



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS ARARANGUÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS DA INFORMAÇÃO E
COMUNICAÇÃO

Rodrigo Cesar Nunes Maciel

**Predição do Teor de Clorofila na Cultura do Arroz Irrigado Utilizando Imagens
Aéreas e Redes Neurais Artificiais**

Araranguá, SC
2021

Rodrigo Cesar Nunes Maciel

**Predição do Teor de Clorofila na Cultura do Arroz Irrigado Utilizando Imagens
Aéreas e Redes Neurais Artificiais**

Dissertação submetida ao Programa de Pós-Graduação em Tecnologias da Informação e Comunicação da Universidade Federal de Santa Catarina para a obtenção do título de Mestre em Tecnologias da Informação e Comunicação.

Orientador: Prof. Roderval Marcelino, Dr.

Coorientador: Prof. Bruno Pansera Espíndola, Dr.

Araranguá, SC

2021

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Nunes Maciel, Rodrigo Cesar

Predição do teor de clorofila na cultura do arroz irrigado utilizando imagens aéreas e redes neurais artificiais / Rodrigo Cesar Nunes Maciel ; orientador, Roderval Marcelino, coorientador, Bruno Pansera Espídola, 2021.

83 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Campus Araranguá, Programa de Pós-Graduação em Tecnologias da Informação e Comunicação, Araranguá, 2021.

Inclui referências.

1. Tecnologias da Informação e Comunicação. 2. Teor de clorofila. 3. Arroz irrigado. 4. Imagens aéreas. 5. Redes neurais artificiais. I. Marcelino, Roderval. II. Pansera Espídola, Bruno. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Tecnologias da Informação e Comunicação. IV. Título.

Rodrigo Cesar Nunes Maciel

**Predição do Teor de Clorofila na Cultura do Arroz Irrigado Utilizando Imagens
Aéreas e Redes Neurais Artificiais**

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca
examinadora composta pelos seguintes membros:

Prof. Antônio Carlos Sobieranski, Dr.
Universidade Federal de Santa Catarina

Prof. Anderson Luiz Fernandes Perez, Dr.
Universidade Federal de Santa Catarina

João Paulo Generoso Silveira, Dr.
Compass Minerals - Plant Nutrition

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi
julgado adequado para obtenção do título de Mestre em Tecnologias da Informação e
Comunicação.

Prof. Fernando José Spanhol, Dr.
Coordenação do Programa de
Pós-Graduação

Prof. Roderval Marcelino, Dr.
Orientador

Araranguá, SC, 2021.

Este trabalho é dedicado aos meus queridos pais, filhos,
esposa e orientadores.

AGRADECIMENTOS

Meu muito obrigado aos meus pais Sérgio e Maria, aos meus filhos Isabeli e Caio e minha querida esposa Eliete, pelo apoio, paciência e compreensão durante todos os momentos de dificuldades enfrentados durante o período de realização deste trabalho. Ao meu professor e orientador Prof. Dr. Roderval Marcelino pelo seu conhecimento, correções, avaliações, enfim, por todo o seu suporte prestado sem medir esforços nesta jornada. Ao meu coorientador Prof. Dr. Bruno Pansera Espíndola, pela parceria e dedicação, conhecimento e orientação sobre o problema estudado. Ao meus colegas e amigos de jornada que compartilharam comigo as centenas de horas trabalhadas nos laboratórios LPA e LABTEL. A todo os membros que compõem o corpo docente e técnico do PPGTIC que me proporcionaram a oportunidade da realização deste trabalho.

RESUMO

Esta pesquisa teve como objetivo desenvolver modelos computacionais para predição do teor de clorofila (Chl) na cultura do arroz irrigado utilizando imagens aéreas do espectro de cores visível e Redes Neurais Artificiais (RNA). Através do dispositivo *clorofiLOG*, foram realizadas medições dos níveis de Chl nas folhas das plantas do arroz e coletado imagens aéreas por uma câmera digital RGB portátil, embarcada em um Veículo Aéreo Não Tripulado (VANT). As imagens foram coletadas com a aeronave em movimento com velocidade de 2 m/s a uma altura de 50 m do solo. Utilizando Processamento Digital de Imagens (PDI), foram extraídos e gerados 42 índices espectrais. Eles foram selecionados e correlacionados com os níveis e Chl medidos. Os índices espectrais foram atribuídos como entrada e as medições de Chl como saída para os modelos de predição. Por se tratar de um problema de regressão não linear, optou-se em solucioná-lo através de RNAs. Foi utilizada a técnica de seleção de características (índices espectrais) por seleção de filtro, selecionando entre os 42 índices espectrais, apenas aqueles com maiores níveis de correlações com os valores de Chl medidos. Desta forma, quatro modelo de RNAs do tipo *Multi Layer Perceptron* (MLP) foram gerados com diferentes configurações. O modelo da RNA 1 foi obtido com 5 entradas, 5 neurônios na camada oculta e desempenho médio de $R^2=0,80$. A RNA 2 foi obtido com 16 entradas, 10 neurônios na camada oculta e desempenho médio de $R^2=0,7395$. A RNA 3 foi gerada a partir da RNA 2 contendo 9 entradas, 10 neurônios na camada oculta e desempenho médio de $R^2=0,7775$. O quarto modelo representado pela RNA 4 foi gerado a partir da RNA 3 contendo com 5 entradas, 10 neurônios na camada oculta e desempenho médio de $R^2=0,799$. As RNAs 1 e 4 obtiveram os melhores resultados e demonstraram que atingiram aos objetivos desta pesquisa. Desta forma evidencia-se a utilidade destes modelos de predição como ferramentas de auxílio à rizicultura. Conclui-se que a RNA 1 obteve o melhor desempenho geral e pode fornecer novas perspectivas na forma de estimar os níveis Chl de forma indireta e rápida em grandes áreas.

Palavras-chave: Níveis de Clorofila. Imagens Aéreas. Veículos Aéreos Não Tripulados. Rede Neurais Artificiais.

ABSTRACT

This research aimed to develop computational models to predict the chlorophyll (Chl) content in rice culture using aerial images of the visible color spectrum and Artificial Neural Networks (ANN). Through the chlorofiLOG device, measurements of Chl content in the leaves of rice plants were performed and aerial images were collected by a portable RGB digital camera, loaded in an Unmanned Aerial Vehicle (UAV). The images were collected with the aircraft moving with speed of 2 m/s and height of 50 m above ground. Using Digital Image Processing (DIP), 42 spectral indexes were extracted and generated. They were selected and correlated with the measured contents of Chl. Spectral indices were assigned as input and Chl measurements as output to the prediction models. Like a non-linear regression problem, it was decided to solve it through ANNs. The technique of selecting characteristics (spectral indexes) by filter selection was used, selecting from the 42 spectral indexes, only those with the highest levels of correlations with the measured Chl values. In this way, four models of ANNs of the Mult Layer Perceptron (MLP) type were generated with different configurations. The ANN 1 model was obtained with 5 inputs, 5 neurons in the hidden layer and an average performance of $R^2=0,80$. The ANN 2 was obtained with 16 inputs, 10 neurons in the hidden layer and an average performance of $R^2=0,7395$. The ANN 3 was generated from ANN 2 containing 9 inputs, 10 neurons in the hidden layer and an average performance of $R^2=0,7775$. The fourth model represented by ANN 4 was generated from ANN 3 containing 5 inputs, 10 neurons in the hidden layer and an average performance of $R^2=0,799$. The ANNs models 1 and 4 obtained the best results and demonstrated that they achieved the objectives of this research. In this way, the usefulness of these prediction models is evidenced as tools to aid rice growing. It is concluded that RNA 1 obtained the best overall performance and can provide new perspectives on how to estimate Chl levels indirectly and quickly in large areas.

Keywords: Chlorophyll Content. Aerial Images. Unmanned Aerial Vehicle. Artificial Neural Networks.

LISTA DE FIGURAS

Figura 1 – Etapas da Metodologia Aplicada.	20
Figura 2 – Planta do arroz sobre solo inundado.	21
Figura 3 – Sistema de plantio do arroz pré-germinado.	22
Figura 4 – Fases de crescimento da planta do arroz.	22
Figura 5 – Áreas de rizicultura nos estados de SC e RS.	23
Figura 6 – Espectro eletromagnético da luz.	25
Figura 7 – Sensores ativos e passivos.	25
Figura 8 – Estrutura multidimensional de uma imagem digital.	26
Figura 9 – Mapa de cores RGB.	27
Figura 10 – Modelos mais comuns de VANTs.	28
Figura 11 – Estrutura de uma rede Perceptron.	30
Figura 12 – Estrutura de uma rede MLP.	32
Figura 13 – Modelos de funções de ativação: (a) Sigmoid, (b) Tangente Hiperbólica, (c) Gaussiana, (d) Complemento Gaussiano, (e) Seno.	32
Figura 14 – Etapas dos procedimentos metodológicos da pesquisa.	39
Figura 15 – Vista aérea do local do experimento.	40
Figura 16 – Unidade Amostral.	41
Figura 17 – Dispositivo Medidor dos Níveis de Clorofila.	42
Figura 18 – Câmera digital utilizada na coleta das imagens.	43
Figura 19 – Aeronave utilizada para transporte da câmera digital.	43
Figura 20 – Plano de voo do VANT.	44
Figura 21 – Exemplo de unidade amostral selecionada.	45
Figura 22 – Exemplos de imagens segmentadas.	47
Figura 23 – Transformação entre espaços de cores.	47
Figura 24 – Performance de Treinamento e Validação da RNA 1.	56
Figura 25 – Histograma de Erros da RNA 1.	56
Figura 26 – Performance de Treinamento e Validação da RNA 2.	57
Figura 27 – Histograma de Erros da RNA 2.	57
Figura 28 – Performance de Treinamento e Validação da RNA 3.	58
Figura 29 – Histograma de Erros da RNA 3.	59
Figura 30 – Performance de Treinamento e Validação da RNA 4.	59
Figura 31 – Histograma de Erros da RNA 4.	60
Figura 32 – Gráficos de regressão da RNA 1.	63
Figura 33 – RNA 1: Variação geral dos erros.	64
Figura 34 – Gráficos de regressão da RNA 2.	65
Figura 35 – RNA 2: Variação geral dos erros.	66
Figura 36 – Gráficos de regressão da RNA 3.	67

Figura 37 – RNA 3: Variação geral dos erros.	68
Figura 38 – Gráficos de regressão da RNA 4.	69
Figura 39 – RNA 4: Variação geral dos erros.	70

LISTA DE TABELAS

Tabela 1 – Trabalhos publicados no PPGTIC.	19
Tabela 2 – Índices Extraídos e Gerados.	49
Tabela 3 – Análise Estatística dos Índices.	50
Tabela 4 – Correlação de <i>Pearson</i>	51
Tabela 5 – Correlação de <i>Spearman</i>	53
Tabela 6 – Arquitetura das RNAs Implementadas.	60
Tabela 7 – Desempenho entre etapas da RNA 1.	65
Tabela 8 – Desempenho entre etapas da RNA 2.	67
Tabela 9 – Desempenho entre etapas da RNA 3.	69
Tabela 10 – Desempenho entre etapas da RNA 4.	71
Tabela 11 – Comparação de desempenhos entre os modelos.	71

LISTA DE ABREVIATURAS E SIGLAS

ANAC	Agência Nacional de Aviação Civil
BP	<i>Back Propagation</i>
Chl	Clorofila
CNN	<i>Convolutional Neural Network</i>
CNP	Concentração de Nitrogênio na Planta
EPAGRI	Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina
GSD	<i>Ground Sample Distance</i>
IA	Inteligência Artificial
IBN	Índice de Balanço de Nitrogênio
ICF	Índice de Clorofila Falker
ICVE	Índice de Cor Verde Escuro
MLP	<i>Multilayer Perceptron</i>
MSE	Mean Squared Error
N	Nitrogênio
NTIC	Novas Tecnologias da Informação e Comunicação
PDI	Processamento Digital de Imagens
PPGTIC	Programa de Pós-Graduação em Tecnologias da Informação e Comunicação
RGB	<i>Red, Green and Blue</i>
RNA	Redes Neurais Artificiais
RNN	<i>Recurrent Neural Network</i>
VANTs	Veículos Aéreos Não Tripulados

SUMÁRIO

1	INTRODUÇÃO	14
1.1	DESCRIÇÃO DO PROBLEMA	15
1.2	OBJETIVOS	16
1.2.1	Objetivo Geral	16
1.2.2	Objetivos Específicos	16
1.3	JUSTIFICATIVAS	17
1.4	ADERÊNCIA AO PPGTIC	18
1.4.1	Identidade	18
1.4.2	Contexto estrutural no PPGTIC	18
1.4.3	Referência	18
1.5	MÉTODO DE PESQUISA	19
1.6	ESTRUTURA DO TRABALHO	19
2	RIZICULTURA NO BRASIL	21
3	SENSORIAMENTO REMOTO POR IMAGENS AÉREAS	24
3.1	SENSORIAMENTO REMOTO	24
3.2	PROCESSAMENTO DIGITAL DE IMAGENS - PDI	25
3.3	VEÍCULOS AÉREOS NÃO TRIPULADOS - VANTS	27
4	REDES NEURAIS ARTIFICIAIS - RNA	29
4.1	DEFINIÇÃO	29
4.2	REDES PERCEPTRON	30
4.3	PERCEPTRON DE MÚLTIPLAS CAMADAS	31
5	ESTADO DA ARTE	34
5.1	PROCEDIMENTOS ADOTADOS	34
5.2	ANÁLISE DESCRITIVA DOS ARTIGOS	35
6	PROCEDIMENTOS METODOLÓGICOS	39
6.1	DESCRIÇÃO DO LOCAL DO EXPERIMENTO	39
6.2	DELINEAMENTO DO EXPERIMENTO	40
6.3	MEDIÇÕES DOS NÍVEIS DE CLOROFILA	41
6.4	AQUISIÇÃO DAS IMAGENS	42
6.5	PREPARAÇÃO DOS DADOS	44
6.5.1	Seleção das Imagens	45
6.5.2	Segmentação das Imagens	45
6.5.3	Extração e Geração de Características	46
6.5.4	Seleção das Características	48
6.6	IMPLEMENTAÇÃO DAS REDES NEURAIS ARTIFICIAIS	52
6.6.1	Treinamento e Validação	55
7	RESULTADOS E DISCUSSÕES	62

7.1	INTERPRETAÇÃO DOS RESULTADOS	62
7.2	RESULTADOS DA RNA 1	63
7.3	RESULTADOS DA RNA 2	65
7.4	RESULTADOS DA RNA 3	67
7.5	RESULTADOS DA RNA 4	69
8	CONCLUSÃO	72
	REFERÊNCIAS	74

1 INTRODUÇÃO

As Novas Tecnologias da Informação e Comunicação (NTIC) têm proporcionado grandes avanços na agricultura, causando uma revolução na mecanização e automatização de grande parte dos processos agrícolas e desta forma, reduzindo os trabalhos manuais e melhorando a produtividade das safras (LIU, Y. *et al.*, 2020). A integração das NTICs com a agricultura tem promovido uma transformação digital nas lavouras. Sensores são usados para medir as condições do solo e das folhas para um controle preciso da saúde das plantas (SUN *et al.*, 2018; CHEN, W. *et al.*, 2019). Monitoramento de grandes áreas, identificação de doenças nas plantas e previsão de colheitas, entre outras, são oportunidades oferecidas pelo sensoriamento remoto (WEISS; JACOB; DUVEILLER, 2019).

Recentemente, os Veículos Aéreos Não Tripulados (VANTs) tem oferecido vantagens sobre outras formas de sensoriamento remoto e estendendo suas capacidades de monitoramento. De forma não destrutiva, as câmeras digitais embarcadas nestas aeronaves proporcionam grande resolução espacial e resolução espectral adaptada do local monitorado (ZHENG *et al.*, 2018). Elas permitem o sensoriamento remoto para a coleta de informações espectrais de grandes áreas de plantio quase que em tempo real (ARTIOLI; BELONI, 2016).

Nos últimos anos, as câmeras digitais tem sido utilizadas na identificação de um dos pigmentos mais importantes, a Clorofila (Chl), responsável pela fotossíntese das plantas e associada a um dos mais importantes nutrientes, o Nitrogênio (N). Relações entre índices de refletância espectral, obtidos a partir das imagens digitais, e níveis de Chl, obtidos a partir medições nas folhas das plantas, indicam o potencial da utilização das câmeras digitais para estimar os níveis de Chl (AMARAL *et al.*, 2019). Em muitos estudos, estas relações são baseadas em correlações matemáticas de linearidades entre os índices espectrais, extraídos das imagens digitais empregando-se técnicas de Processamento Digital de Imagens (PDI) e os níveis de Chl, medidos por sensores nas folhas das plantas (HU *et al.*, 2014; WANG; WANG; SHI *et al.*, 2014).

Porém, a natureza não linear e não determinística das plantações muitas vezes tornam essas relações incompreensíveis (MOHAN; GUPTA, 2019). No entanto, as soluções baseadas em Redes Neurais Artificiais (RNA), uma técnica de Inteligência Artificial (IA), possuem uma inerente habilidade em determinar relações complexas e não lineares de um sistema biológico (KROGH, 2008; PRASAD; GUPTA, 2008; OSAMA; MISHRA; SOMVANSHI, 2015). Imagens digitais no espectro de cores visíveis, por exemplo, também conhecidas como imagens *Red, Green and Blue* (RGB), aliadas ao PDI e as RNAs, vêm demonstrando grande potencial na agricultura e sendo capazes de auxiliarem na estimativa dos níveis de Chl (DUTTA GUPTA; IBARAKI; TRIVEDI, 2014; MARIA *et al.*, 2014; WANG; WANG; SHI *et al.*, 2014; RIGON *et al.*, 2016; MOHAN;

GUPTA, 2019). O exemplo sugerido em utilizar-se câmeras digitais com sensores RGB é devido ao seu baixo custo se comparada às câmeras digitais com sensores multi e hiper espectrais.

Sendo assim, percebe-se que a combinação destas tecnologias pode trazer grandes contribuições ao cultivo de arroz. Os VANTs estão começando a oferecer soluções de baixo custo para vários aspectos relacionados ao monitoramento e gestão sustentável da agricultura (HUNT; DAUGHTRY, 2018; KHANAL; FULTON; SHEARER, 2017; YANG *et al.*, 2017).

1.1 DESCRIÇÃO DO PROBLEMA

O arroz é um cereal de grande relevância a nível mundial. A eficiência de suas safras está fortemente relacionada ao correto suprimento de nutrientes, necessários ao seu desenvolvimento. Além dos nutrientes, a Chl é considerada a molécula de pigmento mais importante na absorção da luz e subsequente transferência de sua energia para condução das reações fotoquímicas da fotossíntese (MOHAN; GUPTA, 2019). A Chl é capaz de caracterizar as condições fisiológicas e ser considerada como um importante indicador do nível de saúde das plantas (CURRAN; WINDHAM; GHOLZ, 1995; PAGOLA *et al.*, 2009; YADAV; IBARAKI; DUTTA GUPTA, 2010; MUÑOZ-HUERTA *et al.*, 2013).

Modernos métodos não destrutivos baseados em sensores espectrais tem recebido considerável atenção devido às suas capacidades de medição dos níveis de Chl em tempo real (HU *et al.*, 2014; JINWEN, 2014; NOVICHONOK *et al.*, 2015). Desta forma, diferentes tipos de dispositivos eletrônicos para medições da Chl foram desenvolvidos. Conseguem medir a absorvância e a refletância espectral das folhas para estimar os níveis de Chl (PAGOLA *et al.*, 2009; NOVICHONOK *et al.*, 2015). Dois dispositivos comuns são o *SPAD-502* (Minolta Camera Co., Osaka) e o *cloroFILOG* (Falker Automação Agrícola). Porém, a utilização destes dispositivos requer um grande numero de repetições nas medições, dada a pequena área de medição dos sensores nas amostras e aos possíveis erros cometidos pelo operador durante o manuseio do dispositivo (MOHAN; GUPTA, 2019).

Em contrapartida, sensores hiper espectrais embarcados em satélites, por exemplo, podem obter informações simultâneas de várias bandas espectrais além de captarem imagens com cobertura espacial em grandes escalas (CHEN, P. *et al.*, 2010; LI, F. *et al.*, 2014). Mas, o alto custo destas imagens, a baixa frequência de passagem dos satélites sobre a área de interesse e os riscos da presença de nuvens no momento da captura das imagens, limitam a aplicação destas plataformas (ZHANG; KOVACS, 2012). Também existem outras soluções comerciais que conseguem melhores resultados que os satélites. Sensores de proximidade tais como o *GreenSeeker* (NTech Industries Inc.) e o *Yara N-sensor* (Yara International ASA), instalados a 1 m de

altura sob as plantas, são capazes de medir a reflectância das folhas das plantas na banda do infra-vermelho próximo, superando as limitações dos satélites (SAMBORSKI; TREMBLAY; FALLON, 2009). No entanto, sua acurácia é influenciada por interferências causadas pela reflectância da cor escura do solo abaixo das plantas (CHEN, P. *et al.*, 2010).

De forma alternativa, as câmeras digitais convencionais podem indicar soluções de baixo custo, pois conseguem gerar imagens de alta resolução dentro do espectro de cores visíveis. Desta forma, consegue-se medir a intensidade da coloração das folhas das plantas, além de fácil distinção entre a vegetação e o solo, o que facilita a segregação, ou segmentação, das partes que compõem cada imagem (BERGER; PARENT; TESTER, 2010; LI, Y. *et al.*, 2010; GOLZARIAN *et al.*, 2011; WANG; WANG; GANG *et al.*, 2012).

Diante deste contexto, este trabalho visa responder a seguinte pergunta de pesquisa:

É possível desenvolver modelos computacionais para predição do teor de clorofila em uma plantação de arroz irrigado utilizando imagens aéreas RGB e Redes Neurais Artificiais?

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Esta pesquisa tem como objetivo desenvolver modelos computacionais para predição do teor de clorofila em uma plantação de arroz irrigado, utilizando imagens aéreas RGB e Redes Neurais Artificiais.

1.2.2 Objetivos Específicos

Para que o objetivo geral seja alcançado, os seguintes objetivos específicos foram elaborados:

1. Identificar uma área de plantio de arroz irrigado que demonstre variações na pigmentação das planta e seja apropriada para o experimento;
2. Determinar e demarcar sobre a área do experimento, as unidades amostrais para coleta dos níveis de clorofila;
3. Identificar um padrão de voo para o VANT que possibilite sobrevoar a área de experimento com altitude e velocidade adequadas a coleta das imagens aéreas;
4. Identificar técnicas de PDI adequadas à extração de índices espectrais das imagens aéreas da plantação de arroz;

5. Definir e aplicar modelos de RNAs visando correlacionar os índices espectrais das imagens com os níveis de clorofila medidos na plantação;

1.3 JUSTIFICATIVAS

O arroz é considerado um dos cereais de maior importância econômica nos países em desenvolvimento, constituindo-se um alimento básico para essas populações (CANTRELL, 2002; CANCELLIER *et al.*, 2011). A região do vale do Araranguá, segundo a Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (EPAGRI), é a maior produtora de arroz entre as 11 micro regiões produtoras do Estado, com produção estimada para a safra 2019/20 de 404,02 mil toneladas, equivalente a 35,14% da produção total do Estado (EPAGRI; CEPA, 2019). Isso evidencia a grande importância econômica que a rizicultura representa a esta região.

Estes altos níveis de produção são conseguidos graças as boas práticas de manejo da cultura do arroz e utilização de vários tipos de fertilizantes para a suplementação nutricional das plantas. No entanto, a falta ou ineficiência dos dispositivos existentes para identificação dos níveis de Chl, evidenciam incertezas quanto a saúde nutricional das plantas. Pode-se facilmente observar variações na tonalidade da cor verde da vegetação, causada principalmente pela desigualdade dos níveis de Chl entre as plantas. Maior tonalidade na cor verde indica maior concentração de Chl e conseqüentemente, melhor é a saúde da planta. Mas, estas incertezas induzem os agricultores a aplicarem os fertilizantes, principalmente os nitrogenados, de forma homogênea em toda a plantação. No entanto, isso pode provocar excessos de nutrientes naquelas plantas já bem nutridas, causando doenças, perdas na produção e contaminação do solo.

Para mitigar esses problemas, as NTICs oferecem grandes oportunidades de auxílio a identificação dos níveis de Chl nas plantações de arroz. As câmeras digitais RGB são de pequeno porte, fáceis de transportar e possuem alta qualidade em suas imagens, com preços mais acessíveis se comparadas as câmeras multi e hiper espectrais. Além disso, os VANTs estão se popularizando dado a redução em seu custo de aquisição e ao seu elevado grau de automatismo. Essas aeronaves podem sobrevoar com rapidez grandes áreas de plantio e embarcar diversos dispositivos para sensoriamento remoto. Essas tecnologias reunidas podem viabilizar o monitoramento dos níveis de Chl de grandes áreas de plantações de arroz com maior rapidez e de forma não destrutiva.

Com base nestes argumentos, essa pesquisa busca proporcionar resultados satisfatórios, combinando os potenciais do emprego de VANTs com aplicações de técnicas de PDI e RNAs, juntos visando a construção de modelos computacionais para predição de Chl em plantações de arroz irrigado. Espera-se que a junção destas tecnologias possa contribuir para as ciências agrônômicas como ferramenta de auxílio

na gestão da saúde das lavouras.

1.4 ADERÊNCIA AO PPGTIC

1.4.1 Identidade

Essa pesquisa se identifica, dentro do Programa de Pós-Graduação em Tecnologias da Informação e Comunicação (PPGTIC), com a linha “Tecnologia Computacional”, pois visa utilizar ferramentas computacionais para a solução de problemas de natureza interdisciplinar (Tecnologia, Agronomia e Gestão).

1.4.2 Contexto estrutural no PPGTIC

Este trabalho se contextualiza com as linhas de pesquisa do PPGTIC da seguinte forma:

- Computacional: serão utilizadas tecnologias computacionais atuais na busca dos objetivos dessa pesquisa;
- Gestão: os resultados dessa pesquisa poderão melhorar a gestão das lavouras de arroz da região do vale do Araranguá, contribuindo para a redução dos gastos com fertilizantes e melhoria da produtividade;
- Agronomia: essa pesquisa busca auxiliar as ciências agronômicas no desenvolvimento de novas formas de identificação de níveis de Chl em grandes áreas e de forma rápida e não destrutiva.

1.4.3 Referência

Esta etapa teve como objetivo realizar uma busca na base de dados do PPGTIC por trabalhos correlatos de outros autores. Isso foi necessário para comprovar a inexistência de trabalhos semelhantes e garantir a originalidade desta pesquisa dentro do PPGTIC. Sendo assim, a Tabela 1 lista os trabalhos de outros autores publicados até o dia 14 de Agosto de 2019, período em que foi realizada a busca na base de dados. Embora os trabalhos listados na Tabela 1 também se refiram a automação de processos na agricultura, é possível observar que nenhum deles abordou temas relacionados ao plantio do arroz, sensoriamento por imagens aéreas e identificação de Chl. Por fim, essa pesquisa se diferencia das demais por ser aplicada em escalas maiores, além de propor um impacto global maior tanto na questão econômica quanto ambiental, caso consigam-se atingir seus objetivos.

Tabela 1 – Trabalhos publicados no PPGTIC.

Título	Autor	Ano
Agricultura de precisão em casas de vegetação: controle e gestão de cultivo em produção de mudas	Braz da Silva Ferraz Filho	2018
Um sistema de controle de energia sustentável para abrigos de cultivo	Cristiano S. P. de Abreu	2018
Avaliação de um sistema de controle autônomo para o monitoramento de abrigos de cultivo	Ronaldo T. M. junior	2016

Fonte: Do autor.

1.5 MÉTODO DE PESQUISA

Esta Seção descreve a metodologia empregada nesta pesquisa. Também a descreve quanto a sua classificação, abordagem, natureza, objetivos e procedimentos.

Esta pesquisa é classificada como sendo de caráter interdisciplinar. Envolve áreas distintas tais como Tecnologias da Informação e Comunicação, Engenharia de Computação e Engenharia Agrônômica.

Quanto a sua abordagem, predomina-se a análise quantitativa, pois emprega a coleta, medição e tratamento de dados além de correlações e outras ferramentas estatísticas (RICHARDSON, 1999).

Quanto a natureza, classificada-se como pesquisa aplicada, pois utiliza recursos computacionais na busca de soluções práticas a resolução de um problema específico (CERVO; BERVIAN; SILVA, 2007).

Quanto aos objetivos, classifica-se como explicativa pois tenta explicar causa e efeito gerado por medições de dados em campo, visando respostas a problemas baseados em testes experimentais (MARCONI; LAKATOS, 2001).

Conforme descrito em Marconi e Lakatos (2001), no que refere-se aos procedimentos, pode-se caracterizá-la como bibliográfica, pois sua fundamentação teórica e experimental é baseada em trabalhos correlatos de fontes distintas publicadas em artigos de periódicos.

A Figura 1 ilustra o fluxograma com as etapas realizadas nesta pesquisa.

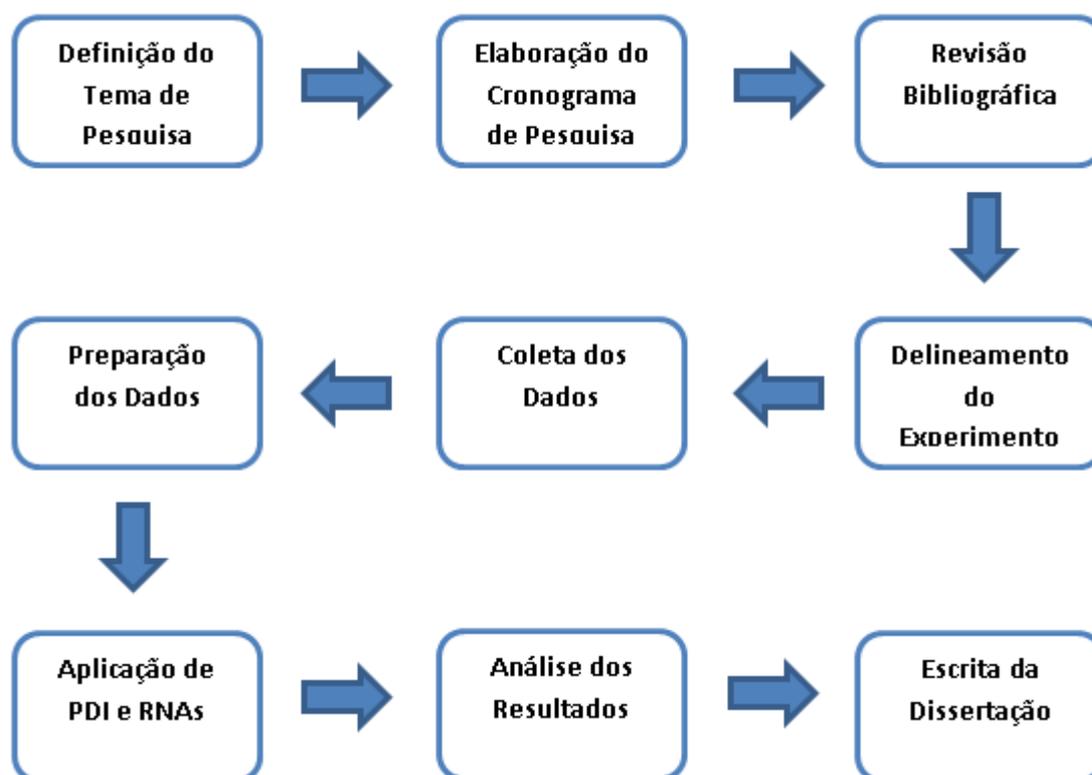
1.6 ESTRUTURA DO TRABALHO

Esta dissertação foi organizada em oito capítulos e referências bibliográficas.

O Capítulo 1 faz a contextualização do tema de pesquisa, apresenta os objetivos, as justificativas, descreve a aderência da pesquisa ao PPGTIC, a metodologia desenvolvida e finaliza com a estrutura da dissertação.

O Capítulo 2 apresenta conceitos sobre a rizicultura. Descreve sua importância econômica a nível mundial, nacional e regional. Também descreve as características

Figura 1 – Etapas da Metodologia Aplicada.



Fonte: Do autor.

biológicas e tratamentos agrônômicos durante as fases de cultivo da planta.

O Capítulo 3 apresenta conceitos sobre Sensoriamento Remoto por Imagens Aéreas. Descreve suas caracterizações e as principais tecnologias envolvidas.

O Capítulo 4 apresenta conceitos sobre as Redes Neurais Artificiais. Descreve as arquiteturas de redes mais comuns, as formas de aprendizado e suas aplicações.

O Capítulo 5 apresenta os estado da arte. Demonstra os principais resultados de alguns trabalhos correlatos a esta pesquisa.

O Capítulo 6 descreve todos os procedimentos metodológicos utilizados para se alcançar os objetivos propostos nesta pesquisa.

O Capítulo 7 apresenta e discute, através de gráficos e tabelas, os resultados dos modelos de redes neurais desenvolvidas visando a predição dos níveis de Chl nas plantas do arroz.

O Capítulo 8 apresenta as conclusões. Baseado na análise dos resultados, tenta-se responder a pergunta de pesquisa e apresenta sugestões para trabalhos futuros. Na sequência são apresentadas todas as referências bibliográficas utilizadas nesta pesquisa.

2 RIZICULTURA NO BRASIL

Segundo Yoshida (1981), o arroz é uma planta herbácea incluída na classe Liliopsida, ordem Poales, família Poaceae, gênero *Oryza*. É uma gramínea de ciclo anual e com capacidade de adaptação à ambientes aquáticos conforme ilustra a Figura 2.

Figura 2 – Planta do arroz sobre solo inundado.



Fonte: Do autor.

A maior parte da produção mundial de arroz é cultivada e consumida na região asiática, principalmente pela China e Índia, responsáveis por mais de 50% do total da produção mundial (SATO; REIS, 2020). A América Latina e a África também vêm apresentando um crescimento considerável na produção e consumo do arroz (MUTHAYYA *et al.*, 2014). No Brasil, os estados do Rio Grande do Sul e Santa Catarina se destacam, com níveis de produção anuais acima de um milhão de toneladas (CONAB, 2019). De acordo com o relatório do CONAB (2020), estimou-se para a safra de 2020 uma produção em torno de 11,2 milhões de toneladas, representando um aumento de 6,5% em relação à safra de 2019. A área plantada sofreu redução de 2,2%, como vem acontecendo nas últimas safras. Apesar da redução da área cultivada nos últimos anos, a proporção do plantio de arroz irrigado gera uma maior produtividade, o que vem permitindo a manutenção da produção ajustada ao consumo nacional.

Quanto a sua forma de cultivo, no estado de Santa Catarina (SC) predomina-se o sistema de plantio pré-germinado sob terreno irrigado (FURTADO; LUCA, 2003). Esse sistema consiste na semeadura das sementes de arroz em áreas niveladas e com lâmina d'água existente conforme ilustrado na Figura 3.

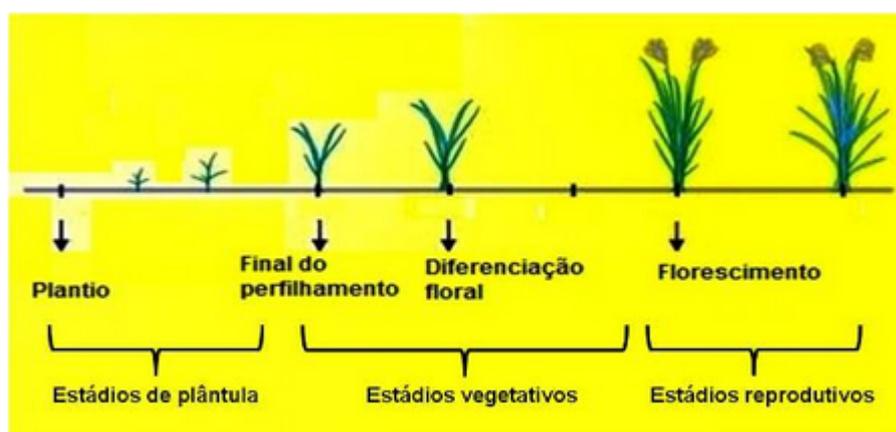
Figura 3 – Sistema de plantio do arroz pré-germinado.



Fonte: <https://www.mundoecologia.com.br>

Ainda segundo Furtado e Luca (2003), essa técnica é muito utilizada pois facilita o controle de plantas daninhas prejudiciais ao arroz. Para a região do litoral Catarinense, Steinmetz e Braga (2001) indicam que a semeadura do arroz deve ser feita entre os meses de agosto a janeiro, dependendo do cultivar utilizado. Conforme Yoshida (1981), seu ciclo de desenvolvimento pode ser dividido em três fases principais: plântula, vegetativa e reprodutiva, conforme ilustrado na Figura 4. A duração de cada

Figura 4 – Fases de crescimento da planta do arroz.



Fonte: <https://www.agrolink.com.br>

fase depende do cultivar, da época de semeadura, região de cultivo e das condições de fertilidade do solo, sendo que a duração do ciclo de plantio pode variar entre 100 à 140 dias. As variedades da espécie diferem no tamanho dos grãos e na altura da planta.

Segundo Alonço *et al.* (2004), os solos apropriados ao cultivo do arroz irrigado, especificamente nos Estados do Rio Grande do Sul (RS) e SC, são encontrados,

principalmente, nos ecossistemas de várzeas formados por planícies de rios, lagoas e lagunas. Em SC, os solos cultivados com arroz irrigado ocupam áreas relativamente menores, que representam, aproximadamente 7% da área total do Estado. Estão localizadas principalmente nas planícies litorâneas, ao sul, da divisa com o RS até o Cabo de Santa Marta, e ao norte, na Baía de Babitonga e região de Joinville e Itajaí, incluídas as várzeas dos sistemas fluviais dos rios Araranguá, Tubarão, Itajaí-Açu, Itapoçu e Piraí. Os 10% restantes ocorrem no planalto de Canoinhas, nas várzeas dos rios Negro, Canoinhas e Iguaçu, em altitudes que variam desde valores próximos ao nível do mar até 1.100 m. A Figura 5 ilustra um mapa de ocorrência de plantações de arroz nos estados de SC e RS.

Figura 5 – Áreas de rizicultura nos estados de SC e RS.



Fonte: Alonço *et al.* (2004).

Embora os solos de plantio de arroz sejam, em sua maioria, ricos em nutrientes, é necessário uma complementação nutricional através de adubações em várias etapas do crescimento do planta. Entre os nutrientes destacam-se o N, P e K. O N cumpre um papel de destaque, por ser o nutriente que proporciona as maiores respostas com grande eficiência na capacidade de promover aumento de produtividade por unidade de nutriente adicionado ao solo (ALONÇO *et al.*, 2004).

3 SENSORIAMENTO REMOTO POR IMAGENS AÉREAS

Este capítulo apresenta conceitos básicos sobre Sensoriamento Remoto por imagens aéreas. Por se tratar de uma técnica de sensoriamento que envolve a utilização conjunta de outras tecnologias, serão abordados também conceitos básicos sobre Processamento Digital de Imagens e Veículos Aéreos Não Tripulados. Estas três tecnologias juntas proporcionam o Sensoriamento Remoto por Imagens Aéreas. Para facilitar a organização e o entendimento dos conceitos de cada tecnologia, cada tema será apresentado em seções separadas.

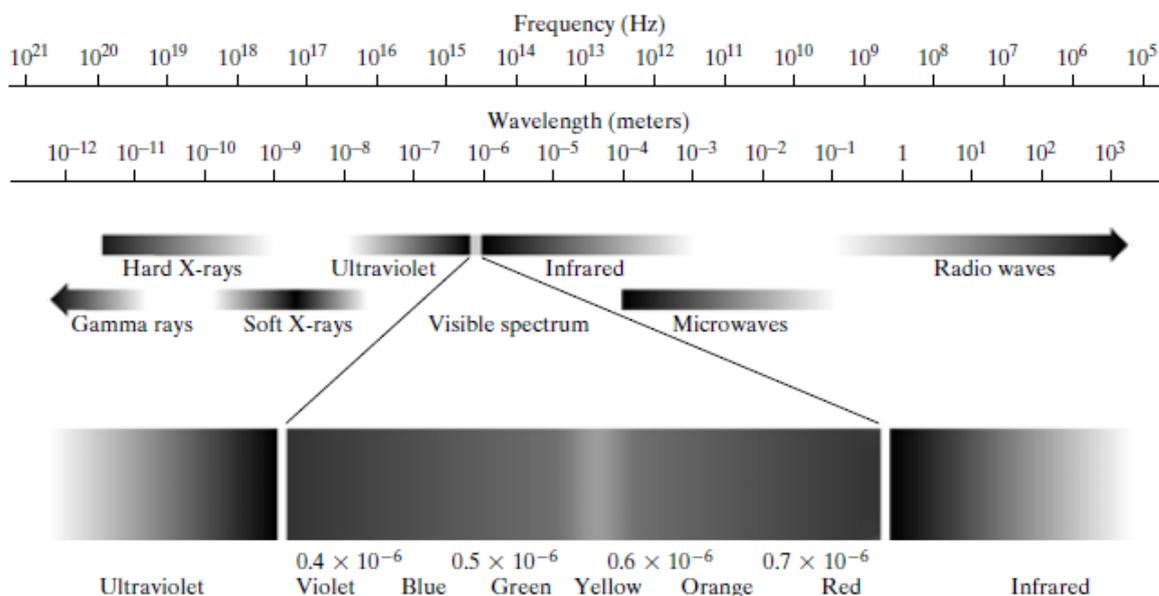
3.1 SENSORIAMENTO REMOTO

De acordo com Denniss (1995), o sensoriamento remoto é a ciência de se obter informação sobre um objeto, área ou fenômeno através da análise de dados adquiridos por um sensor que não está em contato direto com o objeto, área ou fenômeno sob investigação. Os dados coletados remotamente podem ser de diversas formas: variação na distribuição de forças; Variação na distribuição de ondas mecânicas e variação na distribuição de ondas eletromagnéticas. Nesta pesquisa, será dado enfoque apenas à coleta por distribuição de ondas eletromagnéticas.

Segundo Parsons (1985), os sensores de radiação eletromagnética podem ser utilizados para capturar imagens e registrá-las em formatos digitais, por exemplo, que podem ser interpretadas para fornecer informações úteis sobre o ambiente monitorado. Conseguem obter informações do espectro eletromagnético da luz visível e outras faixas invisíveis. Os sensores mais comuns instalados em câmeras digitais são: sensores RGB, que capturam o espectro de luz visível; Sensores multi espectrais, que capturam o espectro RGB mais o espectro de borda vermelha e o espectro do infravermelho próximo; Sensores hiper espectrais, esses capazes de capturar todo o espectro eletromagnético da luz. A Figura 6 ilustra as faixas do espectro eletromagnético com destaque para as faixas de luz visíveis.

De acordo com Kairu (1982), os sensores de radiação eletromagnética podem ser divididos em dois grupos. O primeiro grupo é formado pelos sensores ativos, que possuem sua própria fonte de emissão de energia. Irradiam energia eletromagnética sobre o alvo monitorado e capturam a energia refletida para o registro dos dados. São mais eficientes porque não sofrem com alterações de luminosidade. Um exemplo comum de sensor ativo são aqueles usados pelos equipamentos de radar. O segundo grupo de sensores são os chamados passivos, que não possuem fonte própria de emissão de energia contra o alvo monitorado. Dependem de fontes naturais de luminosidade, geralmente fornecidas pelo sol. São mais susceptíveis as variações de luminosidade. Um exemplo comum de sensores passivos são aqueles utilizados por câmeras digitais. A Figura 7 ilustra o modo básico de funcionamento dos sensores

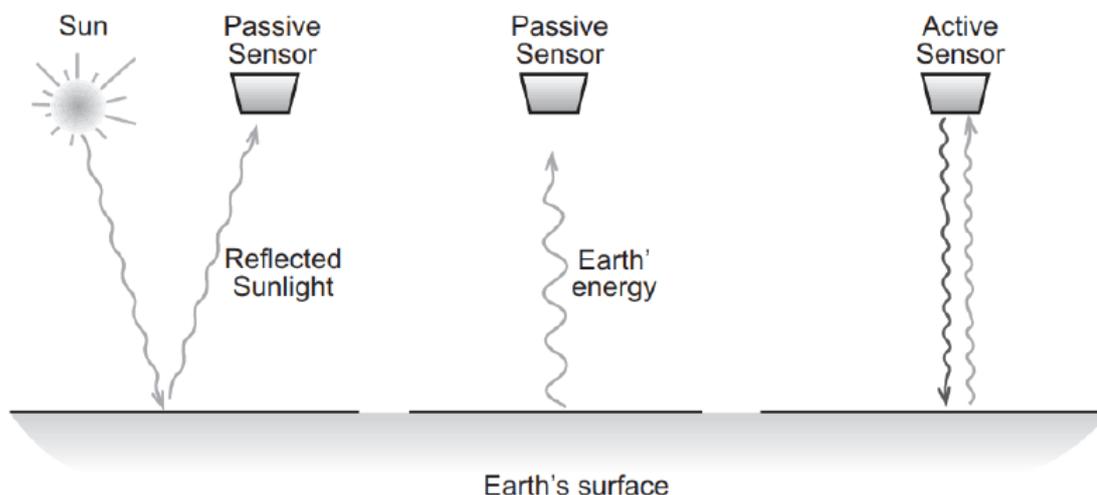
Figura 6 – Espectro eletromagnético da luz.



Fonte: Gonzalez e Woods (2001)

ativos e passivos.

Figura 7 – Sensores ativos e passivos.



Fonte: Tempfli *et al.* (2004)

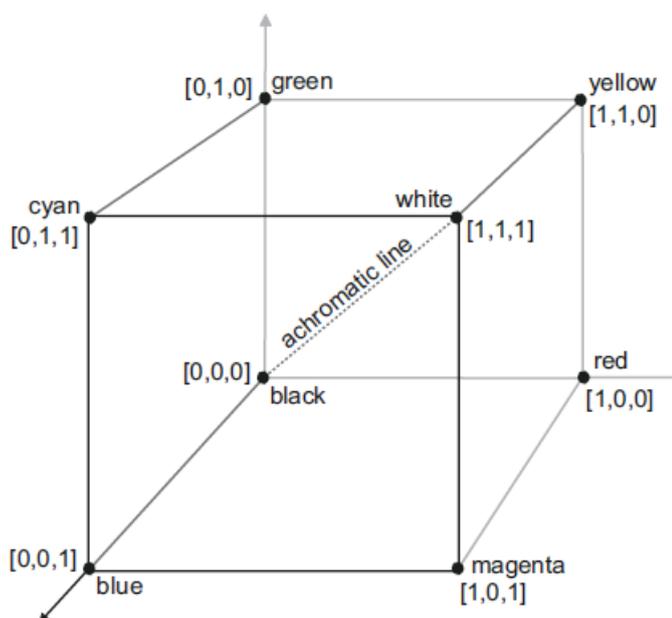
Com o desenvolvimento das tecnologias de sensoriamento remoto, tornou-se rápido e conveniente o monitoramento das lavouras através de imagens aéreas coletadas por satélites, aviões e VANTs (LANG *et al.*, 2019).

3.2 PROCESSAMENTO DIGITAL DE IMAGENS - PDI

Segundo Tempfli *et al.* (2004), as imagens digitais geradas pelos sensores são compostas uma matriz multidimensional que contém um número finito de elementos,

sendo que cada qual tem uma localização e um valor em particular. Esses elementos são comumente conhecidos como pixels e são usados para denotar os menores elementos de uma imagem digital. Cada pixel é composto por um conjunto de pontos que variam de posição e tamanho, dependendo da aplicação. Esses pontos podem conter informações que representam cores visíveis para nós ou de outros espectros de cores que não percebemos mas são registrados pelos sensores. A Figura 8 representa a forma estrutural simplificada de uma imagem digital.

Figura 8 – Estrutura multidimensional de uma imagem digital.

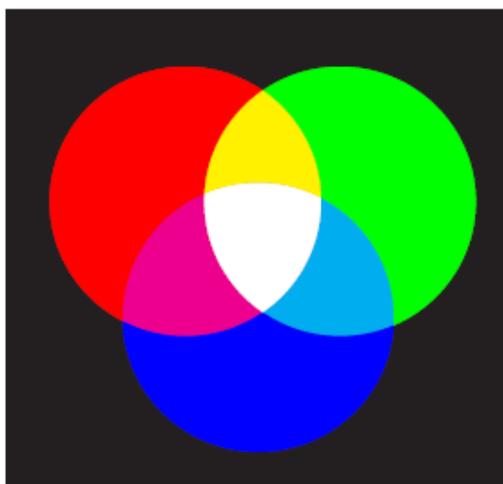


Fonte: Tempfli *et al.* (2004)

As imagens digitais, além da sua composição pelos pixels, costumam ser representadas através de faixas de cores bem definidas chamadas mapas de cores. O espaço de cor RGB é o mais comum pois contém as três faixas de cores visíveis, sendo elas as faixas do espectro vermelho, verde e azul (BREWER, 1997). A Figura 9 ilustra o mapa de cores do espectro RGB. Todas as cores visíveis podem ser expressadas como combinações das cores vermelha, verde e azul e desta forma serem representadas por imagens sobre um espaço tridimensional com os espectro R, G e B sobre os eixos descritos pela Figura 8.

De acordo com Gonzalez e Woods (2001), podemos fazer alterações nas informações dos pixels, a fim de promover melhorias ou modificar algumas características de interesse de cada imagem. Para isso utiliza-se técnicas de PDI através de sistemas computacionais. O PDI tem por objetivo alterar ou melhorar as informações contidas nas imagens para análise e interpretação por nós ou por outras máquinas. Filtragens, geração de histogramas, alterações nas cores, geração de índices espectrais e segmentação de imagens são algumas das ferramentas mais comuns em PDI. Ainda

Figura 9 – Mapa de cores RGB.



Fonte: Tempfli *et al.* (2004)

segundo Gonzalez e Woods (2001), o PDI traz benefícios a inúmeras áreas. Equipamentos utilizados na medicina (ultrassom, raio X, tomógrafo, etc.), Engenharias (visão computacional, simulação, inteligência artificial, etc.), ciências agrônômicas (monitoramento de florestas, identificação de pragas, classificação de plantas invasoras, etc.), entre outras, são alguns dos benefícios proporcionados pelo emprego de PDI.

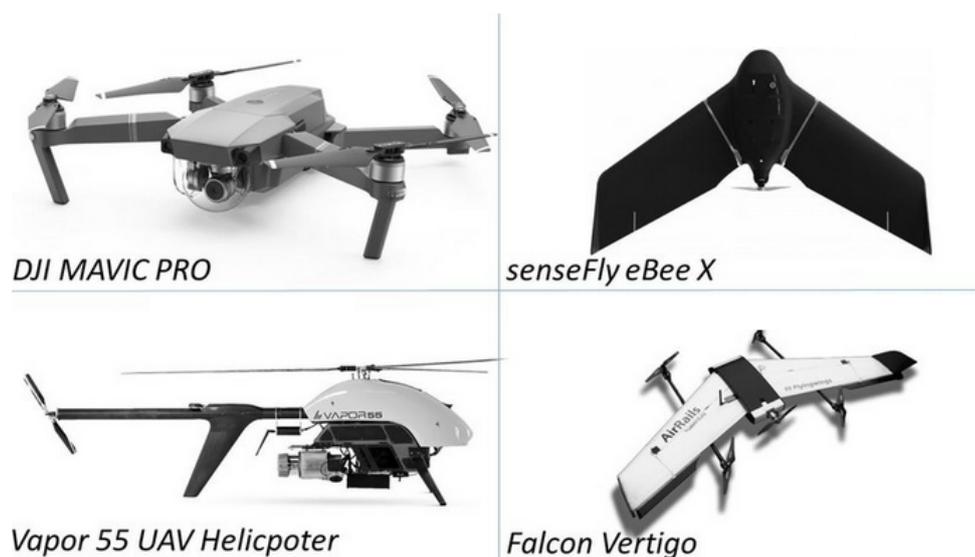
Outra ferramenta importante empregada através do PDI é a geração de outros mapas de cores além do RGB. Através de transformações matemáticas, pode-se destacar elementos presentes nas imagens antes não tão perceptíveis pelo mapa RGB. Alguns mapas de cores comuns e utilizados nesta pesquisa foram os mapas HSV, $L^*a^*b^*$ e o mapa YCbCr. São muito úteis quando deseja-se segmentar imagens, ou seja, separar alguns elementos indesejáveis e destacar outros elementos de interesse. Posteriormente no Capítulo 6 serão apresentadas imagens com estes mapas de cores gerados a partir do mapa RGB.

3.3 VEÍCULOS AÉREOS NÃO TRIPULADOS - VANTS

Os VANTS são caracterizados como sendo aeronaves de qualquer tamanho que podem voar sem tripulação e serem controlados remotamente ou através de sistemas de controles embarcados, neste caso voando de forma autônoma (VITOR *et al.*, 2008). Existem VANTS de vários tipos e, dentre os mais comuns, os de asa fixa, estilo avião e os de asa rotativa, estilo helicóptero (CAI; DIAS; SENEVIRATNE, 2014). A Figura 10 mostra alguns modelos de VANTS mais comuns e disponíveis comercialmente para sensoriamento remoto.

Segundo Beard e McLain (2012), semelhante a uma aeronave tripulada, um VANT é capaz de deslocar-se no espaço e realizar movimentos horizontais e verticais, mensuráveis através de sensores indicadores de velocidade e altitude, por exemplo.

Figura 10 – Modelos mais comuns de VANTs.



Fonte: Adaptado de Tkáč e Mesároš (2019)

Quanto a sua classificação, no Brasil os VANTs são classificados em três classes segundo a Agência Nacional de Aviação Civil - ANAC (2017), sendo elas:

- Classe 1: são considerados VANTs de grande porte, com peso acima de 150 kg. Necessitam de piloto habilitado e a aeronave deve passar por um processo de certificação, semelhante as aeronaves tripuladas, para poderem operar;
- Classe 2: são considerados VANTs de médio porte, com peso acima de 25 kg e abaixo ou igual a 150 kg. Também precisam de piloto habilitado, mas a aeronave não necessita de certificação, porém sua construção deve atender a requisitos técnicos exigidos por regulamentação do órgão federal responsável;
- Classe 3: são considerados VANTs de pequeno porte, com peso menor ou igual a 25 kg. Nesta categoria, não cabem as exigências das outras classes. Porém, necessitam ser cadastradas Agência Nacional de Aviação Civil (ANAC), para obtenção de matrícula de identificação da aeronave.

Entre as três classes, o VANT da Classe 3, vem ganhando cada vez mais espaço no mercado devido ao seu baixo custo operacional, alta manobrabilidade e fácil manutenção (CAI; DIAS; SENEVIRATNE, 2014). O modelo de VANT utilizado nesta pesquisa pertence a Classe 3. Devido a capacidade dessas aeronaves embarcarem diversos tipos de sensores e dispositivos de comunicação, muitas pesquisas vêm utilizando VANTs para coleta de dados de forma remota através de imagens digitais. Em comparação com outros métodos, o sensoriamento por VANTs tem como vantagens o baixo custo, alta flexibilidade, grandes áreas de cobertura e versatilidade em termos de dados coletados (YU *et al.*, 2020).

4 REDES NEURAIS ARTIFICIAIS - RNA

O objetivo deste capítulo é descrever de forma sucinta o funcionamento de uma RNA. Serão apresentadas apenas definições dos termos utilizados nos procedimentos adotados para a realização desta pesquisa. Dada a complexidade matemática que envolve o funcionamento das redes neurais, apenas algumas equações mais simples serão apresentadas, ficando as mais complexas disponíveis em suas referências citadas.

4.1 DEFINIÇÃO

De acordo com Haykin (2001), uma RNA é um modelo computacional baseado na arquitetura neural de um cérebro biológico. É composta por unidades matemáticas simples chamadas neurônios artificiais, com capacidade de armazenar conhecimento e disponibilizá-lo para uso futuro. São algoritmos com capacidade de aprendizado baseado em históricos de dados passados e desta forma desenvolvem a capacidade de predição, reconhecimento de padrões e tomadas de decisões. Segundo Murphy (2013), existem vários tipos de RNAs, entre as mais comuns destacam-se:

- *Redes Multilayer Perceptron (MLP)*: traduzido como Perceptron de Múltiplas Camadas, as redes MLP costumam ser simples em termos de arquitetura. São geralmente empregadas para a solução de problemas de regressão não linear e classificação de padrões;
- *Convolutional Neural Network (CNN)*: traduzido como Redes Neurais Convolucionais, as redes CNN são popularmente conhecidas como redes profundas. Possuem estruturas mais complexas e muito maiores em quantidade de camadas de neurônios. São largamente utilizadas em problemas que envolvem a classificação de padrões mais complexos. É comum utilizá-la para classificação de imagens, reconhecimento facial, visão de máquinas, entre outras aplicações;
- *Recurrent Neural Network (RNN)*: traduzido como Redes Neurais Recorrentes, as RNN possuem em sua arquitetura um sistema de realimentação de suas saídas às suas entradas, tornando-a uma rede em *loop*. São conhecidas como redes com memória, dada a característica da realimentação contínua de informações passadas (saídas aplicadas as entradas). Em suas aplicações utilizam dados sequenciais ou temporais e periódicos para resolver problemas tais como modelagem de sistemas dinâmicos, sistemas de controle autônomo, previsão de ações em mercados financeiros, previsões meteorológicas, etc.

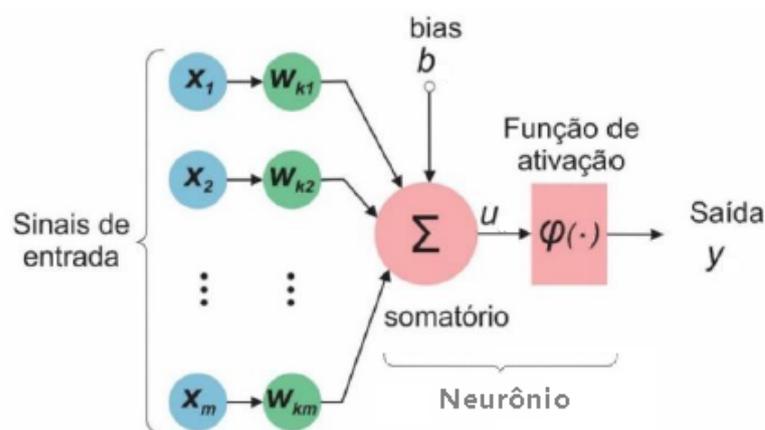
Neste trabalho foi definido por utilizar uma rede MLP, dada a natureza do problema desta pesquisa ser de associação ou correlação, entre os índices espectrais,

obtidos a partir das imagens RGB e os níveis de Chl medidos nas plantas. Trata-se de uma problema de regressão não linear cuja a base de dados é composta por valores numéricos que representam as entradas e a saída dos modelos de predição. Uma rede CNN não se aplicaria a este problema pois a base de dados não é composta por classes de entrada e saída, por isso sua indicação na solução de problemas de classificação de padrões. Da mesma forma, uma RNN não se aplicaria pois a base de dados não é formada por informações sequências ou que tenham dependência temporal. Logo, todos os conceitos descritos a seguir serão com ênfase as RNAs do tipo MLP.

4.2 REDES PERCEPTRON

Antes de descrever as redes MLP, será brevemente conceituado o modelo computacional que lhe deu origem, o Perceptron. Após o início dos estudos sobre as RNAs na década de 40, em 1958 Frank Rosenblatt desenvolveu o Perceptron (ROSENBLATT, 1958). Tratava-se de um modelo computacional composto por apenas um neurônio artificial, várias entradas binárias e apenas uma saída. Seu único neurônio possuía uma função para somar o produto das entradas pelos pesos atribuídos a cada entrada sendo que em seguida, o valor do somatório era aplicado a uma função de ativação que liberava um sinal binário em sua saída. A Figura 11 ilustra a composição da estrutura de um Perceptron. Onde x_m são as entradas, w_{km} são os pesos correspondentes

Figura 11 – Estrutura de uma rede Perceptron.



Fonte: Adaptado de Haykin (2001).

a cada entrada, chamados de pesos sinápticos em referência a palavra sinapse existentes nos neurônios biológicos, b é uma entrada com valor constante utilizada para deslocar o resultado final da soma, u é a saída do somador que serve como entrada para a função de ativação ϕ , cujo a sua saída é a própria variável y . Com base nestas

definições, a saída y pode ser representada pela Equação 1.

$$y = \phi \left(\sum_{j=0}^m x_j w_{kj} + b \right) \quad (1)$$

A função de ativação ϕ é uma função do tipo degrau unitário e pode ser descrita pela Equação 2.

$$\phi = \begin{cases} 1 & \text{se } \sum_{j=0}^m x_j w_{kj} + b \geq 0 \\ 0 & \text{se } \sum_{j=0}^m x_j w_{kj} + b < 0 \end{cases} \quad (2)$$

Devido a natureza matemática da função de ativação, apenas valores binários 0 ou 1 podem aparecer na saída do Perceptron. Com base nesta arquitetura, Rosenblatt (1958) afirmava que o ajuste dos pesos sinápticos W servia como forma de treinamento para a rede aprender a classificar alguns tipos de padrões. Esse modelo de RNA resolve problemas simples de classificação e tomadas de decisões e que sejam linearmente separáveis tais como *OR* e *AND* lógicos, por exemplo.

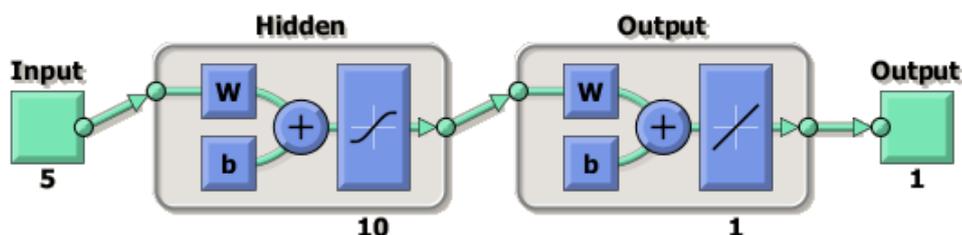
4.3 PERCEPTRON DE MÚLTIPLAS CAMADAS

Em um dado momento, o Perceptron não era mais suficiente para a solução e muitos problemas, principalmente aqueles que não eram linearmente separáveis. Com o surgimento do algoritmo de treinamento *Back Propagation* (BP), do inglês Retro-Propagação, surgiu uma RNA baseada no Perceptron, porém mais complexa. Segundo Samarasinghe (2006), o MLP consiste em um sistema interconectado de neurônios que seguem um padrão de organização. Neste caso, os neurônios são organizados em três camadas distintas:

- Camada de Entrada: os neurônios nesta camada recebem os sinais de entrada e não realizam qualquer operação matemática. Apenas direcionam os valores recebidos para a camada seguinte;
- Camada oculta: os neurônios desta camada recebem os sinais enviados pela camada de entrada e processam essas informações conforme a Equação 1. Em seguida, enviam os resultados de cada operação a camada seguinte;
- Camada de Saída: seus neurônios recebem os sinais da camada oculta e também os processam conforme Equação 1. Logo após, seus resultados são enviados para a saída do MLP

A Figura 12 ilustra um modelo de arquitetura de uma rede MLP utilizado nesta pesquisa.

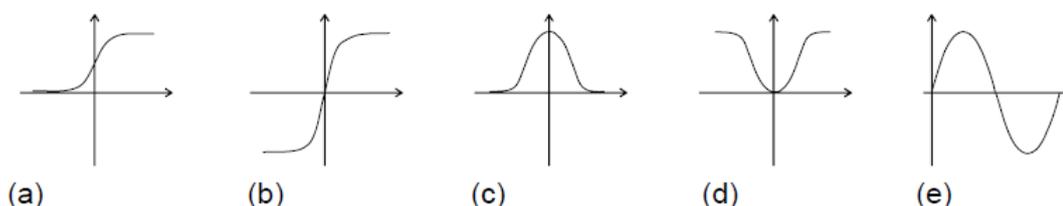
Figura 12 – Estrutura de uma rede MLP.



Fonte: Do autor.

A rede MLP ilustrada na Figura 12 é o padrão gerado pelo programa *Matlab*[®]. Neste exemplo, o diagrama de blocos mostra 5 entradas, 10 neurônios na camada oculta e apenas 1 neurônio na camada de saída. As informações desta RNA são apresentadas de forma compacta, sendo que internamente cada neurônio tem uma estrutura semelhante ao Perceptron mostrado na Figura 11. Um detalhe importante das redes MLP é que a função de ativação dos neurônios pode ser de vários tipos. A Figura 13 ilustra alguns dos modelos mais comuns de funções de ativação. A Equação

Figura 13 – Modelos de funções de ativação: (a) Sigmoid, (b) Tangente Hiperbólica, (c) Gaussiana, (d) Complemento Gaussiano, (e) Seno.



Fonte: Samarasinghe (2006)

3 representa a função Tangente Hiperbólica, naturalmente não linear e utilizada em todos os modelos de RNAs desenvolvidos nesta pesquisa por se tratar de problema de regressão também não linear.

$$f(u) = \frac{1 + e^{-u}}{1 - e^{-u}} \quad (3)$$

Onde u é a saída do somador de cada neurônio. Ainda segundo Haykin (2001) e Samarasinghe (2006), as redes MLP tem sua configuração chamada de *Feedforward*, tradução livre pra "propaga para frente". Significa que, após treinada, a saída de cada neurônio sempre é direcionada para a frente até atingir a saída da rede neural.

Uma das principais características das redes MLP é a sua capacidade de aprender padrões a partir de uma base de dados pré-existente (SAMARASINGHE, 2006). A base de dados deve ser composta com informações envolvendo dados de entrada e saída de um experimento, por exemplo. A técnica de utilizar uma base de dados

pré-existente é chamada "Aprendizagem Supervisionada". Esse processo de aprendizagem consiste em atualizar os pesos sinápticos de cada neurônio existente na rede neural.

Segundo Murphy (2013), o objetivo desta técnica é fazer a RNA aprender um mapeamento das entradas x para as saídas y , desde que fornecidos um conjunto rotulado de pares entrada-saída, onde cada entrada deverá estar associada a uma saída. A rede MLP deve aprender a encontrar os caminhos que levam cada entrada a suas respectivas saídas associadas. Nesta técnica, o processo de aprendizagem ocorre atualizando-se os pesos sinápticos w de cada neurônio. Os pesos são atualizados através do algoritmo BP.

Conforme descrito nas obras de Samarasinghe (2006), Haykin (2001) e Murphy (2013), a aprendizagem de um MLP consiste em reduzir a um valor mínimo o erro entre a saída desejada (presente na base de dados) e o erro obtido na saída da rede neural. Para isso, existem vários algoritmos utilizados para ajuste dos pesos sinápticos dos neurônios e entre eles destaca-se o algoritmo de otimização de *Levenberg-Marquardt*, escolhido por ser um dos algoritmos mais rápidos para o treinamento de um MLP (MORÉ, 1978).

De forma resumida, na primeira etapa do processo de treinamento, atualizam-se os pesos w com pequenos valores randômicos. Em seguida, aplicam-se os dados de entrada no MLP e compara-se sua saída com o valor desejado. Se o erro for grande, recalculam-se os valores de w iniciando da última camada para a primeira, ou seja, de trás para frente (retro-propagação) e sempre tentando manter um gradiente descendente do valor do erro. Então o ciclo se repete aplicando-se novamente as entradas e comparando os erros. Cada ciclo é chamado de época. O algoritmo encerra quando atinge-se um valor de erro mínimo e número máximo de épocas, parâmetros esses definidos previamente ao início do treinamento do MLP. A partir deste ponto, tem-se um modelo computacional formado por uma RNA treinada para reconhecer padrões e pronta para uso na solução de problemas de classificação ou regressão não linear.

5 ESTADO DA ARTE

Este capítulo descreve uma revisão bibliográfica do estado da arte sobre predição do teor de Clorofila em plantações de arroz utilizando sensoriamento remoto através de imagens aéreas. Esse capítulo tem como objetivo apresentar trabalhos correlatos atuais sobre a temática tratada nesta pesquisa.

5.1 PROCEDIMENTOS ADOTADOS

A busca pelas publicações foi realizada através de três bases de dados: base *EBD-EBSCO*, sendo esta uma plataforma integrada a dezenas de outras bases de dados, acessada através do site da Biblioteca Universitária da UFSC em <https://portal.bu.ufsc.br/>; base *IEEE Xplore* e base *Scopus*, acessadas pelo Portal Capes em <http://www.periodicos.capes.br>. Após alguns testes preliminares na busca por trabalhos correlatos a temática desta pesquisa, definiu-se as três palavras-chaves para as buscas: *rice chlorophyll*, *image processing* e *unmanned aerial vehicle*. As palavras foram escritas na língua inglesa pois as ferramentas de buscas são todas bases de dados internacionais.

Antes de iniciarem-se as pesquisas, os seguintes parâmetros de filtros foram selecionados:

- **Expansores:** Buscar também nos textos completos dos artigos; Aplicar assuntos equivalentes;
- **Limitadores:** Periódicos revisados por pares; Data de publicação entre 2010 e 2020;
- **Idioma:** Português e Inglês.

Logo, na primeira etapa das buscas foi inserido como descritor a palavra "*rice chlorophyll*". Com ela obteve-se 5835 artigos na plataforma *EBD-EBSCO*, 5 artigos na base *IEEE Xplore* e 1987 artigos na base *Scopus*, totalizando 7827 publicações encontradas. Na segunda etapa foi adicionada a segunda palavra formando o descritor Booleano "*rice chlorophyll AND image processing*". Desta forma obteve-se 299 artigos na plataforma *EBD-EBSCO*, 2 artigos na base *IEEE Xplore* e 7 artigos na base *Scopus*, totalizando 308 publicações encontradas. Por fim, na terceira etapa foi adicionada a terceira palavra-chave formando o descritor Booleano "*rice chlorophyll AND image processing AND unmanned aerial vehicle*". Sendo assim, obteve-se 103 artigos na plataforma *EBD-EBSCO*, 01 artigo da base *IEEE Xplore* e 3 artigo da base *Scopus*, totalizando 107 publicações encontradas.

Com base nos resultados da ultima etapa de buscas, foram selecionadas para uma análise descritiva apenas as publicações que continham em seus títulos ou re-

sumos as palavras que formam o terceiro descritor utilizado nas buscas. Desta forma, foram selecionados 5 artigos das respectivas bases de dados: *Food Science Source*, *Scopus*, *Computers and Applied Sciences Complete* e *AGRIS*.

5.2 ANÁLISE DESCRITIVA DOS ARTIGOS

Na publicação de Yu *et al.* (2020) intitulada "*Inversion model of chlorophyll content in japonica rice canopy based on PSO-ELM and hyper-spectral remote sensing*", disponível na base de dados *Food Science Source*, os autores desenvolveram um modelo computacional baseado em uma arquitetura de rede neural chamada ELM, sigla para *Extreme Learning Machine*, utilizada na predição dos níveis de Chl em uma plantação de arroz. A área do experimento foi dividida em 12 unidades amostrais de igual tamanho medindo 30 x 45 m cada. Os níveis de Chl foram medidos através de análises químicas com 196 amostras de plantas coletadas entre as unidades amostrais. As imagens aéreas foram coletas por um VANT do tipo hexacóptero durante voos pairados a uma altura de 150 m sobre a área do experimento. A aeronave foi equipada com uma câmera digital com sensor hiper espectral de 256 bandas e com sensibilidade entre 400 a 1.000 nm. Os autores utilizaram a técnica SPA, sigla para *Successive Projection Algorithm*, para redução de dimensionalidade e extração das características, resultando em cinco bandas espectrais nas faixas de 410 nm, 481 nm, 533 nm, 702 nm e 798 nm que serviram como entrada da rede neural. A rede ELM foi desenvolvida e seus parâmetros otimizados através da técnica PSO, sigla para *Particle Swarm Optimization*. De acordo com os autores, seu modelo computacional PSO-ELM conseguiu modelar com precisão a relação não linear entre os dados hiper espectrais das imagens e os níveis de clorofila. O modelo atingiu um coeficiente de determinação $R^2=0,791$. Ainda segundo os autores, a rede neural exibiu boa capacidade preditiva e poderá servir como modelo de referência para pesquisas em diagnóstico de nutrientes em plantações de arroz.

Na publicação de Colorado *et al.* (2020) intitulada "*Estimation of Nitrogen in Rice Crops from UAV-Captured Images*", disponível na base de dados *Scopus*, os autores desenvolveram três modelos computacionais baseados em técnicas de aprendizagem de máquinas para a predição dos níveis de N em três fases de crescimento de uma plantação de arroz. Utilizaram as técnicas MLR, sigla para *Multivariable Linear Regressions*, SVM, sigla para *Support Vector Machines* e uma RNA. A área do experimento foi dividida em 24 unidades amostrais de igual tamanho medindo 2,1 x 2,75 m cada. Em cada uma delas os níveis de Chl foram medidos através de um dispositivo chamado SPAD 502, totalizando 24 medições de Chl. As imagens aéreas foram coletas por um VANT do tipo quadricóptero durante sobrevoos com velocidade de 1,5 m/s e a uma altura de 20 m sobre a área do experimento. A aeronave foi equipada com uma câmera digital com sensor multi espectral de 4 bandas sensível as faixas RGB, borda vermelha

e infravermelho próximo. Utilizaram PDI sobre as imagens coletadas combinando o método de segmentação chamado *GrabCut* com a técnica de filtro para extração e seleção dos 7 índices espectrais, posteriormente correlacionados com os níveis de Chl para a construção dos modelos de predição. De acordo com os autores, entre os três modelos de predição desenvolvidos, a RNA se destacou com os melhores desempenhos com coeficientes de correlação $r=0,98$, $r=0,94$ e $r=0,89$ para as respectivas fases de crescimento das plantas.

No trabalho publicado por Yuhao *et al.* (2020) intitulado "*Rice Chlorophyll Content Monitoring using Vegetation Indices from Multispectral Aerial Imagery*", disponível na base de dados *Computers and Applied Sciences Complete*, os autores desenvolveram quatro modelos computacionais para predição de níveis de Chl baseados na técnica estatística chamada Correlação de *Pearson*. A área do experimento foi dividida em 20 unidades amostrais totalizando 8 ha de área. Em oito pontos de cada unidade amostral foram medidos os níveis de Chl através do dispositivo SPAD 502, totalizando 160 medições de Chl. As imagens aéreas foram coletadas por um VANT do tipo multi rotor. A aeronave foi equipada com uma câmera digital com sensor multi espectral de 4 bandas sensível as faixas RGB, borda vermelha e infravermelho próximo. Utilizaram PDI sobre as imagens coletadas através do programa *Agisoft Photoscan Professional*[®], para a geração de ortomosaico e extração dos 4 índices espectrais utilizados nos modelos. Logo, utilizando correlação linear de *Pearson*, os autores desenvolveram quatro modelos de predição de Chl, sendo um para cada respectivo índice espectral extraído. Os autores apresentaram os resultados de cada modelo através dos respectivos coeficientes de correlação: Modelo 1: $r=0,957$; Modelo 2: $r=0,974$; Modelo 3: $r=0,964$ e Modelo 4: $r=0,966$. Os autores concluem que seus modelos poderão auxiliar os produtores de arroz no monitoramento e gerenciamento em tempo real de suas lavouras.

Na trabalho de Zheng *et al.* (2018) intitulado "*Evaluation of RGB, color-infrared and multispectral images acquired from unmanned aerial systems for the estimation of nitrogen accumulation in rice*", disponível na base de dados *Scopus*, seu objetivo foi explorar o potencial de imagens multi espectrais obtidas através de VANTs, para estimar a Concentração de Nitrogênio na Planta (CNP) e melhorar a acurácia destas estimativas com o auxílio de dados coletados em campo por um Radiômetro hiper espectral. Os autores combinaram índices espectrais de vegetação e informação da textura para estimar o CNP na planta do arroz. Essas informações foram obtidas através de PDI aplicado as imagens coletadas pelo VANT e pelos dados fornecidos em solo pelo Radiômetro. Os experimentos foram conduzidos ao longo de dois anos consecutivos, envolvendo diferentes taxas de fertilizantes a base de N, densidades de plantio e cultivares de arroz. Os resultados demonstraram que os índices de vegetação obtidos através das imagens aéreas não foram satisfatórios para estimativa do CNP

em todas as fases de crescimento da plantação. Em contrapartida, os índices obtidos a partir das medições em solo, se mantiveram consistentes em todas as fases do plantio. No entanto, os autores concluíram que a integração das informações obtidas pelos dois métodos de sensoriamento poderiam se tornar uma técnica promissora no monitoramento do CNP das safras de arroz.

Em Saberioon e Gholizadeh (2016) intitulado *Novel approach for estimating nitrogen content in paddy fields using low altitude remote sensing system*, disponível na base Scopus, seu objetivo foi desenvolver um novo índice para estimar os níveis de N e Chl nas folhas do arroz. Para isso utilizou duas câmeras digitais sendo uma RGB e outra multi espectral com 4 bandas. As imagens foram coletadas por um VANT do tipo avião durante dois voos consecutivos, um para cada modelo de câmera. Aplicando-se PDI sobre as imagens coletadas, foram gerados 12 índices espectrais. Através do método estatístico de correlação linear de *Pearson*, os índices espectrais foram correlacionados com os valores de Chl medidos por um dispositivo SPAD 502. Segundo os autores, os resultados mostraram uma tendência crescente e linear nos valores das medições de clorofila em todas as fases de crescimento das plantas, indicando uma correlação positiva de $r=0,78$ entre níveis de N e Chl. Ao final, os autores concluíram que câmeras digitais RGB podem ser empregadas para predição rápida, precisa e de forma não destrutiva dos níveis e Chl e assim estimar os níveis de N, gerando melhorias no manejo dos fertilizantes nitrogenados nas plantações de arroz.

Na publicação de Jinwen Li *et al.* (2015) intitulada *Quantification of rice canopy nitrogen balance index with digital imagery from unmanned aerial vehicle*, disponível na base de dados *AGRIS*, os autores utilizaram uma câmera digital RGB acoplada a um VANT do tipo multi rotor. A aeronave sobrevoou uma plantação de arroz a uma altura de 50 m sobre o solo para captura de imagens. Juntamente a câmera, foi instalado um dispositivo emissor de luz multi espectral. A emissão de fluorescência das folhas da planta do arroz sobre a excitação de luz foi usada para medir de forma não destrutiva os níveis de clorofila e polifenol. O Índice chamado Índice de Balanço de Nitrogênio (IBN), conhecido como sendo a razão da clorofila pelo polifenol, foi utilizado para determinar as concentrações de N na plantação. Através de PDI foi gerado um índice de cor chamado Índice de Cor Verde Escuro (ICVE). Desta forma, foi possível utilizar o ICVE para estimar a concentração de N com um $R^2 = 0.672$ e o IBN com um $R^2 = 0.711$. Estes valores foram comparados com medições dos níveis de N obtidos a partir de análises químicas das folhas das plantas. Segundo os autores, os resultados de sua pesquisa indicaram que o sensoriamento remoto por imagens coletadas por VANTs, tem a capacidade de estimar, em grande escala, os níveis de N nas plantações de arroz e desta forma auxiliar na gestão da fertilização.

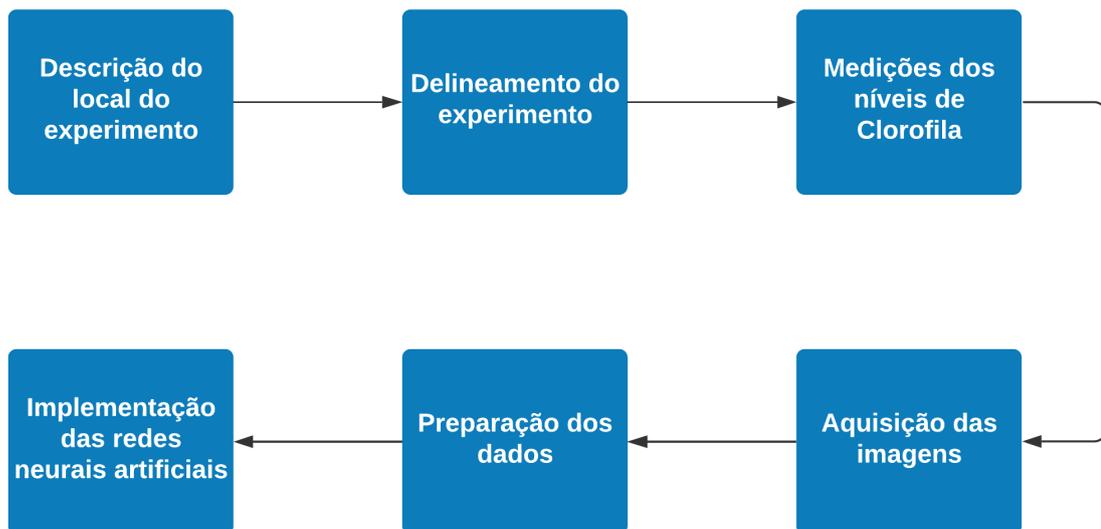
Analisados os trabalhos correlatos, esta pesquisa de mestrado propôs desenvolver modelos computacionais para a predição dos níveis de Clorofila em uma plantação

de arroz irrigado utilizando imagens aéreas RGB e redes neurais artificiais. Diferencia-se dos demais trabalhos por utilizar uma câmera digital convencionais RGB de baixo custo, se comparadas as câmeras multi e hiper espectrais de alto valor de mercado. Traz como vantagem a produção de conhecimento para os rizicultores, dada a inexistência de pesquisas correlatas na região sul do Brasil. Desta forma, poderá beneficiar diretamente a agricultura familiar, predominante na região do vale do Araranguá, além de servir como ferramenta de auxílio as ciências agronômicas.

6 PROCEDIMENTOS METODOLÓGICOS

Neste capítulo serão descritos todos os procedimentos experimentais executados para a realização desta pesquisa. Seu objetivo é demonstrar como cada etapa do experimento foi realizada e também possibilitar sua reprodução. A Figura 14 demonstra uma visão geral das etapas desenvolvidas nos procedimentos metodológicos desta pesquisa.

Figura 14 – Etapas dos procedimentos metodológicos da pesquisa.



Fonte: Do autor.

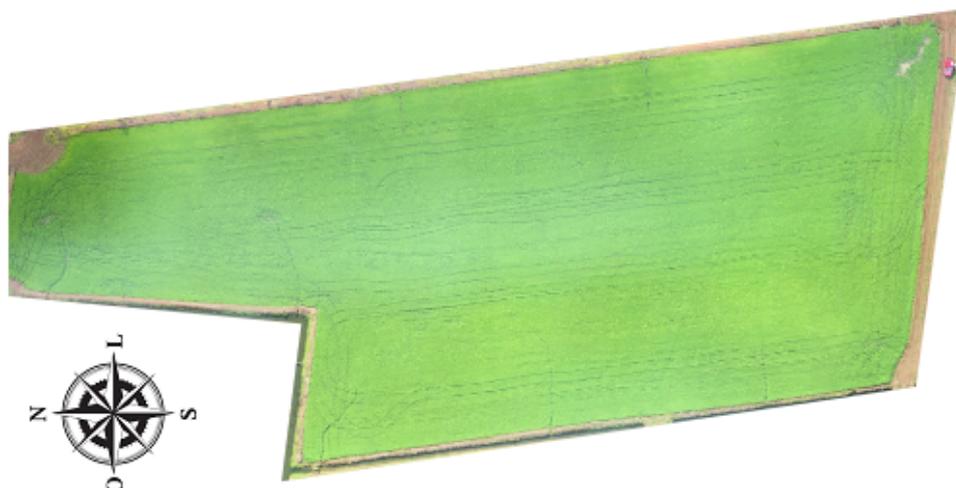
6.1 DESCRIÇÃO DO LOCAL DO EXPERIMENTO

A lavoura de cultivo de arroz utilizada nesta pesquisa possui área de aproximadamente 1,15 ha e está localizada na cidade de Araranguá, SC, sob coordenadas $-28^{\circ},9138'29''S$ e $-49^{\circ},4861'42''W$. Segundo SDR (2003), essa região possui clima subtropical mesotérmico úmido, com verão quente e com as respectivas médias anuais de temperatura, precipitação e umidade relativa do ar de $19,5^{\circ}$, 1.400 mm e 81%. Possui solos planos hidromórficos dos tipos Gleissolos e Organossolos. A Figura 15 ilustra uma imagem aérea do local do experimento.

Antes do plantio das sementes, o produtor realizou o trato cultural da seguinte forma:

- Aplicado o rolo faca por três vezes para deitar a palhada;
- Aplicado a grade aradora por três vezes para arar a terra;
- Aplicado herbicida *Zapp Qi* na dose de 4 L/ha.

Figura 15 – Vista aérea do local do experimento.



Fonte: Do autor.

- Aplicado enxada rotativa por duas vezes para remoção de vegetação;
- Aplicado adubo nitrogenado por duas vezes com densidade de 150 kg/ha;
- Não foi aplicado calcário antes do plantio.

O cultivar de arroz semeado nesta área foi o Epagri SCS121 CL com sistema de plantio pré-germinado. As sementes foram semeadas pelo produtor no dia 09 de novembro de 2019.

6.2 DELINEAMENTO DO EXPERIMENTO

O experimento desta pesquisa foi realizado nos dias 19, 20 e 21 de dezembro de 2019. A área do experimento foi definida sob orientação de um Engenheiro Agrônomo e escolhida por apresentar maiores variações na coloração do solo, se comparada com as áreas adjacentes, indicando maior diversidade nas concentrações de macro e micronutrientes em pontos distintos da área e por isso, mais propícia ao experimento.

O delineamento experimental utilizado foi em blocos casualizados contendo 24 grupos homogêneos. Os blocos foram definidos de forma aleatória através de 24 unidades amostrais randomicamente espaçadas entre si. Cada unidade amostral foi demarcada com uma estaca de madeira de 50 cm de altura. Na ponta superior de cada estaca foi colocado um marcador na cor branca com o objetivo de identificação das unidades a partir das imagens aéreas. A Figura 16 ilustra a demarcação de uma destas unidades amostrais. Conforme se pode observar na Figura 16, o marcador de formato circular na cor branca se destaca em meio a vegetação sendo desta forma facilmente visualizado através das imagens aéreas.

Figura 16 – Unidade Amostral.



Fonte: Do autor.

Um único experimento com taxa constante de aplicação de fertilizante nitrogenado foi realizado. A fase de crescimento da planta do arroz escolhida para o experimento foi o estágio de ponto de algodão. De acordo com o Engenheiro Agrônomo, especialista que nos auxiliou nesta pesquisa, esta é a melhor fase de crescimento da planta onde se pode verificar alterações espectrais nas folhas do arroz.

Um dia após a segunda adubação com fertilizante nitrogenado foi realizada uma coleta de dados para medição dos níveis de Chl. No segundo dia após a adubação, foi realizada a primeira coleta de dados para aquisição das imagens aéreas. Por fim, no terceiro dia após a adubação, foram realizadas duas novas coletas de dados para aquisição das imagens, sendo uma no período da manhã e outra no período da tarde. Os dados do teor de clorofila foram organizados em tabelas enquanto as imagens aéreas em pastas de arquivos, ambos os dados diferenciados por data de coleta para posterior análise e processamento.

6.3 MEDIÇÕES DOS NÍVEIS DE CLOROFILA

No primeiro dia de coleta de dados, foi realizada a medição do teor de clorofila através do dispositivo *clorofilOG* modelo FCL1030 da marca *Falker* conforme ilustrado na Figura 17. Este dispositivo utiliza um sensor espectral do tipo ativo capaz de detectar três faixas de luz para identificação do teor de clorofila nas folhas das plantas. Suas medições indicam o Índice de Clorofila Falker (ICF), com intervalo de

Figura 17 – Dispositivo Medidor dos Níveis de Clorofila.



Fonte: <https://www.falker.com.br>

medições variando entre 0 a 100 ICF. É um equipamento portátil e com capacidade de armazenamento interno para até 3 mil medições.

Entorno das estacas com os marcadores de cada unidade amostral, foram selecionadas de forma aleatória, 10 plantas para as medições dos níveis de Chl. Em cada planta foram realizadas duas leituras de forma não destrutiva com o *clorofiLOG* e descartando-se o terço médio inferior, totalizando 20 leituras em cada unidade amostral. A duração de cada medição levou em torno de 2 segundos. Ao todo, foram 480 leituras gravadas internamente no *clorofiLOG*.

Ao final, os dados do *clorofiLOG* foram transferidos para um computador e armazenados em uma planilha eletrônica. Em seguida, com base na metodologia proposta por Guo *et al.* (2020), calculou-se a média das 20 leituras de cada unidade amostral, totalizando 24 medições ICF sendo uma para cada respectiva unidade amostral.

6.4 AQUISIÇÃO DAS IMAGENS

A coleta das imagens foi realizada no segundo e terceiro dia do experimento. Para isso, foi utilizado uma câmera digital da marca *Canon* modelo ELPH 300HS. Esta câmera é equipada com sensor RGB do tipo passivo com tamanho de 6,17 x 4,55 mm, lente objetiva com distância focal entre 24 e 120 mm e máxima resolução espacial de 4011 x 3016 pixels, equivalentes a 12,1 Megapixels. A Figura 18 ilustra o modelo de câmera utilizada nesta etapa. A câmera foi configurada para manter distância focal mínima, ou seja, 24 mm, exposição fixa do sensor e ajuste automático de luminosidade e disparo possibilitando a tomada de uma fotografia a cada 1,5 segundos.

Para possibilitar a coleta das imagens aéreas, a câmera foi embarcada em um VANT do tipo multi-rotor modelo MK Hexa XL da marca *Mikrokopter*. Este modelo de VANT possui 6 motores propulsores capazes de transportar uma carga útil de até 1,5 kg a uma velocidade máxima de 9 m/s. Também possui alguns sistemas embarcados de controle, navegação por GPS e comunicação sem fio, permitindo voos autônomos

Figura 18 – Câmera digital utilizada na coleta das imagens.

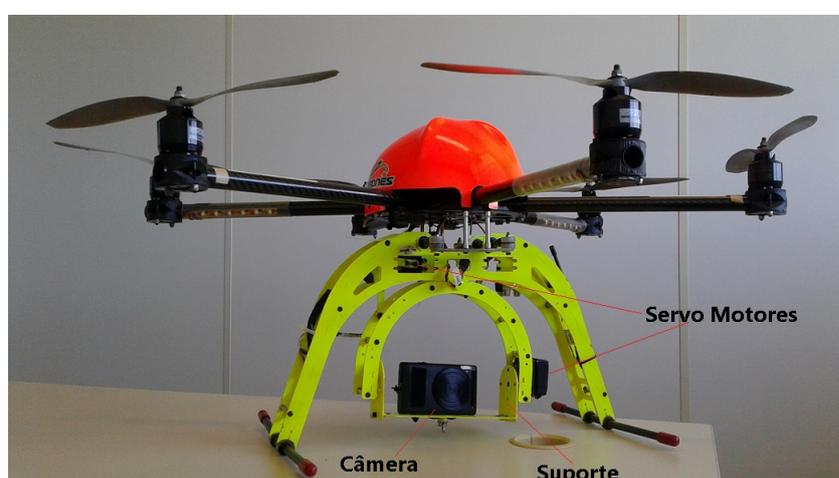


Fonte: <https://www.cnet.com>

e monitorados a uma distância de até 1500 m da estação base localizada em solo.

A coleta das imagens foi baseada nas metodologias propostas por Cen *et al.* (2019) e Stavrakoudis *et al.* (2019). Durante os voos, a câmera ficou sempre posicionada com sua lente para baixo a 90°. Este controle de posicionamento da câmera foi realizado de forma automática através de um sensor do tipo giroscópio e dois servo motores acoplados no suporte da câmera localizado na parte inferior da aeronave. A Figura 19 mostra o VANT equipado com a câmera digital.

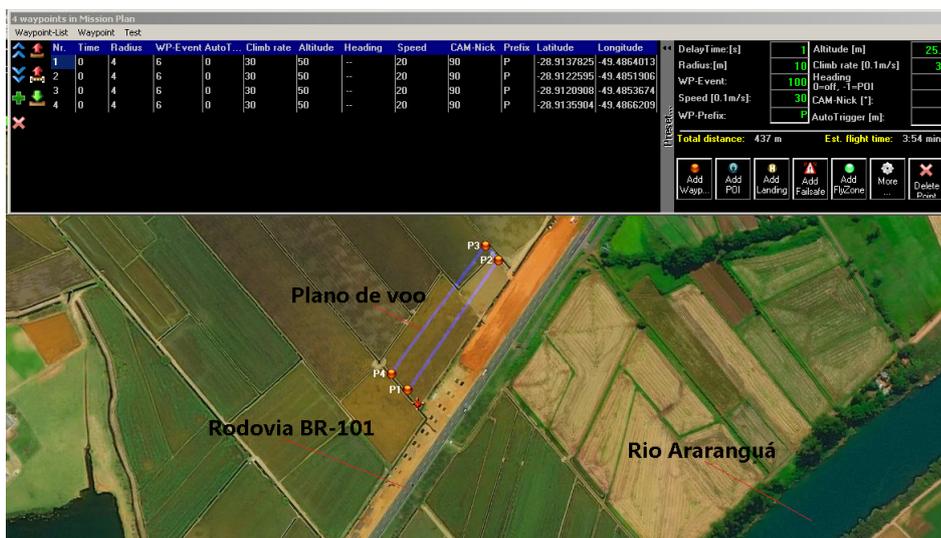
Figura 19 – Aeronave utilizada para transporte da câmera digital.



Fonte: Do autor.

Os três voos de coleta das imagens ocorreram nos respectivos dias 20, por volta das 8 horas da manhã e, no dia 21, em dois períodos sendo o primeiro por volta das 8 horas da manhã e o segundo por volta das 16 horas da tarde, do mês de dezembro de 2019. Após vários testes experimentais foi definido que as três coletas de imagens seguiriam o mesmo plano de voo a uma altura de 50 m sobre o terreno e velocidade de 2 m/s. O plano de voo foi gerado através da ferramenta *Mikrokopter Toll* fornecida pelo fabricante do VANT conforme ilustrado pela Figura 20.

Figura 20 – Plano de voo do VANT.



Fonte: Do autor.

Nos três voos, o VANT decolou em modo de controle manual a partir da estação base, identificada pelo ponto vermelho na Figura 20. Em seguida, ao atingir altura de aproximadamente 20 m sobre o terreno, foi acionado o piloto automático e a aeronave seguiu de forma autônoma nas rotas delimitadas entre os pontos P1, P2, P3 e P4. Ao final, foi desligado o piloto automático seguido do pouso do VANT também no modo de controle manual. O voo autônomo entre as rotas definidas foi necessário para garantir a precisão de rumo, altitude e velocidade, necessário para a correta aquisição das imagens. Cada voo teve duração média de 6 minutos.

Todas as coletas de imagens foram realizadas em dias ensolarados mas com presença de nuvens, ventos fracos abaixo de 10 km/h e com condições pouco estáveis de luminosidade. Devido a presença de nuvens, em alguns momentos ocorreram variações de luminosidade interferindo no brilho de algumas fotos e gerando sombra das nuvens em algumas partes do terreno. No entanto, ao todo foram coletadas 240 imagens aéreas com tamanho de 2816 x 1880 pixels cada, cujo *Ground Sample Distance* (GSD) ficou em torno de 0,456 cm/pixel.

6.5 PREPARAÇÃO DOS DADOS

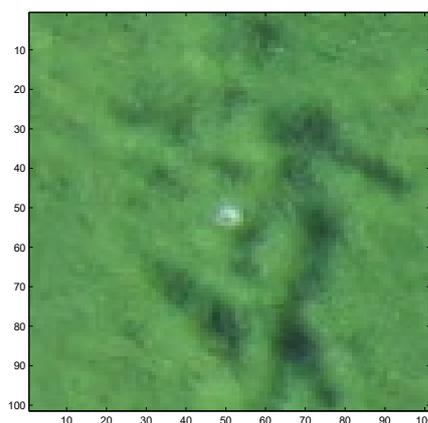
O objetivo desta seção foi realizar uma série de procedimentos baseados em aplicação de PDI e análises estatísticas para obtenção dos dados utilizados pelas RNAs. Será descrito como as imagens foram selecionadas e segmentadas, bem como a extração, geração e escolha das características das imagens para aplicação nas redes neurais. Todos os procedimentos descritos a seguir foram realizados através do programa *Matlab*[®].

6.5.1 Seleção das Imagens

Esta etapa teve como objetivo identificar, entre as várias imagens aéreas feitas pelo VANT, as unidades amostrais em meio a área do experimento. Inicialmente, em cada uma das imagens foram localizados os pontos brancos dos marcadores em meio a vegetação. Devido a altitude dos voos e a distância de separação entre as unidades amostrais, algumas das marcações apareceram em mais de uma imagem. Como critério de seleção, as unidades amostrais visualmente mais nítidas e com menos borrões foram selecionadas.

Em seguida, através da função *imcrop()*, 24 amostras (imagens) de cada voo de coleta e com tamanho de 101 x 101 pixel foram recortadas das imagens originais, totalizando 72 amostras. Considerou-se o tamanho do recorte das imagens o suficiente para representar cada uma das unidades amostrais e assumiu-se que cada unidade continha um único valor ICF médio. A Figura 21 ilustra um exemplo de unidade amostral selecionada a partir de uma imagem de um dos voos de coleta.

Figura 21 – Exemplo de unidade amostral selecionada.



Fonte: Do autor.

Conforme se pode observar na Figura 21, no centro da imagem aparece o ponto branco de referência ou marcador. As manchas escuras em torno do ponto de referência ocorreram devido a vegetação amassada durante as medições dos níveis de Chl, deixando o solo exposto nestas áreas. Na Subseção seguinte são descritos os procedimentos para segmentação entre vegetação, solo e os marcadores.

6.5.2 Segmentação das Imagens

O objetivo desta etapa foi segmentar a camada de vegetação do solo e dos pontos de referência. Dois procedimentos distintos foram realizados:

1. **Remoção dos pontos brancos:** neste procedimento, as imagens foram inicialmente convertidas para o mapa de cor HSV através da função *rgb2hsv()*. Em

seguida, as imagens foram limiarizadas de acordo com a Equação 4 descrita em Moghaddam, Derafshi e G. Shayesteh (2010) e Caliskan *et al.* (2019).

$$g_i(x, y) = \begin{cases} 0 & f_i(x, y) \leq T_i \\ f_i(x, y) & f_i(x, y) \geq T_i \end{cases} \quad (4)$$

onde $g_i(x, y)$ é o nível HSV segmentado no ponto (x, y) , $f_i(x, y)$ é o nível HSV original no ponto (x, y) , T_i é o valor do limiar e i representa os componentes RGB da imagem. O valor do limiar aplicado na Equação 4 foi definido de forma experimental com sendo $T_i = 0,3$ e aplicado igualmente nas 72 amostras. Isso fez com que os pixels com valores abaixo de T_i assumissem valor zero, ou seja, ficaram na cor preta. Ao final deste procedimento, as imagens foram reconvertidas para o seu mapa de cor original RGB através da função `hsv2rgb()`. Desta forma, foi possível modificar apenas os pontos brancos e manter as demais características das imagens.

2. **Remoção do solo:** este procedimento foi realizado através da replicação do método de limiarização $G-R$ realizado por Wang, Wang, Zhang *et al.* (2013). Tratou-se inicialmente de separar as três bandas das imagens RGB, calcular os valores médios de cada banda através da função `mean()` e, subtrair os respectivos valores máximos das médias da banda verde (G) da banda vermelha (R). Em seguida, aplicou-se novamente a Equação 4 utilizando o valor máximo de cada média como sendo o parâmetro T_i da equação. Neste caso, não foi possível manter um valor fixo para o limiar devido as variações das características espectrais de cada imagem, ou seja, existiu um valor de limiar T_i para cada imagem.

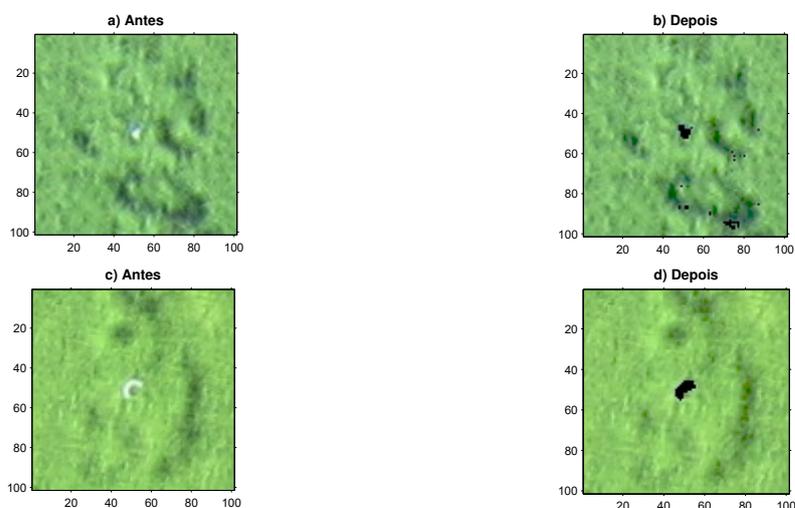
A Figura 22 apresenta dois exemplos de imagens ilustrando o antes e o depois da aplicação dos procedimentos de segmentação descritos nos itens 1 e 2. Conforme se pode observar na Figura 22, em ambas as imagens 3-b e 3-d os pontos brancos ficaram na cor preta e as manchas que caracterizavam o solo tornaram-se mais escuras.

6.5.3 Extração e Geração de Características

Esta etapa descreve dois procedimentos realizados para extração e geração de características a partir das imagens coletadas. Devido a falta de referências de luminosidade para a calibração da câmera digital, não foram utilizados filtros de qualquer tipo durante os procedimentos. A obtenção de informações morfológicas não foram necessárias, pois tratava-se de um problema de regressão que envolveu dados numéricos provenientes das características espectrais de cada imagem.

No primeiro procedimento, através das funções `rgb2hsv()`, `rgb2lab()` e `rgb2ycbcr()`, foi realizado a conversão das imagens RGB para os respectivos mapas de cores HSV,

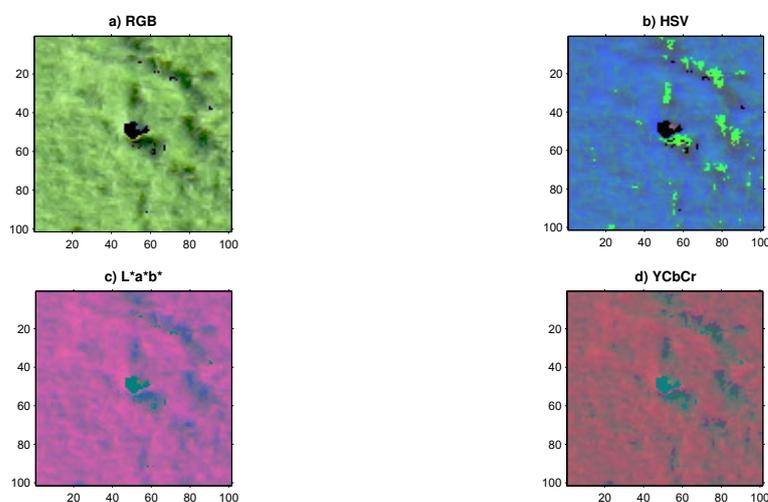
Figura 22 – Exemplos de imagens segmentadas.



Fonte: Do autor.

L*a*b* e YCbCr . O processo foi repetido para cada uma das 72 imagens, sendo elas convertidas conforme exemplo ilustrado na Figura 23. Conforme se pode observar

Figura 23 – Transformação entre espaços de cores.



Fonte: Do autor.

na Figura 23, a transformação entre coordenadas geradas neste processo muda a percepção espectral em relação a imagem RGB original. Como vantagem, estas transformações podem destacar alguns detalhes importantes tais como a distinção mais nítida entre o que é ou não vegetação.

Em seguida, ainda no mesmo procedimento, em todas as imagens foram separadas as três bandas de cada mapa de cor, seguido do cálculo do valor da média de cada banda através da função *mean2()*. No momento da obtenção da média o programa *Matlab*[®] desconsidera os pixels com valores iguais a zero. O resultado desse

processo foi a extração de 12 índices de cores que serviram de base para a geração de novos índices.

No segundo procedimento, foram utilizados os 12 índices obtidos no procedimento anterior. Com base nas metodologias de sete publicações distintas, estes índices foram aplicados a equações matemáticas para a geração 30 novos índices, totalizando 42 índices ou características espectrais conforme demonstrado na Tabela 2.

A quantidade de informações demonstradas pela Tabela 2, se fez necessário porque a maioria dos trabalhos correlatos utilizavam as câmeras digitais posicionadas de forma fixa e a curtas distâncias das plantas. Poucos trabalhos utilizavam imagens áreas obtidas por câmeras RGB em movimento e a longas distâncias. Esse fator implicou no aumento de incertezas sobre quantos e quais índices seriam necessários para atender as demandas desta pesquisa e por isso, considerou-se a necessidade de se obter tal quantidade.

A fim de se projetar uma visão geral das informações disponíveis e verificar as diferentes magnitudes de cada índice, foram calculados os valores mínimos e máximos, médias e o desvio padrão de cada índice conforme demonstrado na Tabela 3. Todas as informações descritas na Tabela 3 referem-se aos valores globais dos índices das 72 imagens, ou seja, não representam o valores individuais de cada imagem. É importante destacar as diferentes escalas de valores entre os índices. Por isso, na próxima subseção considerou-se a necessidade de uma avaliação estatística para a escolha dos dados posteriormente empregados pelas RNAs.

6.5.4 Seleção das Características

Nesta etapa, serão descritos os procedimentos realizados para a seleção das características, ou seja, a definição de quantos e quais índices foram escolhidos para posterior aplicação nas RNAs. Foi utilizado o método de seleção por aplicação de filtro para escolha dos índices espectrais com maior correlação com os valores ICF. Cabe ressaltar que, para cada um dos 24 valores ICF medidos, existem respectivamente três conjuntos (um para cada dia) contendo 42 índices espectrais cada associados. Logo, nos procedimentos a seguir, as correlações foram realizadas separadamente, ou seja, uma para cada dia de coleta de imagens. No entanto, os resultados das análises dos três dias de coletas de imagens serão agrupados nas mesmas tabelas.

Inicialmente foi realizada uma análise de correlação linear de *Pearson* com nível de confiança de 95% conforme procedimentos descritos em (RISQIWATI *et al.*, 2020). A Tabela 4 demonstra o coeficiente de correlação de *Pearson* r e a probabilidade de significância *valor-p*, para cada um dos 42 índices espectrais correlacionados com as medições ICF.

Conforme se pode observar na Tabela 4, a correlação linear de *Pearson* de-

Tabela 2 – Índices Extraídos e Gerados.

Índice	Equação	Referência
R		
G		
B		
H		
S		
V		
L*	Extração Direta	Do Autor
a*		
b*		
Y		
Cb		
Cr		
r	$R/(R+G+B)$	
g	$G/(R+G+B)$	
b	$B/(R+G+B)$	
INT	$(R+G+B)/3$	Wang, Wang, Shi <i>et al.</i> (2014)
VI	$(G-R)/(G+R)$	
i*	b^*/a^*	
GMR	G-R	Wang, Wang, Zhang <i>et al.</i> (2013)
VDVI	$(2G-R-B)/(2G+R+B)$	
GRRl	G/R	
MGRVI	$(G^2-R^2)/(G^2+R^2)$	Cen <i>et al.</i> (2019)
RBG	R+B+G	
RB	R+B	
RG	R+G	Hu <i>et al.</i> (2014)
BG	B+G	
BGR	B+G-R	
BR	$0,3R+0,6G+0,1B$	
IKAW	$(R-B)/(R+B)$	Sun <i>et al.</i> (2018)
ExR	$1,4r-g$	
ExG	$2g-r-b$	
RMB	R-B	
RMG	R-G	
GMB	G-B	
TORGB	$2R+G-B$	Moghaddam, Derafshi e G. Shayesteh (2010)
TORB	$2R-B$	
TOGB	$2G-B$	
RGRG	$(R-G)/(R+G)$	
GBGB	$(G-B)/(G+B)$	
RGRGB	$(R-G)/(R+G+B)$	Kawashima e Nakatani (1998)
RBRGB	$(R-B)/(R+G+B)$	
GBRGB	$(G-B)/(R+G+B)$	

Fonte: Do autor.

Tabela 3 – Análise Estatística dos Índices.

Índice	Mínimo	Máximo	Média	σ
R	84,154	165,610	132,980	20,204
G	139,887	219,108	188,819	22,305
B	38,981	140,163	96,923	19,942
INT	88,696	171,018	139,574	19,851
VI	0,117	0,266	0,176	0,024
GMR	43,880	67,408	55,839	5,393
VDVI	0,181	0,378	0,246	0,033
GRR	1,265	1,723	1,429	0,071
MGRVI	0,231	0,496	0,341	0,043
RBG	266,088	513,053	418,722	59,554
RB	126,201	295,078	229,903	37,951
RG	227,108	377,953	321,799	42,218
BG	178,868	358,137	285,742	40,341
BGR	91,647	203,222	152,762	22,905
BR	113,996	191,276	162,878	20,990
IKAW	0,019	0,382	0,161	0,066
ExR	-0,088	0,045	-0,009	0,022
ExG	0,256	0,577	0,358	0,053
RMB	3,166	60,251	36,057	13,097
RMG	-67,408	43,880	-55,839	5,393
GMB	64,018	118,012	91,896	12,766
TORGB	232,326	435,244	357,856	47,753
TORB	87,321	217,794	169,037	27,601
TOGB	209,023	332,072	280,716	30,385
RGRG	-0,266	0,117	-0,176	0,024
GBGB	0,217	0,564	0,327	0,061
RGRGB	-0,198	0,088	-0,135	0,019
RBRGB	0,010	0,181	0,087	0,033
GBRGB	0,152	0,379	0,223	0,040
r	0,271	0,339	0,317	0,012
g	0,419	0,526	0,453	0,018
b	0,146	0,273	0,230	0,024
H	0,243	0,323	0,269	0,016
S	0,352	0,735	0,493	0,071
V	0,549	0,859	0,740	0,087
Y	112,729	179,384	154,825	17,965
Cb	85,259	109,028	95,879	5,580
Cr	105,211	114,739	110,035	2,384
L*	135,144	207,697	180,886	20,251
a*	92,708	102,309	97,126	2,174
b*	155,358	178,068	167,607	5,540
i*	1,563	1,909	1,727	0,083

Fonte: Do autor.

Tabela 4 – Correlação de Pearson.

Índice	Primeiro Voo		Segundo Voo		Terceiro Voo	
	r	valor-p	r	valor-p	r	valor-p
R	-0,0924	0,6675	-0,1729	0,4191	-0,2036	0,3400
G	-0,1032	0,6314	-0,2154	0,3121	-0,1930	0,3662
B	-0,0318	0,8829	-0,0546	0,8000	0,2832	0,1799
INT	-0,0859	0,6897	-0,1559	0,4669	-0,0047	0,9824
VI	0,0243	0,9102	0,0398	0,8535	0,1373	0,5224
GMR	-0,0674	0,7544	-0,2000	0,3488	-0,0476	0,8251
VDVI	-0,0353	0,8699	-0,0579	0,7882	-0,4043	0,0500
GRR1	0,0134	0,9504	0,0285	0,8948	0,1293	0,5471
MGRVI	0,0294	0,8915	0,0446	0,8362	0,1408	0,5117
RBG	-0,0859	0,6897	-0,1559	0,4669	-0,0047	0,9824
RB	-0,0735	0,7330	-0,1219	0,5705	0,0933	0,6646
RG	-0,0982	0,6481	-0,1941	0,3634	-0,1995	0,3500
BG	-0,0793	0,7125	-0,1449	0,4993	0,0813	0,7058
BGR	-0,0439	0,8387	-0,1000	0,6420	0,2459	0,2467
BR	-0,0969	0,6525	-0,1902	0,3732	-0,1418	0,5086
IKAW	-0,0662	0,7587	-0,1469	0,4934	-0,4844	0,0165
ExR	-0,0298	0,8901	-0,0372	0,8629	-0,1221	0,5698
ExG	-0,0365	0,8655	-0,0590	0,7842	-0,4036	0,0505
RMB	-0,0985	0,6470	-0,2702	0,2016	-0,5143	0,0101
RMG	0,0674	0,7544	0,2000	0,3488	0,0476	0,8251
GMB	-0,1225	0,5685	-0,3043	0,1482	-0,5531	0,0051
TORGB	-0,1046	0,6267	-0,2254	0,2896	-0,4092	0,0471
TORB	-0,1018	0,6358	-0,2292	0,2813	-0,4898	0,0151
TOGB	-0,1185	0,5813	-0,2861	0,1753	-0,4834	0,0167
RGRG	-0,0243	0,9102	-0,0398	0,8535	-0,1373	0,5224
GBGB	-0,0702	0,7445	-0,1063	0,6211	-0,4610	0,0234
RGRGB	-0,0209	0,9228	-0,0139	0,9485	0,0595	0,7824
RBRGB	-0,0637	0,7674	-0,1646	0,4421	-0,4890	0,0153
GBRGB	-0,0613	0,7761	-0,0962	0,6549	-0,4544	0,0257
r	-0,0536	0,8035	-0,1691	0,4295	-0,4808	0,0174
g	-0,0365	0,8655	-0,0590	0,7842	-0,4036	0,0505
b	0,0660	0,7594	0,1271	0,5539	0,4755	0,0189
H	0,0378	0,8607	0,1879	0,3793	0,4747	0,0191
S	-0,0506	0,8145	-0,0979	0,6489	-0,4838	0,0166
V	-0,1032	0,6314	-0,2153	0,3123	-0,1929	0,3664
Y	-0,0964	0,6542	-0,1884	0,3779	-0,1337	0,5333
Cb	0,1145	0,5943	0,2983	0,1569	0,5444	0,0060
Cr	-0,0064	0,9764	0,0220	0,9186	-0,2456	0,2473
L*	-0,1007	0,6397	-0,2046	0,3376	-0,1813	0,3965
a*	0,1317	0,5396	0,2673	0,2067	0,4279	0,0370
b*	-0,1173	0,5852	-0,3039	0,1488	-0,5418	0,0062
i*	-0,1380	0,5202	-0,3104	0,1398	-0,5467	0,0057

Fonte: Do autor.

monstrou a existência de 17 índices, destacados em negrito, com *valor-p* abaixo de 0,05. Estes índices apresentaram valores de *r* variando entre as faixas de correlação fraca a moderada.

Em seguida, o procedimento anterior foi repetido mas desta vez, com uma análise de correlação não linear de *Spearman* e mantendo-se o mesmo nível de confiança de 95% conforme descrito em (LI, C. *et al.*, 2020). A Tabela 5 mostra os resultados indicando o coeficiente de correlação de *Spearman* ρ e o *valor-p*.

Conforme demonstrado na Tabela 5, existem 21 índices, destacados em negrito, com *valor-p* abaixo de 0,05. Estes índices apresentaram valores de ρ variando também entre as faixas de correlação fraca a moderada. A diferença de apenas 4 índices em relação a Tabela 4 indicou não ser suficiente para afirmar qual das duas técnicas de correlação foi melhor para usar como critério de seleção dos índices. Nota-se que em ambas as tabelas, há correlações positivas e negativas entre os índices destacados. No entanto, todos os valores de *r* e ρ ficaram abaixo de 0,70 ou 70%, o que reforça a justificativa pela escolha de utilizar RNAs para este problema.

Outro fator importante a ser observado é que, em ambas as técnicas de correlações aplicadas, somente obteve-se resultados favoráveis nos índices referente as imagens coletadas no terceiro voo. Diante desse fato, surgiu a hipótese de que os índices com *valor-p* abaixo de 0,05 pudessem ser diretamente proporcional a variância dos índices entre os três dias de coleta, ou seja, quanto menor o *valor-p* menor seria a variância, diminuindo gradativamente do primeiro para o terceiro dia.

Então, foi realizado uma análise de variância com os índices dos três dias de coleta e constatou-se que tal hipótese não se confirmava, exceto para poucos casos isolados. Por isso, essa análise não será demonstrada aqui. Um fator que pode ter contribuído para esse efeito é o fato de ocorrerem variações de luminosidade causadas pelas presença de nuvens durante os três voos de coleta de imagens. Também a presença de ventos em alguns momentos pode ter afetado a qualidade de algumas imagens. Os ventos causam turbulências no VANT que dependendo de sua intensidade, nem mesmo o controle automático de posicionamento da câmera seria o suficiente para a obtenção de imagens sem borrões e fora de foco.

Diante destas incertezas, decidiu-se em um primeiro momento, em selecionar todos os índices espectrais com *valor-p* abaixo de 0,05 de ambas as Tabelas 4 e 5, totalizando 21 índices, sendo eles: **B, VDVI, IKAW, ExG, RMB, GMB, TORGB, TORB, TOGB, GBGB, RBRGB, GBRGB, r, g, b, H, S, Cb, a*, b* e i***. A seguir, na Seção 6.6, estes índices serão utilizados para aplicação nas RNAs.

6.6 IMPLEMENTAÇÃO DAS REDES NEURAIAS ARTIFICIAIS

O objetivo desta seção foi aplicar alguns modelos de RNAs na tentativa de associar os 21 índices espectrais com os seus respectivos valores ICF relacionados. Para

Tabela 5 – Correlação de Spearman.

Índice	Primeiro Voo		Segundo Voo		Terceiro Voo	
	ρ	valor-p	ρ	valor-p	ρ	valor-p
R	-0,0861	0,6884	-0,0304	0,8884	-0,2296	0,2805
G	-0,0922	0,6674	-0,1548	0,4685	-0,2070	0,3319
B	0,1809	0,3959	-0,0104	0,9627	0,4487	0,0279
INT	-0,0374	0,8628	-0,0174	0,9368	0,0652	0,7621
VI	0,0322	0,8820	0,0226	0,9174	0,1104	0,6075
GMR	-0,1470	0,4915	-0,0991	0,6438	-0,0052	0,9807
VDVI	-0,3009	0,1529	-0,0774	0,7186	-0,5696	0,0037
GRR1	0,0322	0,8820	0,0226	0,9174	0,1104	0,6075
MGRVI	0,0322	0,8820	0,0226	0,9174	0,1104	0,6075
RBG	-0,0374	0,8628	-0,0174	0,9368	0,0652	0,7621
RB	-0,0270	0,9013	-0,0148	0,9465	0,2461	0,2464
RG	-0,1070	0,6177	-0,0435	0,8404	-0,2365	0,2658
BG	-0,0174	0,9368	-0,0278	0,8981	0,1843	0,3885
BGR	0,0748	0,7278	-0,0461	0,8309	0,3478	0,0958
BR	-0,0843	0,6944	-0,0565	0,7930	-0,1417	0,5088
IKAW	-0,2165	0,3080	-0,2270	0,2848	-0,6609	0,0004
ExR	-0,0470	0,8277	-0,0165	0,9400	-0,1104	0,6075
ExG	-0,3009	0,1529	-0,0774	0,7186	-0,5696	0,0037
RMB	-0,1470	0,4915	-0,3548	0,0895	-0,6226	0,0012
RMG	0,1470	0,4915	0,0991	0,6438	0,0052	0,9807
GMB	-0,1748	0,4123	-0,4043	0,0511	-0,6461	0,0006
TORGB	-0,1278	0,5502	-0,1565	0,4634	-0,4426	0,0303
TORB	-0,1496	0,4838	-0,1626	0,4460	-0,4800	0,0176
TOGB	-0,1739	0,4146	-0,3313	0,1141	-0,5026	0,0123
RGRG	-0,0322	0,8820	-0,0226	0,9174	-0,1104	0,6075
GBGB	-0,2435	0,2505	-0,0600	0,7804	-0,6357	0,0008
RGRGB	0,0443	0,8372	0,0183	0,9336	0,1374	0,5220
RBRGB	-0,2183	0,3041	-0,2565	0,2253	-0,6696	0,0003
GBRGB	-0,2417	0,2539	-0,0513	0,8119	-0,6157	0,0014
r	-0,1983	0,3514	-0,2035	0,3387	-0,5635	0,0041
g	-0,3009	0,1529	-0,0774	0,7186	-0,5696	0,0037
b	0,2078	0,3283	0,1583	0,4584	0,6417	0,0007
H	0,1896	0,3733	0,2600	0,2189	0,5591	0,0045
S	-0,2426	0,2522	-0,0191	0,9303	-0,6496	0,0006
V	-0,0922	0,6674	-0,1548	0,4685	-0,2070	0,3319
Y	-0,0652	0,7617	-0,0565	0,7930	-0,1200	0,5765
Cb	0,1730	0,4170	0,3922	0,0590	0,6400	0,0008
Cr	-0,0443	0,8372	-0,0922	0,6674	-0,2935	0,1639
L*	-0,1017	0,6350	-0,0965	0,6526	-0,2000	0,3488
a*	0,2470	0,2436	0,1965	0,3557	0,4643	0,0223
b*	-0,1974	0,3536	-0,4043	0,0511	-0,6174	0,0013
i*	-0,1765	0,4076	-0,2722	0,1975	-0,6139	0,0014

Fonte: Do autor.

isso, foi utilizado a ferramenta *nftool* incorporada ao programa *Matlab*[®], desenvolvida exclusivamente para resolver problemas de regressão. Por padrão, essa ferramenta implementa RNAs do tipo MLP com as seguintes configurações:

- Uma camada de entrada sem função de ativação;
- Uma camada oculta com função de ativação não linear do tipo *Tangente Hiperbólica*;
- Uma camada de saída com função de ativação linear do tipo *Purelin*;
- Algoritmo de treinamento supervisionado *Backpropagation Levenberg-Marquardt*;
- Critério de parada do treinamento baseado nos seguintes parâmetros: número máximo de épocas igual a 1000; Mean Squared Error (MSE) igual a zero; Gradiente Mínimo igual a 1×10^{-7} ; Número máximo de falhas na validação igual a 6;
- Critério de desempenho baseado no Erro Médio Quadrático MSE;
- Separação aleatória da base de dados em 70% para treinamento e 30% para validação;
- Normalização da base de dados entre o intervalo de -1 à 1.

Desta forma, coube ao autor realizar testes experimentais durante a etapa de treinamento alterando-se apenas a quantidade de neurônios na camada oculta até se atingir os menores valores de MSE possíveis conforme sequência descrita abaixo:

- **Passo 1:** Selecionar dados de entrada e saída;
- **Passo 2:** Separar percentual dos dados de treinamento e validação;
- **Passo 3:** Definir quantidade de neurônios da camada oculta;
- **Passo 4:** Criar a rede neural;
- **Passo 5:** Realizar o treinamento;
- **Passo 6:** Verificar gráficos de performance;
- **Passo 7:** Se resultado for satisfatório então finalizar, senão retornar ao **Passo 3**.

6.6.1 Treinamento e Validação

Em um primeiro experimento baseado nas publicações de Mohan e Gupta (2019), Barman e Choudhury (2020) e Shi *et al.* (2020), do total de 21 índices espectrais selecionados no final da Subseção 6.5.4, os 5 índices com correlação positiva em relação aos valores ICF medidos foram selecionados e atribuídos como entrada da RNA. Os índices selecionados foram: **B**, **b**, **H**, **Cb** e **a***. Os dados de entrada e saída da RNA foram organizados conforme as Equações 5 e 6.

$$\begin{bmatrix} X_{1,1} & X_{1,2} & \dots & X_{1,j} \\ X_{2,1} & X_{2,2} & \dots & X_{2,j} \\ \cdot & & & \\ \cdot & & & \\ \cdot & & & \\ X_{i,1} & X_{i,2} & \dots & X_{i,j} \end{bmatrix} \quad (5)$$

$$\begin{bmatrix} Y_1 & Y_2 & \dots & Y_j \end{bmatrix} \quad (6)$$

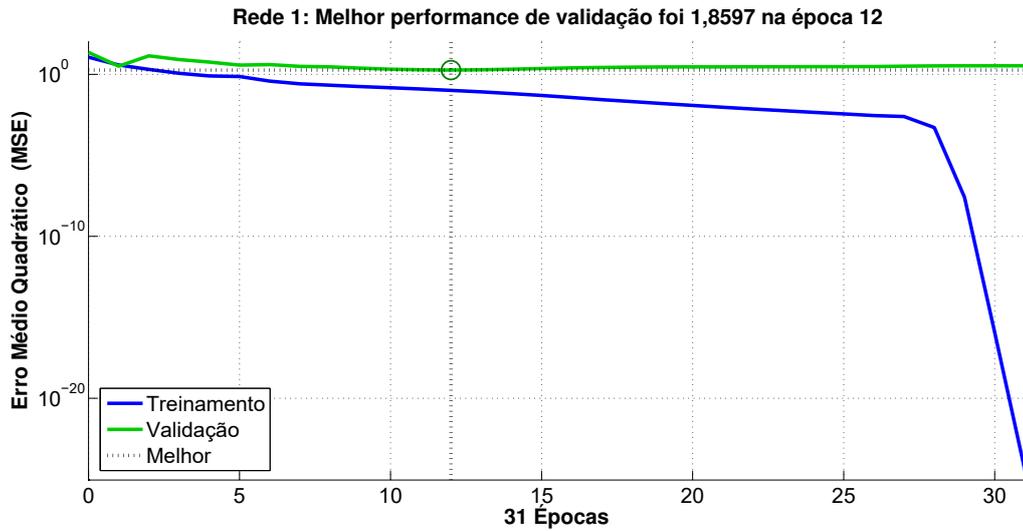
onde $X_{i,j}$ são os índices espectrais atribuídos como entrada e organizados em i linhas j colunas e Y_j são os valores ICF medidos atribuídos como saída e organizados em j colunas.

Neste primeiro procedimento, os dados de entrada foram organizados conforme a Equação 5 contendo 5 linhas e 24 colunas, enquanto a saída foi organizada através a Equação 6 contendo 1 linha e 24 colunas. Cabe ressaltar que o número de colunas se deve as 24 unidades amostrais do experimento. Em seguida, vários testes variando-se apenas a quantidade de neurônios na camada oculta da RNA foram realizados até que se obtivesse a melhor performance possível. Esse procedimento resultou em uma RNA com 5 neurônios na camada oculta. A Figura 24 ilustra a performance de treinamento e validação da primeira RNA obtida.

Conforme se pode observar na Figura 24, um total de 31 épocas foram necessárias para encerrar o treinamento. Não há indicações de *overfitting* da RNA 1 pois a performance de treinamento, representado pela linha na cor azul, reduziu com o passar das épocas enquanto a performance de validação, representado pela linha na cor verde, permaneceu estável em torno da linha de melhor performance representada pela linha pontilhada. A Figura 25 ilustra o histograma de erros obtidos pela RNA 1 durante sua etapa de treinamento e validação.

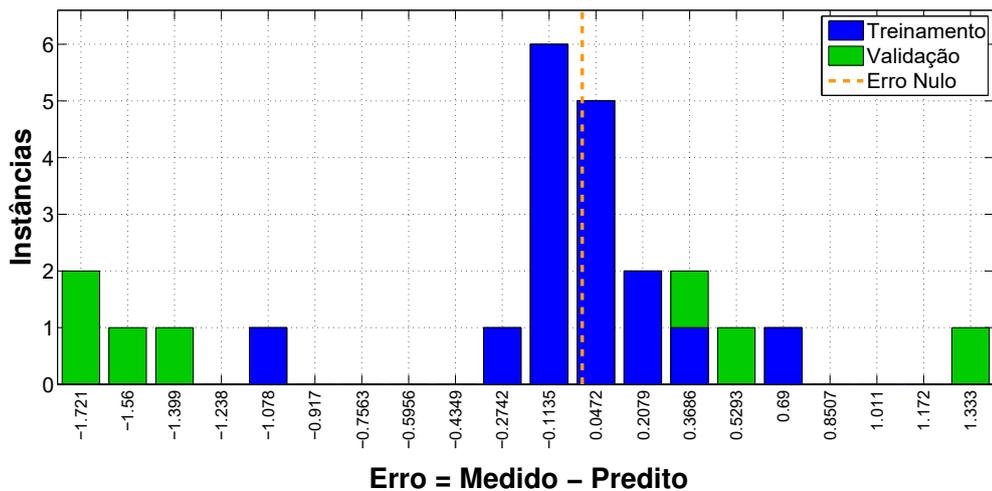
De acordo com a Figura 25, os erros da etapa de treinamento, representados pelas barras na cor azul, estão mais concentrados próximo a linha de erro nulo, representada pela linha tracejada na cor amarela, enquanto os erros da etapa de validação, representados pelas barras na cor verde, aparecem um pouco mais dispersos a direita e a esquerda da linha de erro nulo. Isso indica que o desempenho na etapa de validação foi inferior ao da etapa de treinamento.

Figura 24 – Performance de Treinamento e Validação da RNA 1.



Fonte: Do autor.

Figura 25 – Histograma de Erros da RNA 1.

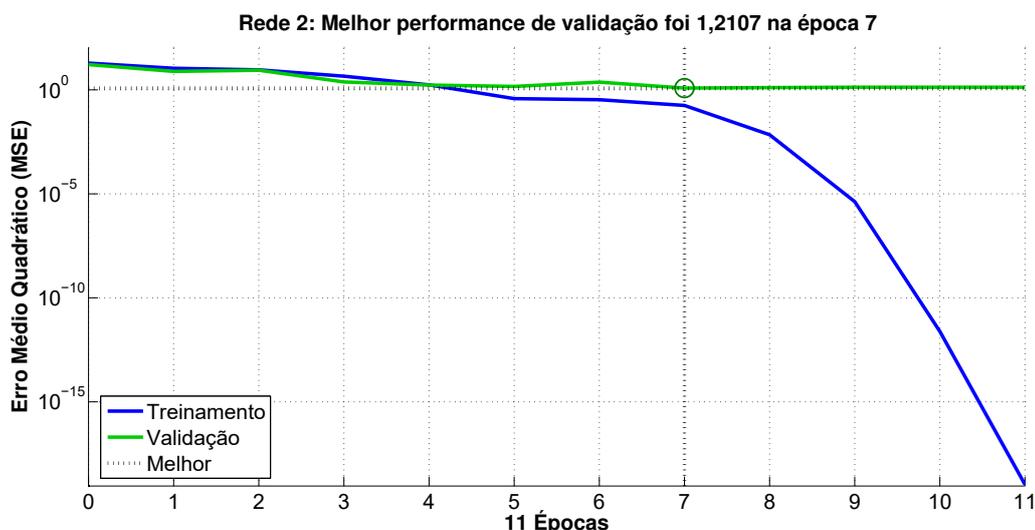


Fonte: Do autor.

Logo após, em um segundo experimento, foram selecionados e organizados como entrada da rede neural os 16 índices restantes, cujo as correlações com os valores ICF eram negativas. Os índices selecionados foram: **VDVI, IKAW, ExG, RMB, GMB, TORGB, TORB, TOGB, GBGB, RBRGB, GBRGB, r, g, S, b*** e **i***. Estes índices foram organizados conforme a Equação 5 contendo 16 linhas e 24 colunas, sendo que manteve-se a mesma matriz de saída do primeiro experimento. Replicando-se os procedimentos executados para a RNA 1, obteve-se a RNA 2 com 10 neurônios na camada oculta e com performance descrita pela Figura 26.

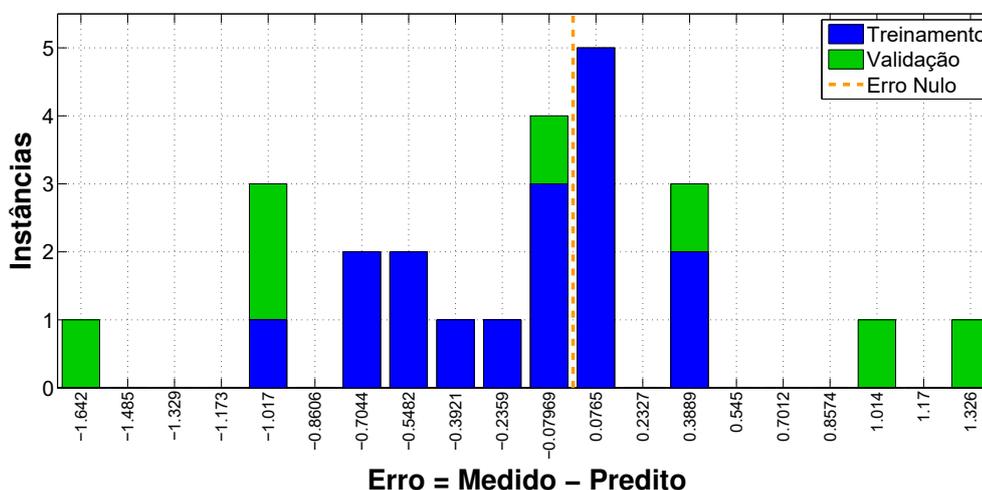
Conforme se pode observar na Figura 26, apenas 11 épocas foram necessários para encerrar o treinamento. Observa-se que a linha de validação manteve-se estável sobre a linha de melhor performance, enquanto a linha de treinamento se deslocou

Figura 26 – Performance de Treinamento e Validação da RNA 2.



para baixo com o passar das épocas, indicando que não ocorreu *overfitting* da RNA 2. A Figura 27 ilustra o histograma de erros obtidos pela RNA 2 durante sua etapa de treinamento e validação.

Figura 27 – Histograma de Erros da RNA 2.

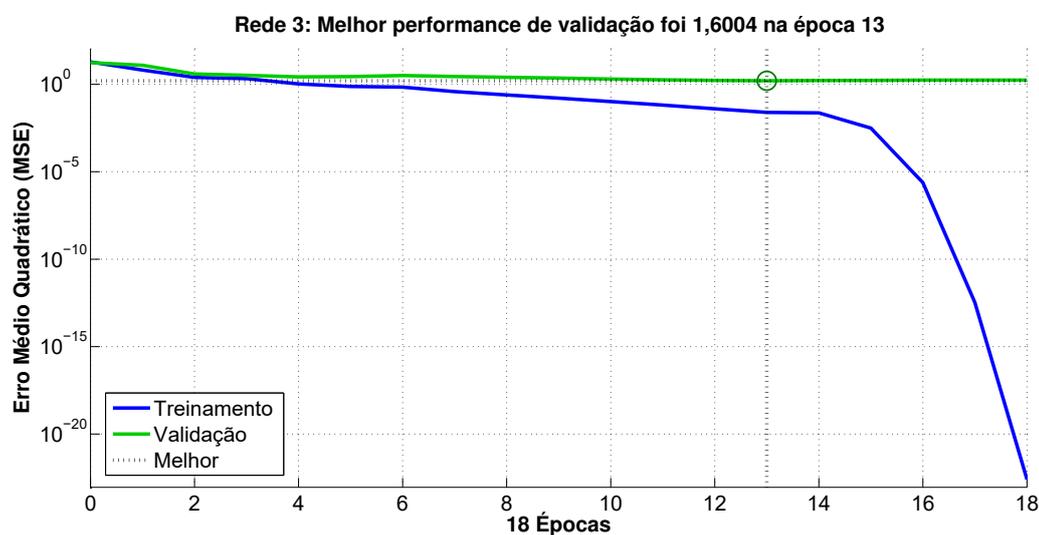


De acordo com o gráfico ilustrado pela Figura 27, a maior parcela dos erros da etapa de treinamento da RNA 2 estão mais próximos a linha de erro nulo e o restante distribuído mais a esquerda, enquanto o erros da etapa de validação aparecem um pouco mais dispersos a direita e a esquerda da linha de erro nulo. Essa maior dispersão dos erros de ambas as etapas indica que o desempenho geral da RNA 2 foi um pouco superior ao da RNA 1.

A fim de tentar diminuir a quantidade e a complexidade dos dados de entrada

com correlação negativa, dois novos modelos de redes neurais foram gerados com base nos dois procedimentos anteriores. No terceiro experimento para geração da RNA 3, somente os índices com correlação negativa e maiores que 50% foram selecionados e atribuídos como entrada. Desta forma, 9 índices espectrais foram utilizados para treinar um novo modelo de RNA. Os índices selecionados foram: **IKAW**, **RMB**, **GMB**, **GBGB**, **RBRGB**, **GBRGB**, **S**, **b*** e **i***. Estes índices foram organizados conforme a Equação 5 contendo 9 linhas e 24 colunas, sendo que manteve-se a mesma matriz de saída dos experimentos anteriores. Ao final deste procedimento obteve-se uma rede neural com 10 neurônios na camada oculta conforme gráfico de performance ilustrado na Figura 28.

Figura 28 – Performance de Treinamento e Validação da RNA 3.

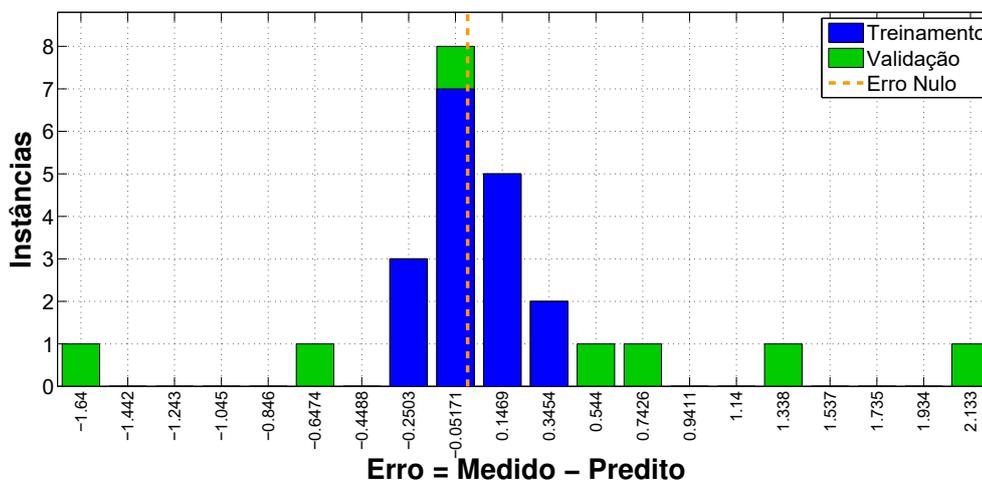


Fonte: Do autor.

Conforme demonstrado na Figura 28, apenas 18 épocas foram necessárias para encerrar o treinamento. É provável que a redução de 7 índices na matriz de entrada tenha implicado no acréscimo de 7 épocas durante a etapa de treinamento. No entanto, observa-se que a linha de validação manteve-se estável sobre a linha de melhor performance, enquanto a linha de treinamento se deslocou para baixo com o passar das épocas, indicando que também não ocorreu *overfitting* da RNA 3. A Figura 29 ilustra o histograma de erros obtidos pela RNA 3 durante sua etapa de treinamento e validação.

De acordo com a Figura 29, a quase totalidade dos erros da etapa de treinamento da RNA 3 ficaram distribuídos próximos a linha de erro nulo. Os erros da etapa de validação também aparecem em maior quantidade muito próximos a linha de erro nulo e o restante distribuídos de forma quase homogênea a direita e a esquerda da linha. Essa distribuição mais limpa dos erros de ambas as etapas indica que o desempenho geral da RNA 3 foi um pouco superior ao das RNAs 1 e 2.

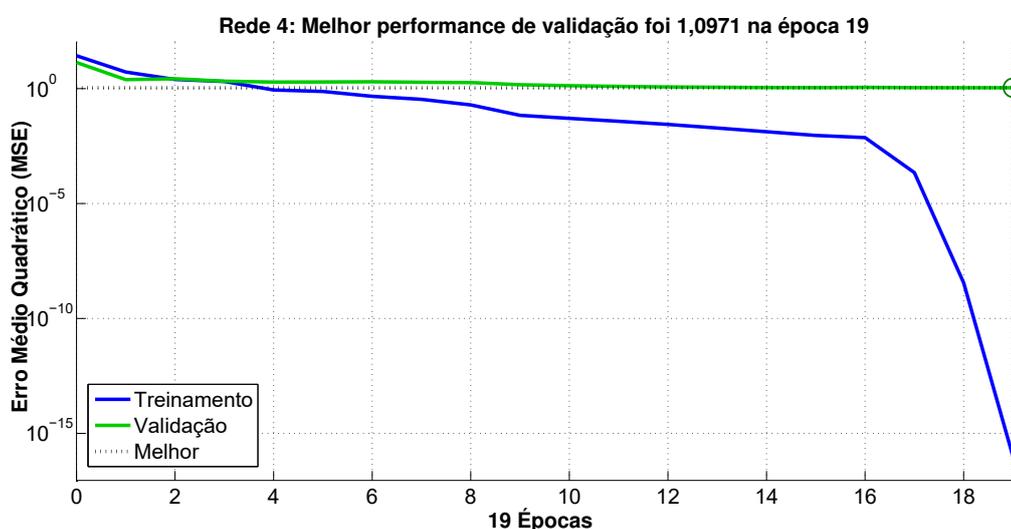
Figura 29 – Histograma de Erros da RNA 3.



Fonte: Do autor.

Por fim, um quarto experimento foi realizado para a geração da RNA 4. Foram selecionados os índices com correlação negativa maiores que 50% e *valor-p* abaixo de 0,001. Seu objetivo foi reduzir ainda mais a quantidade e complexidade dos dados de entrada. Desta forma, resultou em 5 índices espectrais selecionados e utilizados para treinar o último modelo de RNA. Os índices selecionados foram: **IKAW**, **GMB**, **GBGB**, **RBRGB** e **S**. Estes índices foram organizados conforme a Equação 5 contendo 5 linhas e 24 colunas, sendo que também manteve-se a mesma matriz de saída dos experimentos anteriores. Ao final deste último procedimento obteve-se uma rede neural com 10 neurônios na camada oculta conforme gráfico de performance ilustrado na Figura 30.

Figura 30 – Performance de Treinamento e Validação da RNA 4.



Fonte: Do autor.

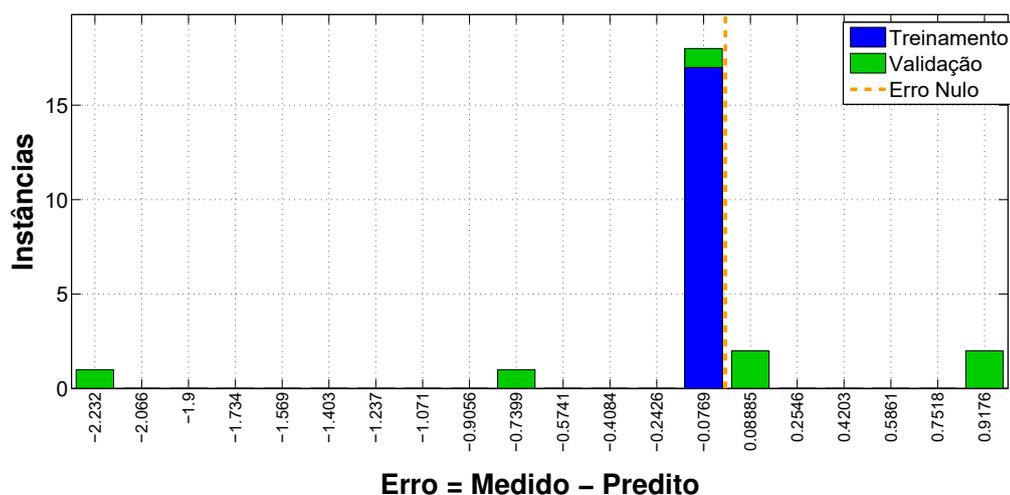
Tabela 6 – Arquitetura das RNAs Implementadas.

Rede	Entradas	Camadas Ocultas	Neurônios Ocultos	Saídas
1	05	01	05	01
2	16	01	10	01
3	09	01	10	01
4	05	01	10	01

Fonte: Do autor

Conforme ilustrado na Figura 30, apenas 19 épocas foram necessárias para encerrar o treinamento. Isso implicou, se comparada a RNA 3, na redução 4 índices espectrais e acréscimo de apenas 1 época. Além disso, observa-se que a linha de validação também manteve-se estável sobre a linha de melhor performance, enquanto a linha de treinamento se deslocou para baixo com o passar das épocas, indicando que não ocorreu *overfitting* da RNA 4. A Figura 31 ilustra o histograma de erros obtidos pela RNA 4 durante sua etapa de treinamento e validação.

Figura 31 – Histograma de Erros da RNA 4.



Fonte: Do autor

De acordo com a Figura 31, a totalidade dos erros da etapa de treinamento da RNA 4 ficaram distribuídos muito próximos a linha de erro nulo, indicando excelente performance nesta etapa. Os erros da etapa de validação também aparecem em sua quase totalidade próximos a linha de erro nulo e o restante, com poucas instâncias e distribuídos de forma quase homogênea a direita e a esquerda da linha. Essa foi a distribuição de erros mais limpa entre os quatro modelos de RNAs gerados, indicando que o desempenho geral da RNA 4 foi um pouco superior as demais redes.

A fim de demonstrar de forma geral a arquitetura dos modelos de redes neurais desenvolvidos nesta etapa, a Tabela 6 descreve os principais parâmetros implementados. Conforme se pode observar na Tabela 6, a RNA 1 foi implementada com uma diferença de 5 neurônios a menos em relação as demais redes. Não é possível afirmar

se a pior performance obtida pela RNA 1 está diretamente relacionada a sua quantidade inferior de neurônios, haja visto que outros parâmetros tais como quais e quantos índices espectrais utilizados, por exemplo, também deveriam ser analisados para se chegar a uma conclusão. No entanto, não é o foco desta pesquisa fazer uma análise comparativa de performance entre as RNAs. No Capítulo 7 serão demonstrados e discutidos os resultados das quatro redes neurais obtidas nesta seção.

7 RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados e discutidos os resultados dos quatro modelos de RNAs desenvolvidos no Capítulo 6. Cabe ressaltar que tratou-se de um problema de regressão não linear com entradas e saídas numéricas. Muitos problemas semelhantes são resolvidos com técnicas de regressão linear clássicas, desde que hajam bons níveis de correlação entre as variáveis de entrada e saída do modelo. No entanto, conforme detalhado na Subseção 6.5.4 do Capítulo 6, as variáveis envolvidas neste problema possuem baixos níveis de correlação entre si, tornando impraticável sua solução através dos métodos clássicos de regressão linear. Por isso utilizou-se RNAs devido sua maior capacidade em resolver problemas com baixos níveis de linearidade, além de serem técnicas mais modernas e baseadas em novas tecnologias computacionais. No decorrer deste capítulo, serão apresentados gráficos de regressões e variações de erros de cada modelo desenvolvido, bem como tabelas para simples comparações de desempenhos das RNAs.

7.1 INTERPRETAÇÃO DOS RESULTADOS

Os resultados de cada RNA serão apresentados em três gráficos distintos nas mesmas figuras. Os gráficos apresentarão, através de retas de regressão, índices e equações, os respectivos resultados das etapas de treinamento, validação e o desempenho geral dos modelos. Devido a baixa quantidade de amostras da base de dados, julgou-se necessário apresentar o terceiro gráfico para verificar o desempenho geral das RNAs. Desta forma, este gráfico demonstrará os resultados com base na aplicação das 24 amostras da base de dados às redes neurais e comparadas as suas saídas preditas com os valores ICF medidos. As amostras serão representadas nos gráficos por pequenas circunferências distribuídas em torno e sobre as retas de regressão.

Em cada gráfico, três índices de desempenho serão apresentados. O primeiro índice será o coeficiente de correlação de *Pearson* r , que associará os valores ICF medidos com os níveis de Chl preditos pela saída da RNA. Quanto maior o valor absoluto de r , maior o nível de correlação. O valor de r é fornecido pelo programa *Matlab*[®] e indicado para medir a precisão das retas de correlação em relação as linhas pontilhadas de referências.

O segundo índice de desempenho será o coeficiente de determinação R^2 . Conforme demonstrado na publicação de Meiling Liu *et al.* (2010), este índice é obtido elevando-se os valores de r ao quadrado. Ele explicará a variância dos níveis de Chl preditos pelas RNAs a partir da variação dos valores ICF medidos. Indica que quanto maior o valor de R^2 melhor será a capacidade de predição de cada modelo.

O terceiro índice de desempenho será o erro quadrático médio ou MSE. Este índice também é fornecido pelo programa *Matlab*[®] que o apresenta em todas as etapas

de teste das RNAs. Ele apresentará uma visão geral do erro de predição, comparando os valores de ICF medidos com os valores de Chl preditos na saída de cada rede neural. Quanto menor o MSE apresentado, maior a precisão do modelo.

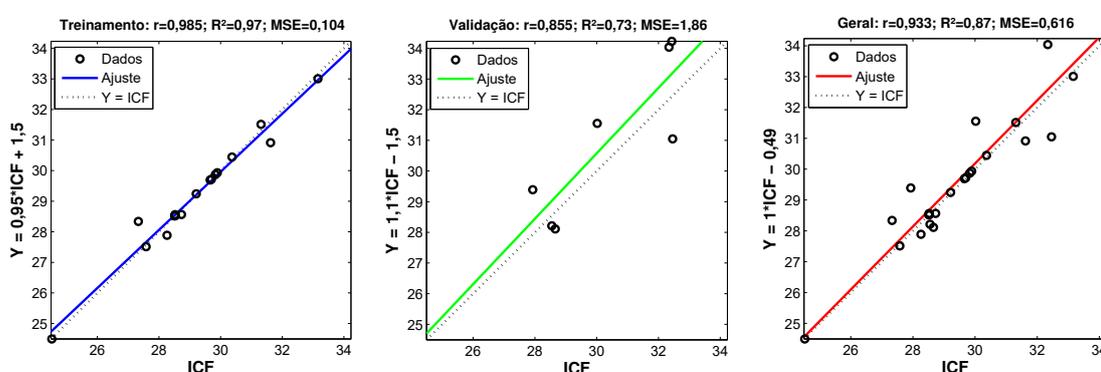
Para cada saída, representada nos gráficos pela letra Y, existirá uma equação de reta associada que descreverá a inclinação e o deslocamento, em relação a linha pontilhada de referência, de cada uma das retas de regressão identificadas pelas cores azul, para a etapa de treinamento, verde, para a etapa de validação e vermelho, para análise do desempenho geral. As retas explicam o comportamento dos modelos em cada etapa avaliada. Quanto maior a sobreposição das retas de regressão sobre as linhas pontilhadas, maiores serão os valores de r e R^2 e conseqüentemente, melhores os resultados das redes neurais.

A fim de se obter uma visão geral dos erros gerados entre os valores ICF medidos e os níveis de Chl preditos por cada modelo de RNA, figuras ilustrando a variação dos erros também serão apresentadas. Através da variação no comprimento de barras verticais, as magnitudes dos erros das redes neurais serão demonstradas. Estes gráficos associarão os erros de cada uma das amostras da base de dados. Por fim, serão utilizadas tabelas para agrupar todas as variáveis numéricas de desempenho, possibilitando uma visão geral dos resultados obtidos pelas redes neurais desenvolvidas.

7.2 RESULTADOS DA RNA 1

Os resultados do primeiro modelo foram obtidos com base nos 5 índices espectrais: **B**, **b**, **H**, **Cb** e **a***. A Figura 32 apresenta os três gráficos de regressões para as etapas de treinamento, validação e desempenho geral. Observa-se na Figura 32

Figura 32 – Gráficos de regressão da RNA 1.



Fonte: Do autor.

que na etapa de treinamento, a linha azul encontra-se quase sobreposta sobre a linha

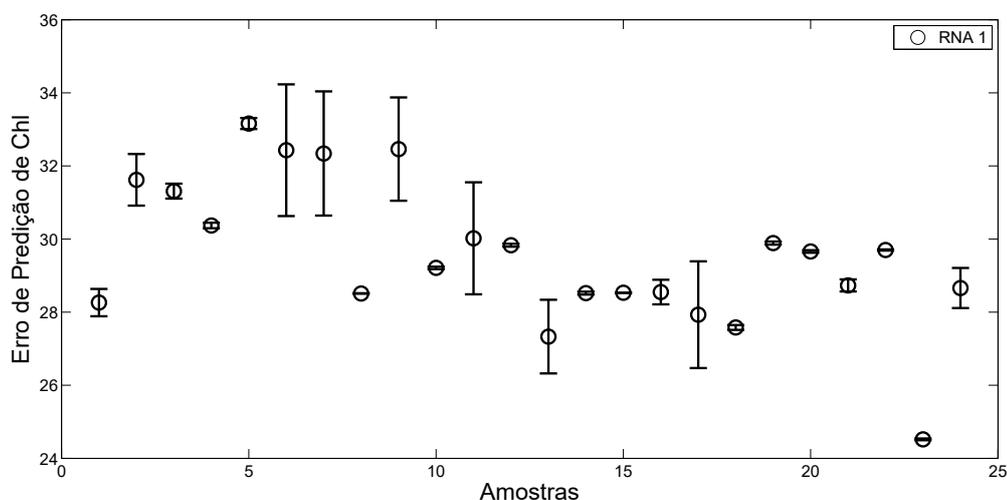
pontilhada. Isso explica as 17 amostras utilizadas nesta etapa estarem distribuídas muito próximas a linha azul. Desta forma, a etapa de treinamento da RNA 1 obteve um desempenho demonstrado pelos índices $r=0,985$, $R^2=0,97$ e $MSE=0,104$.

Para a etapa de validação, é possível observar que as 7 amostras utilizadas encontram-se mais dispersas, o que justifica a linha verde estar um pouco deslocada para cima em relação a linha pontilhada. Isso proporcionou um desempenho demonstrado pelos índices $r=0,855$, $R^2=0,73$ e $MSE=1,86$. A etapa de validação é certamente a mais importante para verificação de desempenho de uma RNA, pois as amostras utilizadas por ela não pertenceram ao conjunto de amostras utilizadas na etapa de treinamento. No entanto, não é possível afirmar se apenas a baixa quantidade de amostras utilizadas nesta etapa tenha contribuído para o seu desempenho inferior, se comparada a etapa de treinamento. Desta forma, com base no valor do índice R^2 supõe-se que a RNA 1, no pior cenário, obteve uma precisão de 73% em sua capacidade de predição dos níveis de Chl na planta do arroz.

O terceiro gráfico da Figura 32, ilustra o desempenho geral da RNA 1. Se comparada a etapa de validação, observa-se uma melhor distribuição das amostras, o que justifica a linha vermelha encontrar-se muito próxima a linha pontilhada. Isso proporcionou um desempenho indicado pelos índices $r=0,933$, $R^2=0,87$ e $MSE=0,616$. Considerando-se válido o teste de desempenho geral que envolveu todas as amostras da base de dados, pode-se supor que a RNA 1, no seu melhor cenário, obteve uma precisão de 87% em sua capacidade de predição dos níveis de Chl.

Através da Figura 33, é possível fazer uma análise dos erros de predição da RNA 1. Conforme se pode observar na Figura 33, quanto maior o comprimento das

Figura 33 – RNA 1: Variação geral dos erros.



Fonte: Do autor.

barras verticais, maior o valor do erro. Observa-se ainda várias amostras com erros

pequenos, quase nulos. A Tabela 7 mostra um agrupamento dos resultados numéricos de desempenhos obtidos nas três etapas de avaliação da RNA 1.

Tabela 7 – Desempenho entre etapas da RNA 1.

Etapas	Equação	MSE	r	R ²
Treinamento	$Y = 0,95 * ICF + 1,5$	0,104	0,985	0,97
Validação	$Y = 1,1 * ICF - 1,5$	1,86	0,855	0,73
Geral	$Y = 1 * ICF - 0,49$	0,616	0,933	0,87

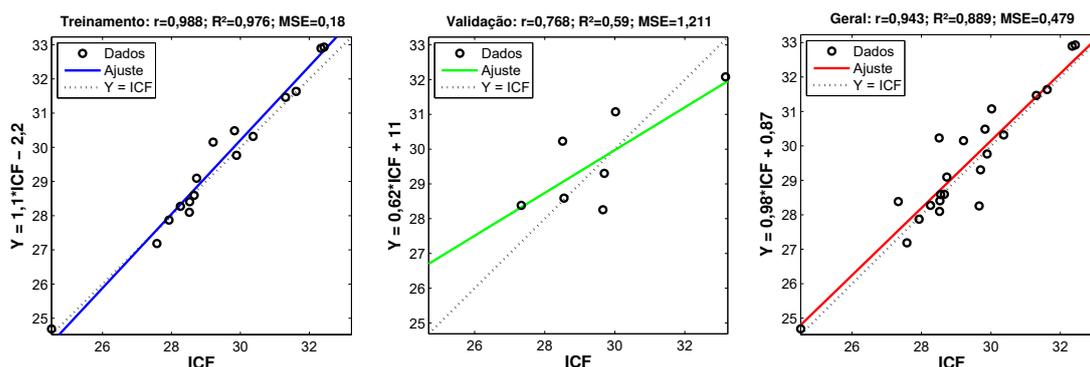
Fonte: Do autor

As equações lineares descritas na Tabela 7 descrevem a inclinação e o deslocamento de cada uma das retas de regressão ilustradas na Figura 32. É possível observar que existe uma clara relação inversamente proporcional entre os valores do MSE e os valores de r e R² de cada etapa, ou seja, quanto menor o valor do MSE, maiores os valores de r e R².

7.3 RESULTADOS DA RNA 2

Para o segundo modelo, seus resultados foram obtidos com base nos 16 índices espectrais: **VDVI, IKAW, ExG, RMB, GMB, TORGB, TORB, TOGB, GBGB, RBRGB, GBRGB, r, g, S, b* e i***. A Figura 34 ilustra os três gráficos com os resultados de cada etapa da RNA 2. Observa-se um excelente resultado para a etapa de treinamento,

Figura 34 – Gráficos de regressão da RNA 2.



Fonte: Do autor.

com a linha azul quase sobreposta sobre a linha pontilhada. Desta forma, a RNA 2 obteve um desempenho indicado pelos índices $r=0,988$, $R^2=0,976$ e $MSE=0,18$. Seu desempenho nesta etapa foi um pouco superior em relação a RNA 1.

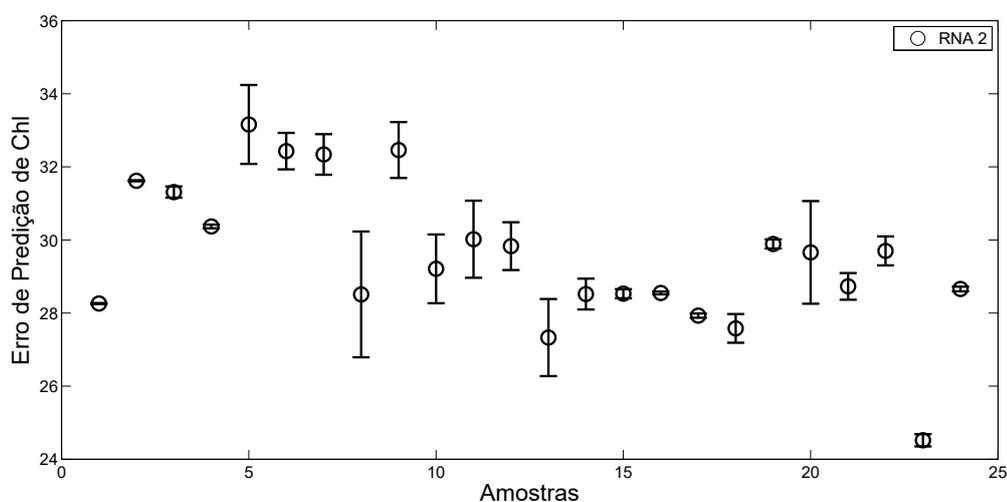
Para a etapa de validação, observa-se uma degradação no seu desempenho. As 7 amostras utilizadas nesta etapa encontram-se ainda mais dispersas e a linha verde

mais deslocada e com inclinação inferior a linha pontilhada. Neste resultado, a RNA 2 obteve um desempenho indicado pelos índices $r=0,768$, $R^2=0,59$ e $MSE=1,211$, sendo muito inferior se comparado aos resultados para a mesma etapa da RNA 1. Cabe ressaltar que a RNA 2 foi treinada com 16 índices espectrais aplicados em sua entrada, ou seja, 11 índices a mais se comparada a RNA 1. Outro fator são os índices espectrais possuírem correlações negativas em relação aos valores ICF medidos, enquanto na RNA 1, os índices possuem correlação positiva. Não é possível afirmar se tanto a quantidade inferior de amostras para o teste da etapa de validação quanto o sentido das correlações e aumento na quantidade de índices de entrada para a etapa de treinamento, tenham contribuído para o desempenho inferior da RNA 2. Desta forma, supõe-se que a RNA 2, em seu pior cenário, obteve uma precisão de 59% em sua capacidade de predição dos níveis de Chl na planta do arroz.

O terceiro gráfico da Figura 34, ilustra o resultado geral da RNA 2. Se comparada com a etapa de validação, observa-se também uma melhor distribuição das amostras, o que justifica a linha vermelha encontrar-se muito próxima a linha pontilhada. Isso proporcionou um desempenho indicado pelos índices $r=0,943$, $R^2=0,889$ e $MSE=0,479$. Considerando-se válido esse teste, é possível afirmar que a RNA 2, em seu melhor cenário, obteve uma precisão de 88,9%, um pouco superior ao mesmo teste para a RNA 1, indicando um bom desempenho deste modelo.

Para possibilitar uma visão geral dos erros gerados entre os valores ICF medidos e os níveis de Chl preditos pela RNA 2, a Figura 35 ilustra as magnitudes dos erros para cada uma das 24 amostras da base de dados utilizada no teste geral RNA 2. Observa-se na Figura 35, várias amostras com erros muito pequenos, quase nulos.

Figura 35 – RNA 2: Variação geral dos erros.



Fonte: Do autor.

A Tabela 8 mostra um agrupamento dos índices de desempenhos obtidos nas três etapas de avaliação da RNA 2.

Tabela 8 – Desempenho entre etapas da RNA 2.

Etapas	Equação	MSE	R	R ²
Treinamento	$Y = 1,1 * ICF - 2,2$	0,18	0,988	0,976
Validação	$Y = 0,62 * ICF + 11$	1,211	0,768	0,59
Geral	$Y = 0,98 * ICF - 0,87$	0,479	0,943	0,889

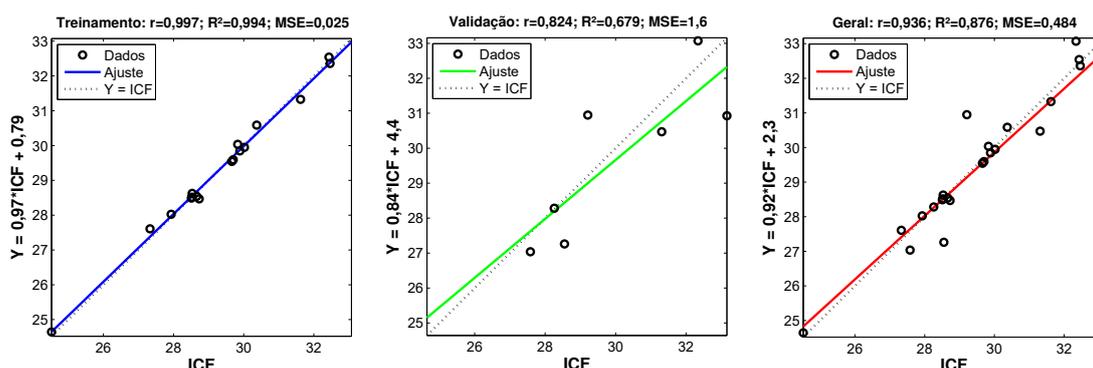
Fonte: Do autor

É possível observar na Tabela 8, que a equação da reta de regressão da etapa de validação da RNA 2 é muito diferente da equação de reta da mesma etapa se comparada com a RNA 1. No entanto, observa-se uma clara aproximação das equações das retas de regressão na análise de desempenho geral de ambos os modelos para a RNA 1 e RNA 2.

7.4 RESULTADOS DA RNA 3

Conforme detalhado no Capítulo 6, o terceiro modelo de rede neural foi desenvolvido a partir de uma modificação da RNA 2. Seus resultados foram obtidos com base nos 9 índices espectrais: **IKAW**, **RMB**, **GMB**, **GBGB**, **RBRGB**, **GBRGB**, **S**, **b*** e **i***. Para análise dos resultados, a Figura 36 ilustra os três gráficos com o desempenho de cada etapa da RNA 3. Se comparada aos dois modelos anteriores, observa-se

Figura 36 – Gráficos de regressão da RNA 3.



Fonte: Do autor.

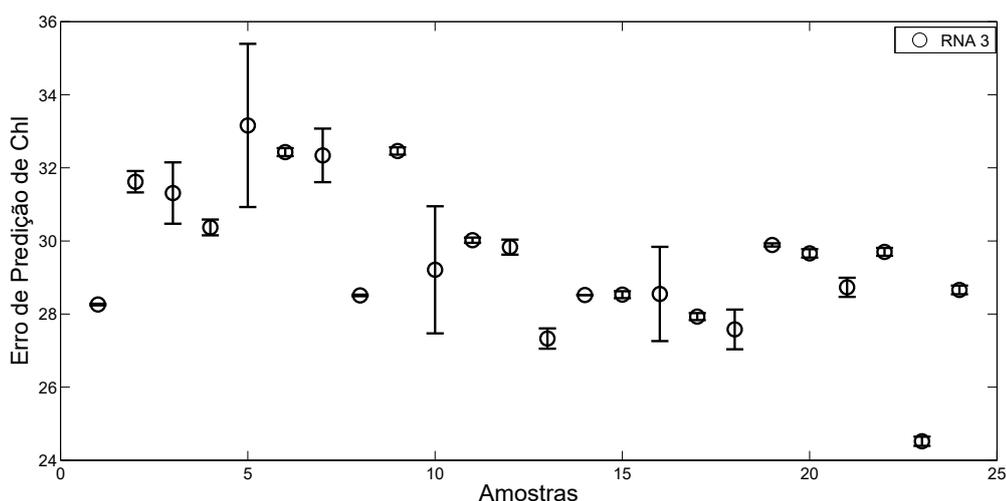
um excelente resultado, com suas 17 amostras também distribuídas muito próximas a linha azul, quase sobreposta sobre a linha pontilhada. Desta forma, nesta etapa a RNA 3 obteve um desempenho indicado pelos índices $r=0,997$, $R^2=0,994$ e $MSE=0,025$, sendo que o desempenho nesta etapa foi um pouco superior em relação as RNAs 1 e 2.

Para a etapa de validação, observa-se para a RNA 3 um desempenho superior a RNA 2 mas inferior a RNA 1. As 7 amostras desta etapa encontram-se ainda dispersas e a linha verde também deslocada e com inclinação inferior a linha pontilhada. Esse resultado demonstra um desempenho indicado pelos índices $r=0,824$, $R^2=0,679$ e $MSE=1,6$. Cabe ressaltar que a RNA 3 é uma modificação da RNA 2, cuja a quantidade de entradas foi reduzida para 9 índices espectrais, ou seja, 7 índices a menos se comparada a RNA 2. Supõe-se que a redução dos índices tenha eliminado informações redundantes da base de dados e desta forma contribuído para a melhora no desempenho deste modelo. Desta forma, pode-se afirmar que a RNA 3, em seu pior cenário, obteve uma precisão de 67,9% em sua capacidade de predição dos níveis de Chl.

O terceiro gráfico da Figura 36 faz uma projeção do resultado geral da RNA 3. Se comparada à etapa de validação, observa-se também uma melhor distribuição das amostras, o que justifica a linha vermelha encontrar-se muito próxima a linha pontilhada. Isso proporcionou um desempenho demonstrado pelos índices $r=0,936$, $R^2=0,876$ e $MSE=0,484$, indicando um bom desempenho geral para a RNA 3. Considerando-se válido esse teste, pode-se afirmar que a RNA 3, em seu melhor cenário, obteve uma precisão de 87,6%, um valor intermediário entre as RNAs 1 e 2.

Através da Figura 37 verificam-se as magnitudes dos erros entre os valores de Chl medidos e os valores preditos pela saída da RNA 3. Observa-se na Figura

Figura 37 – RNA 3: Variação geral dos erros.



Fonte: Do autor.

37 várias amostras com erros muito pequenos, quase nulos. A Tabela 9 mostra um agrupamento dos índices de desempenho obtidos nas três etapas de avaliação da RNA 3.

Tabela 9 – Desempenho entre etapas da RNA 3.

Etapas	Equação	MSE	R	R ²
Treinamento	$Y = 0,97*ICF + 0,79$	0,025	0,997	0,994
Validação	$Y = 0,84*ICF + 4,4$	1,6	0,824	0,679
Geral	$Y = 0,92*ICF + 2,3$	0,484	0,936	0,876

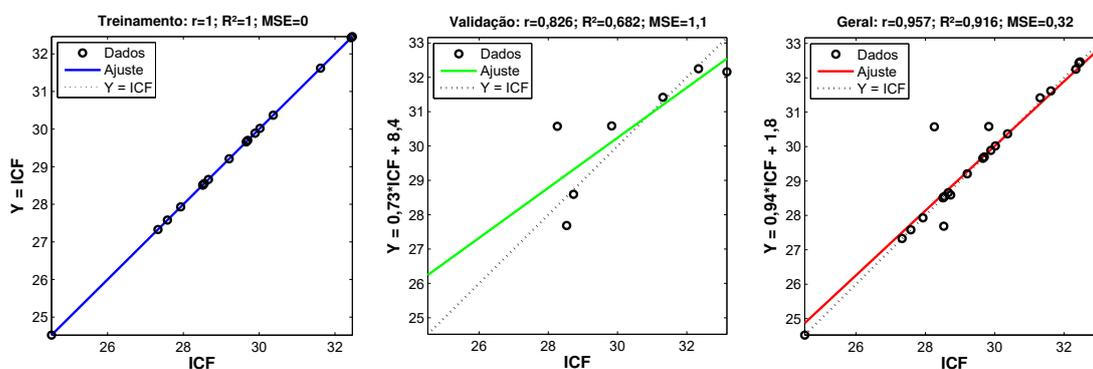
Fonte: Do autor

Observa-se na Tabela 9, que a equação da reta de regressão do teste de desempenho geral da RNA 3 é semelhante a equação da mesma etapa se comparada com a RNA 2. No entanto, observa-se uma clara distinção na distribuição dos dados em torno da linha vermelha de ambos os modelos de redes neurais.

7.5 RESULTADOS DA RNA 4

O quarto modelo de rede neural foi desenvolvido a partir da modificação da RNA 3. Seus resultados foram obtidos com base nos 5 índices espectrais: **IKAW**, **GMB**, **GBGB**, **RBRGB** e **S**. Para a sua análise de desempenho, a Figura 38 ilustra os três gráficos com os resultados de cada etapa da RNA 4. Se comparado aos três modelos

Figura 38 – Gráficos de regressão da RNA 4.



Fonte: Do autor.

anteriores, observa-se para a RNA 4 o melhor resultado obtido na etapa de treinamento, com suas 17 amostras distribuídas exatamente sobre a linha azul e sobrepostas a linha pontilhada. Desta forma, na etapa de treinamento obteve-se um desempenho indicado pelos índices $r=1$, $R^2=1$ e $MSE=0$, ou seja, um desempenho de 100% nesta etapa.

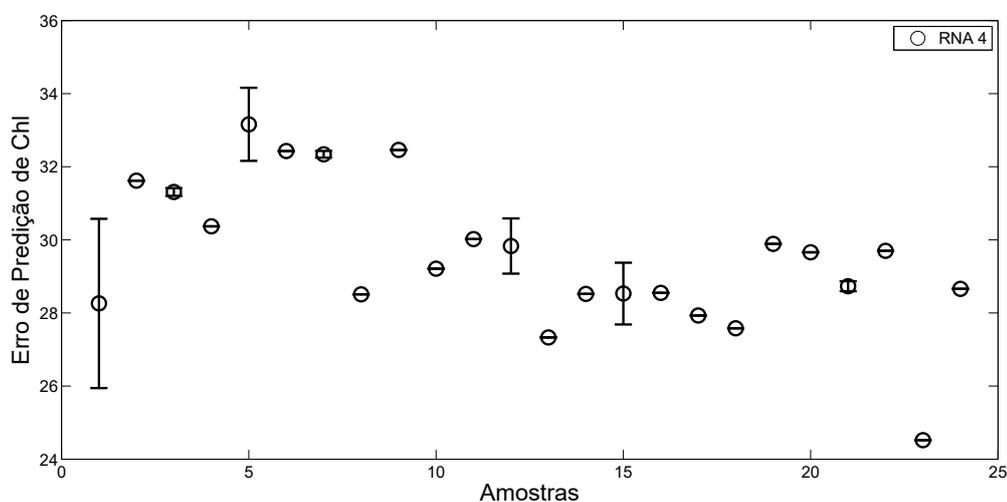
Para a etapa de validação, observa-se um desempenho superior às RNAs 2 e 3 mas inferior ao desempenho da RNA 1. As 7 amostras desta etapa encontram-se melhor distribuídas sobre a linha pontilhada se comparada aos dois modelos anteriores. Esse resultado demonstra um desempenho indicado pelos índices $r=0,826$, $R^2=0,682$

e $MSE=1,1$. Cabe ressaltar que a RNA 4 é uma modificação da RNA 3, onde a quantidade de entradas foi reduzida para 5 índices espectrais, ou seja, 4 índices a menos que a RNA 3. Sendo assim, observou-se uma tendência na melhora do desempenho dada a redução dos índices de entrada. Por isso, também supõe-se que essa alteração tenha eliminado mais informações redundantes da base de dados e assim, contribuído para a melhora no desempenho da RNA 4. Logo, pode-se afirmar que a RNA 4, em seu pior cenário, obteve uma precisão de 68,2% em sua capacidade de predição dos níveis de Chl na planta do arroz.

No terceiro gráfico da Figura 38, está ilustrado o resultado geral da RNA 4. Se comparada à etapa de validação, observa-se também uma melhor distribuição das amostras, o que justifica a linha vermelha encontrar-se muito próxima a linha pontilhada. Isso demonstra um desempenho indicado pelos índices $r=0,957$, $R^2=0,916$ e $MSE=0,484$, os melhores índices de desempenho geral se comparado as RNAs 1, 2 e 3. Considerando-se válido esse teste, é possível afirmar que a RNA 4, em seu melhor cenário, obteve uma precisão de 91,6%, um excelente nível de desempenho.

Através da Figura 39 verificam-se as magnitudes dos erros entre os valores de Chl medidos e os valores preditos na saída da RNA 4. É possível observar na Figura

Figura 39 – RNA 4: Variação geral dos erros.



Fonte: Do autor.

39 que a grande maioria das amostras possuem erros muito pequenos, quase nulos. A Tabela 10 mostra um agrupamento dos índices de desempenhos obtidos nas três etapas de avaliação da RNA 4.

Tabela 10 – Desempenho entre etapas da RNA 4.

Etapas	Equação	MSE	R	R²
Treinamento	$Y = ICF$	0	1	1
Validação	$Y = 0,73*ICF + 8,4$	1,1	0,826	0,682
Geral	$Y = 0,94*ICF + 1,8$	0,32	0,957	0,916

Fonte: Do autor

Observa-se na Tabela 10, que a equação da reta de regressão do teste de desempenho geral da RNA 4 é semelhante a equação da mesma etapa se comparada com a RNA 3, o que sugere boa similaridade entre os modelos, apesar da RNA 4 possuir menos entradas e melhor desempenho que a RNA 3. Na Tabela 11 estão reunidos os valores de cada cenário discutido, bem como o desempenho médio calculado entre o melhor e o pior cenário para cada RNA.

Tabela 11 – Comparação de desempenhos entre os modelos.

RNA	Pior Cenário %	Melhor Cenário %	Média %
1	73,00	87,00	80,00
2	59,00	88,90	73,95
3	67,90	87,60	77,75
4	68,20	91,60	79,90

Fonte: Do autor

Conforme descrito na Tabela 11, as RNAs 1 e 4 apresentam os maiores valores médios de desempenho. Cabe ressaltar que estes modelos não generalizam suas aplicações para a predição do teor de Chl em qualquer estágio de crescimento da planta do arroz. Seu uso se restringe exclusivamente ao estágio de ponto de algodão da planta. No entanto, todos os modelos apresentaram resultados satisfatórios e se comparados aos trabalhos correlatos citados no Capítulo 5, atingindo os objetivos propostos nesta pesquisa.

8 CONCLUSÃO

Esta pesquisa teve como objetivo desenvolver modelos computacionais para a predição dos níveis de Chl na cultura do arroz irrigado. As NTIC proporcionaram a integração de vários sistemas que possibilitaram atingir os objetivos desta pesquisa. A quantidade de publicações científicas sobre esse tema evidenciam a importância da contínua investigação nesta área visando melhorias nos métodos de sensoriamento remoto e descobertas de novas formas de identificação dos níveis de Chl de forma rápida e não destrutiva.

Percebeu-se que, embora a maioria das publicações aqui citadas utilizaram áreas de plantio maiores e com maior variabilidade nos níveis de Chl identificados, a área escolhida para esta pesquisa demonstrou-se apropriada para o experimento, pois conseguiu-se observar variações nos níveis de Chl em quantidades suficientes para as devidas correlações com as imagens digitais.

A definição pelas 24 unidades amostrais possibilitou a criação dos modelos. No entanto, percebeu-se que uma amostragem maior poderia gerar mais informações sobre a variação de Chl na plantação e desta forma melhorar a base de dados para o treinamento e validação das RNAs e assim, gerar modelos mais precisos e mais generalizados em suas capacidades de predição Chl.

O padrão de voo com o VANT em movimento possibilitou a coleta das imagens aéreas cobrindo toda a área do experimento. No entanto, as duas primeiras coletas de imagens foram descartadas devidos grandes variabilidades nas características espectrais das imagens, causando índices de correlações muito baixos entre os valores ICF e os índices espectrais. Percebeu-se que a presença de nuvens causou variações significativas de luminosidade nas imagens. A constante presença de ventos causou turbulências mecânicas sobre o VANT, gerando atrasos no sistema de controle de estabilização da câmera digital e desfocando algumas imagens.

Observou-se boa eficiência das técnicas de PDI empregadas na preparação e geração dos dados. Replicando-se os procedimentos de algumas publicações citadas, conseguiu-se de forma ágil segmentar as imagens, extrair e gerar os índices espectrais utilizados para o treinamento das RNAs. A combinação do PDI com o método estatístico de seleção de características por filtragem dos índices de maior grau de correlação, proporcionou uma melhoria gradativa nos modelos de RNAs gerados, evitando o uso de informações redundantes na base de dados.

Observou-se também que a escolha do MLP como modelo de RNA trouxe simplicidade na geração dos modelos de predição de Chl. O MLP demonstrou-se eficiente, dentro de suas limitações, em correlacionar os índices espectrais das imagens RGB com os níveis de Chl medidos na plantação. A RNA 1 apresentou o melhor desempenho computacional entre os quatro modelos desenvolvidos, dada sua estrutura ser

composta por apenas 5 neurônios na camada oculta contra 10 neurônios nos demais modelos.

Apesar do destaque para a RNA 1, conclui-se que os quatro modelos de redes MLP desenvolvidos foram capazes de responder a pergunta de pesquisa e conseguiram, em maior e menor grau de desempenho, fazer a predição dos níveis de Chl na cultura do arroz irrigado, utilizando sensoriamento remoto por imagens aéreas RGB captadas a partir de um VANT em movimento sobre a área do experimento. A utilização do VANT foi de grande valia e proporcionou grandes benefícios para essa pesquisa, pois sem a sua combinação com as demais ferramentas, o sensoriamento dos níveis de Chl ficaria restrito as medições através do *clorofiLOG* ou ensaios químicos em laboratório, tornando o procedimento tedioso, demorado ou até mesmo impraticável.

No entanto, embora nenhum dos modelos de MLP tenham obtido desempenhos superiores a 80% de eficácia, é a primeira vez que na região do vale do Araranguá foi realizado uma pesquisa com essa temática interdisciplinar, envolvendo tecnologias computacionais baseadas em PDI, RNAs e VANTs em conjunto com as ciências agrônômicas aplicadas a rizicultura. A junção destas tecnologias evidencia possíveis inovações locais que poderão gerar boas práticas na rizicultura e assim ocasionar melhorias na identificação dos níveis de Chl. Outros estudos poderão basear-se nesta pesquisa afim de melhorar seus resultados, além de tentar replicá-la para outras culturas de plantas.

Como sugestões para trabalhos futuros, deseja-se: a replicação deste experimento em escalas maiores, com mais unidades amostrais e em mais de um estágio de crescimento da planta do arroz; Testar novos padrões de voos baseados em diferentes altitudes e velocidades, visando melhores características espectrais das imagens digitais; Testar outros métodos de extração de características para fazer uma análise comparativa entre eles; Também deseja-se um estudo comparativo entre várias arquiteturas de RNAs visando a melhoria do desempenho para valores acima de 90%; Por fim, um estudo que avalie o impacto econômico sobre o custo de produção entre safras com e sem a utilização destas ferramentas oferecidas pelas NTICs.

REFERÊNCIAS

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL - ANAC. **Requisitos Gerais para Aeronaves Não Tripuladas de Uso Civil**. [S.l.], 2017. P. 26. Disponível em: <http://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94-emd-00>.

ALONÇO, Airton dos Santos *et al.* Sistema de Cultivo de Arroz Irrigado no Brasil. **EMBRAPA - Sistemas de Produção 03**, n. 1, p. 270, 2004.

AMARAL, Elizabeth Santos do *et al.* Relationships between reflectance and absorbance chlorophyll indices with RGB (Red, Green, Blue) image components in seedlings of tropical tree species at nursery stage. **New Forests**, v. 50, n. 3, p. 377–388, 2019. ISSN 1573-5095. DOI: 10.1007/s11056-018-9662-4. Disponível em: <https://doi.org/10.1007/s11056-018-9662-4>.

ARTIOLI, Felipe; BELONI, Tatiane. Diagnóstico do perfil do usuário de Drones no Agronegócio Brasileiro. **Revista iPecege**, v. 2, n. 3, p. 40, jul. 2016. ISSN 2359-5078. DOI: 10.22167/r.ipecege.2016.3.40. Disponível em: <https://revista.ipecege.org.br/Revista/article/view/73>.

BARMAN, Utpal; CHOUDHURY, Ridip Dev. Smartphone image based digital chlorophyll meter to estimate the value of citrus leaves chlorophyll using Linear Regression, LMBP-ANN and SCGBP-ANN. **Journal of King Saud University - Computer and Information Sciences**, The Authors, n. 40, 2020. ISSN 22131248. DOI: 10.1016/j.jksuci.2020.01.005. Disponível em: <https://doi.org/10.1016/j.jksuci.2020.01.005>.

BEARD, Randal W.; MCLAIN, Timothy W. **Small Unmanned Aircraft: Theory and Practice**. [S.l.: s.n.], 2012. P. 320. ISBN 1400840600.

BERGER, B.; PARENT, B.; TESTER, M. High-throughput shoot imaging to study drought responses. **Journal of Experimental Botany**, v. 61, n. 13, p. 3519–3528, ago. 2010. ISSN 0022-0957. DOI: 10.1093/jxb/erq201. Disponível em: <https://academic.oup.com/jxb/article-lookup/doi/10.1093/jxb/erq201>.

BREWER, Cynthia A. Spectral Schemes: Controversial Color Use on Maps. **Cartography and Geographic Information Systems**, v. 24, n. 4, p. 203–220, jan. 1997. ISSN 1050-9844. DOI: 10.1559/152304097782439231. Disponível em: <https://www.tandfonline.com/doi/full/10.1559/152304097782439231>.

CAI, Guowei; DIAS, Jorge; SENEVIRATNE, Lakmal. A Survey of Small-Scale Unmanned Aerial Vehicles: Recent Advances and Future Development Trends. **Unmanned Systems**, v. 02, p. 175–199, abr. 2014. DOI: 10.1142/S2301385014300017.

CALISKAN, Omer *et al.* Estimating Chlorophyll Concentration Index in Sugar Beet Leaves Using an Artificial Neural Network. **Polish Journal of Environmental Studies**, ago. 2019. DOI: 10.15244/pjoes/95031.

CANCELLIER, E.L. *et al.* Eficiência agronômica no uso de nitrogênio mineral por cultivares de arroz de terras altas. **Revista Brasileira de Ciências Agrárias - Brazilian Journal of Agricultural Sciences**, v. 6, n. 4, p. 650–656, dez. 2011. ISSN 19810997. DOI: 10.5039/agraria.v6i4a1420. Disponível em: <http://www.agraria.pro.br/ojs-2.4.6/index.php?journal=agraria%7B%5C%7Dpage=article%7B%5C%7Dop=view%7B%5C%7Dpath%7B%5C%7D5B%7B%5C%7D5D=426>.

CANTRELL, R. P. THE RICE GENOME: The Cereal of the World's Poor Takes Center Stage. **Science**, v. 296, n. 5565, p. 53–53, abr. 2002. ISSN 00368075. DOI: 10.1126/science.1070721. Disponível em: <http://www.sciencemag.org/cgi/doi/10.1126/science.1070721>.

CEN, Haiyan *et al.* Dynamic monitoring of biomass of rice under different nitrogen treatments using a lightweight UAV with dual image-frame snapshot cameras. **Plant Methods**, BioMed Central, v. 15, n. 1, p. 1–16, 2019. ISSN 17464811. DOI: 10.1186/s13007-019-0418-8. Disponível em: <https://doi.org/10.1186/s13007-019-0418-8>.

CERVO, Amado Luiz; BERVIAN, Pedro Alcino; SILVA, Roberto da. **Metodologia Científica**. 6. ed. São Paulo, SP: Pearson Prentice Hall, 2007. P. 162.

CHEN, Pengfei *et al.* New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. **Remote Sensing of Environment**, v. 114, n. 9, p. 1987–1997, set. 2010. ISSN 00344257. DOI: 10.1016/j.rse.2010.04.006. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425710001197>.

CHEN, W. *et al.* AgriTalk: IoT for Precision Soil Farming of Turmeric Cultivation. **IEEE Internet of Things Journal**, v. 6, n. 3, p. 5209–5223, 2019. DOI: 10.1109/JIOT.2019.2899128.

COLORADO, Julian D. *et al.* Estimation of nitrogen in rice crops from UAV-captured images. **Remote Sensing**, v. 12, n. 20, p. 1–31, 2020. ISSN 20724292. DOI: 10.3390/rs12203396.

CONAB. **Acompanhamento da safra brasileira: Grãos**. [S.l.], 2020.

CONAB. **Acompanhamento da safra Brasileira: Grãos, safra 2018/2019, oitavo levantamento**. v. 2. [S.l.: s.n.], 2019. P. 1–60.

CURRAN, Paul; WINDHAM, William; GHOLZ, Henry. Exploring the relationship between reflectance red edge and chlorophyll concentration in slash pine. **Tree physiology**, v. 15, p. 203–6, abr. 1995. DOI: 10.1093/treephys/15.3.203.

DENNISS, Anthony. T. M. Lillesand; R. W. Kiefer, 1994. Remote Sensing and Image Interpretation, 3rd ed. xvi 750 pp. New York, Chichester, Brisbane, Toronto, Singapore: John Wiley; Sons. ISBN 0 471 30575 8 (pb). **Geological Magazine**, Cambridge University Press, v. 132, n. 2, p. 249, 1995. DOI: 10.1017/S0016756800012024.

DUTTA GUPTA, Snehasish; IBARAKI, Yasuomi; TRIVEDI, Priyanka. Applications of RGB color imaging in plants. *In: [S.l.: s.n.]*, set. 2014. P. 41–62. DOI: 10.1201/b17441-4.

EPAGRI; CEPA. **Síntese Anual da Agricultura de Santa Catarina 2018-2019**. [S.l.], 2019. P. 197. Disponível em: http://docweb.epagri.sc.gov.br/website%7B%5C_%7Dcepa/publicacoes/Sintese%7B%5C_%7D2018%7B%5C_%7D19.pdf.

FURTADO, Ricardo D.; LUCA, Sérgio J. de. Técnicas de cultivo de arroz irrigado: relação com a qualidade de água, protozoários e diversidade fitoplanctônica. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 7, n. 1, p. 165–172, abr. 2003. ISSN 1415-4366. DOI: 10.1590/S1415-43662003000100027. Disponível em: http://www.scielo.br/scielo.php?script=sci%7B%5C_%7Darttext%7B%5C%7Dpid=S1415-43662003000100027%7B%5C%7Dlng=pt%7B%5C%7Dtlng=pt.

GOLZARIAN, Mahmood R *et al.* Accurate inference of shoot biomass from high-throughput images of cereal plants. **Plant Methods**, v. 7, n. 1, p. 2, 2011. ISSN 1746-4811. DOI: 10.1186/1746-4811-7-2. Disponível em: <http://plantmethods.biomedcentral.com/articles/10.1186/1746-4811-7-2>.

GONZALEZ, Rafael C.; WOODS, Richard E. **Digital Image Processing**. 2nd. USA: Addison-Wesley Longman Publishing Co., Inc., 2001. ISBN 0201180758.

GUO, Yahui *et al.* Scaling effects on chlorophyll content estimations with RGB camera mounted on a UAV platform using machine-learning methods. **Sensors (Switzerland)**, v. 20, n. 18, p. 1–22, 2020. ISSN 14248220. DOI: 10.3390/s20185130.

HAYKIN, Simon. **Redes neurais: princípios e prática**. [S.l.: s.n.], 2001. P. 900. ISBN 9788573077186. DOI: 8573077182.

HU, Hao *et al.* Estimation of leaf chlorophyll content of rice using image color analysis. **Canadian Journal of Remote Sensing**, v. 39, p. 185–190, jan. 2014. DOI: 10.5589/m13-026.

HUNT, E. Raymond; DAUGHTRY, Craig S. T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? **International Journal of Remote Sensing**, v. 39, n. 15-16, p. 5345–5376, ago. 2018. ISSN

0143-1161. DOI: 10.1080/01431161.2017.1410300. Disponível em:
<https://www.tandfonline.com/doi/full/10.1080/01431161.2017.1410300>.

JINWEN, Li. Determination of Canopys Average SPAD Readings Based on the Analysis of Digital Images. **Agrotechnology**, v. 03, jan. 2014. DOI: 10.4172/2168-9881.1000121.

KAIRU, E.N. An introduction to remote sensing. **GeoJournal**, v. 6, n. 3, 1982. ISSN 0343-2521. DOI: 10.1007/BF00210657. Disponível em:
<http://link.springer.com/10.1007/BF00210657>.

KAWASHIMA, Shigeto; NAKATANI, Makoto. An algorithm for estimating chlorophyll content in leaves using a video camera. **Annals of Botany**, v. 81, n. 1, p. 49–54, 1998. ISSN 03057364. DOI: 10.1006/anbo.1997.0544.

KHANAL, Sami; FULTON, John; SHEARER, Scott. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, v. 139, p. 22–32, jun. 2017. ISSN 01681699. DOI: 10.1016/j.compag.2017.05.001. Disponível em:
<https://linkinghub.elsevier.com/retrieve/pii/S0168169916310225>.

KROGH, Anders. What are artificial neural networks? **Nature Biotechnology**, v. 26, n. 2, p. 195–197, 2008. ISSN 1546-1696. DOI: 10.1038/nbt1386. Disponível em:
<https://doi.org/10.1038/nbt1386>.

LANG, Qiao *et al.* Detection of Chlorophyll Content in Maize Canopy from UAV Imagery. **IFAC-PapersOnLine**, v. 52, n. 30, p. 330–335, 2019. ISSN 24058963. DOI: 10.1016/j.ifacol.2019.12.561.

LI, Chao *et al.* Spearman Correlation Coefficient Abnormal Behavior Monitoring Technology Based on RNN in 5G Network for Smart City. **2020 International Wireless Communications and Mobile Computing, IWCMC 2020**, p. 1440–1442, 2020. DOI: 10.1109/IWCMC48107.2020.9148469.

LI, Fei *et al.* Reflectance estimation of canopy nitrogen content in winter wheat using optimised hyperspectral spectral indices and partial least squares regression. **European Journal of Agronomy**, v. 52, p. 198–209, 2014. ISSN 1161-0301. DOI: <https://doi.org/10.1016/j.eja.2013.09.006>. Disponível em:
<http://www.sciencedirect.com/science/article/pii/S1161030113001172>.

LI, Jinwen *et al.* Quantification of rice canopy nitrogen balance index with digital imagery from unmanned aerial vehicle. **Remote Sensing Letters**, v. 6, n. 3, p. 183–189, 2015. ISSN 21507058. DOI: 10.1080/2150704X.2015.1021934. Disponível em: <http://dx.doi.org/10.1080/2150704X.2015.1021934>.

LI, Y. *et al.* Estimating the nitrogen status of crops using a digital camera. **Field Crops Research**, v. 118, n. 3, p. 221–227, set. 2010. ISSN 03784290. DOI: 10.1016/j.fcr.2010.05.011. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378429010001358>.

LIU, Meiling *et al.* Neural-network model for estimating leaf chlorophyll concentration in rice under stress from heavy metals using four spectral indices. **Biosystems Engineering**, v. 106, n. 3, p. 223–233, 2010. ISSN 15375110. DOI: 10.1016/j.biosystemseng.2009.12.008.

LIU, Y. *et al.* From Industry 4.0 to Agriculture 4.0: Current Status, Enabling Technologies, and Research Challenges. **IEEE Transactions on Industrial Informatics**, p. 1–1, 2020. DOI: 10.1109/TII.2020.3003910.

MARCONI, M. A.; LAKATOS, E. M. **Fundamentos de metodologia científica**. 4. ed. São Paulo, SP: Atlas, 2001.

MARIA, Riccardi *et al.* Non-destructive evaluation of chlorophyll content in quinoa and Amaranth leaves by simple and multiple regression analysis of RGB image components. **Photosynthesis research**, v. 120, jan. 2014. DOI: 10.1007/s11120-014-9970-2.

MOGHADDAM, Parviz; DERAFFSHI, Mohammadali; G. SHAYESTEHEH, Mahrokh. A new method in assessing sugar beet leaf nitrogen status through color image processing and artificial neural network. **Journal of Food, Agriculture and Environment**, v. 8, abr. 2010.

MOHAN, P. Jagan; GUPTA, S. Dutta. Intelligent image analysis for retrieval of leaf chlorophyll content of rice from digital images of smartphone under natural light. **Photosynthetica**, Photosynthetica, v. 57, n. 2, p. 388–398, 2019. ISSN 15739058. DOI: 10.32615/ps.2019.046. Disponível em: <https://doi.org/10.32615/ps.2019.046>.

MORÉ, Jorge J. The Levenberg-Marquardt algorithm: Implementation and theory. *In*: WATSON, G. A. (Ed.). **Numerical Analysis**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1978. P. 105–116.

MUÑOZ-HUERTA, Rafael *et al.* A Review of Methods for Sensing the Nitrogen Status in Plants: Advantages, Disadvantages and Recent Advances. **Sensors (Basel, Switzerland)**, v. 13, p. 10823–43, ago. 2013. DOI: 10.3390/s130810823.

MURPHY, Kevin P. **Machine learning : a probabilistic perspective**. Cambridge, Mass. [u.a.]: MIT Press, 2013. ISBN 9780262018029 0262018020. Disponível em: https://www.amazon.com/Machine-Learning-Probabilistic-Perspective-Computation/dp/0262018020/ref=sr_1_2?ie=UTF8&qid=1336857747&sr=8-2.

MUTHAYYA, Sumithra *et al.* An overview of global rice production, supply, trade, and consumption. **Annals of the New York Academy of Sciences**, v. 1324, n. 1, p. 7–14, set. 2014. ISSN 00778923. DOI: 10.1111/nyas.12540. Disponível em: <http://doi.wiley.com/10.1111/nyas.12540>.

NOVICHONOK, E. *et al.* Use of the atLEAF+ chlorophyll meter for a nondestructive estimate of chlorophyll content. **Photosynthetica**, v. 54, ago. 2015. DOI: 10.1007/s11099-015-0172-8.

OSAMA, Khwaja; MISHRA, Bhartendu Nath; SOMVANSHI, Pallavi. Machine Learning Techniques in Plant Biology. *In*: **PlantOmics: The Omics of Plant Science**. Edição: Debmalya Barh, Muhammad Sarwar Khan e Eric Davies. New Delhi: Springer India, 2015. P. 731–754. ISBN 978-81-322-2172-2. DOI: 10.1007/978-81-322-2172-2_26. Disponível em: https://doi.org/10.1007/978-81-322-2172-2_26.

PAGOLA, Miguel *et al.* New method to assess barley nitrogen nutrition status based on image colour analysis Comparison with SPAD-502. **Computers and Electronics in Agriculture - COMPUT ELECTRON AGRIC**, v. 65, p. 213–218, mar. 2009. DOI: 10.1016/j.compag.2008.10.003.

PARSONS, A. J. Principles of Remote Sensing. By P. J. Curran. London: Longman, 1985. **International Journal of Remote Sensing**, v. 6, n. 11, p. 1765–1765, nov. 1985. ISSN 0143-1161. DOI: 10.1080/01431168508948322. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431168508948322>.

PRASAD, V.S.S.; GUPTA, S. Dutta. Applications And Potentials Of Artificial Neural Networks In Plant Tissue Culture. *In*: **Plant Tissue Culture Engineering**. Edição: S. Dutta Gupta e Yasuomi Ibaraki. Dordrecht: Springer Netherlands, 2008. P. 47–67. ISBN 978-1-4020-3694-1. DOI: 10.1007/978-1-4020-3694-1_3. Disponível em: https://doi.org/10.1007/978-1-4020-3694-1_3.

RICHARDSON, Roberto Jarry. **Pesquisa Social: métodos e técnicas**. 3. ed. São Paulo, SP: Atlas, 1999. P. 334.

RIGON, João *et al.* A novel method for the estimation of soybean chlorophyll content using a smartphone and image analysis. **Photosynthetica**, v. 54, mar. 2016. DOI: 10.1007/s11099-016-0214-x.

RISQIWATI, Diah *et al.* Feature Selection for EEG-Based Fatigue Analysis Using Pearson Correlation. **Proceedings - 2020 International Seminar on Intelligent Technology and Its Application: Humanification of Reliable Intelligent Systems, ISITIA 2020**, p. 164–169, 2020. DOI: 10.1109/ISITIA49792.2020.9163760.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958. ISSN

0033-295X. DOI: 10.1037/h0042519. Disponível em:
<http://dx.doi.org/10.1037/h0042519>.

SABERIOON, M. M.; GHOLIZADEH, A. Novel approach for estimating nitrogen content in paddy fields using low altitude remote sensing system. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, 2016-January, July, p. 1011–1015, 2016. ISSN 16821750. DOI: 10.5194/isprsarchives-XLI-B1-1011-2016.

SAMARASINGHE, Sandhya. **Neural Networks for Applied Sciences and Engineering**. USA: Auerbach Publications, 2006. ISBN 084933375X.

SAMBORSKI, Stanislaw Marek; TREMBLAY, Nicolas; FALLON, Edith. Strategies to Make Use of Plant Sensors-Based Diagnostic Information for Nitrogen Recommendations. **Agronomy Journal**, v. 101, n. 4, p. 800–816, jul. 2009. ISSN 00021962. DOI: 10.2134/agronj2008.0162Rx. Disponível em:
<http://doi.wiley.com/10.2134/agronj2008.0162Rx>.

SATO, Leandro Kenji; REIS, Joao Gilberto Mendes dos. Estudo da produção de arroz brasileira e o papel do estado Mato Grosso do Sul. **Agrarian**, v. 13, n. 50, p. 548–555, 2020. DOI: 10.30612/agrarian.v13i50.9212.

SDR, Secretaria de Desenvolvimento Regional. **Caracterização Regional**. Florianópolis, 2003. P. 51.

SHI, Peihua *et al.* Rice nitrogen nutrition estimation with RGB images and machine learning methods. **Computers and Electronics in Agriculture**, Elsevier B.V., October, p. 105860, 2020. ISSN 01681699. DOI: 10.1016/j.compag.2020.105860. Disponível em: <https://doi.org/10.1016/j.compag.2020.105860>.

STAVRAKOUDIS, Dimitris *et al.* Estimating Rice Agronomic Traits Using Drone-Collected Multispectral Imagery. **Remote Sensing**, v. 11, n. 5, p. 545, mar. 2019. ISSN 2072-4292. DOI: 10.3390/rs11050545. Disponível em:
<https://www.mdpi.com/2072-4292/11/5/545>.

STEINMETZ, Silvio; BRAGA, Hugo José. Zoneamento de arroz irrigado por época de semeadura nos estados do Rio Grande do Sul e de Santa Catarina. **Revista Brasileira de Agrometeorologia**, v. 9, n. 3, p. 429–438, 2001. Disponível em:
<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/143049/1/RBAGro9-2001-Zoneamento-1480.pdf>.

SUN, Yuanyuan *et al.* Identification of nitrogen, phosphorus, and potassium deficiencies based on temporal dynamics of leaf morphology and color. **Sustainability (Switzerland)**, v. 10, n. 3, 2018. ISSN 20711050. DOI: 10.3390/su10030762.

TEMPFLI, Klaus *et al.* Principles of remote sensing : an introductory textbook. *In:* [S.l.: s.n.], jan. 2004. P. 56–85. ISBN 978-90-6164-270-1.

TKÁČ, Matúš; MESÁROŠ, Peter. Utilizing drone technology in the civil engineering. **Selected Scientific Papers - Journal of Civil Engineering**, v. 14, p. 27–37, dez. 2019. DOI: 10.1515/sspjce-2019-0003.

VITOR, Hugo *et al.* Aspectos de Segurança na Integração de Veículos Aéreos Não Tripulados (Vant) No Espaço Aéreo Brasileiro. v. 7, p. 506–517, jan. 2008.

WANG, Yuan; WANG, D.; GANG, Zhang *et al.* Digital camera-based image segmentation of rice canopy and diagnosis of nitrogen nutrition. **Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering**, v. 28, p. 131–136, set. 2012. DOI: 10.3969/j.issn.1002-6819.2012.17.019.

WANG, Yuan; WANG, Dejian; SHI, Peihua *et al.* Estimating rice chlorophyll content and leaf nitrogen concentration with a digital still color camera under natural light. **Plant Methods**, v. 10, n. 1, p. 36, 2014. ISSN 1746-4811. DOI: 10.1186/1746-4811-10-36. Disponível em: <http://plantmethods.biomedcentral.com/articles/10.1186/1746-4811-10-36>.

WANG, Yuan; WANG, Dejian; ZHANG, Gang *et al.* Estimating nitrogen status of rice using the image segmentation of G-R thresholding method. **Field Crops Research**, v. 149, p. 33–39, ago. 2013. ISSN 03784290. DOI: 10.1016/j.fcr.2013.04.007. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S037842901300124X>.

WEISS, Marie; JACOB, Frederic; DUVEILLER, Gregory. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, v. 236, nov. 2019. DOI: 10.1016/j.rse.2019.111402.

YADAV, Satya; IBARAKI, Yasuomi; DUTTA GUPTA, Snehasish. Estimation of the chlorophyll content of micropropagated potato plants using RGB based image analysis. **Plant Cell, Tissue and Organ Culture (PCTOC)**, v. 100, p. 183–188, fev. 2010. DOI: 10.1007/s11240-009-9635-6.

YANG, Guijun *et al.* Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. **Frontiers in Plant Science**, v. 8, jun. 2017. ISSN 1664-462X. DOI: 10.3389/fpls.2017.01111. Disponível em: <http://journal.frontiersin.org/article/10.3389/fpls.2017.01111/full>.

YOSHIDA, S. **Fundamentals of Rice Crop Science**. [S.l.]: International Rice Research Institute, 1981. ISBN 9789711040529. Disponível em: <https://books.google.com.br/books?id=323XxM076SsC>.

YU, Fenghua *et al.* Inversion model of chlorophyll content in japonica rice canopy based on PSO-ELM and hyper-spectral remote sensing. **Journal of South China Agricultural University**, v. 41, n. 6, p. 59–66, 2020. ISSN 1001411X. DOI: 10.7671/j.issn.1001-411X.202007044.

YUHAO, Ang *et al.* Rice chlorophyll content monitoring using vegetation indices from multispectral aerial imagery. **Pertanika Journal of Science and Technology**, v. 28, n. 3, p. 779–795, 2020. ISSN 22318526.

ZHANG, Chunhua; KOVACS, John M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, v. 13, n. 6, p. 693–712, dez. 2012. ISSN 1385-2256. DOI: 10.1007/s11119-012-9274-5. Disponível em: <http://link.springer.com/10.1007/s11119-012-9274-5>.

ZHENG, Hengbiao *et al.* Evaluation of RGB, color-infrared and multispectral images acquired from unmanned aerial systems for the estimation of nitrogen accumulation in rice. **Remote Sensing**, v. 10, n. 6, 2018. ISSN 20724292. DOI: 10.3390/rs10060824.