

PREDIÇÃO DO TEOR DE CLOROFILA EM UMA PLANTAÇÃO DE ARROZ IRRIGADO UTILIZANDO IMAGENS AÉREAS E REDES NEURAIS ARTIFICIAIS

PREDICTION OF THE CHLOROPHYLL CONTENT IN AN IRRIGATED RICE PLANTATION USING AERIAL IMAGES AND ARTIFICIAL NEURAL NETWORKS

Rodrigo Cesar Nunes Maciel **1**
Roderval Marcelino **2**
Bruno Pansera Espindola **3**

Mestre em Tecnologias da Informação e Comunicação pela Universidade Federal de Santa Catarina (UFSC). **1**
Lattes: <http://lattes.cnpq.br/3378435763858879>.
ORCID: <https://orcid.org/0000-0001-8138-2263>.
E-mail: rodrigo.enc@outlook.com

Doutor em Engenharia pela Universidade Federal de Santa Catarina (UFSC). **2**
Lattes: <http://lattes.cnpq.br/0122916218414168>.
ORCID: <https://orcid.org/0000-0002-5489-0171>.
E-mail: roderval.marcelino@ufsc.br

Doutor em Engenharia pela Instituto Federal Catarinense (UFSC). **3**
Lattes: <http://lattes.cnpq.br/1022796380908744>.
ORCID: <https://orcid.org/0000-0002-0789-5199>.
E-mail: brunopansera@hotmail.com

Resumo: O objetivo deste artigo foi desenvolver modelos computacionais para predição do teor de clorofila em uma plantação de arroz irrigado utilizando imagens aéreas e Redes Neurais Artificiais. Através do dispositivo clorofiLOG, foram realizadas medições dos níveis de clorofila nas folhas das plantas do arroz e correlacionados com imagens aéreas coletadas por uma câmera digital portátil, embarcada em um Veículo Aéreo Não Tripulado. As imagens foram coletadas com a aeronave em movimento com velocidade de 2 m/s a uma altura de 50 m sobre o local do experimento. Utilizando Processamento Digital de Imagens, foram gerados 42 índices espectrais, posteriormente selecionados pelo método de seleção por filtro. Os índices foram atribuídos como entradas e as medições de clorofila como saída dos modelos de predição. Desta forma foram desenvolvidos quatro modelos de redes neurais com os respectivos índices de desempenho de $R^2=0,80$, $R^2=0,7395$, $R^2=0,7775$ e $R^2=0,799$. Todos os modelos demonstraram que atingiram ao objetivo desta pesquisa. Desta forma evidencia-se a utilidade destes modelos de predição como ferramentas de auxílio às ciências agrônomicas para identificação dos níveis de clorofila na rizicultura. Podem fornecer novas perspectivas na gestão da adubação nitrogenada e melhorias nos custos entre as safras de arroz.

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

Abstract: This paper aimed to develop computational models to predict the chlorophyll content in an irrigated rice plantation using aerial images and Artificial Neural Networks. Through the chlorofiLOG device, measurements of chlorophyll levels in rice leaves plants were performed and correlated with aerial images collected by a portable digital camera, embedded in an Unmanned Aerial Vehicle. The images were collected with the aircraft moving at speed of 2 m/s and height of 50 m above the site. Using digital image processing, 42 spectral indexes were generated, subsequently selected by the filter selection method. The indices were assigned as inputs and chlorophyll measurements as output from the prediction models. In this way, four models of neural networks were developed with the respective performance indexes of $R^2 = 0.80$, $R^2 = 0.7395$, $R^2 = 0.7775$ and $R^2 = 0.799$. All models demonstrated that they reached the objectives of this research. In this way, the usefulness of these prediction models is evidenced as tools to aid agronomic sciences for the identification of chlorophyll levels in rice growing. They can provide new perspectives in the management of nitrogen fertilization and improvements in costs between rice crops.

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

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 NTIC com a agricultura tem promovido uma transformação digital nas lavouras. Sensores espectrais estão sendo usados para medir as condições das folhas para um controle preciso da saúde das plantas (SUN et al., 2018; CHEN et al., 2019). A combinação entre sensores espectrais, Veículos Aéreos Não Tripulados (VANT), Processamento Digital de Imagens (PDI) e Inteligência Artificial (IA), possibilitam o sensoriamento de forma remota e não destrutiva de grandes áreas, proporcionando à identificação de doenças nas plantas e previsão de colheitas, entre outras (WEISS; JACOB; DUVEILLER, 2019).

Muitas pesquisas vêm demonstrando a utilização destas tecnologias combinadas visando à predição dos níveis de clorofila (Chl) nas plantações de arroz. Dentre os vários nutrientes, a Chl é um dos principais para o cultivo do arroz e 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).

O teor de Chl nas folhas também serve como um indicador indireto dos níveis de nitrogênio (N) presente nas plantas (YUAN et al., 2016; RAVIER; QUEMADA; JEUFFROY, 2017). O N se enquadra entre um dos nutrientes de grande importância para o cultivo do arroz, sendo considerado um dos maiores contribuintes para a geração de Chl e outras proteínas, além de ser um fator limitante para se atingir grandes níveis de produtividade (FAGERIA; MOREIRA; COELHO, 2011; NASCENTE et al., 2011). O suprimento incorreto de N provoca a geração de folhas menores, menor teor de Chl, menor produção de biomassa e conseqüentemente, menor qualidade dos grãos (PRASERTSAK; FUKAI, 1997; ADHIKARI et al., 1999).

As deficiências de N e Chl podem ser supridas através de fertilizantes nitrogenados, aplicados em várias etapas de crescimento da planta (VEÇOZZI et al., 2017). No entanto, a aplicação excessiva destas substâncias é uma questão alarmante que vem indicando baixa eficiência no uso dos fertilizantes e causando sérios problemas ambientais (CONANT; BERDANIER; GRACE, 2013; HUANG et al., 2017). O óxido nitroso é um dos principais gases liberados pelo solo como consequência da fertilização nitrogenada, com forte potencial de poluição da atmosfera, em torno de 298 vezes maior que o dióxido de carbono (BALAFOUTIS et al., 2017; STAVRAKOUDIS et al., 2019).

Mas, uma boa correlação entre os níveis de Chl e N foi observada no tecido foliar de uma variedade de espécies vegetais e entre elas, o arroz, possibilitando estimativas indiretas dos níveis de N com base nos níveis de Chl (LIN et al., 2010; WANG; WANG; SHI et al., 2014; YUAN et al., 2016). Como vantagem, a gestão no manejo dos fertilizantes nitrogenados pode ser baseada nas informações dos níveis de Chl. A medição dos níveis de N requer medições diretas, realizadas através de amostragens destrutivas com base em análises químicas das folhas da planta e do solo, o que torna o trabalho tedioso e demorado (ZHENG et al., 2018).

No entanto, as medições dos níveis de Chl, tem uma vantagem: modernos métodos não destrutivos baseados em sensores espectrais tem recebido considerável atenção devido às suas capacidades de medição em tempo real (HU et al., 2014; JINWEN, 2014; NOVICHONOK et al., 2015). Sendo assim, diferentes tipos de dispositivos eletrônicos para medição dos níveis de Chl foram desenvolvidos. Eles medem a absorvância e a refletância espectral das folhas para estimar os níveis de Chl (PAGOLA et al., 2009; NOVICHONOK et al., 2015). Porém, a utilização destes dispositivos requer um grande número de repetições nas medições dadas a pequenas áreas de medição dos sensores nas amostras (MOHAN; GUPTA, 2019).

Por isso, vários estudos já foram feitos utilizando sensoriamento remoto através de sensores espectrais utilizados por câmeras fotográficas digitais para estimativa dos níveis de Chl em plantações de arroz. Na publicação de Yu et al. (2020), os autores utilizaram uma RNA do

tipo ELM (*Extreme Learning Machine*) para geração de um modelo de predição. Utilizaram análises químicas das folhas das plantas para medições dos níveis de Chl e um VANT equipado com uma câmera digital com sensor hiper espectral de 255 bandas para a coleta das imagens aéreas. Em Colorado et al. (2020), os autores utilizaram as técnicas MLR (*Multivariable Linear Regressions*), SVM (*Support Vector Machines*) e RNA para geração de três modelos de predição. U Utilizaram o dispositivo SPAD 502 para medições dos níveis de Chl nas folhas e um VANT equipado com uma câmera digital com sensor multi espectral de 4 bandas para a coleta das imagens aéreas. Na publicação Yuhao et al. (2020), os autores utilizaram a técnica estatística de regressão linear de *Pearson* para a geração de quatro modelos de predição. Utilizaram o dispositivo SPAD 502 para medições dos níveis de Chl e um VANT equipado com uma câmera digital com sensor multi espectral de 4 bandas para a coleta das imagens aéreas. Diante deste contexto, esta pesquisa teve como objetivo desenvolver modelos computacionais para predição do teor de clorofila em uma plantação de arroz irrigado na cidade de Araranguá, SC, utilizando imagens aéreas RGB e Redes Neurais Artificiais.

A definição pelo formato de imagens RGB (*Red, Green and Blue*) foi devido ser o padrão na maioria das câmeras digitais de uso geral. Também devido ao seu baixo custo, se comparado às câmeras digitais profissionais equipadas com sensores multi e hiper espectrais. Além disso, a região do vale do Araranguá é a maior produtora de arroz entre as 11 micros 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 e por isso justifica os esforços em pesquisas voltadas a rizicultura.


Metodologia

Nesta Seção serão descritos todos os procedimentos experimentais executados nesta pesquisa. Seu objetivo é demonstrar como cada etapa do experimento foi realizada e também possibilitar sua reprodução.

Descrição do Local do Experimento

A área de cultivo de arroz utilizada 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°, 1.400 mm e 81%. Possui solos planos hidromórficos dos tipos gleissolos e organossolos. A Figura 1 ilustra uma imagem aérea do local do experimento.

Figura 1. Área do experimento.



Fonte: Dos autores.

Antes do plantio das sementes, o produtor realizou o trato cultural com as respectivas

aplicações: rolo faca por três vezes para deitar a palhada; Grade de arar por três vezes; Herbicida *Zapp Qi* com densidade de 4 L/ha; Enxada rotativa por duas vezes para remoção de vegetação; Adubo nitrogenado por duas vezes com densidade de 6 sacas/ha. Não foi aplicado calcário antes do plantio. O cultivar de arroz semeado foi o Epagri SCS121 CL com sistema de plantio pré-germinado. As sementes foram semeadas pelo produtor no dia 09 de novembro de 2019 a uma densidade de 200 kg/ha.

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 por 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 contento 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.

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 é possível verificar alterações espectrais nas folhas do arroz após aplicação de fertilizantes.

Um dia após a 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.

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. Suas medições indicam o Índice de Clorofila Falker (ICF), com intervalo de 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 com o *clorofiLOG*, totalizando 20 leituras em cada unidade amostral. As leituras foram feitas de forma não destrutiva diretamente nas folhas das plantas do arroz. Todas as leituras foram realizadas descartando-se o terço inferior das plantas. Ao todo, foram 480 leituras gravadas internamente no *clorofiLOG*.

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.


Aquisição das Imagens

A coleta das imagens foi realizada no segundo e terceiro dia do experimento. Para isso, foi utilizada uma câmera digital portátil da marca *Canon* modelo ELPH 300HS. Esta câmera é equipada com sensor espectral RGB 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 câmera foi configurada para manter distância focal mínima, 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 multirrotor modelo MK Hexa XL da marca *Mikrokopter*. A coleta das imagens foi baseada na metodologia 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 servos motores acoplados no suporte da câmera localizado na parte inferior da aeronave. A Figura 2 mostra o VANT equipado com a câmera digital.


Figura 2. Equipamentos de aquisição das imagens.



Fonte: Dos autores.

Os três voos de coleta das imagens ocorreram nos respectivos dias 20, no período da manhã e, no dia 21, nos períodos da manhã e 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 Tool* fornecida pelo fabricante do VANT conforme ilustrado pela Figura 3.

Figura 3. Plano de voo utilizado pelo VANT.



Fonte: Dos autores.

Nos três voos, o VANT decolou em modo de controle manual a partir da estação base, identificada pelo ponto vermelho na Figura 3. 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.

Todas as coletas de imagens foram realizadas em dias com sol entre nuvens, ventos fracos e com condições pouco estáveis de luminosidade. Devido à presença de nuvens, em alguns momentos ocorreram variações de luminosidade interferindo no brilho de algumas fotos e ge-

rando 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.

Processamento das Imagens

As imagens coletadas nos três voos foram processadas através do programa *Matlab*[®]. Foram realizados os processos de localização e recorte das unidades amostrais, segmentação das imagens e extração e geração dos índices espectrais. Inicialmente foram localizadas e recortadas 24 figuras de cada voo, totalizando 72 imagens com tamanho de 101 x 101 pixels cada, representando cada uma das unidades amostrais. Em seguida, as imagens foram segmentadas conforme procedimentos descritos em Caliskan et al. (2019), para remoção dos marcadores das estacas e, através dos procedimentos descritos por Wang, Wang, Zhang et al. (2013), para remoção do solo.

Após a segmentação, inicialmente foram extraídos de forma direta 12 índices espectrais através dos mapas de cores RGB, HSV, L*a*b* e YCbCr. Em cada mapa de cor foram separadas suas bandas de cores e calculado as médias de cada banda para cada imagem. Em seguida, a partir dos 12 índices extraídos foram gerados 30 novos índices conforme procedimentos descritos em sete publicações distintas, totalizando 42 índices espectrais conforme descritos na Tabela 1.

Tabela 1. Índices espectrais 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 et al. (2014)
VI	$(G-R)/(G+R)$	
I*	b^*/a^*	
GMR	G-R	Wang, Wang, Zhang et al. (2013)
VDVI	$(2G-R-B)/(2G+R+B)$	
GRR	G/R	Cen et al. (2019)
MGRVI	$(G^2-R^2)/(G^2+R^2)$	
RBG	R+B+G	
RB	R+B	
RG	R+G	Hu et al. (2014)
BG	B+G	
BGR	B+G-R	

BR	$0,3R+0,6G+0,1B$	
IKAW	$(R-B)/(R+B)$	Sun et al. (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: Dos autores.

Após a obtenção dos índices espectrais descritos na Tabela 1, foi realizada uma análise de correlação linear de Pearson com nível de confiança de 95% entre os índices espectrais e as medições de clorofila (RISQIWATI et al., 2020). Desta forma, somente as imagens do terceiro voo de coleta foram selecionadas para a geração os modelos. Em seguida aplicou-se a técnica de seleção por filtro sobre a análise de correlação de Pearson sendo que, somente 21 índices espectrais com valor-p abaixo e 0,05 foram selecionados para posterior geração das redes neurais, sendo eles: **B, VDVI, IKAW, ExG, RMB, GMB, TORGB, TORB, TOGB, GBGB, RBRGB, GBRGB, r, g, b, H, S, Cb, a*, b* e i***.

Geração das Redes Neurais Artificiais

O objetivo desta etapa foi aplicar alguns modelos de RNA na tentativa de associar os 21 índices espectrais com os seus respectivos valores ICF relacionados. Para isso, foi utilizada a ferramenta *nftool* incorporada ao programa *Matlab*[®], desenvolvida exclusivamente para resolver problemas de regressão. Por padrão, essa ferramenta gera redes neurais do tipo MLP (*Multilayer Perceptron*) 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; MSE (*Mean Squared Error*) igual a zero; Gradiente Mínimo igual a 1×10^{-7} ; Número máximo de falhas na validação igual a 6;
- Critério de desempenho baseado no 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 aos autores realizarem 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.

Sendo assim, baseado nas publicações de Mohan e Gupta (2019), Barman e Choudhury (2020) e Shi et al. (2020), em um primeiro experimento para a geração da RNA 1, do total de 21 índices espectrais, os 5 índices com correlação positiva em relação aos valores ICF medidos foram selecionados e atribuídos como entrada, enquanto os valores ICF atribuídos como saída da RNA. Os índices selecionados foram: **B, b, H, Cb e a***. 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, cujo o treinamento foi encerrado após 31 épocas.

Logo após, em um segundo experimento, foram selecionados e organizados como entrada da rede neural os 16 índices restantes, sendo que 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***. Replicando-se os procedimentos executados para a RNA 1, obteve-se a RNA 2 com 10 neurônios na camada oculta com treinamento encerrado em 11 épocas. 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 o novo modelo de RNA. Os índices selecionados foram: **IKAW, RMB, GMB, GBGB, RBRGB, GBRGB, S, b* e i***. Ao final deste procedimento obteve-se uma rede neural com 10 neurônios na camada oculta e treinada com 18 épocas.

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**. Ao final deste último procedimento obteve-se uma rede neural com 10 neurônios na camada oculta e treinada após 19 épocas.

A fim de se demonstrar de forma geral a arquitetura dos modelos de redes neurais desenvolvidos nesta etapa, a Tabela 2 descreve os principais parâmetros implementados.

Tabela 2. Arquitetura das RNAs desenvolvidas.

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: Dos autores.

Conforme se pode observar na Tabela 2 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 também deveriam ser analisados para se chegar a uma conclusão. No entanto, não foi o foco desta pesquisa fazer uma análise comparativa de performance entre as RNAs.

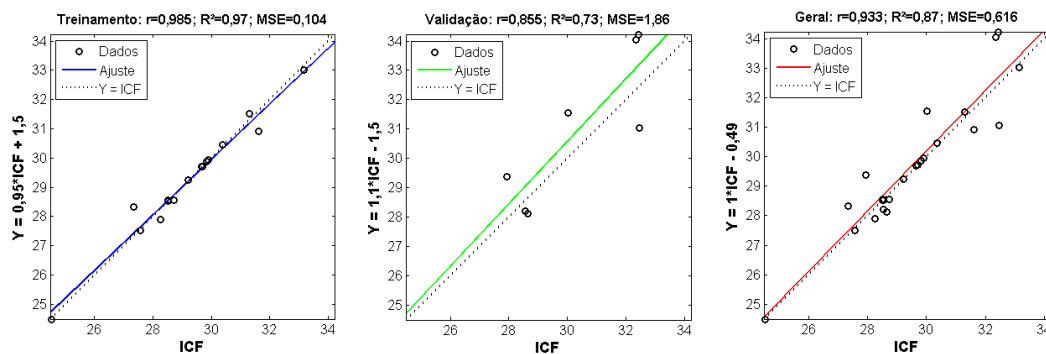
Resultados e Discussões

Nesta seção serão apresentados os resultados dos modelos de predição de clorofila desenvolvidos. Os resultados de cada uma das RNA serão apresentados em três gráficos distintos nas mesmas figuras. Os gráficos apresentarão, através de retas de regressão, os índices de correção de *Pearson r*, coeficiente de determinação R^2 , erro médio quadrático MSE e as equações de reta Y , para os respectivos resultados das etapas de treinamento, validação e o desempenho geral dos modelos. Também serão apresentadas tabelas para simples comparações de desempenho dos modelos.

Resultados da RNA 1

Os resultados do primeiro modelo de predição foram obtidos com base em 5 índices espectrais atribuídos como entrada conforme descrito na Seção anterior. A Figura 4 apresenta os três gráficos de regressões para as etapas de treinamento, validação e desempenho geral.

Figura 4. Gráficos de regressão da RNA 1.



Fonte: Dos autores.


Observa-se na Figura 4 os respectivos resultados para cada etapa de construção da RNA 1: $r=0,985$, $R^2=0,97$ e $MSE=0,104$ para a etapa de treinamento; $r=0,855$, $R^2=0,73$ e $MSE=1,86$ para a etapa de validação; $r=0,933$, $R^2=0,87$ e $MSE=0,616$ para o teste de desempenho geral. Observa-se ainda que na etapa de treinamento, a linha azul encontra-se quase sobreposta sobre a linha pontilhada, o que pode justificar as 17 amostras utilizadas nesta etapa estarem distribuídas muito próximas à linha azul. Quanto à 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 à linha pontilhada.

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 para todos os modelos gerados tenha contribuído para o seu desempenho inferior, se comparada à etapa de treinamento. Considerando-se válido o teste de desempenho geral que envolveu todas as amostras da base de dados, observa-se uma melhor distribuição das amostras, o que justifica a linha vermelha encontrar-se muito próxima a linha pontilhada. Desta forma, com base nos valores de R^2 das respectivas etapas de validação e teste de desempenho geral, supõe-se que a RNA 1 obteve um desempenho de 73% em seu pior cenário e desempenho de 87% em seu melhor cenário.

Resultados da RNA 2

Os resultados do segundo modelo de predição foram obtidos com base em 16 índices espectrais atribuídos como entrada. A Figura 5 apresenta os gráficos de regressões para as etapas de treinamento, validação e desempenho geral.

Figura 5. Gráficos de regressão da RNA 2.



Fonte: Dos autores.

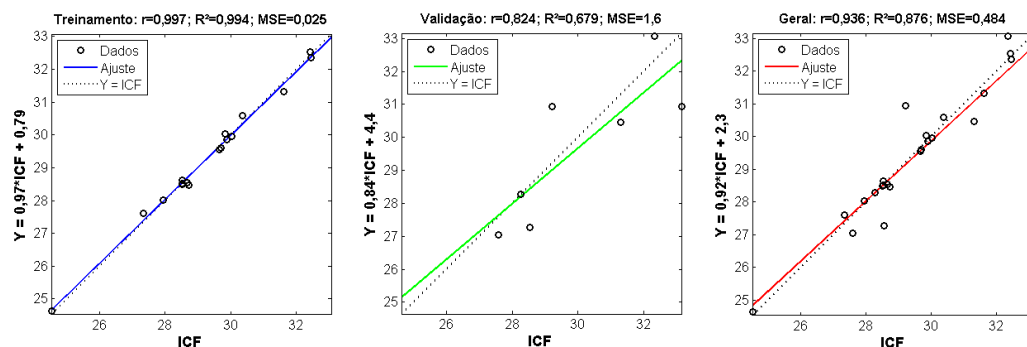
Observa-se na Figura 5 os respectivos resultados para cada etapa de construção da RNA 2: $r=0,988$, $R^2=0,976$ e $MSE=0,18$ para a etapa de treinamento; $r=0,768$, $R^2=0,59$ e $MSE=1,211$ para a etapa de validação; $r=0,943$, $R^2=0,889$ e $MSE=0,479$ para o teste de desempenho geral. É possível verificar um excelente resultado na etapa de treinamento, com a linha azul quase sobreposta sobre a linha pontilhada. Na etapa de validação, observa-se uma degradação do 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.

Novamente considerando-se válido o teste de desempenho geral que envolveu todas as amostras da base de dados, observa-se uma melhor distribuição das amostras com a linha vermelha muito próxima a linha pontilhada. Semelhante a análise final realizada para a RNA 1, pode-se supor que a RNA 2 obteve um desempenho de 59% em seu pior cenário e desempenho de 88,9% em seu melhor cenário.

Resultados da RNA 3

Conforme detalhado na Seção anterior, 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 atribuídos como entrada. A Figura 6 apresenta os três gráficos de regressões para cada uma das etapas de geração da RNA 3.

Figura 6. Gráficos de regressão da RNA 3.



Fonte: Dos autores.

Conforme ilustrado na Figura 6, verifica-se os respectivos resultados de cada etapa da RNA 3: $r=0,997$, $R^2=0,994$ e $MSE=0,025$ para a etapa de treinamento; $r=0,824$, $R^2=0,679$ e $MSE=1,6$ para a etapa de validação; $r=0,936$, $R^2=0,876$ e $MSE=0,484$ para o teste de desempenho geral. Se comparada aos dois modelos anteriores, observa-se um excelente resultado, com suas 17 amostras distribuídas muito próximas à linha azul, quase sobreposta sobre a linha pontilhada. Na etapa de validação, as 7 amostras encontram-se ainda dispersas e a linha verde também deslocada e com inclinação inferior a linha pontilhada.

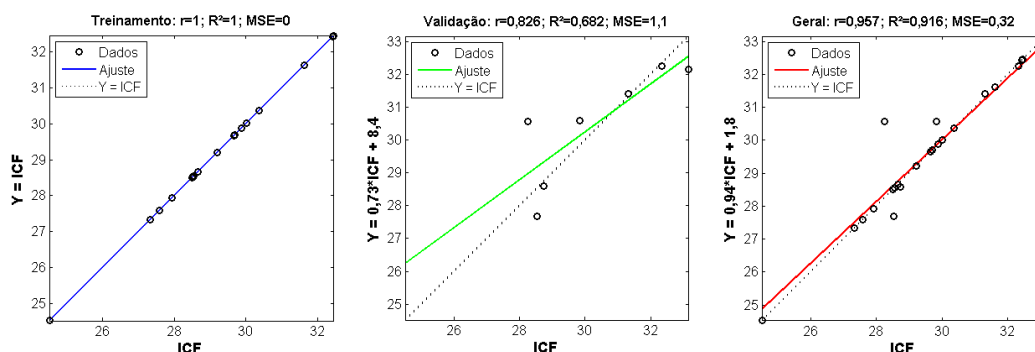
Para o teste de desempenho geral, também se observa uma melhor distribuição das

amostras com a linha vermelha muito próxima a linha pontilhada. Semelhante a análise final realizada para os modelos anteriores, pode-se supor que a RNA 3 obteve um desempenho de 67,9% em seu pior cenário e desempenho de 87,6% em seu melhor cenário.

Resultados da RNA 4

O quarto e último modelo de rede neural foi desenvolvido a partir da modificação da RNA 3. Seus resultados foram obtidos com base em 5 índices espectrais atribuídos com entrada do modelo. A Figura 7 apresenta os três gráficos de regressões para cada uma das etapas de geração da RNA 4.

Figura 7. Gráficos de regressão da RNA 4.



Fonte: Dos autores.

Conforme se pode observar na Figura 7, verifica-se os respectivos resultados de cada etapa da RNA 4: $r=1$, $R^2=1$ e $MSE=0$ para a etapa de treinamento; $r=0,826$, $R^2=0,682$ e $MSE=1,1$ para a etapa de validação; $r=0,957$, $R^2=0,916$ e $MSE=0,32$ para o teste de desempenho geral. Se comparada aos modelos 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. Na etapa de validação, as 7 amostras desta etapa encontram-se melhor distribuídas sobre a linha pontilhada se comparada aos dois modelos anteriores.

Para o teste de desempenho geral, também se observa uma melhor distribuição das amostras com a linha vermelha muito próxima a linha pontilhada. Sendo assim, pode-se supor que a RNA 4 obteve um desempenho de 68,2% em seu pior cenário e desempenho de 91,6% em seu melhor cenário. Na Tabela 3 estão reunidos os valores de cada cenário discutido, bem como o desempenho médio calculado entre o melhor e o pior cenário para cada modelo de RNA desenvolvido.

Tabela 3. Comparação entre 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: Dos autores.

Conforme descrito na Tabela 3, as RNA 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 atingiram os objetivos propostos nesta pesquisa.

Considerações Finais

Esta pesquisa teve como objetivo desenvolver modelos computacionais para a predição dos níveis de Chl em uma plantação de arroz irrigado localizada na cidade de Araranguá, SC. As novas tecnologias computacionais proporcionadas pela evolução das NTICs proporcionou a integração de vários sistemas que possibilitaram atingir o objetivo desta pesquisa. O arroz é um alimento essencial para a nutrição das populações bem como para o agronegócio brasileiro, evidencia a necessidade 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.

É a primeira vez que na região do vale do Araranguá foi realizada 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 gestão e manejo dos fertilizantes nitrogenados.

Conclui-se que os quatro modelos de redes neurais desenvolvidos conseguiram, em maior e menor grau de desempenho, fazer a predição dos níveis de Chl em uma plantação de 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. Sem a combinação de todas estas ferramentas, o sensoriamento dos níveis de Chl ficaria restrito as medições através do dispositivo *clorofiLOG* ou ensaios químicos em laboratório, tornando o procedimento tedioso, demorado ou até mesmo impraticável. 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, além de testar novos padrões de voos baseados em diferentes altitudes e velocidades, visando obter melhorias na extração das características espectrais das imagens digitais.

Referências

ADHIKARI, C et al. **On-farm soil N supply and N nutrition in the rice-wheat system of Nepal and Bangladesh**. *Field Crops Research*, v. 64, n. 3, p. 273–286, dez. 1999. ISSN 03784290. DOI: 10.1016/S0378-4290(99)00063-5.

BALAFOUTIS, A. et al. **Precision Agriculture Technologies Positively Contributing to GHG Emissions Mitigation, Farm Productivity and Economics**. *Sustainability*, v. 9, n. 8, p. 1339, jul. 2017. ISSN 2071-1050. DOI:10.3390/su9081339.

BARMAN, U.; CHOUDHURY, R. **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.

CALISKAN, O. 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.

CEN, H. 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.

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, J. D. et al. **Estimation of nitrogen in rice crops from UAV-captured images**. *Remo-*

te Sensing, v. 12, n. 20, p. 1–31, 2020. ISSN 20724292. DOI: 10.3390/rs12203396.

CONANT, R. T.; BERDANIER, A. B.; GRACE, P. R. **Patterns and trends in nitrogen use and nitrogen recovery efficiency in world agriculture.** *Global Biogeochemical Cycles*, v. 27, n. 2, p. 558–566, jun. 2013. ISSN 08866236. DOI: 10.1002/gbc.20053.

CURRAN, P.; WINDHAM, W.; GHOLZ, H. **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.

EPAGRI; CEPA. **Síntese Anual da Agricultura de Santa Catarina 2018-2019**, 2019. P. 197.

FAGERIA, N. K.; MOREIRA, A.; COELHO, A. M. **Yield and yield components of upland rice as influenced by nitrogen sources.** *Journal of Plant Nutrition*, v. 34, n. 3, p. 361–370, jan. 2011. ISSN 0190-4167. DOI: 10.1080/01904167.2011.536878.

GUO, Y. 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.

HU, H. 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.

HUANG, J. et al. **Nitrogen and phosphorus losses and eutrophication potential associated with fertilizer application to cropland in China.** *Journal of Cleaner Production*, v. 159, p. 171–179, ago. 2017. ISSN 09596526. DOI: 10.1016/j.jclepro.2017.05.008.

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

KAWASHIMA, S.; NAKATANI, M. **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.

LIN, F. et al. **Investigation of SPAD meter-based indices for estimating rice nitrogen status.** *Computers and Electronics in Agriculture*, v. 71, abr. 2010. DOI: 10.1016/j.compag.2009.09.006.

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.

MOGHADDAM, P.; DERAFSHI, M.; G. SHAYESTEH, M. **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. J.; GUPTA, S. D. **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.

MUÑOZ-HUERTA, R. 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.

NASCENTE, A. S. et al. **Produtividade do arroz de terras altas em função do manejo do solo**

e da época de aplicação de nitrogênio. Pesquisa Agropecuária Tropical, v. 41, n. 1, jan. 2011. ISSN 1983-4063. DOI: 10.5216/pat.v41i1.6509.

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

PAGOLA, M. 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.

PRASERTSAK, A.; FUKAI, S. **Nitrogen availability and water stress interaction on rice growth and yield.** Field Crops Research, v. 52, n. 3, p. 249–260, jun. 1997. ISSN 03784290. DOI: 10.1016/S0378-4290(97)00016-6.

RAVIER, C.; QUEMADA, M.; JEUFFROY, M. **Use of a chlorophyll meter to assess nitrogen nutrition index during the growth cycle in winter wheat.** Field Crops Research, v. 214, p. 73–82, ago. 2017. DOI: 10.1016/j.fcr.2017.08.023.

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

SHI, P. 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.

STAVRAKOUDIS, D. 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.

SUN, Y. 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.

TKÁČ, M.; MESÁROŠ, P. **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.

VEÇOZZI, T. A. et al. **Soil solution and plant nitrogen on irrigated rice under controlled release nitrogen fertilizers.** Ciência Rural, v. 48, n. 1, dez. 2017. ISSN 1678-4596. DOI: 10.1590/0103-8478cr20170279.

WANG, Y.; WANG, D.; SHI, P. 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.

WANG, Y.; WANG, D.; ZHANG, G. 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.

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

YADAV, S.; IBARAKI, Y.; DUTTA GUPTA, S. **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.

YU, F. 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.

YUAN, Z. et al. **Indicators for diagnosing nitrogen status of rice based on chlorophyll meter readings.** Field Crops Research, v. 185, p. 12–20, jan. 2016. DOI: 10.1016/j.fcr.2015.10.003.

YUHAO, A. 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.

ZHENG, H. 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.

Recebido em 23 de março de 2021.

Aceito em 28 de setembro de 2021.