-561. **Vers. XVII Tech. Tarwe Comm, Groningen**, [S.l.], 1941.

FRASER, C.; RAVANBAKSH, M. Georeferencing from Geoeye-1 imagery: early indications of metric performance. In: ISPRS HANNOVER WORKSHOP, 2009. **Anais...** [S.l.: s.n.], 2009. v.6.

GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of plant physiology**, Amsterdam, v.160, n.3, p.271–282, 2003.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens**. São Paulo: Pearson Prentice Hall, 2010.

GROHS, D. et al. Estimativa da biomassa e do potencial de rendimento de grãos em cevada através de medições de reflectância. **Ciência Rural**, Santa Maria-RS, v.26, p.192–199, 2007.

GROHS, D. S. et al. Modelo para estimativa do potencial produtivo em trigo e cevada por meio do sensor GreenSeeker. **Engenharia Agrícola. Jaboticabal, SP. Vol. 29, n. 1 (jan./mar. 2009), p. 101-112**, [S.l.], 2009.

GUIJARRO, M. et al. **Automatic segmentation of relevant textures in agricultural images**. New jersey, USA: Elsevier, 2011. 75–83 p. v.75, n.1.

HABOUDANE, D. et al. **Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture. Remote sensing of environment**, New jersey, USA, v.90, n.3, p.337–352, 2004.

HALLIDAY, D.; RESNICK, R.; WALKER, J. **Fundamentos de Física: óptica e física moderna**. Rio de Janeiro: LTC, 2012. v.4, n.9.

HAMUDA, E.; GLAVIN, M.; JONES, E. A survey of image processing techniques for plant extraction and segmentation in the field. **Computers and Electronics in Agriculture**, New jersey, USA, v.125, p.184–199, 2016.

HANSEN, P.; SCHJOERRING, J. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. , New jersey, USA, v.86, n.4, p.542–553, 2003.

HARDERS, S. J. et al. Unmanned Aerial Vehicle Use in Assessing Crop Vitality and Height in Arid Land Cotton Crops. In: ASABE ANNUAL INTERNATIONAL MEETING, 2018, Detroit, MI. **Anais...** ASABE, 2018. p.1.

HAUN, J. Visual Quantification of Wheat Development 1. **Agronomy Journal**, [S.l.], v.65, n.1, p.116–119, 1973.

HAYKIN, S. **Redes Neurais: principios e praticas**. second.ed. Porto Alegre, RS, BR: Bookman, Inc., 2001.

HAYKIN, S. **Neural Networks and Learning Machines**. New jersey, USA: Pearson, 2008.

H.FANG; S.LIANG. Leaf Area Index Models. **Reference Module in Earth Systems and Environmental Sciences**, Amsterdam, NL, v.103, n.D6, p.2139–2148, 2014.

HJ1. **Huan Jing-1**: environmental protection and disaster monitoring constellation.

Disponível em: <https:

//directory.eoportal.org/web/eoportal/satellite-missions/h/hj-1>.

HRUŠKA, J. et al. **Hyperspectral imaging: a review on uav-based sensors, data processing and applications for agriculture and forestry.** *Remote Sensing*, Basel, Switzerland, v.9, n.11, p.1110, 2017.

HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote sensing of environment**, Amsterdam, NL, v.83, n.1-2, p.195–213, 2002.

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

HUNT, E. R. et al. **Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status.** New York: Springer, 2005. 359–378 p. v.6, n.4.

IBGE/SIDRA. **Produção agrícola municipal: cereais, leguminosas e oleaginosas: 2003-2007.** Rio de Janeiro: IBGE, 2016. 1-62 p. n.43.

IBGE/SIDRA. **Levantamento sistemático da produção agrícola.** Rio de Janeiro: IBGE, 2018.

IOVAN, C.; BOLDO, D.; CORD, M. **Detection, segmentation and characterisation of vegetation in high-resolution aerial images for 3d city modelling.** Beijin, China, 2008. 247 p.

JENSEN, A. et al. Radiometric estimation of biomass and nitrogen content of barley grown at different nitrogen levels. **REMOTE SENSING**, Philadelphia, PA, v.11, n.10, p.1809–1820, 1990.

KATAOKA, T. et al. Crop growth estimation system using machine vision. In: INTERNATIONAL CONFERENCE ON ADVANCED INTELLIGENT MECHATRONICS, 2003, Kobe, Japan. **Anais... IEEE**, 2003. v.2, p.b1079–b1083.

LIANG, S.; LI, X.; WANG, J. **Advanced remote sensing: terrestrial information extraction and applications.** San Diego, CA USA: Elsevier, 2012.

MESSINGER, M.; ASNER, G. P.; SILMAN, M. Rapid assessments of Amazon forest structure and biomass using small unmanned aerial systems. **Remote Sensing**, Basel, Switzerland, v.8, p.615, 2016.

MEYER, G. E. et al. Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images. **Computers and electronics in agriculture**, Amsterdam, NL, v.42, n.3, p.161–180, 2004.



MEYER, G. E.; HINDMAN, T. W.; LAKSMI, K. Machine vision detection parameters for plant species identification. In: **PRECISION AGRICULTURE AND BIOLOGICAL QUALITY**, 1999, Boston, Massachusetts. **Anais...** Spring, 1999. v.3543, p.327–336.

MEYER, G. E.; NETO, J. C. Verification of color vegetation indices for automated crop imaging applications. **Computers and electronics in agriculture**, Amsterdam, NL, v.63, n.2, p.282–293, 2008.

MOECKEL, T. et al. Fusion of ultrasonic and spectral sensor data for improving the estimation of biomass in grasslands with heterogeneous sward structure. **Remote Sensing**, Basel, Switzerland, v.9, n.1, p.98, 2017.

MOLIN, J. P.; AMARAL, L. R. do; COLAÇO, A. **Agricultura de precisão**. São Paulo: Oficina de Textos, 2015.

MUKAKA, M. M. A guide to appropriate use of correlation coefficient in medical research. **Malawi Medical Journal**, [S.l.], v.24, n.3, p.69–71, 2012.

MUKHERJEE, J. et al. Relationship between leaf area index of wheat crop and different spectral indices in Punjab. , [S.l.], v.15, p.98–102, 12 2013.

MYNENI, R. et al. Interannual variations in satellite-sensed vegetation index data from 1981 to 1991. **Journal of Geophysical Research: Atmospheres**, Hoboken, New Jersey, v.103, n.D6, p.6145–6160, 1998.

NASA. **NASA Missions**. Disponível em:

<<https://www.nasa.gov/missions>; <https://terra.nasa.gov/>>.

NAYAK, S.; MISRA, B.; BEHERA, H. Impact of data normalization on stock index forecasting. **International Journal of Computer Information Systems and Industrial Management Applications**, Atlanta, GA, v.6, p.357–269, 2014.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, [S.l.], v.9, n.1, p.62–66, 1979.

PANDIT, S.; TSUYUKI, S.; DUBE, T. Estimating above-ground biomass in sub-tropical buffer zone community Forests, Nepal, using Sentinel 2 data. **Remote Sensing**, Basel, Switzerland, v.10, n.4, p.601, 2018.

PARRAGA, A. et al. Wheat Plots Segmentation for Experimental Agricultural Field from Visible and Multispectral UAV Imaging. In: **SAI INTELLIGENT SYSTEMS CONFERENCE**, 2018, London. **Proceedings...** Springer, 2018. p.388–399.

PEDREGOSA, F. et al. **Scikit-learn: machine learning in Python**. **Journal of Machine Learning Research**, [S.l.], v.12, p.2825–2830, 2011.

RA. **Rise Above**. Disponível em: <<https://www.riseabove.com.au/blog/multispectral-imaging-for-agriculture-faq/>>, Acessado: 2018-07-30.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote sensing of environment**, New jersey, USA, v.55, n.2, p.95–107, 1996.

ROUSE JR, J. et al. Monitoring vegetation systems in the Great Plains with ERTS. , Washington, D.C., v.1, 1974.

ROUSE JR, J. W. et al. **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. Greenbelt, Maryland: [s.n.], 1973.

ROY, D. P. et al. **Landsat-8: science and product vision for terrestrial global change research**. **Remote sensing of Environment**, Amsterdam, NL, v.145, p.154–172, 2014.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. San Diego, CA: Elsevier, 2006.

SENTINEL. **Welcome to Sentinel Online**. Disponível em: <<https://sentinel.esa.int/web/sentinel/home>>.

SERPA, M. d. S. **Adequação da densidade de plantas de milho à disponibilidade hídrica em semeadura no final de inverno**. 2011. 38-44 p. Dissertação de Mestrado — PPG Fitotecnia, UFRGS, Porto Alegre, 2011.

SERRANO, L.; FILELLA, I.; PENUELAS, J. Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. **Crop science**, Madison, WI, v.40, n.3, p.723–731, 2000.

SHALABY, A.; ELMOGY, M.; EL-FETOUH, A. A. **Algorithms and Applications of Structure from Motion (SfM): a survey**. **Journal of International Journal of Computer and Information Technology**, [S.l.], v.6, n.06, 2017.

SOUZA, M. Q. Quadros de et al. **Wheat Plots Segmentation for Experimental Agricultural Field from Visible and Multispectral UAV Imaging**. In: IN PROCEEDINGS OF THE 14TH INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE (UNPAGINATED, ONLINE). MONTICELLO, IL, 2018, Montreal, Canada. **Anais...** ;, 2018.

SPIERTZ, J. Grain growth and distribution of dry matter in the wheat plant as influenced by temperature, light energy and ear size. **Neth. J. Agric. Sci.**, [S.l.], v.22, n.3, p.207–220, 1974.

SRIPADA, R. P. et al. Aerial color infrared photography for determining late-season nitrogen requirements in corn. **Agronomy Journal**, Madison, WI, v.97, n.5, p.1443–1451, 2005.

TASKOS, D. et al. Using active canopy sensors and chlorophyll meters to estimate grapevine nitrogen status and productivity. **Precision agriculture**, New York, v.16, n.1, p.77–98, 2015.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote sensing of Environment**, New jersey, USA, v.8, n.2, p.127–150, 1979.

TURRA, M. A. **Manejo do nitrogênio em cultivares de trigo baseado no índice de vegetação por diferença normalizada (NDVI)**. 2016. 40–55 p. Dissertação de Mestrado — PPG Fitotecnia, UFRGS, Porto Alegre, 2016.

VARSHNEY, P. K.; ARORA, M. K. **Advanced image processing techniques for remotely sensed hyperspectral data**. Berlin Heidelberg: Springer Science & Business Media, 2004.

VILJANEN, N. et al. A Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone. **Agriculture**, Basel, Switzerland, v.8, n.5, p.70, 2018.

VINCINI, M.; FRAZZI, E.; D'ALESSIO, P. A broad-band leaf chlorophyll vegetation index at the canopy scale. , New York, v.9, n.5, p.303–319, 2008.

WANG, L. et al. Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. **The Crop Journal**, Amsterdam, NL, v.4, n.3, p.212–219, 2016.

WATSON, D. J. Comparative physiological studies on the growth of field crops: i. variation in net assimilation rate and leaf area between species and varieties, and within and between years. **Annals of botany**, [S.l.], v.11, n.41, p.41–76, 1947.

WENG, Q. **Advances in environmental remote sensing: sensors, algorithms, and applications**. Boca Raton, FL: CRC Press, 2011.

WIDROW; LEHR, M. 30 Years of Adaptive Neural Networks: perceptron, madaline, and backpropagation. **Proceedings of the IEEE**, [S.l.], v.78, n.9, p.1415–1442, 1990.

WILHELM, W.; RUWE, K.; SCHLEMMER, M. R. Comparison of three leaf area index meters in a corn canopy. , Madison, WI, v.40, n.4, p.1179–1183, 2000.

WILLMOTT, C. J.; ROBESON, S. M.; MATSUURA, K. A refined index of model performance. **International Journal of Climatology**, [S.l.], v.32, n.13, p.2088–2094, 2012.

WOEBBECKE, D. M. et al. Plant species identification, size, and enumeration using machine vision techniques on near-binary images. In: OPTICS IN AGRICULTURE AND FORESTRY, 1992, Albuquerque, New Mexico. **Anais...** SPIE, 1992. v.1836, p.208–220.

XAVIER, A. C.; VETTORAZZI, C. A. Monitoring leaf area index at watershed level through NDVI from Landsat-7/ETM+ data. **Scientia Agricola**, Piracicaba, Brasil, v.61, n.3, p.243–252, 2004.

XU, B. et al. Empirical evaluation of rectified activations in convolutional network. **arXiv preprint arXiv:1505.00853**, [S.l.], Nov. 2015. Nov., 2015, Disponível em: <http://arxiv.org/abs/1505.00853>.

YUE, J. et al. Estimation of winter wheat above-ground biomass using unmanned aerial vehicle-based snapshot hyperspectral sensor and crop height improved models. **Remote Sensing**, Basel, Switzerland, v.9, n.7, p.708, 2017.

YUE, J. et al. A Comparison of Regression Techniques for Estimation of Above-Ground Winter Wheat Biomass Using Near-Surface Spectroscopy. **Remote Sensing**, Basel, Switzerland, v.10, n.1, p.66, 2018.

ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision agriculture**, New York, v.13, n.6, p.693–712, 2012.

ZHENG, Y.; ZHANG, M.; WU, B. Using high spatial and temporal resolution data blended from SPOT-5 and MODIS to map biomass of summer maize. In: FIFTH INTERNATIONAL CONFERENCE ON AGRO-GEOINFORMATICS, 2016, Tianjin. **Anais...** IEEE, 2016. p.1–5.

## APÊNDICE A CROQUI DO EXPERIMENTO

O experimento de trigo monitorado no ano de 2017 recebeu tratamento por fertilizante nitrogenado na base e na cobertura. As parcelas que receberam este tratamento encontram-se destacadas na figura 40. As parcelas monitoradas soma um total de 120 que são: as linhas 1,2,3,8,9 e 10 e as colunas 1 até 21, todas as parcelas coloridas.

A quantidade de fertilizante aplicado em cada parcela na base e na cobertura estão indicados dentro de cada parcela no croqui da figura 40. Por exemplo, uma parcela que recebeu  $30Kg * ha^{-1}$  na base e  $40Kg * ha^{-1}$  na cobertura está assinalada 30+40. O experimento foi conduzido desta maneira com o intuito de provocar uma variabilidade de biomassa.

		22	21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1			
1	PARRUDO	30	30	30+80	30+60	30+40	30+20	30+0	0+80	0+60	0+40	0+20	0+0	15+80	15+60	15+40	15+20	15+0	0+80	0+60	0+40	0+20	0+0	1		
2		0	0	0+80	0+60	0+40	0+20	0+0	30+80	30+60	30+40	30+20	30+0	45+80	45+60	45+40	45+20	45+0	15+80	15+60	15+40	15+20	15+0	2		
3		45	45	15+80	15+60	15+40	15+20	15+0	45+80	45+60	45+40	45+20	45+0	30+80	30+60	30+40	30+20	30+0	45+80	45+60	45+40	45+20	45+0	3		
4		30	30	R4 - Tx. Absorção de N				R3 - Tx. Absorção de N				R2 - Tx. Absorção de N				R1 - Tx. Absorção de N (cada repetição de taxa de absor. possui 5 parcelas)				4						
5														Sem N	RICA N	60N +	60N + DFR	45N +	45N + DFR	30N +	30N + DFR	15N +	15N + DFR	ON + NDVI	ON + DFR	5
6		60	45	30	15	ON + NDVI	15N +	60N +	30N +	45N + DFR	Sem N	45N + DFR	60N + DFR	RICA N	30N + DFR	15N + DFR	ON + NDVI	60N +	45N + DFR	30N +	ON + DFR	15N +	ON + DFR	15N +	Sem N	6
7		60	45	30	15	ON + DFR	15N + DFR	60N + DFR	30N + DFR	45N +	RICA N	45N +	60N +	Sem N	30N +	15N +	ON + DFR	60N + DFR	45N +	30N +	ON + NDVI	15N +	RICA N			7
8		TORUK	45	0+80	0+60	0+40	0+20	0+0	45+80	X	45+60	45+40	45+20	45+0	15+80	15+60	15+40	15+20	15+0	0+80	0+60	0+40	0+20	0+0	8	
9			0	0	30+80	30+60	30+40	30+20	30+0	15+80	15+60	15+40	15+20	15+0	45+80	45+60	45+40	45+20	45+0	0+80	0+60	0+40	0+20	0+0	9	
10			30	30	15+80	15+60	15+40	15+20	15+0	30+80	30+60	30+40	30+20	30+0	0+80	0+60	0+40	0+20	0+0	30+80	30+60	30+40	30+20	30+0	10	
11			30	30	R4 - Tx. Absorção de N				R3 - Tx. Absorção de N				R2 - Tx. Absorção de N				R1 - Tx. Absorção de N				11					
12	ON + DFR		Sem N	15N +	Sem N	X	X	ON + DFR	30N +	45N + DFR	60N +	ON + DFR	15N +	60N +	30N + DFR	RICA N	45N +	ON + DFR	15N +	45N +	60N +	30N +	RICA N			12
13	ON + NDVI	RICA N	15N + DFR	RICA N	ON + NDVI	30N + DFR	45N + DFR	60N + DFR	ON + NDVI	15N + DFR	60N + DFR	30N +	Sem N	45N + DFR	ON + NDVI	15N + DFR	45N +	60N +	X	X	30N +	Sem N			13	
14	15N + DFR	15N +	30N +	30N +	45N +	45N +	60N +	60N +	NÃO SEMEADO (3ha)														14			
		22	21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1			

Figura 40: Croqui do experimento 2017