UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ZOOTECNIA E ENGENHARIA DE ALIMENTOS

WELLINGTON RENATO MANCIN

Desenvolvimento de software de processamento digital de imagens para análise do *status* nutricional de nitrogênio em *Brachiaria brizantha* cv. Xaraés utilizando rede neural artificial.

PIRASSUNUNGA

2019

WELLINGTON RENATO MANCIN

Desenvolvimento de software de processamento digital de imagens para análise do *status* nutricional de nitrogênio em *Brachiaria brizantha* cv. Xaraés utilizando rede neural artificial.

Versão Corrigida

Dissertação apresentada à Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo, como parte dos requisitos para a obtenção do Título de Mestre em Ciências do programa de pós-graduação em Gestão e Inovação na Indústria Animal.

Área de Concentração: Gestão e Inovação na Indústria Animal

Orientador: Prof. Dr. Adriano Rogério Bruno Tech

Coorientadora: Profa. Dra. Lilian Elgalise Techio Pereira

PIRASSUNUNGA

2019

Ficha catalográfica elaborada pelo
Serviço de Biblioteca e Informação, FZEA/USP, com os dados fornecidos
pelo(a) autor(a)

Mancin, Wellington Renato

M269d Desenvolvimento de software de processamento digital de imagens para análise do status nutricional de nitrogênio em *Brachiaria brizantha* cv. Xaraés... / Wellington Renato Mancin ; orientador Adriano Rogério Bruno Tech ; coorientadora Lilian Elgalise Techio Pereira. -- Pirassununga, 2019.

60 f.

Dissertação (Mestrado - Programa de Pós-Graduação em Mestrado Profissional Gestão e Inovação na Indústria Animal) -- Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo.

1. Classificação de imagem. 2. Índices de vegetação. 3. Rede neural Multilayer Perceptron. 4. RGB. 5. Segmentação de imagens. I. Tech, Adriano Rogério B., orient. II. Pereira, Lilian Elgalise T., coorient. III. Título.

WELLINGTON RENATO MANCIN

Desenvolvimento de software de processamento digital de imagens para análise do *status* nutricional de nitrogênio em *Brachiaria brizantha* cv. Xaraés utilizando rede neural artificial.

Dissertação apresentada à Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo, como parte dos requisitos para a obtenção do Título de Mestre em Ciências.

Área de Concentração: Gestão e Inovação na Indústria Animal

Data de aprovação: ____/____/____

Banca Examinadora:

Prof. Dr. _____

Instituição _____

Presidente da Banca Examinadora

Prof.(a) Dr.(a) _____

Instituição _____

Prof.(a) Dr.(a) _____

Instituição _____

DEDICATÓRIA

A meus pais Odair (*in memoriam*) e Sueli, por todo ensinamento de vida, valores e princípios, além de todo sacrifício, apoio e incentivo dispensados para minha formação.

À minha esposa Lia, que com toda paciência e amor apoiou este estudo e aguentou firme várias horas sozinhas as dificuldades pelo caminho.

Aos meus filhos Augusto e Benício, para que encontrem na busca por conhecimento a motivação para continuarmos evoluindo como seres humanos, não somente cientificamente como também em sua essência.

AGRADECIMENTOS

A Deus pelo dom da vida, saúde, possibilidade física e direcionamento do saber.

À minha família, esposa, mãe, irmãos – Geisa e Everton, e cunhados pelo auxílio, incentivo e compreensão em todos os momentos.

Aos Professores Dr. Adriano Rogério Bruno Tech e Dra. Lilian Elgalise Techio Pereira pela orientação, oportunidade, disponibilidade, dedicação e compartilhamento de seus conhecimentos, contribuindo desta forma para meu crescimento científico e intelectual.

Às funcionárias do laboratório de bromatologia do Laboratório Multiusuário de Nutrição Animal e Bromatologia - VNP - FMVZ/USP.

Ao meu tio Celso pelo incentivo e apoio durante todo o período de estudo e pesquisa.

Aos colegas do programa de pós-graduação pelas discussões, dicas e troca de experiências, em especial Adriano Virgílio e toda a equipe que auxiliou em campo.

À Faculdade de Zootecnia e Engenharia de Alimentos, pela oportunidade de realização do curso de mestrado.

RESUMO

MANCIN, W. R. **Desenvolvimento de software de processamento digital de imagens para análise do status nutricional de nitrogênio em *Brachiaria brizantha* cv. Xaraés utilizando rede neural artificial**. 2019. 60 f. Dissertação (Mestrado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2019.

Novas ferramentas são criadas constantemente usando as Novas Tecnologias da Informação e Comunicação (NTIC) para todos os setores da economia, possibilitando ampliar a produção, melhorar processos, oferecer condições para obtenção de maiores ganhos financeiros e redução do uso de insumos contribuindo para sustentabilidade do meio ambiente. No atual cenário emergente de novas tecnologias e, sabendo da necessidade do produtor em administrar de forma eficiente sua propriedade, o intuito deste estudo foi o de desenvolver um software usando visão computacional e técnicas de processamento de imagens, atrelado as redes neurais artificiais (RNA), a fim de estimar o *status* nutricional quanto ao nitrogênio (N) em plantas da espécie *Brachiaria brizantha* cv. Xaraés. O experimento foi conduzido em campo aberto no período de novembro de 2017 a março de 2018, nas dependências do Departamento de Zootecnia, na Faculdade de Zootecnia e Engenharia de Alimentos (FZEA/USP) em uma área compreendida por 12 parcelas com área útil de 40 m² cada e dividida em três blocos completos casualizados, onde foram administrados quatro tratamentos com as concentrações de N (0, 15, 30 e 45 kg N ha⁻¹), cuja fonte foi NH₄NO₃ (32%). As imagens obtidas em campo das lâminas foliares por meio de câmera digital, de sensor passivo, presente no smartphone foram processadas e analisadas no sistema de cores RGB (Red, Green e Blue), bem como foram encaminhadas ao laboratório para determinação da concentração de N pelo método Kjeldahl e, assim, gerando uma base de dados correlacionada com as imagens processadas. Uma vez processadas as imagens, foram gerados os índices de vegetação. Para identificação dos índices que melhor explicassem a relação com o teor de N na planta obtido em laboratório foi utilizada a análise de componentes principais (PCA). Inicialmente foram gerados 18 índices que, após análise foram reduzidos para 12, compostos por Gn, Bn, Saturação, ExG, CIVE, VEG e COM, os quais compuseram o primeiro componente e, pelos índices R, G, Brilho, ExR e VARlgreen que compuseram o segundo componente, gerando assim, um coeficiente de determinação de 0,902 (R²), os quais foram utilizados como entrada de dados na rede neural artificial. Para a implementação da rede neural *Multilayer Perceptron* (MLP) foram testadas as redes *Feed-Forward Backpropagation* (FFBP) e *Cascade-Forward Backpropagation* (CFBP) com 5, 10 e 15 neurônios na camada intermediária com aplicação da função de ativação *tansig*, atingindo boa performance na classificação da gramínea (R² de 0,79 e 0,81, respectivamente). Já a rede *Radial Basis Function* (RBF) implementada com valor do *spread* igual a 1 e erro de performance igual a 0,0001, gerou a melhor classificação dentre as redes implementadas, com um R² de 0,99 para a determinação do status de N. Desta forma, o software de processamento de imagem e a rede neural RBF desenvolvidos foram capazes de classificar corretamente como suficiente, moderadamente deficiente ou deficiente o status de N em *Brachiaria brizantha* cv. Xaraés.

Palavras chaves: Classificação de imagem, Índices de vegetação, Rede Neural Multilayer Perceptron, RGB, Segmentação de imagens.

ABSTRACT

MANCIN, W. R. **Development of digital image processing software for analysis of nitrogen nutritional status in *Brachiaria brizantha* cv. Xaraés using artificial neural network**. 2019. 60 f. Dissertation (Master degree) - College of Animal Science and Food Engineering, University of São Paulo, Pirassununga, 2019.

New tools are constantly being created using New Information and Communication Technologies (NICT) for all sectors of the economy, making it possible to expand production, improve processes, offer conditions for greater financial gains and reduce the use of inputs, contributing to the sustainability of the environment. In the current emerging scenario of new technologies and knowing the need of the producer to efficiently manage his property, the aim of this study was to develop a software using computer vision and image processing techniques, linked to an artificial neural network (ANN), in order to estimate nitrogen (N) nutritional status in *Brachiaria brizantha* cv. Xaraés. The experiment was conducted out in the open field from November 2017 to March 2018, on the premises of the Department of Zootechnics, at the Faculty of Zootechnics and Food Engineering (FZEA / USP) in an area comprised of 12 portion with a floor area of 40 m² each and divided into three randomized complete blocks, where were administered four treatments with N concentrations (0, 15, 30 and 45 kg N ha⁻¹), whose source was NH₄NO₃ (32%). The images obtained in the field of the leaf blades through digital camera, passive sensor, present in smartphone, were processed and analyzed in the RGB color system (Red, Green and Blue), were also sent to the laboratory for determination of N concentration by the Kjeldahl method and thus generate a database correlated with the processed images. Once the images were processed, the vegetation indices were generated. To identify the indices that best explain the relationship with the N content obtained in the laboratory, principal component analysis (PCA) was used. Initially, 18 indices were generated which, after analysis, were reduced to 12, composed by Gn, Bn, Saturation, ExG, CIVE, VEG and COM which composed the first component and, by the indices R, G, Brightness, ExR and VARlgreen that composed the second component, thus generating determination coefficient of 0,902 (R²), which were used as input layer of the artificial neural network. For the implementation of the neural network *Multilayer Perceptron* (MLP), the *Feed-Forward Backpropagation* (FFBP) e *Cascade-Forward Backpropagation* (CFBP) networks were tested with 5, 10 and 15 neurons in the intermediate layer with the application of the tansig activation function achieving good performance in the grass classification (R² 0,79 and 0,81, respectively). However, the *Radial Basis Function* (RBF) network implemented with spread value equal to 1 and minimum error of 0,0001, generated the highest rating among the implemented networks, with an R² of 0,99 for determining the status of N. Thus, the image processing software and RBF neural network developed can correctly classify as sufficient, moderately deficient or deficient the status of N in *Brachiaria brizantha* cv. Xaraés.

Keywords: Image classification, Vegetation indexes, Neural Network Multilayer Perceptron, RGB, Image segmentation.

LISTA DE ILUSTRAÇÕES

Figura 1 – Detalhamento das cores visíveis por comprimento de onda	19
Figura 2 – Formato de combinação das cores RGB(a) e Sistema de cor HSB(b) ...	20
Figura 3 – Indicação de formação de uma imagem (a) e sua visualização separada nas bandas espectrais R(b), G(c) e B (d).....	21
Figura 4 – Diagrama esquemático da absorção e reflexão dos diferentes comprimentos de onda pela folha.....	22
Figura 5 – Diagrama representativo da relação clorofila x refletância x RGB na Imagem	23
Figura 6 – Exemplo de um neurônio artificial(a) e um neurônio vivo(b).....	27
Figura 7 – Exemplo de arquitetura de uma rede neural MLP	29
Figura 8 – Exemplo de arquitetura de uma rede neural Função Base Radial.....	31
Figura 9 – Precipitação durante período experimental	33
Figura 10 – Esquema da distribuição dos tratamentos aos blocos e especificações das doses aplicadas	34
Figura 11 – Exemplo de uma foto da subamostra para obtenção do RGB.....	36
Figura 12 – Esquematização do processamento das imagens.....	38
Figura 13 – Exemplo do processamento da imagem realizado pelo software	40
Figura 14 – Tela do software para obter imagem e exemplo do resultado após processamento	41
Figura 15 – Relação entre adubação realizada por corte e a concentração de N foliar	42
Figura 16 – Gráfico resultante após análise dos componentes principais dos IVxN..	48
Figura 17 – Exemplo de folhas após classificação do <i>status</i> e respectivos valores RGB após processamento.....	50

LISTA DE TABELAS

Tabela 1 – Fórmulas dos índices de vegetação (IV's) baseados no sistema de cor RGB obtidos das imagens	26
Tabela 2 – Atributos químicos do solo obtidos pela análise laboratorial	34
Tabela 3 – Cálculos da normalização das cores R, G e B e conversão para HSB. ...	40
Tabela 4 – Teor de nitrogênio (média $\pm$ erro padrão, g N kg ⁻¹ de matéria seca foliar) das folhas de acordo com o nível de adubação e período de rebrotação	44
Tabela 5 – Teor de nitrogênio (média $\pm$ erro padrão, g N kg ⁻¹ de matéria seca foliar) das folhas de acordo com as classes de N e as taxas de fertilização estimadas (kg ha ⁻¹ de N por corte) para atingir o nível de suficiência.	46
Tabela 6 – Autovalores, autovetores e escores dos índices de vegetação (IV's) selecionados para os dois primeiros componentes principais (PRIN).....	47
Tabela 7 – Valores R, G, e B das imagens (média $\pm$ erro padrão) de acordo com o status N, p-valor e coeficiente de determinação (R ²) linear	49
Tabela 8 – Resumo do desempenho dos modelos de RNA definidas com formato da arquitetura e demais parâmetros internos.	51

LISTA DE SIGLAS

ABIEC – Associação Brasileira das Indústrias Exportadoras de Carnes
ACP – Análise de Componentes Principais
B – (Blue) Azul do sistema de cor RGB
Bn – Azul normalizado
Brightness – Brilho
Cwa – Clima subtropical de inverno seco e verão quente húmido
G – (Green) Verde do sistema de cor RGB
Gn – Verde normalizado
H – (Hue) Matiz
HSB – Hue, Saturation, Brightness (Matiz, Saturação e Brilho)
IL – Interceptação luminosa
IR – Infravermelho
IV – Índice de Vegetação
JDK – Kit de desenvolvimento Java
K – Unidade básica da temperatura termodinâmica Kelvin
LCC – *Leaf Color Chart* (Cartela de Cores da Folha)
MLP – *Multilayer Perceptron*
MLR – Regressão Linear Múltipla
MS – Matéria Seca
MSE – Erro quadrático médio
N – Nitrogênio
NUE – *Nitrogen Use Efficiency* (Uso eficiente do nitrogênio)
OOA – Análise orientada a objetos
PCA – Análise de Componentes Principais
PIB – Produto Interno Bruto
RBFNN – Rede neural Função de Base Radial
Red – Vermelho do sistema de cor RGB
RGB – Red, Green, Blue (Sistema de cores aditivo em imagens)
RMSE – Raiz do Erro Quadrático Médio
Rn – Vermelho normalizado
RNA – Rede neural artificial
ROI – Região de interesse
S – (Saturation) Saturação

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivo da pesquisa	16
1.1.1	Objetivos específicos	16
2	REVISÃO DE LITERATURA	17
2.1	Benefícios da Tecnologia	18
2.2	Imagens e sistemas de cores.....	18
2.3	Assinatura espectral na imagem	22
2.4	Índices de vegetação	24
2.5	Redes Neurais Artificiais – RNA.....	26
3	MATERIAL E MÉTODOS	33
3.1	Local e tratamentos experimentais.....	33
3.2	Coleta e procedimentos com as lâminas foliares e obtenções das imagens.....	35
3.3	Análise estatística dos dados	36
3.4	Etapas do processamento das imagens e implementação do software	38
4	RESULTADOS E DISCUSSÃO	42
4.1	Definição de taxas de fertilização de acordo com a demanda da cultura	42
4.2	Análise de componentes principais e seleção dos índices de vegetação	46
4.3	Arquitetura da Rede Neural e desempenho atingidos	50
5	CONCLUSÃO	54
6	REFERÊNCIAS BIBLIOGRÁFICAS	55

1 INTRODUÇÃO

Dentre os três setores da economia, o setor primário que está relacionado a extração de recursos da natureza, mais especificamente nas atividades de agricultura e pecuária, tem gerado movimentação financeira considerável, contribuindo de forma ímpar para o crescimento do país. O PIB (Produto Interno Bruto) do agronegócio no Brasil, no ano de 2017, superou 1,42 trilhão de reais, sendo que a cadeia produtiva da pecuária movimentou aproximadamente R\$ 433 bilhões, segundo o relatório anual da Associação Brasileira das Indústrias Exportadoras de Carnes (2018). Conforme o último Censo Agro do IBGE realizado em 2017, existem aproximadamente 172 milhões de cabeças de gado (IBGE, 2017) e, aproximadamente, 165 milhões de hectares de pastagens nativas e cultivadas (ABIEC, 2018). Entretanto, mesmo com um dos maiores rebanhos mundiais, o Brasil possui baixa produtividade devido a falhas no manejo das pastagens e extensão rural deficitária, que limita a transmissão de conhecimentos (SANTINI, 2014; DIAS FILHO, 2014).

Apesar de uma relativa estabilização no crescimento das áreas de pastagens no Brasil e aumento da produção da pecuária de modo geral em todo país, ainda é apontado por Dias Filho (2014), que de 50% a 70% das pastagens no Brasil apresentam algum grau de degradação do solo e, conseqüentes perdas de qualidade das pastagens. Dias Filho (2017, p.10) define degradação de pastagens como “[...] a queda acentuada e contínua da produtividade da pastagem, no decorrer do tempo.” Esse cenário está ligado ao fato de que melhorias no planejamento, manejo e ampliação de práticas agronômicas, tais como calagem e adubação, não são proporcionais aos aumentos em produção animal. Tais práticas acarretam maiores gastos ao produtor para manter as pastagens em níveis ideais para que os índices de produtividade se mantenham no padrão desejado.

Diversas tecnologias têm sido aplicadas na Zootecnia de Precisão com o intuito de criar condições mais adequadas ao manejo das pastagens para os animais. O uso adequado do pasto, bem como o seu correto manejo tende a incrementar a produtividade da pastagem e, como consequência, permite aumentos em produtividade animal ao mesmo tempo em que assegura a persistência do recurso vegetal.

Vários estudos estão sendo conduzidos com o intuito de melhorar a performance dos sistemas de manejo. O uso de tecnologias de processamento de

imagens tem sido empregado nessas atividades com o pressuposto de identificar reais necessidades de adequado manejo de adubação e identificar as características das forrageiras e sua relação com a adubação nitrogenada em pastagens (WEZEL *et al.*, 2014). Vários outros trabalhos utilizando processamento de imagens por meio de análises espectrais têm ganhado destaque com a utilização de câmeras fotográficas convencionais (SRIDEVY *et al.*, 2018; XIE, 2018; SAFA *et al.*, 2019; MESTRE, 2017; XUE *et al.*, 2017; ANDRADE, 2015; GUPTA *et al.*, 2014; LIU *et al.*, 2010).

O princípio de utilização da análise de imagens é baseado no fato de que características de crescimento e parâmetros de produtividade de espécies vegetais podem ser descritos pela refletância diferencial dos comprimentos de onda do espectro eletromagnético. Mudanças em parâmetros da vegetação são detectadas por meio de sensores remotos ou terrestres, caracterizando uma assinatura espectral. Assinaturas espectrais são, então, descritas por variações nos comprimentos de ondas (REM) e, conseqüentemente, gerando variações nos índices de vegetação (IV's), sendo que atualmente estão descritos centenas de índices na literatura (HENRICH *et al.*, 2012).

Para fins de adubação e manejo de pastagens, a demanda por tecnologias de baixo custo tem impulsionado o desenvolvimento de métodos alternativos, de fácil utilização por produtores menos capacitados ou capitalizados. Estimar o teor de nitrogênio na produção agrícola e em plantas forrageiras utilizando câmeras fotográficas comuns vem ganhando espaço nesse cenário, uma vez que são de fácil manuseio, não exigem muito treinamento na sua utilização como as câmeras multiespectrais e hiperespectrais, além de ser um método rápido, econômico e não invasivo para tomada de decisão sobre adubação, devido ao elevado poder de processamento dos dispositivos móveis atuais e ao aprimoramento de técnicas no processamento de imagens.

Assim, a manipulação dos comprimentos de onda no espectro do visível registrados nas imagens tem ganhado aplicação através de diversos índices de vegetação, uma vez que o conhecimento em tempo real da necessidade de adubação permite que a planta tenha o insumo basilar para não ficar abaixo de seu nível crítico, com a menor perda possível para o meio ambiente, garantindo ainda a manutenção de sua sustentabilidade.

1.1 Objetivo da pesquisa

O objetivo deste trabalho foi desenvolver um software capaz de identificar o status nutricional da planta (suficiente, moderadamente deficiente e deficiente), baseado no nitrogênio em *Brachiaria brizantha* cv. Xaraés, utilizando processamento digital de imagens e redes neurais artificiais.

Para tanto, o software desenvolvido deve ser capaz de correlacionar adequadamente a concentração do nutriente nitrogênio, extraída por método analítico na planta, com os dados das imagens obtidos no sistema RGB mais os índices de vegetação.

1.1.1 Objetivos específicos

- Desenvolver o software de processamento de imagem para a *Brachiaria brizantha* cv. Xaraés.
- Identificar o(s) melhor(es) índice(s) de vegetação.
- Identificar o status nutricional da planta .
- Analisar o desempenho das redes neurais *Multilayer Perceptron* e *Radial Basis Function* para classificar a *Brachiaria brizantha* cv. Xaraés.

2 REVISÃO DE LITERATURA

O PIB do Agronegócio no Brasil alcançou R\$ 1,42 trilhão em 2017, representando, aproximadamente 23,6% do PIB total brasileiro, sendo que, somente a cadeia produtiva da pecuária movimentou, em 2017, aproximadamente R\$ 433 bilhões, o que representa 30,5% do PIB do agronegócio (ABIEC, 2018). Isso ressalta a importância dos sistemas de produção animal do país, o que é ratificado pelo fato de que o Brasil possui, atualmente, o segundo maior rebanho bovino do mundo (em milhões de cabeças), sendo também o segundo maior produtor mundial de carne (ton. equivalente carcaça) (ABIEC, 2018).

Segundo Dias Filho (2014), a vocação da pecuária brasileira advém das características climáticas, extensão territorial do país e do fato de que, cerca de 87% dos animais abatidos estão inseridos em sistemas de produção baseados em pastagens, muitos desses ainda sob sistema extensivo, fato esse que garante os menores custos de produção de carne do mundo. Entretanto, os índices de produtividade média da pecuária brasileira ainda estão muito aquém do seu potencial.

O perfil extrativista dos sistemas de produção baseados em pastagens, caracterizados pelo desconhecimento e não adoção de tecnologias disponíveis, manejo inadequado do rebanho e das pastagens, vêm contribuindo para a perda da capacidade produtiva das pastagens, com impactos sobre o ambiente e comprometimento da sustentabilidade da atividade e a deficiência de nitrogênio tem sido apontada como um dos principais limitantes aos aumentos em produtividade das gramíneas tropicais (SANTINI, 2014; DIAS FILHO, 2014).

Os estudos de Villar *et al.* (2015), Shukla *et al.* (2004) e Li *et al.* (2015) apontam que a identificação de nutrientes em tempo real através do *Leaf Color Chart* (LCC), softwares aplicativos em dispositivos móveis e processamento de imagens, para uma recomendação variável de fertilizante ao invés da aplicação de doses fixas, baseado no índice de suficiência da planta, traz grande benefício para o meio ambiente e para o produtor. Todavia, enquanto várias ferramentas informatizadas para identificação de deficiências nutricionais em diversas culturas já estão disponíveis ao produtor, poucos estudos têm sido delineados com vistas ao desenvolvimento de softwares e ferramentas de apoio para tomada de decisão e produtividade em pastagens de clima tropical.

2.1 Benefícios da Tecnologia

A adubação nitrogenada é estratégia agrônômica essencial na manutenção e maximização da produtividade das culturas. Todavia, a aplicação incorreta de fertilizantes não beneficia o crescimento vegetal e pode, ainda, contribuir substancialmente para a emissão de gases de efeito estufa e contaminação das águas.

A volatilização de amônia (NH_3) é apontada como a principal via de perdas de N dos fertilizantes (LIANG *et al.*, 2017; LI *et al.*, 2015) e, embora em menor quantidade que a amônia, as emissões de óxido nitroso (N_2O) também aumentaram devido ao maior uso de fertilizantes nitrogenados (MAZZETTO *et al.*, 2015; LI *et al.*, 2015).

Alguns estudos como de Muñoz-Huerta *et al.* (2013), Vergara-Diaz *et al.* (2016), Zheng *et al.* (2018), Sridevy *et al.* (2018), Hallik *et al.* (2017) e Shukla *et al.* (2004) apontam que a identificação do teor de N na planta, em tempo real realizado em campo, utilizando dispositivos móveis e processamento de imagem já são realizados para diversas culturas com resultados satisfatórios, sendo estratégia efetiva na mitigação das perdas de N e melhorias na eficiência de uso do fertilizante.

O desenvolvimento de um sistema que possa ser utilizado em campo para identificar, através da análise de imagens, a suficiência ou deficiência do nitrogênio para fins de tomada de apoio no uso da adubação em pastagens permitirá a otimização e, com efeito, favorecer a ampliação da utilização desse nutriente de forma mais adequada e precisa (ANDRADE, 2015).

Nesse sentido, a ampliação dos sistemas de produção pastoris apoiadas em sistemas computacionais é apontada como uma das alternativas de exploração sustentável, cujo modelo, entretanto, deverá ser pautado pelo uso eficiente dos recursos físicos, incluindo a recuperação de áreas degradadas, calcada no aporte de conhecimento e de tecnologias poupadoras de insumos (DIAS FILHO, 2014; ANDRADE, 2015).

2.2 Imagens e sistemas de cores

A palavra “imagem”, de acordo com dicionários de línguas, é a imitação ou representação visual de algo. Na ausência de luz é impossível representar algo que se possa interpretar, uma vez que a representação visual é capturada com uma cor

uniforme, o preto. Assim, uma imagem pode ser originada pela captura de comprimentos de ondas de luz (radiação eletromagnética). Quando é incidida luz branca sobre um corpo de cor verde, por exemplo, esse absorve todas as outras cores do espectro visível, refletindo de forma difusa apenas o verde, o que torna possível distinguir sua cor. Por isso, um corpo de cor branca é aquele que reflete todas as cores, sem absorver nenhuma, enquanto um corpo de cor preta absorve todas as cores sobre ele incididas, sem refletir nenhuma, o que causa aquecimento (GONZALEZ; WOODS, 2010).

Existem vários comprimentos de onda do espectro eletromagnético, porém nem todas são visíveis ao olho humano. Os comprimentos visíveis ao olho humano vão de aproximadamente 400 nm a 700 nm (0,4 a 0,7 μm), conforme Gonzalez e Woods (2010). Nesse intervalo de comprimentos de onda é que a luz refletida de qualquer objeto ou “corpo” nos oferece uma grande quantidade de cores que se consegue distinguir, através das combinações das três cores básicas (vermelho, azul e verde), dentro de seus respectivos comprimentos, sendo o azul (450 – 495 nm), o verde (495 – 570 nm) e o vermelho (620 – 750 nm) (GONZALEZ; WOODS, 2010).

Figueiredo (2005) oferece maiores detalhes através de uma figura sobre os comprimentos de ondas visíveis dentre a enorme variação de ondas, que também são conhecidas e amplamente utilizadas, mas que não são visíveis (Figura 1).

Figura 1 – Detalhamento das cores visíveis por comprimento de onda.

Fonte: Figueiredo (2005)

Como o ser humano consegue observar somente algumas cores primárias na sua forma natural, as demais cores são a combinação resultante da mistura dessas três cores básicas – vermelho, verde e azul, também conhecido pela sigla RGB, formada pelo nome das cores na língua inglesa *red*, *green* e *blue*, respectivamente.

No sistema RGB para fins de análise de imagens, para cada uma das três cores são utilizadas as intensidades de 0 a 255, sendo o zero a ausência da cor e o 255 o máximo de sua tonalidade. A combinação do R, G e B com seus valores possíveis de intensidade é que permite ter a enorme variação de cores. A fim de ilustração, se correlacionar as cores R, G e B nas três dimensões (X, Y, Z), quando os três vértices estiverem na intensidade zero será formada a cor preta e, quanto mais próximo desse ponto terá tons escuros. À medida que se distanciam do ponto zero ficam mais claros até se atingir o branco (Figura 2a) (GONZALEZ; WOODS, 2010).

Outro sistema de cor amplamente utilizado para representar toda a variação do espectro visível é o HSB. É uma conversão do sistema RGB que prioriza outras propriedades de maior percepção para o ser humano que são, respectivamente, H - Hue (Matiz), S – Saturation (Saturação) e B – Brightness (Brilho) (Figura 2b).

Figura 2 – Formato de combinação das cores RGB (a) e Sistema de cor HSB (b)

Fonte: Figueiredo (2005)

O matiz define a cor, sendo ela que distingue o azul, do vermelho e do verde, por exemplo. Já a saturação retrata a pureza da cor em relação à contaminação por outras cores, sendo tons saturados os mais “brilhantes” ou vívidos e os menos saturados, os quais são os chamados “pastel” ou pálidos. A cor “branco”, por exemplo,

possui saturação zero. O brilho compreende a quantidade ou potência de luz da fonte, sendo que na intensidade zero terá tons mais escuros e com intensidade mais próxima de um, terá tons mais claros (GONZALEZ; WOODS, 2010; FIGUEIREDO, 2005).

Dessa forma, a imagem digital nada mais é do que a conversão para representação discreta (digital) do que existe na representação contínua (real). Essa representação discreta ocorre pela organização de uma matriz de pontos (*pixels*) para cada tipo de onda, totalizando três matrizes – 1 para *blue*, 1 para *green* e 1 para *red* (GONZALEZ; WOODS, 2010). Cada ponto de cada matriz possui o valor de 0 a 255, representando a intensidade da cor em escala de cinza. Dessa forma, cada ponto tem seu tom (cor) próprio e o software de tratamento de imagem é que realiza a combinação das três matrizes (Figura 3) (GONZALEZ; WOODS, 2010). A montagem de uma matriz de pontos é expressa por uma função $f(x,y)$ em duas dimensões, sendo que y é usado com sentido invertido, ficando a primeira posição o canto superior esquerdo, conforme a Figura 3 (GONZALEZ; WOODS, 2010; MIRANDA, 2006). Com isso é possível realizar várias análises e cálculos em cada *pixel* da imagem.

Figura 3 – Indicação de formação de uma imagem (a) e sua visualização separada nas bandas espectrais R(b), G(c) e B(d).

Fonte: Própria autoria.

O processamento de uma imagem compreende a aplicação de funções específicas de baixo, médio ou alto nível para melhorar sua qualidade, extrair atributos e interpretá-la atingindo um nível de significação (GONZALEZ; WOODS, 2010). Ainda, segundo os mesmos autores, dentre todas as funções existentes, as mais aplicadas são equalização de histograma e quantização, filtros de domínio espacial como gaussiana, laplaciano, convolução e ordem estatística, restauração por remoção de ruído e/ou borrão, segmentação por *threshold* ou detecção de bordas, transformação para o domínio da frequência (Fourier), conversão entre sistemas de cores, erosão, dilatação e análise de texturas.

2.3 Assinatura espectral na imagem

O termo assinatura espectral refere-se a como ocorre a variação da refletância de um objeto para cada comprimento de onda (MIRANDA, 2011). No processo de fotossíntese de uma folha (STREIT *et al.*, 2005), na medida em que a radiação eletromagnética da luz solar – na faixa visível do espectro, atinge a folha, as moléculas de clorofila – um dos principais pigmentos fotossintéticos, entram em ação para refletir o comprimento de onda do verde, porém refletir numa proporção extremamente menor a quantidade de azul e de vermelho, conforme Figura 4. Essa diferença de refletância espectral dos comprimentos de onda sobre uma mesma folha de planta pode ser aplicada na avaliação da concentração de suas moléculas, pois a clorofila é altamente correlacionada com o teor de N na planta (STREIT *et al.*, 2005).

Figura 4 – Diagrama esquemático da absorção e reflexão dos diferentes comprimentos de onda pela folha.

Fonte: Adaptado de <http://www.senteksystems.com/2015/11/20/leaf-reflectance-vegetation-indices/>

No entanto, a refletância captada pelos equipamentos digitais é armazenada na forma de valores entre 0 e 255 para cada pixel que forma a imagem. Essa informação é de extrema importância, pois o fato da planta possuir mais clorofila faz com que ela reflita mais o comprimento de onda do verde, que responde em baixos valores para a cor verde na imagem, representando assim, sua intensidade. Desta forma, uma menor concentração de clorofila fará com que ela reflita menos o comprimento de onda do verde, correspondendo assim, a um alto valor de intensidade para a cor verde na imagem. A demonstração dessa inversão proporcional na relação “refletância espectral” - “RGB imagem” pode ser observado na Figura 5, não levando em consideração a correlação de valores, mas somente uma ilustração dos fatos. O mesmo efeito ocorre para as outras bandas espectrais visíveis.

Figura 5 – Diagrama representativo da relação clorofila x refletância x RGB na imagem.

Fonte: Própria autoria

Existe, ainda, o efeito de luminosidade que interfere na captura da refletância pelos equipamentos. O cálculo ponderado do grau de luminosidade, ou seja, a refletância que o olho humano e os equipamentos digitais de sensor passível conseguem perceber, é $0.299 \cdot R + 0.587 \cdot G + 0.114 \cdot B$, conforme descrito por Miranda (2006) e Gonzalez e Woods (2010).

Compreendendo, então, que a refletância é registrada com valores relativos aos comprimentos de onda do R, G e B, exprimindo as informações contidas numa imagem, e utilizando dessas variações de intensidades para cálculos de índices de vegetação, é possível dizer que através da análise de imagens seja possível estimar o status de N na planta (LEE; LEE, 2013; HUANG *et al.*, 2015; FENG *et al.*, 2017).

2.4 Índices de vegetação

Índices de vegetação (IV) são cálculos matemáticos realizados com valores dos pixels das bandas espectrais das imagens coletadas de plantas, a fim de prever e avaliar diversas situações biológicas. A geração dos índices só é possível devido a variação da clorofila que, por sua vez, altera o tom do verde conforme sua concentração nas folhas das plantas, sendo que o nitrogênio é o principal elemento para sua síntese celular. Devido a esta característica da variação do verde estar altamente relacionado ao nitrogênio é que o monitoramento do nível de N se torna tão importante, e permite a agricultura de precisão realizar aplicações mais localizadas e específicas. São amplamente utilizados para monitorar, analisar e mapear variações temporais e espaciais na estrutura da vegetação, bem como certos parâmetros biofísicos.

Centenas de índices de vegetação já foram catalogados, alguns com aplicações muito específicas e/ou que utilizam bandas espectrais de alta frequência, necessitando assim, de equipamentos próprios. Contudo, muitos índices utilizam somente as bandas espectrais no comprimento do visível e estão apresentando resultados satisfatórios em diversas áreas de estudo.

O ExG (*Excess Green Index*) extrai a área de interesse da planta potencializando o efeito da clorofila e destacando-se do solo (GUIJARRO *et al.*, 2011; YANG *et al.*, 2015), enquanto o ExR (*Excess Red Index*) busca minimizar o ruído de fundo, tanto da reflexão do solo quanto de possíveis resíduos ficando com a maior porção do verde refletido pela folha (GUIJARRO *et al.*, 2011; YANG *et al.*, 2015). O ExGR (*Excess Green minus Excess Red Index*) consiste na combinação dos índices ExG e o ExR, resultando numa subtração entre eles (GUIJARRO *et al.*, 2011; YANG *et al.*, 2015).

O índice CIVE (*Colour Index of Vegetation Extraction*) realiza a segmentação tão bem quanto o NDVI, porém usando somente os valores normalizados das bandas

R, G e B da imagem, obtidos após uma análise de componentes principais (KATAOKA *et al.*, 2003). Já o VEG (*Vegetative Index*) é projetado para lidar com a variabilidade da iluminação natural da luz do dia, contendo uma constante “a” de valor 0,667 (GUIJARRO *et al.*, 2011; YANG *et al.*, 2015).

Existem mais três índices que são bem específicos. O COM1 (*Combined Indices 1*) é a combinação de três índices, o ExG, o CIVE e o VEG associados também a um fator de peso individual (YANG *et al.*, 2015). O VARI (*Visible Atmospherically Resistant Index*), também é conhecido por ARVI, foi desenvolvido para corrigir efeitos atmosféricos (GITELSON *et al.*, 2002), permitindo a estimativa de fração de cobertura da vegetação com um erro menor de 10%. Um índice que é obtido com os valores do sistema de cor HSB é o DGCI (Dark Green Color Index), cujo objetivo é medir a cor verde escura relativa numa imagem (KARCHER; RICHARDSON, 2003).

Guijarro *et al.* (2011) utilizou os índices ExG, ExR, ExGR, VEG, CIVE, juntamente com processo de limiarização para identificar texturas de solo e a cultura (cevada – *Hordeum vulgare L.* e milho – *Zea mays L.*) em imagens agrícolas, atingindo peso médio 0,33 para classificação dos dados com o CIVE. Já Yang *et al.* (2015) testou a identificação de mudas de milho aplicando conversão do RGB para sistema de cores HSV, sendo sua indicação para identificação das plantas, porém obteve equivalência a Guijarro *et al.* (2011) com o índice CIVE. O estudo de Meyer e Camargo-Neto (2008) verificou que a subtração do índice ExG pelo ExR proporcionou melhor separação do verde ($0,88 \pm 0,06$), se aplicados em separados com um método de threshold ou limiarização. Beniaich *et al.* (2019) testaram 11 índices de vegetação na cultura de feijão-de-porco (*Canavalia ensiformis L.*), sendo que os índices ExG e CIVE apresentaram melhor R^2 (0,85 e 0,80), respectivamente, com o mesmo coeficiente de correlação (0,92), seguidos por VEG e COM. Na análise foliar do milho Canteri (2015) registrou uma correlação com R^2 de 0.92 e Rorie *et al.* (2011) obteve R^2 de 0.89, utilizando o índice DGCI.

Esses índices de vegetação citados têm suas fórmulas detalhadas na Tabela 1 e vários outros usando regressões com os valores das matrizes de cor R, G e B são trabalhados em vários softwares voltados para análise de plantas. De acordo, com o site <http://www.plant-image-analysis.org/>, existem 174 softwares para análise de imagens em plantas, entretanto, nenhum desses busca, especificamente, estimar o status de nitrogênio de gramíneas em clima tropical.

Tabela 1 – Fórmulas dos índices de vegetação (IV's) baseados no sistema de cor RGB obtidos de imagens.

Índice de Vegetação	Fórmula de cálculo	Autor
ExG	$(2 \cdot G_N) - R_N - B_N$	Guijarro et al. (2011) e Yang et al. (2015)
ExR	$(1.4 \cdot R_N) - G_N$	Guijarro et al. (2011) e Yang et al. (2015)
ExGR	$ExG - ExR$	Guijarro et al. (2011) e Yang et al. (2015)
CIVE	$0.441 \cdot R_N - 0.811 \cdot G_N + 0.385 \cdot B_N + 18.78745$	Guijarro et al. (2011) e Yang et al. (2015)
VEG	$G_N / (R_N^{0,667}) * (B_N^{1-0,667})$	Guijarro et al. (2011) e Yang et al. (2015)
COM	$0.25 \cdot ExG + 0.30 \cdot ExGR + 0.33 \cdot CIVE + 0.12 \cdot VEG$	Yang et al. (2015)
VARlgreen	$(G - R) / (G + R - B)$	Gitelson et al. (2002)
DGCI	$((H - 60)/60 + (1 - S) + (1 - Brilho)) / 3$	Karcher & Richardson (2003)

Fonte: Própria autoria

2.5 Redes Neurais Artificiais – RNA

As redes neurais artificiais (RNA) são mecanismos computacionais que buscam realizar as mesmas funções da inteligência humana, tentando ser o mais similar possível, sendo tratada como uma ferramenta de sistemas inteligentes informatizados. Sua estrutura pode ser compreendida, fazendo uma analogia às células nervosas vivas, os neurônios, em que os dendritos do neurônio seriam as conexões de entradas de dados, o corpo celular representa o processamento dos dados e, consequentemente, os axônios representam a saída ou o resultado da rede (Figura 6).

A rede neural ocorre então, pela interligação de vários “neurônios” artificiais, proporcionando assim, a transferência de dados entre eles e, assim, gerando a “pseudointeligência”(TONSIG, 2000; SILVA, 2012).

Figura 6 – Exemplo de um neurônio artificial (a) e um neurônio vivo (b)

Fonte: a) Adaptado de Silva (2012) e b) Adaptado de <http://cs231n.github.io/neural-networks-1/>

De acordo com CASTRO (2010), assemelham-se ao cérebro humano em dois aspectos:

1. O conhecimento é adquirido pela RNA através de um processo de aprendizado.
2. As transmitâncias das conexões interneurônios, conhecidas como pesos sinápticos, às quais está submetido o fluxo de informações através da rede, são utilizadas para armazenar o conhecimento. Uma RNA nada mais é, portanto, do que uma máquina projetada para modelar a maneira pela qual o cérebro desempenha funções de interesse.

Em cada neurônio de uma rede existe uma função que transforma dados de entrada em um único valor de saída. As funções mais empregadas são (HAYKIN, 2003; MIRANDA, 2011; SILVA, 2012):

- “*Heavyside*”: é uma função linear, gerando somente duas saídas possíveis, 0 (zero) ou 1 (um);
- “*Degrau Bipolar*”: também linear, cujos resultados são os valores -1, 0 ou 1;
- “*Rampa Simétrica*”: retorna os próprios valores dos potenciais de ativação, caracterizando-se pelo tipo linear, sendo mais conhecida por *Purelin*.
- “*Logística*”: é uma função sigmoideal, também chamada *Logsig*, que possui um ponto de inflexão e retorna valores do conjunto dos números reais entre zero e um;
- “*Tangente Hiperbólica*”: também chamada *Tansig*, é similar a função Logística, tipo sigmoideal, porém, diferenciando-se que o ponto de inflexão sempre será o valor 0 (zero) e as saídas podem ser valores reais entre -1 e 1.

- “Gaussiana”: é uma classe especial de função tipicamente radial, sendo que a resposta diminui ou aumenta com a distância de um ponto central.

As redes neurais possuem características importantes, além da capacidade de aprendizado, como: adaptação por experiência, habilidade de generalização, organização de dados, tolerância a falhas, facilidade de prototipagem, bem como armazenamento distribuído (SILVA, 2012). Dentre suas aplicações são usadas para classificação de padrões, sistemas de previsão, otimização de sistemas, clusterizações e em projetos que envolvam memórias associativa (HAYKIN, 2003).

Toda rede neural tem sua fase de treinamento ou aprendizagem para ajustar pesos e limiares dos neurônios, gerando sua pseudointeligência, para então estar apta a ser empregada numa solução de um problema. Suas formas de treinamento são a supervisionada, quando são informados os valores de entrada e seus respectivos valores de saída, como se existisse alguém acompanhando a aprendizagem, e a não supervisionada, quando a rede não sabe os exatos valores que devem servir de entrada e nem sabe os valores de saída, ou seja, ela deve aprender sozinha através dos elementos do conjunto de dados fornecidos, os quais devem ser usados como entrada e que devem ser comparadas com a sua respectiva saída (HAYKIN, 2003; MIRANDA, 2011; SILVA, 2012).

Existem vários tipos de redes neurais, como por exemplo, a *Adaline*, a Regra Delta, a *Perceptron* e *Multilayer Perceptron (MLP)*, a Recorrentes de *Hopfield*, *Radial Basis Function (RBFNN)*, as Auto-organizáveis de *Kohonen*, as Redes Neurais Convolucionais (CNN) e as ART (*Adaptive Resonance Theory*), cada uma com características próprias que as definem, permitindo utilizá-las em todas as áreas do conhecimento (HAYKIN, 2003). As RNAs possuem uma gama variada de arquitetura, dependendo, principalmente, de sua aplicação. Entretanto, suas estruturas possuem basicamente uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída (SILVA, 2012).

A rede *MultiLayer Perceptron (MLP)*, devido a sua facilidade de treinamento supervisionado e trabalho com múltiplas camadas, tem sido empregada em vários estudos a fim de resolver problemas de classificação e agrupamento (HAYKIN, 2003). Utiliza um algoritmo de retropropagação do erro (*Error Back-Propagation – BP*), fazendo sua aprendizagem pela correção do erro, aplicando uma generalização do mínimo quadrado médio (LMS). A retropropagação foca nos desvios (erros) entre as respostas desejadas e as produzidas pelos neurônios de saída, ajustando, então, os

pesos e limiares de todos os neurônios para o correto treinamento da rede (HAYKIN, 2003; SILVA, 2012). Basicamente, os valores de entrada se propagam camada por camada a frente, com os pesos sinápticos fixos nos neurônios, gerando uma saída. Em seguida, realiza um passo atrás, ajustando os pesos sinápticos dos neurônios, de acordo com uma regra de correção, objetivando atingir a saída desejada (HAYKIN, 2003).

Sua estrutura pode ser visualizada através da Figura 7. Ela pode ser configurada por dois formatos: a FFBP (*Feed-Forward Back-Propagation*), em que os dados de uma camada passam somente para a camada imediatamente seguinte de forma sequencial e a CFBP (*Cascade-Forward Back-Propagation*), em que as camadas além de receber os dados da camada imediatamente anterior, também recebem dados de outras camadas antecessoras, incluindo a camada de entrada, realizando o efeito cascata dos dados.

Figura 7 – Exemplo de arquitetura de uma rede neural MLP

Fonte: SILVA, 2012

Ao testar as redes *MultiLayer Perceptron* FFBP e CFBP com algoritmo de treinamento de *Levenberg-Marquardt* (LM) em comparação com a regressão parcial de mínimos quadrados (SHARABIANI; SOLTANI; NOGUCHI, 2018), a rede CFBP apresentou maior R^2 (0,9881) do que a regressão para seu conjunto de dados para predição do índice de proteína no trigo (*Triticum aestivum* L.). Zhang *et al.* (2012) ao testar esse mesmo tipo de rede (MLP) para determinar o teor de proteína bruta em grãos de arroz (*Zhegeng 22*) pela refletância espectral do dossel, também obteve

melhores resultados (R^2) em relação a regressão linear múltipla *stepwise* (0,92 e 0,90), respectivamente. Já os resultados de Safa *et al.* (2019), mostraram que o modelo de RNA implementado foi capaz de estimar o teor de N na pastagem de azevém perene (*Lolium perenne*) com correlação entre os dados de 94%. Também Liu (2010) aplicou um modelo de rede neural com retropropagação usando duas camadas intermediárias para estimar a concentração de clorofila em arroz (*Oryza sativa* L.) sob estresse de metais pesados, usando índices espectrais atingindo um alto nível de correlação, com um R^2 de 0,9014, indicando um uso eficaz para as RNA.

Outro tipo de rede que tem sido aplicada em alguns experimentos, cujo objetivo é realizar agrupamentos de dados, é a rede Função de Base Radial (RBFNN). Gautam e Panigrahi (2007) compararam os resultados da RBFNN com as MLP num experimento para determinar o nível de N em milho, usando imagens aéreas atingindo resultado levemente superior para a RBFNN (88,8%), com RMSE de 6,6%. No estudo de Li *et al.* (2017) sobre aprendizado de máquina na previsão de nutrientes em degradação de pastagens, os autores concluíram que a RBFNN é caracterizada por um modelo de estrutura mais razoável e de maior credibilidade, tendo atingido um R^2 de 95%.

A rede Função de Base Radial possui somente uma camada escondida com maior número de neurônios, sendo que para cada neurônio é aplicado uma função base não linear, em sua maioria do tipo Gaussiana. Para a camada de saída a função aplicada é linear, dando a resposta da rede, de acordo com a ativação dos dados da entrada, conforme demonstrado na Figura 8.

Nos dados de entrada, usando o algoritmo *K-means*, são escolhidos aleatoriamente alguns valores para serem um ponto central, a partir do qual é gerado a dispersão obtida pelo cálculo da distância Euclidiana até *i*-valores da entrada. Dessa forma, na sua primeira etapa é realizado um treinamento não supervisionado, enquanto na segunda etapa ocorre um treinamento supervisionado. Com isso, essa rede gera um espaço de alta dimensionalidade de uma maneira não linear. A rede função base radial tem ganhado destaque, devido sua versatilidade e capacidade de aprendizagem, uma vez que sua abordagem não está na utilização de hiperplanos somente, mas também no conceito de aproximação dos pontos baseado na expansão radial do valor referente a um ponto central. Assim, isso nos remete a um estado tridimensional de observação dos pontos em um gráfico.

Figura 8 – Exemplo de arquitetura de uma rede neural Função Base Radial

Fonte: Adaptado de HAYKIN(2003), p 307 – fig 5.5.

Para se atingir maior performance em uma rede neural são utilizadas, previamente ao processo de treinamento, análises estatísticas em todo o conjunto de dados para identificar variáveis que representem de forma significativa as características de interesse do objeto de estudo, de forma a contribuir na redução do banco de dados que irá compor as informações de entrada na rede neural. A análise multivariada através da análise de componentes principais ou PCA (*Principal Component Analysis*) tem sido muito aproveitada em estudos mais recentes, devido a sua capacidade de redução de observações, possivelmente não correlacionadas, para um menor número de variáveis pelo emprego de técnica exploratória para análise de séries estatísticas multidimensionais.

Yi *et al.* (2010) utilizaram a PCA para identificar quais comprimentos de onda em um banco de dados de refletância hiperespectral do dossel de arroz (cv. *Xieyou* 9308 e cv. *Xiushui* 110) deveriam compor as entradas para a rede neural, bem como Sharabiani *et al.* (2018) também selecionaram as bandas espectrais que realmente se correlacionavam com o índice de proteína no trigo e que formariam um conjunto de dados que permitiria uma identificação e classificação mais eficiente para a rede

neural. Em seus trabalhos, Xie *et al.* (2018) reduziram seus dados de comprimentos de onda para não haver redundância nas informações e, assim, produzir um bom desempenho para avaliar níveis do nitrogênio no milho.

3 MATERIAL E MÉTODOS

3.1 Local e tratamentos experimentais

O experimento foi conduzido na Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo (FZEA-USP), Campus Fernando Costa, cidade de Pirassununga, estado de São Paulo, Brasil (21°57'34.1" S, 47°27'09.4" W, 620 m de altitude) entre 20 de outubro de 2017 e 10 de março de 2018. A espécie forrageira estudada foi a *Brachiaria brizantha* cv. Xaraés, implantada em novembro de 2012. O clima da região é o Cwa, conforme classificação de Köppen, com temperatura média de 23,7°C, sendo registrada precipitação média de 147,9 mm/mês durante o período experimental (CEPAGRI, 2018; AGRÁRIAS, 2018). Houve grande variação de precipitação pluviométrica durante o experimento, especialmente entre o segundo (82 mm) e terceiro (209 mm) período de coleta. A Figura 9 demonstra os valores em intervalos a cada dez dias e a indicação da coleta das amostras com valor total de precipitação dentre os ciclos. Não houve precipitação nos dias de adubação nitrogenada no início de cada período.

Figura 9 – Precipitação durante período experimental

Fonte: Própria autoria

O relevo da região é suave a moderadamente ondulado, e o solo classificado como Latossolo Vermelho Distrófico (Embrapa, 2006) de textura muito argilosa.

A área do experimento foi compreendida por 12 parcelas com área útil de 40 m² cada com os tratamentos distribuídos em um delineamento em blocos completos casualizados (Figura 10). Os tratamentos corresponderam a quatro níveis de adubação nitrogenada, as quais foram aplicadas após cada corte (Figura 10), sendo a fonte de nitrogênio utilizada o nitrato de amônio (NH₄NO₃ contendo 32% N). O critério de bloqueamento foi a fertilidade do solo, obtida através de análise laboratorial (Tabela 2) com amostras dos três blocos de 0 a 20 cm de profundidade. Os critérios de manejo, altura pós-corte e frequência de corte foram definidos com base nas recomendações para a *Brachiaria brizantha* cv. Xaraés, conforme Pedreira *et al.* (2007).

Figura 10 – Esquema da distribuição dos tratamentos aos blocos e especificação das doses aplicadas

Fonte: Própria autoria.

Tabela 2 – Atributos químicos do solo obtidos pela análise laboratorial

Descrição	pH	P(res)	S	K(res)	Ca	Mg	Al	H+Al	MO	V	Argila	Silte	Areia total
	(CaCl ₂)	mg dm ⁻³			mmolc dm ⁻³				g kg ⁻¹	%		g dm ⁻³	
Bloco 1	4,5	12,0	8,0	2,2	9,0	3,0	6,1	33,5	21,4	30,0	648,0	46,0	306,0
Bloco 2	5,2	13,0	6,0	2,4	21,0	6,0	3,4	26,8	24,4	52,0	633,0	46,0	321,0
Bloco 3	4,9	10,0	11,0	2,8	15,0	3,0	5,6	26,6	24,1	44,0	653,0	46,0	301,0

Principais resultados da análise química. pH - Acidez ativa (CaCl₂), P(res) - Fósforo (Resina), S - enxofre, K - potássio, Ca - cálcio, Mg - magnésio, Al - alumínio, H+Al - acidez potencial, MO - Matéria orgânica (Fotométrico), V - Saturação por bases.

Fonte: Laboratório de solos, Ciências Agrárias – FZEA/USP.

Para homogeneização das parcelas experimentais e em preparação ao início do experimento foi realizada uma roçada em 20 de outubro de 2017, adotando-se a altura de 15 cm. O primeiro ciclo de crescimento (20 de outubro a 15 de novembro de 2017) foi destinado a aplicação das adubações de correção com base na análise do solo (Tabela 2), sendo aplicados o equivalente a 45 kg ha⁻¹ de P₂O₅ (superfosfato triplo, 43%) e 30 kg ha⁻¹ de K₂O (Cloreto de potássio, 60%) por unidade experimental. Em 15 de novembro de 2017 foi realizada a primeira adubação nitrogenada conforme delineamento dos quatro tratamentos. A segunda adubação de correção foi realizada em 01 de dezembro de 2017, sendo aplicados o equivalente a 15 kg ha⁻¹ de P₂O₅ e 10 kg ha⁻¹ de K₂O.

Um novo corte foi realizado em 13 de dezembro de 2017, a partir do qual as coletas deste experimento tiveram início. Os cortes foram realizados a cada 28 dias, conforme recomendação para espécie, com auxílio de roçadora costal, a uma severidade de corte correspondente ao resíduo de 15 cm, sendo que os resíduos vegetais foram retirados da área experimental após o corte. O primeiro período de monitoramento correspondeu ao intervalo de 15 de novembro a 13 de dezembro de 2017; o segundo período de 13 de dezembro de 2017 a 10 de janeiro de 2018; o terceiro período de 10 de janeiro a 09 de fevereiro de 2018 e, o quarto período de 09 de fevereiro a 10 de março de 2018.

3.2 Coleta e procedimentos com as lâminas foliares e obtenções das imagens

As plantas foram monitoradas durante seu crescimento ao longo do período de rebrotação. Ao atingir a condição de pré-corte foram coletadas as folhas diagnósticas (primeira e segunda folhas mais jovens completamente expandidas - folhas maduras com lígula visível) formando as amostras com porções de 60 g de folhas por parcela. Por ocasião da coleta, as folhas foram momentaneamente alocadas em sacos plásticos, previamente identificados, até que as amostras fossem levadas ao laboratório. Ainda no local de coleta, de cada amostra foram retiradas 5 subamostras, contendo 5 folhas cada. Para cada subamostra foi coletado uma foto da face superior ou epiderme adaxial das lâminas foliares, utilizando-se câmera digital com foco automático e resolução de 16 megapixels interpolada, presente no smartphone Lenovo-Motorola K6 Plus, somente com incidência de luz solar em sombra

(temperatura entre 6.500K e 7.500K). As imagens digitais foram armazenadas em imagens coloridas de 24 bits com resolução de 3260 x 1840 pixels em formato JPEG. As imagens foram obtidas a altura fixa de 23 cm através de um suporte apropriado, com base nas recomendações de RICO-GARCIA *et al.* (2009), com fundo base na cor preto fosco, para reflexão da luz somente das folhas, sem interferência de luz da base (Figura 11). A base de dados para análise foi composta por 240 fotos contendo 1200 lâminas foliares.

Figura 11 – Exemplo de uma foto da subamostra para obtenção do RGB.

Fonte: Própria autoria

Após a obtenção das imagens, as subamostras de cada parcela foram agrupadas, formando uma amostra composta, a qual foi submetida a secagem em estufa de circulação forçada de ar a 65°C até peso constante e, em seguida, moídas em micromoinho de facas, com peneira de 1 mm, acondicionadas em sacos zipados e mantidas em local sem umidade até análise de laboratório. A análise realizada no laboratório de bromatologia utilizou o método de Kjeldahl (GALVANI; GAERTNER, 2006) com a amostra homogeneizada obtendo o N total.

3.3 Análise estatística dos dados

A concentração de N da folha resultante dos tratamentos de fertilização foi analisada pelo software SAS®, versão 9.3, utilizando o procedimento MIXED do

software. O período de rebrotação foi considerado uma medida repetida e a correção dos graus de liberdade foi aplicada de acordo com KENWARD e ROGER (1997). Quando apropriado, as médias foram calculadas usando o comando 'LSMEANS', as comparações foram feitas usando a opção 'PDIF = ALL' e as diferenças significativas foram declaradas quando $P_{\text{valor}} < 0,05$.

O teor crítico de N para uma determinada cultura representa sua concentração mínima de N nas folhas para atingirem pelo menos 80% da taxa máxima de crescimento da cultura, e é representado por uma função de poder negativa chamada “curva de diluição” (Ata-UI-Karim *et al.*, 2017).

Costa *et al.* (2015) identificaram que o nível crítico de N no capim-Xaraés (*Brachiaria brizantha*) variou de 18,0 a 19,4 g N kg⁻¹ de matéria seca, respectivamente, para as estações seca e chuvosa, ao testar uma faixa de taxas de fertilização de N de 50 a 400 kg N ha⁻¹. Com base nesses valores, e a fim de se ter uma faixa mais ampla para a recomendação de adubação, foi definido que as plantas apresentando um teor de N abaixo de 17 g N kg⁻¹ de matéria seca (MS) são deficientes. As plantas apresentando uma variação de 17,1 a 20,0 g N kg⁻¹ de MS foram consideradas moderadamente deficientes – a fim de se ter maior controle das doses variadas, enquanto as plantas acima de 20,1 g N kg⁻¹ de MS foram consideradas como tendo um conteúdo de N suficiente – para garantir seu pleno estado de crescimento.

Após a reorganização dos dados, de acordo com as classes definidas (deficientes, moderadamente deficientes e suficientes) foi gerado o cálculo da regressão para compreender o nível de relação e tendência dos dados, aplicando como variáveis o teor de N foliar obtido na análise laboratorial em função da taxa de adubação aplicada por corte conforme tratamentos estabelecidos, que resultou numa expressão exponencial, sendo o expoente a taxa de adubação.

Procedeu-se a identificação de quais índices melhor representariam os dados, de maneira a identificar uma melhor relação com o status de N na planta, e que comporiam os elementos de entrada da RNA para o treinamento e classificação de cada amostra. Esta identificação foi feita por meio das análises dos componentes principais (PCA) utilizando o software estatístico Minitab (versão 18). Nesta primeira PCA, após aplicar o valor de corte (0,290) para identificação dos índices significativos, somente três índices não demonstraram significância, tendo ainda 15 índices para entrada da RNA. Uma nova análise, então, foi realizada apresentando uma leve

redução nas variáveis com aplicação de novo valor de corte (0,340), sendo identificados 12 índices por meio da segunda PCA.

3.4 Etapas do processamento das imagens e implementação do software

O software foi desenvolvido em linguagem Java por ter grande portabilidade e segurança, sob o paradigma da análise orientada a objeto (OOA) em ambiente de programação Netbeans, versão 8.2, utilizando-se da arquitetura Java 2D e JDK (Java Development Kit) versão 8.

Para cada processamento realizado nas imagens foram construídos os métodos correspondentes com aplicações de técnicas de programação orientada a objeto para atingir maior flexibilização, organização e performance da codificação tendo em vista o seu aprimoramento futuro com inclusão de novas espécies de forrageiras. Cada método trabalha basicamente com o carregamento de imagens, sua manipulação em forma de matriz de dados e sua gravação, novamente em formato de imagens.

A sequência do processamento realizado nas imagens obtidas das amostras pode ser observada através da Figura 12.

Figura 12 – Esquematisação do processamento das imagens

Fonte: Adaptado de GONZALEZ, 2010.

Para cada foto registrada das lâminas foliares, obtidas com incidência somente da luz natural em sombra (devido as câmeras digitais comuns possuírem apenas sensores passivos – a mesma necessita de luz externa) foram realizados os procedimentos de efeito de suavização, ou passa-baixa do tipo gaussiana, utilizando

o método *GaussianBlur()*, do pacote *Imgproc* da biblioteca OpenCV versão 3.2, para filtrar baixas frequências eliminando ruídos e, em seguida, realizada a equalização do histograma para normalizar os níveis de intensidades das cores realçando a imagem.

Após o tratamento de suavização e equalização do histograma foi realizada a conversão da imagem em escala de cinza, pela aplicação do método de soma sobre os valores médios das três matrizes R, G e B, transformando-as em uma única matriz (Figura 13 b).

A próxima etapa foi a binarização (segmentação), procedimento que permite a extração do fundo da imagem, sendo possível separá-lo do objeto que será analisado (Figura 13 c), ou ROI (Região de Interesse). Para isto, é necessário aplicação de um valor limite, também conhecido como limiar ou *threshold*. Neste trabalho foi aplicado o *threshold* pelo método de Otsu, que consiste em identificar o valor do limiar de forma automática por cálculos, através de histograma. Desta maneira, cada imagem possui seu *threshold* mais adequado para se realizar a análise e separação entre o objeto (ROI) e o fundo (*background*) (MIRANDA, 2006). O método de Otsu utiliza a variância entre as classes (σ_B^2), dividido pela variância total (σ_T^2), ou seja, por meio da Eq.(1) e seu desmembramento na Eq.(2).

$$\eta = \sigma_B^2 / \sigma_T^2 \quad (1)$$

onde:

$$\sigma_B^2 = \omega_0 \omega_1 (\mu_1 \mu_0)^2 \quad \text{e} \quad \sigma_T^2 = \sum_{i=0}^{L-1} (i - \mu_T)^2 P_i \quad (2)$$

Com uma cópia da imagem agora binarizada, procedeu-se a remoção do fundo na imagem original, restando somente as folhas das plantas, que é a região de interesse (ROI) (Figura 13 d).

Com a matriz da imagem representando os dados somente das folhas da planta, o sistema realiza uma varredura (*scan*), registrando os valores médios de R (*red*), G (*green*) e B (*blue*). Para a obtenção dos valores R, G e B, o algoritmo desenvolvido percorreu cada pixel da imagem armazenando os valores e, após, calculou o valor médio de cada canal (cor). Na linguagem Java, a classe *BufferedImage* é responsável por manipular as imagens 2D, bem como a subclasse

Raster e o método `getSample()`. Este método usa como parâmetro os valores 0, para o vermelho, 1 para o verde e 2 para o azul, que quando aplicados ao pixel conseguem extrair seu valor. A Figura 13 demonstra as principais etapas do processamento realizada pela aplicação dos métodos do software desenvolvido numa imagem do tratamento 4, do bloco1 referente ao segundo período.

Figura 13 – Exemplo do processamento da imagem realizado pelo software.

a) Imagem obtida original, b) filtro aplicado de equalização, suavização e conversão escala cinza, c) binarização pelo threshold e d) imagem original com fundo removido usado para obter valor RGB.

Fonte: Própria autoria

O procedimento após a obtenção dos valores RGB da imagem foi a realização da normalização destas cores individualmente e a conversão para o sistema de cor HSB, conseguindo assim, outra forma de representação em quantidade de pixels para os cálculos dos índices de vegetação, conforme demonstra a Tabela 3.

Tabela 3 – Cálculos da normalização das cores R, G e B e conversão para HSB.

Variáveis	Fórmula de cálculo	Autor
G_N	$G / (R + G + B)$	Yang et al. (2015)
R_N	$R / (R + G + B)$	Yang et al. (2015)
B_N	$B / (R + G + B)$	Yang et al. (2015)
H	Se $\max R, G, B = R$ e $G \geq B$; $H = 60^\circ \cdot [(G - B) / (\max R, G, B - \min R, G, B)]$ Se $\max R, G, B = R$ e $G < B$; $H = 60^\circ \cdot [(G - B) / (\max R, G, B - \min R, G, B)] + 360$ Se $\max R, G, B = G$; $H = 60^\circ \cdot [(B - R) / (\max R, G, B - \min R, G, B)] + 120$ Se $\max R, G, B = B$; $H = 60^\circ \cdot [(R - G) / (\max R, G, B - \min R, G, B)] + 240$	Wang et al. (2013)
S	$(\max R, G, B - \min R, G, B) / \max R, G, B$	Wang et al. (2013)
Brilho	$\max R, G, B / 255$	Wang et al. (2013)

Variáveis: G_N – Verde normalizado, R_N – Vermelho normalizado, B_N – Azul normalizado, H – matiz e S – saturação.

Fonte: Própria autoria.

A tela do software permite escolher entre capturar a imagem pela webcam ou abrir de um arquivo pronto nos formatos JPEG ou PNG e, após realizar o processamento, exibindo os valores a serem utilizados como entrada na RNA (Figura 14).

Figura 14 – Tela do software para obter imagem e exemplo do resultado após processamento.

Fonte: Própria autoria

Para a implementação do software de classificação do *status* de N foi utilizado o software Matlab (versão 2015a), onde foram implementadas as redes neurais do tipo *Multilayer Perceptron* (MLP), com variações no algoritmo de treinamento, de ativação e no número de neurônios na camada intermediária para a validação da melhor configuração de rede para a classificação da classe correspondente ao N determinado em laboratório. Os tipos de redes implementados para o treinamento foram a *Feed-Forward Backpropagation*, a *Cascade-Forward Backpropagation* com uma camada escondida, variando somente a quantidade de neurônios (5, 10 e 15), a função de treinamento utilizada foi a *Levenberg Marquardt*, a função de aprendizado adaptativo foi a GDM e, as funções de ativação foram a logística (*logsig*), a hiperbólica (*tansig*) e a *Radial Basis Function* (*fewer neurons*) com a função de ativação linear (*purelin*) para a camada de saída. Para os treinamentos foram utilizados 70% dos dados, sendo o restante 30% distribuídos entre a validação e o teste, ou seja, 15% para cada um.

4 RESULTADOS E DISCUSSÃO

4.1 Definição de taxas de fertilização de acordo com a demanda da cultura

A relação entre as doses de adubação nitrogenada ($p < 0,0001$) e o resultante teor de nitrogênio nas lâminas foliares (g N kg^{-1} de matéria seca de folhas), considerando-se todo o período experimental, seguiu um padrão exponencial de variação (Figura 15). A equação que descreve a relação indica uma demanda média mínima entre 30 a 35 kg N ha^{-1} por período de rebrotação, durante a estação de crescimento, para que as plantas atinjam o nível crítico de 20 g N kg^{-1} de matéria seca de folhas. Todavia, a recomendação de adubação baseada em taxas fixas tem demonstrado menor viabilidade do que estratégias de aplicação a taxas variáveis (VILLAR, 2012), uma vez que não consideram a real demanda da cultura.

Figura 15 – Relação entre adubação realizada por corte e a concentração de N foliar

Fonte: Própria autoria.

Tanto nas recomendações de Santos *et al.* (2010) quanto Costa, Oliveira e Faquin (2006), a quantidade mínima recomendada por parcela de aplicação é de 50 kg N ha^{-1} , valor este que é maior do que a demanda registrada no presente trabalho.

Todavia, não foram encontrados, até o presente, trabalhos que avaliam a quantidade mínima adequada por parcela de aplicação e que relacionam este parâmetro com a demanda da planta.

As recomendações de adubação nitrogenada para pastagens propõem uma variação bem ampla, dependendo da espécie forrageira ou nível de intensificação do sistema, com doses totais que podem variar de 50 a 300 kg N ha⁻¹ (COSTA; OLIVEIRA; FAQUIN, 2006), e alguns casos chegam até a 500 kg N ha⁻¹ (Costa *et al.*, 2015).

A aplicação de N em quantidades elevadas e/ou maiores do que a demanda da planta pode induzir maiores perdas por volatilização e lixiviação (COSTA; OLIVEIRA; FAQUIN, 2006). Nesse sentido, em outros países, ferramentas de apoio a tomada de decisão, capazes de indicar o momento de aplicação e quantidade de fertilizantes nitrogenados baseados em um critério de suficiência (ou índice de suficiência da planta) já estão disponíveis, sendo os mais utilizados o clorofilômetro portátil e uma ferramenta de comparação visual da folha com padrões de cores previamente definidos, denominada *Leaf Color Chart* (LCC).

Singh e Khind (2015) demonstraram que a utilização do índice de suficiência, baseado nas leituras do clorofilômetro portátil, resultou em recomendação de 80 kg N ha⁻¹ para arroz (*Oryza sativa* L.) e as recomendações baseadas nos escores do LCC apontaram demanda total de 100 kg N ha⁻¹. Em ambos os métodos a dose total de adubação foi menor do que a recomendação tradicional de 120 kg N ha⁻¹, gerando inclusive maior eficiência agrônômica e menores gastos com fertilizantes.

Benefícios ambientais da aplicação da adubação nitrogenada a taxas variáveis também foram reportadas por Bathia *et al.* (2012), que demonstraram redução de 11% nas emissões de óxido nitroso (N₂O) e 16% de redução nas emissões de metano do solo pelo uso do LCC, comparativamente à aplicação convencional de ureia em taxas fixas.

O desdobramento da interação entre as doses de adubação nitrogenada aplicadas em campo e os período de avaliação ($p < 0,0001$) para o resultante teor de nitrogênio nas lâminas foliares do capim-Xaraés demonstrou que a quantidade de N, a ser provida pela adubação, para que as plantas atinjam o nível crítico, varia ao longo da estação de crescimento (Tabela 4).

No primeiro período de rebrotação, as pastagens demonstraram um requerimento mínimo de 45 kg N ha⁻¹ para que o nível crítico fosse atingido, enquanto

no segundo e terceiro períodos a aplicação de 30 kg N ha⁻¹ foi capaz de suprir a demanda de N da pastagem. Menor quantidade de N para que o nível crítico fosse atingido foi registrado no último período de crescimento, sendo requeridos apenas cerca de 15 kg N ha⁻¹.

Tabela 4 - Teor de nitrogênio (média ± erro padrão, g N kg⁻¹ de matéria seca foliar) das folhas de acordo com o nível de adubação e período de rebrotação.

Tratamentos	Período 1	Período 2	Período 3	Período 4
1	14,5 ± 0,31 Cc	16,3 ± 0,31 ABd	15,8 ± 0,31 Bd	17,1 ± 0,32 Ac
2	15,1 ± 0,31 Cc	17,4 ± 0,31 Bc	17,5 ± 0,31 Bc	20,6 ± 0,38 Ab
3	16,9 ± 0,38 Cb	22,2 ± 0,31 Ab	20,0 ± 0,31 Bb	20,5 ± 0,31 Bb
4	19,4 ± 0,31 Ca	23,2 ± 0,31 Ba	22,4 ± 0,31 Ba	25,9 ± 0,31 Aa

Tratamentos aplicados por corte: T1 – 0 kg N ha⁻¹, T2 – 15 kg N ha⁻¹, T3 – 30 kg N ha⁻¹, T4 – 45 kg N ha⁻¹. Período 1 corresponde ao ciclo de rebrotação de 15 de novembro a 13 de dezembro de 2017; o Período 2 corresponde de 13 de dezembro de 2017 a 10 de janeiro de 2018; o Período 3 corresponde de 10 de janeiro a 09 de fevereiro de 2018 e Período 4 corresponde de 09 de fevereiro a 10 de março de 2018. Letras maiúsculas comparam média entre os períodos para o mesmo tratamento, enquanto letras minúsculas comparam as doses em cada período.

Fonte: Própria autoria.

No estudo de Caminha *et al.* (2010) fica evidente que o ciclo natural de variação da densidade populacional de perfilhos nas épocas do ano e, mais especificamente, na estação de crescimento, parece estar ligada às variações sazonais – temperatura, precipitação e luz, mas também depende da dose de N empregada, identificando então o nitrogênio como um importante fator que determina a velocidade de recuperação das plantas.

De forma geral, pode-se observar na literatura que em épocas do ano onde ocorre intensa renovação da população de perfilhos (início da primavera e, no caso da *Brachiaria decumbens*, no verão) existe maior demanda de N, o que favorece a manutenção de maior proporção de perfilhos jovens na população, sendo estes mais produtivos e com maior potencial para produção de folhas (PAIVA *et al.*, 2012).

Outros exemplos da viabilidade na adoção de taxas variáveis de adubação em relação a doses fixas incluem os resultados reportados por Shukla *et al.* (2004) para arroz (*Oryza sativa* L.) e trigo, baseada no LCC, e Villar *et al.* (2015) em pastagens de *B. decumbens*.

Após dois anos de estudo, os resultados de Shukla *et al.* (2004) apontaram que mais de 60% do N aplicado era perdido, devido em parte, à falta de sincronia entre

demanda de N da planta com o suprimento via adubação. Os autores concluíram que as recomendações atuais de N em tempo fixo não são adequadas para manter os altos rendimentos ($R^2 > 0,84$), tendo assim um uso eficiente de N, com aumento da produtividade total, e um lucro do agricultor ao utilizar adubação em taxas variáveis.

Já no estudo de Villar *et al.* (2015) cujo objetivo foi verificar o índice de suficiência para definição da recomendação de nitrogênio em *Brachiaria decumbens*, consistiu em cinco diferentes tratamentos, sendo um tratamento sem a aplicação de N, um tratamento com uma taxa de N fixa de 150 kg ha⁻¹ e os outros três com diferentes leituras espectrais para a aplicação de N em taxas variáveis. A conclusão foi que na recomendação de adubação nitrogenada em taxas variáveis, baseado no índice de suficiência em N definido por meio de leituras do SPAD, melhores resultados na produção de matéria seca foram alcançados comparado à adubação com taxa fixa, pois as plantas exigiram 33% menos fertilizantes.

Liang *et al.* (2017), em estudo sobre perdas de N e emissão de gases de efeito estufa no cultivo de arroz (cv. *Tianyou 3618*), analisaram opções para a sustentabilidade econômica e ambiental através da otimização da gestão de água e adubação nitrogenada. Os autores observaram que a principal perda de N ocorreu por volatilização (50%) e que a quantidade reduzida de N, combinado com o tempo correto de sua aplicação na cultura, ajudam a melhorar o uso eficiente do nitrogênio (NUE) reduzindo suas perdas, concluindo ser eficaz a aplicação do fertilizante de forma variada.

Li *et al.* (2016) também destacaram que o requerimento em N pode variar amplamente dentro de uma determinada área plantada e, da mesma forma, a adoção de taxas uniformes de adubação pode levar a diferenças entre as quantidades aplicadas e o requerimento das culturas. Os autores testaram a utilização de sensores de refletância (comprimentos de onda na faixa do visível e NIR), para definição da necessidade de adubação em tempo real em milho (*Zea mays* L.), estimando os impactos ambientais da técnica através de modelagem (*model-based environmental Life Cycle Assessment*). O modelo identificou que a aplicação de precisão de N é capaz de reduzir as emissões de N₂O do solo em 10%, perda de NH₃ por volatilização em 23% e as perdas de NO₃⁻ por lixiviação em 16% o que, por sua vez, reduziu o consumo de energia não renovável, o potencial de aquecimento global, o potencial de acidificação do solo e o potencial de eutrofização em 7, 10, 22 e 16%, respectivamente. Além disso, os autores comprovaram que a adoção de taxas

variáveis de adubação reduziu em 11% a quantidade de fertilizantes aplicados, sem quaisquer perdas em produtividade.

Ao reagrupar as imagens e amostras segundo sua classe de suficiência, e aplicando-se a equação resultante da Figura 15, foi possível estimar a dose de adubação recomendada para atingir a classe de suficiência, por ciclo de avaliação (Tabela 5).

Tabela 5 – Teor de nitrogênio (média $\pm$ erro padrão, g N kg⁻¹ de matéria seca foliar) das folhas de acordo com as classes de N e as taxas de fertilização estimadas (kg ha⁻¹ de N por corte) para atingir o nível de suficiência.

Classes de N ¹	Ciclos de avaliação			
	Período 1	Período 2	Período 3	Período 4
Deficiente TNS ²	15.0 $\pm$ 0.25 35	15.2 $\pm$ 0.34 35	15.8 $\pm$ 0.38 30	16.9 $\pm$ 0.48 20
Moderadamente deficiente TNS	18.6 $\pm$ 0.38 10	18.2 $\pm$ 0.49 15	18.5 $\pm$ 0.27 10	18.6 $\pm$ 0.41 10
Suficiente TNS	19.8 $\pm$ 0.68 0	22.7 $\pm$ 0.27 0	22.8 $\pm$ 0.39 0	23.6 $\pm$ 0.27 0

¹ Folhas consideradas deficientes ao apresentar um teor de N abaixo de 17 g N kg⁻¹ MS; moderadamente deficiente estando no intervalo de 17,1 a 20,0 g N kg⁻¹ MS e suficiente quando mostrar um teor de N acima de 20,1 g N kg⁻¹ MS.

² Taxa de Nitrogênio estimada para suficiência (TNS) calculado com base na equação da Figura 17 inversa, sendo então $TNS = \ln(20/\text{teor N classe}) * (1/0.0081)$

Fonte: Própria autoria

Assim, os resultados descritos no presente trabalho fornecem importantes indícios para o desenvolvimento de tecnologias direcionadas ao monitoramento em tempo real do status de N em capim-Xaraés, com potencial de utilização na definição de adubação em taxas variáveis para pastagens.

4.2 Análise de componentes principais e seleção dos índices de vegetação

A análise exploratória utilizando componentes principais (PCA) demonstrou que 89% da variação no conjunto de dados foi explicada por dois componentes, compostos ainda por 15 índices dentre os 18 índices analisados. Os índices significativos identificados nesta primeira PCA foram aplicados em nova análise, onde foi confirmado que 90,2% da variância no conjunto de dados foi explicada por dois componentes principais. Entre os índices avaliados, B (blue), Rn (vermelho normalizado), H (matiz) e DGCI não demonstram contribuição significativa, e foram removidos da análise, comprovando que 12 índices são necessários na formação de dois componentes principais e devem formar o conjunto de dados de entrada da rede

neural. O primeiro componente (PRIN1) foi responsável por 62,9% da variância nos dados, e o segundo componente (PRIN2) explicou 27,3% da variância (Tabela 6). O PRIN1 foi composto por G_N , Saturação, ExG, VEG e COM, com escores positivos, bem como por B_N e CIVE, ambos com escores negativos. Já o PRIN2 foi composto pelos valores R e G das imagens, Brilho e ExR, índices estes que apresentaram escores positivos, além do VARlgreen com escore negativo.

Tabela 6 – Autovalores, autovetores e escores dos índices de vegetação (IV's) selecionados para os dois primeiros componentes principais (PRIN).

	PRIN1	PRIN2
Autovalores	7.55	3.28
Proporção	0.629	0.273
Acumulado	0.629	0.902
Corte	0.340	0.340
IV's	Autovetores	
R	0.028	0.543
G	0.151	0.452
G_N	0.362	-0.025
B_N	-0.337	-0.110
Saturação	0.350	0.065
Brilho	0.151	0.452
ExG	0.362	-0.025
ExR	-0.199	0.357
CIVE	-0.362	0.034
VEG	0.361	-0.063
COM	0.360	-0.077
VARlgreen	0.160	-0.375

Dados obtido através da análise realizada no software estatístico Minitab (versão 18)

Fonte: Própria autoria.

A PCA identificou uma correlação positiva entre G_N e saturação, mas ambas estão negativamente associadas a B_N , uma vez que o aumento da intensidade de B_N está associado à diminuição da intensidade da saturação e do G_N à medida que o teor de N na planta aumentou. A mesma situação inversamente proporcional ocorre entre o CIVE para com o VEG e COM. De acordo com Karcher e Richardson (2003), a saturação está relacionada com a pureza da cor, e imagens com menor porcentagem de saturação aparecerão mais próximas de uma cor pálida à cinza, apresentando cores mais escuras ao olho, sendo o caso de imagens representando plantas com teor suficiente de N no presente experimento.

O brilho também foi observado positivamente correlacionado com os valores do vermelho, do verde e do índice ExR nas imagens (Tabela 6), detectado no segundo componente do PCA. O brilho indica a leveza ou escurecimento de uma cor, que no conjunto de dados deste experimento destacará a intensidade do verde nas imagens. Porém, o índice VARlgreen relaciona-se negativamente no segundo componente ao reduzir o efeito do azul na tentativa de eliminar resistência atmosférica, deixando-o proporcionalmente invertido quanto aos demais índices.

A classe que representava plantas deficientes (onde $N < 17,0 \text{ g N kg}^{-1}$ folha MS), na sua maioria, demonstrou valores positivos para o primeiro e segundo componentes, localizando-se no quadrante superior direito do gráfico (Figura 18). Em contrapartida, as plantas classificadas como suficientes (onde $N > 20,1 \text{ g N kg}^{-1}$ folha MS), tiveram na maior parte valores negativos para Prin1 e Prin2 e, para algumas amostras, foram observados valores positivos no Prin2, estando posicionadas desta forma distribuídas entre os demais quadrantes (Figura 16), bem como as plantas classificadas como moderadamente suficientes.

Figura 16 – Gráfico resultante após análise dos componentes principais dos IV x N.

Fonte: Própria autoria.

Nos últimos anos a aplicação de tecnologias de sensoriamento remoto tem sido empregada em substituição aos métodos tradicionais de monitoração de N, devido a melhor identificação da assinatura espectral que as plantas fornecem com o reconhecimento da absorção ou reflexão que está diretamente relacionada as condições físicas e fisiológicas da planta (SRIDEVY *et al.*, 2018; VERGARA-DÍAZ *et al.*, 2016).

Esta assinatura espectral refere-se aos comprimentos de onda da luz que fica registrado na imagem adquirida em alta resolução e descrita pelas cores básicas vermelho, verde e azul (RGB).

Neste experimento o verde teve variação de $176,4 \pm 1,4$ e $164,4 \pm 0,78$, respectivamente para plantas deficientes e com N suficiente e o vermelho apresentou variação de $151,1 \pm 1,3$ nas plantas deficientes a $140,9 \pm 0,83$ para as plantas suficientes. Já o azul, também nestas respectivas classes, apresentou valores de $109,1 \pm 1,6$ a $118,4 \pm 1,44$ (Tabela 7).

A variação dentre as três classes definidas pode ser observada na Figura 17 com um exemplo de folhas em cada classe. Uma variação semelhante no padrão dos componentes RGB de acordo com o teor de N contido nas folhas neste experimento foram descritos para as clorofilas 'a' e 'b' e os carotenóides por Rigon *et al.* (2016) em folhas de soja (*Glycine max* L.) e por Hu *et al.* (2013) em arroz (*Oryza sativa* L.).

Tabela 7 - Valores R, G, e B das imagens (média $\pm$ erro padrão) de acordo com o status N, p-valor e coeficiente de determinação (R^2) linear.

Valores	status de N na planta			p-valor	R^2
	Deficiente	Moderadamente Suficiente	Suficiente		
R	$151,1 \pm 1,03$	$143,9 \pm 0,85$	$140,9 \pm 0,83$	< 0.0001	0.21
G	$176,4 \pm 1,04$	$167,2 \pm 0,90$	$164,4 \pm 0,78$	< 0.0001	0.26
B	$109,1 \pm 1,06$	$118,1 \pm 1,22$	$118,4 \pm 1,44$	< 0.0001	0.10

As folhas foram consideradas deficientes ao apresentar um teor de N abaixo de 17 g N/ kg MS; moderadamente deficiente estando no intervalo de 17,1 a 20,0 g N/kg MS e suficiente quando mostrar um teor de N acima de 20,1 g N/ kg MS.

Fonte: Própria autoria

Figura 17 – Exemplo de folhas após classificação do *status* e respectivos valores RGB após processamento.

Fonte: Própria autoria.

4.3 Arquitetura da Rede Neural e desempenho atingidos

Acerca da aplicabilidade de uma rede neural, esta ocorreu pelo fato de ser uma ferramenta extremamente eficiente não somente pela precisão dos tratamentos com os dados, como também para resolver sistemas de relações não lineares que não podem ser descritas por expressões matemáticas (Li et al., 2017), além do alto desempenho atingido sobretudo com a evolução tecnológica no âmbito computacional. Sua execução em trabalhos de pesquisa é cada vez maior uma vez que oferece credibilidade nos resultados apresentados de acordo com Safa *et al.* (2019) e Yi *et al.* (2010) na verificação de nitrogênio e clorofila.

Neste estudo os dados foram testados nas redes neurais Função de Base Radial (RBFNN) e as *Multilayer Perceptron* FFBP e *Multilayer Perceptron* CFBP. Para todas as arquiteturas testadas, na camada de entrada foram utilizados os doze IV's identificados na PCA mais o valor de N da taxa de fertilização referente aos quatro tratamentos aplicados. A função de ativação *Tansig* foi utilizada nas redes do tipo *MultiLayer Perceptron* por apresentar melhor desempenho que a função *Logsig* com dados de treinamento em uma camada escondida, variando a quantidade de neurônios (5, 10 e 15).

A rede FFBP com topologia 13-5-1 permitiu atingir 79% de classificação direta das imagens nas classes (deficientes, moderadamente deficientes e suficiente) com RMSE de 0,3967. Entretanto, o desempenho de classificação foi aumentado para 81% tendo um menor RMSE (0,3658) na arquitetura da rede CFBP com topologia 13-10-1 (Tabela 8). O melhor desempenho da CFBP é pelo fato destas serem auto organizáveis e realizarem conexões diretas da camada de entrada com todas camadas intermediárias e a saída, além do processo base camada a camada à frente. Sharabiani *et al.* (2018) também compararam as redes FFBP e CFBP a fim de avaliar a previsão do teor de proteínas no trigo de inverno com dados de refletância espectral, atingido desempenho equivalente com leve destaque para CFBP ao usar algoritmo de aprendizagem *LM* em confronto com algoritmo BFGS *quasi-Newton*.

Apesar de ser empregada com menos frequência, especialmente em aplicações no âmbito do agronegócio, a rede função base radial (RBFNN) foi formada pela camada de entrada, uma camada escondida com função não-linear e a camada de saída com função linear, com seleção de *n* centros usando *K-means* e aplicação do critério de distância euclidiana em relação a cada centro. Ao definir a RBFNN neste experimento com um raio (*spread*) de 1.0 e valor objetivo de performance para 0.001, esta se auto ajustou com 212 neurônios em sua camada intermediária, formando uma topologia 13-212-1, atingindo o valor de $R^2 = 0.99$ com o RMSE=0.0311 (Tabela 8),

Tabela 8 – Resumo do desempenho dos modelos de RNA definidas com formato da arquitetura e demais parâmetros internos.

Rede	Arquitetura	Função Ativação	Função Treino	Taxa de Aprendiz.	Índices de desempenho					
					R ² Train. (n=148)	R ² Valid. (n=32)	R ² Teste (n=32)	R ² Geral	MSE ⁽³⁾	RMSE ⁽⁴⁾
FFBP	13-5-1	Tansig-Tansig	LM ⁽¹⁾	0.1	0.79	0.78	0.78	0.79	0.1575	0.3967
CFBP	13-5-1	Tansig-Tansig	LM	0.1	0.76	0.81	0.65	0.75	0.1864	0.4316
FFBP	13-10-1	Tansig-Tansig	LM	0.1	0.73	0.83	0.88	0.77	0.1656	0.4069
CFBP	13-10-1	Tansig-Tansig	LM	0.1	0.86	0.76	0.63	0.81	0.1338	0.3658
FFBP	13-15-1	Tansig-Tansig	LM	0.1	0.73	0.77	0.81	0.75	0.2104	0.4587
CFBP	13-15-1	Tansig-Tansig	LM	0.1	0.77	0.77	0.82	0.78	0.1608	0.4010
RBFNN ⁽²⁾	13-212-1	Radial Base	RBF	-	-	-	-	0.99	0.0009	0.0311

Dados entrada (13) – R, G, G_N, B_N, S, Br, ExG, ExR, CIVE, VEG, COM, VARI e Taxa de fertilização.

¹ Levenberg-Marquardt (LM). ² A rede neural de função de base radial, a inicialização do valor central inicial é determinado a partir dos dados de entrada tomados aleatoriamente usando o algoritmo *k-means*, a valor de distância euclidiana foi definida para medir a distância entre o vetor de entrada *P* e o nó *j* da camada e o valor do *spread* foi 1 e a meta 0.0001, sendo a função gaussiana que transfere a distância euclidiana para dar saída para cada nó. ³ Erro quadrado médio. ⁴ Raiz do erro quadrado médio.

Fonte: Própria autoria.

alcançando assim, um desempenho superior a CFBP e indicando ser plenamente satisfatória na classificação para a *Brachiaria brizantha* cv. Xaraés.

Wang *et al.* (2009) compararam a predição de N usando redes neurais com retropropagação e regressão linear múltipla *stepwise* (MLR) de colza oleaginosa (*Brassica napus* L.) utilizando refletância espectral do dossel e obtiveram como resultado menor RMSE e maior valor-*T* para a rede neural em relação a MLR, concluindo que a razão para um desempenho mais baixo para a MLR é que as relações entre a reflectância do dossel e a concentração de N não são lineares. Zhang *et al.* (2012) também observaram que em comparação ao modelo MLR, as redes neurais têm a vantagem de se adequar as relações não lineares das assinaturas espectrais e N total nos grãos de arroz, atingindo um $R^2 = 0,92$, destacando ainda que a PCA foi importante para eliminar as informações redundantes na redução dos dados espectrais.

Maior capacidade de previsão do teor de N em arroz aplicando RNA do tipo FFBP ($R^2 = 0,94$ calibração e $R^2 = 0,89$ validação) com variáveis selecionadas por PCA, também foi registrado por Yi *et al.* (2010) em relação aos modelos MLR. Sharabiani *et al.* (2018) obteve melhor resultado com a rede CFBP ($R^2=0.9881$) com topologia 8-8-1 e algoritmo aprendizagem *Levenberg-Marquardt* (LM) frente a regressão parcial de mínimos quadrados no trigo de inverno após seleção das bandas espectrais através de uma PCA . Com o tipo de rede FFBP o valor para R^2 acima de 0.90, também foi obtido por Safa *et al.* (2019) e Liu *et al.* (2010) na predição de dados.

No estudo de Gautam e Panigrahi (2007) a rede RBFNN também comprovou ter maior desempenho ($R^2= 0,82$), quando comparado com a rede FFBP ($R^2= 0,76$) para previsão do teor de N nas folhas de milho em condições de campo através de informações espectrais nas bandas do verde e do infravermelho próximo (NIR).

Assim, respeitando o propósito deste experimento em pesquisar o uso de imagens no sistema básico de cores RGB, a fim de estimar de forma preliminar o *status* nutricional quanto o nitrogênio para a *Brachiaria brizantha* cv. Xaraés em clima tropical, e com os resultados obtidos, é notável que a metodologia pode ser empregada para o desenvolvimento de um software que possa agilizar acesso a informações para tomada de decisão, contribuindo para uso mais eficiente de insumos de acordo com a demanda da pastagem e ainda na redução de custos. Torna-se evidente não ser necessário o emprego de outras bandas espectrais especiais, além

do sistema de cor RGB e câmeras digitais profissionais dispendiosas para obter dados significativos.

5 CONCLUSÃO

O software desenvolvido apresentou ótimo processamento nas imagens atingindo precisão na segmentação das folhas, extração dos valores dos pixels, além dos cálculos dos índices de vegetação.

Estimar a situação nutricional de N utilizando sistema de cor RGB e câmeras digitais não profissionais demonstrou ser possível ao atingir o grau de correlação de 90,2%, de acordo com a PCA, após identificar para o primeiro componente os índices ExG, VEG, COM e CIVE, e para o segundo componente os índices ExR e VARlgreen.

As redes neurais apresentaram desempenho satisfatório para a classificação do status de N (deficiente, moderadamente deficiente ou suficiente) e geraram um coeficiente de determinação de 79% ao usar a tipo FFBP, 81% para a rede CFBP e, atingindo a melhor predição, a RBFNN com um coeficiente de 99%, confirmando que as assinaturas espectrais das imagens adquiridas em campo com uma câmera de smartphone pode ser determinada com precisão.

As análises com processamento das imagens da *Brachiaria brizantha* cv. Xaraés permitiram perceber que os tons da cor verde desta forrageira se aproximam mais da cor preto, o que dificultou o processamento na segmentação da imagem quando utilizando fundo preto para obtenção da imagem. Também, ficou claramente identificado que, a obtenção da imagem em sombra, influenciou a captura da banda espectral do azul, bem como gerou a amplificação do brilho nas folhas.

Novas vistas para o horizonte se abrem com a metodologia aqui apresentada, para seu aperfeiçoamento como a variação hídrica, outros sistemas de cor agregadas as técnicas de processamento de imagens e métodos de obtenção das imagens e ampliação de uso em outras espécies.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ABIEC - ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS EXPORTADORAS DE CARNES. **Perfil da Pecuária no Brasil: Relatório Anual**. 2018. Disponível em <<http://abiec.siteoficial.ws/images/upload/sumario-pt-010217.pdf>>. Acesso em 14/01/2018.

AGRÁRIAS. **Dados da estação meteorológica**. Laboratório de Ciências Agrárias – FZEA/USP. Pirassununga. 2018. Disponível em <<http://www.agrariasusp.com.br/agrariasusp01/estacao.html>>. Acesso em 19/06/2018.

ANDRADE, E. C. de. **Processamento Digital de Imagens como estimativa de teor de N foliar na cultura de milho**. 2015. Dissertação (Mestrado) – Universidade Estadual de Ponta Grossa, 2015. Disponível em <<http://tede2.uepg.br/jspui/handle/prefix/134>>. Acesso em 10/01/2018.

ATA-UL-KARIM, S. T. *et al.* Comparison of different critical nitrogen dilution curves for nitrogen diagnosis in rice. **Scientific Reports**, United Kingdom, v.7:42679, p.1-14, Março 2017. Open access. doi.org/10.1038/srep42679.

Bhatia, A. *et al.* **Greenhouse gas mitigation in rice–wheat system with leaf color chart-based urea application**. Environ. Monit. Assess, v.184, n.5, p.3095-3107, 2012.

BENIAICH, A. *et al.* **Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera**. Semina: Ciências Agrárias, v. 40, p. 49-66, 2019.

CAMINHA, F. O. *et al.* **Estabilidade da população de perfilhos de capim-marandu sob lotação contínua e adubação nitrogenada**. Pesq. Agropec. brasileira, v.45, n.2, p.213-220, 2010.

CASTRO, F. C. C. de. **Predição Não-Linear de Séries Temporais – Redes Neurais Artificiais**. 2010. Dissertação (Mestrado) – PUCRS-FENG-DEE, 2010. Disponível em <http://www.politecnica.pucrs.br/~decastro/pdf/RNA_C1.pdf>. Acesso em 25/02/2018.

CEPAGRI. **Centro de Pesquisas Meteorológicas e Climáticas Aplicadas a Agricultura**. Campinas: Unicamp, 2018. Disponível em <https://www.cpa.unicamp.br/outras-informacoes/clima_muni_442.html>. Acesso em 01/02/2018.

COSTA, K. A. P.; Oliveira, I. P.; FAQUIN, V. **Adubação nitrogenada para pastagens do gênero Brachiaria em solos do Cerrado** – Documento 192. Embrapa Arroz e Feijão. Santo Antônio de Goiás, 60p., 2006.

COSTA, J. P. R. *et al.* **Relative chlorophyll contents in the evaluation of the nutritional status of nitrogen from xaraes palisade grass and determination of critical nitrogen sufficiency index**. Acta Scientiarum. Animal Sciences, v.37, n.2, p.109-114, 2015.

DIAS-FILHO, M. B. **Diagnóstico das Pastagens no Brasil**. 2014. Documentos 402. Embrapa Amazônia Oriental. 2014. 36 p. Disponível em < <http://ainfo.cnptia.embrapa.br/digital/bitstream/item/102203/1/DOC-402.pdf> > Acesso em: 01/10/2016.

DIAS-FILHO, M. B. **Degradação de pastagens: o que é e como evitar**. Embrapa Amazônia Oriental. Brasília, DF. 2017. 19 p. Disponível em < <http://www.embrapa.br/am56publicaçõesntal/publicacoes>>. Acesso em: 06/08/2018.

EMBRAPA. **Sistema Brasileiro de Classificação de Solos**. 2 ed. Rio de Janeiro: Embrapa Solos, 2006. Disponível em < http://www.agencia.cnptia.embrapa.br/gestor/solos_tropicais/arvore/CONT000fzyjaywi02wx5ok0q43a0r9rz3uhk.html>. Acesso em: 06/02/2018.

FENG, Hui. *et al.* **Accurate Digitization of the Chlorophyll Distribution of Individual Rice Leaves Using Hyperspectral Imaging and an Integrated Image Analysis Pipeline**. *Frontiers in Plant Science*, v. 8:1238, 2017.

FIGUEIREDO, D. **Conceitos Básicos de Sensoriamento Remoto**. Companhia Nacional de Abastecimento - CONAB. Brasília - DF, 2005. Disponível em <http://www.conab.gov.br/conabweb/download/SIGABRASIL/manuais/conceitos_sm.pdf> Acesso em: 05/04/2017.

GALVANI, F.; GAERTNER, E. **Adequação da Metodologia Kjeldahl para determinação de Nitrogênio Total e Proteína Bruta**. Circular Técnicas nº 63. Embrapa. 2006. Disponível em <<http://www.cpap.embrapa.br/publicacoes/online/CT63.pdf>> Acesso em 07/04/2017.

GAUTAM, R.K.; PANIGRAHI, S. **Leaf nitrogen determination of corn plant using aerial images and artificial neural networks**. *Canadian Biosystems Engineering*, v.49, p.71-79, 2007.

GITELSON, A. A. *et al.* **Novel algorithms for remote estimation of vegetation fraction**. *Remote Sensing of Environment*, n.80, p.76-87, 2002.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**, 3ª ed., Pearson: Prentice Hall, 2008. 624 p.

GUIJARRO, M. *et al.* **Automatic segmentation of relevant textures in agricultural images**. *Computers and Electronics in Agriculture*, Athens, v. 75, n. 1, p. 75-83, 2011.

GUPTA, S. D.; IBARAKI, Y.; TRIVEDI, P. **Applications of RGB color imaging in plants**. In: *Plant Image Analysis: Fundamentals and Applications*., p.41-62. CRC Press, 2014.

HALLIK, L. *et al.* **Generality of relationships between leaf pigment contents and spectral vegetation indices in Mallorca (Spain)**. *Reg Environ Change*, v.17, p.2097–2109, 2017.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2ª ed. Canadá: Bookman, 2003. 898p.

HENRICH, V. *et al.* **Entwicklung einer Datenbank für Fernerkundungsindizes**. IDB - www.indexdatabase.de, AK Fernerkundung, Bochum, v.10, p.4-5, 2012.

HU, H. *et al.* **Estimation of leaf chlorophyll content of rice using image color analysis.** Canadian Journal of Remote Sensing, v. 39, n.2, p.185-190, 2013.

HUANG, J. *et al.* Meta-Analysis of the Detection of Plant Pigment Concentrations Using Hyperspectral Remotely Sensed Data. **Plos One**, San Francisco, v.10: e0137029. Setembro 2015. Open access. doi.org/10.1371/journal.pone.0137029

KATAOKA, T. *et al.* **Crop growth estimation system using machine vision.** Proceedings 2003 IEEE/ASME - International Conference on Advanced Intelligent Mechatronics, Kobe, v. 2, n. 1, p. 1079-1083, 2003.

KARCHER, D. E.; RICHARDSON, M. D. **Quantifying turfgrass color using digital image analysis.** Crop Sci., v.43, n.3, p.943-951, 2003.

KENWARD, M.G.; ROGER, J.H. **Small sample inference for fixed effects from restricted maximum likelihood.** Biometrics v.53, p.983-997, 1997.

KURIHARA, C.H.; MAEDA, S.; ALVAREZ V., V.H. **Interpretação de resultados de análise foliar.** Documentos 74. Embrapa Agropecuária Oeste; Colombo; Embrapa Florestas, Dourados, Mato Grosso do Sul. 2005. 42 p.

LEE, K.-J.; LEE, B.-W. **Estimation of rice growth and nitrogen nutrition status using color digital camera image analysis.** European Journal of Agronomy, v. 48, p. 57-65, 2013.

LI, Y. *et al.* **Machine learning for the prediction of L. chinensis carbon, nitrogen and phosphorus contents and understanding of mechanisms underlying grassland degradation.** Journal of Environmental Management, v.192, p.116-123, 2017.

LI, A. *et al.* **A Case Study of Environmental Benefits of Sensor-Based Nitrogen Application in Corn.** Journal of Environmental Quality, v.45, n.2, p.675-683. Janeiro 2016. Open access. doi:10.2134/jeq2015.07.0404

LIANG, K. *et al.* **Nitrogen losses and greenhouse gas emissions under different N and water management in a subtropical double-season rice cropping system.** Science of the Total Environment, v.609, p.46–57, 2017.

LIU, M. *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, p. 223–233, 2010.

MALAVOLTA, E.; VITTI, G. C.; OLIVEIRA, S. A. **Avaliação do estado nutricional das plantas: princípios e aplicações.** 2ª. ed. Piracicaba: POTAFOS, 1997. 319p.

MARSCHNER, H. **Mineral nutrition of higher plants.** 2ª. ed. New York: Academic Press, 1995. 889 p.

MAZZETTO, A.M. *et al.* **Improved pasture and herd management to reduce greenhouse gas emissions from a Brazilian beef production system.** Livestock Science, v.175, p.101–112, 2015.

MESTRE, D. A. F. **Monitorização de crescimento de plantas cultivadas in-vitro usando processamento digital de imagem.** 2017. Dissertação (Mestrado) -

Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa, 2017. Disponível em <https://run.unl.pt/bitstream/10362/23415/1/Mestre_2017.pdf>. Acesso em: 10/12/2017.

MEYER, G.E., CAMARGO-NETO, J. **Verification of color vegetation indices for automated crop imaging applications**. Computers and Electronics in Agriculture, v. 63, p.282–293, 2008

MIRANDA, J. I. **Processamento de imagens digitais: prática usando Java**. Campinas: Embrapa Informática Agropecuária, 2006. 319 p.

MIRANDA, José Iguelmar. **Processamento de imagens digitais: métodos multivariados em Java**. Campinas: Embrapa Informática Agropecuária, 2011. 400 p.

MUÑOZ-HUERTA, R.F. *et al.* **A review of methods for sensing the nitrogen status in plants**: Advantages, Disadvantages and Recent Advances. Sensors, v. 13, p.10823-10843, Agosto.2013. Open access. doi:10.3390/s130810823

PAIVA, A. J., **Structural characteristics of tiller age categories of continuously stocked marandu palisade grass swards fertilized with nitrogen**. Revista Brasileira de Zootecnia, v.41, n.1, p.24-29, 2012.

PEDREIRA, B. C.; PEDREIRA, C. G. S.; SILVA, S. C. **Acúmulo de forragem durante a rebrotação de capim-xaraés submetido a três estratégias de desfolhação**. Revista Brasileira de Zootecnia, v.38, n.4, p.618-625. 2009.

PEDREIRA, B.C.; PEDREIRA, C. G. S.; SILVA, S. C. **Estrutura do dossel e acúmulo de forragem de Brachiaria brizantha cultivar Xaraés em resposta a estratégias de pastejo**. Pesquisa Agropecuária Brasileira. v. 42, n. 2, p. 281-287, 2007.

PEDREIRA, B. C. *et al.* **Densidade e perfilhamento de perfilhos em *Brachiaria brizantha* cv. Pastagens de Marandu inoculadas com *Azospirillum brasilense***. Arq. Bras. Med. Veterinária e Zootec., v.69, n.4, p.1039-1046, 2017.

REIS, R. A.; BERNARDES, T. F.; SIQUEIRA, G. R. **Forragicultura: ciência, tecnologia e gestão dos recursos forrageiros**. 1ª ed, Jaboticabal: Maria de Lourdes Brandel – ME, 2013. 714 p.

RICO-GARCIA, E. *et al.* **Two new methods for the estimation of leaf area using digital photography**. International Journal of Agriculture & Biology, v. 11, n. 4, 2009.

RIGON, J. P. G. *et al.* **A novel method for the estimation of soybean chlorophyll content using a smartphone and image analysis**. Photosynthetica, v.54, n.4, p.559-566, 2016.

RORIE, R.L. *et al.* **The Assessment of Leaf Nitrogen in Corn from Digital Images**. Crop science, v.51, p. 2174–2180, 2011.

SAFA, M. *et al.* **Modelling nitrogen content of pasture herbage using thermal images and artificial neural networks**. Thermal Science and Engineering Progress, v.11, p.283-288, 2019.

SANTINI, J. M. K. **Fontes e doses de nitrogênio na cultura da *Brachiaria brizantha* cv. Xaraés sob condições edafoclimáticas de cerrado**. 2014. Dissertação (Mestrado) – Universidade Estadual Paulista, 2014. Disponível em < <https://repositorio.unesp.br/handle/11449/110294>>. Acesso em 10/12/2017.

SHARABIANI, V. R.; SOLTANI A. S.; NOGUCHI N. **Multivariate analyzing and artificial neural networks for prediction of protein content in winter wheat using spectral characteristics**. International Scientific Journal "Science Business Society", v. 3, n. 4, p. 153-157, 2018.

SHUKLA, A. K. *et al.* **Calibrating the leaf color chart for nitrogen management in different genotypes of rice and wheat in a systems perspective**. Agronomy Journal, v. 96, p.1606-1621, 2004.

SILVA, I. N. **Perceptron Multicamadas**: Aspectos de Treinamento e aplicação em aproximação de funções. Redes Neurais Artificiais – ICMC-USP. São Carlos, 2012.

SIMÕES, C. R. *et al.* **Imagens multiespectrais para avaliação de índice de área foliar e massa seca do capim 'Tifton 85', sob adubação nitrogenada**. Ciência Rural, Santa Maria, v.45, n.4, p.697-703, 2015.

SINGH, J.; KHIND, C. S. **Enhancing fertilizer nitrogen use efficiency in irrigated rice by using a chlorophyll meter and leaf colour chart**. The Ecoscan, v. 9(1&2), p.663-666, 2015.

SRIDEVY,, S. *et al.* **Nitrogen and potassium deficiency identification in maize by image mining, spectral and true colour response**. Indian Journal of Plant Physiology, v.23, p.91-99, 2018.

STREIT, N. M. *et. al.* **As Clorofilas**. Ciência Rural, v.35, n.3, p.748-755. Santa Maria, 2005.

TONSIG, S. L. **Redes Neurais Artificiais Multicamadas e o Algoritmo Backpropagation**. 2000. Dissertação (Mestrado) – PUC Campinas, 2000.

VERGARA-DÍAZ, O. *et al.* **A novel remote sensing approach for prediction of maize yield under different conditions of nitrogen fertilization**. Frontiers in Plant Science, v. 7:666. Maio.2016. Open Access. doi: 10.3389/fpls.2016.00666

VILLAR, F. M. M. *et al.* **Sufficiency index for defining nitrogen recommendation in brachiaria grass pasture**. Biosci. J., v.31, n.5, p.1333-1340, Uberlândia, 2015.

WANG, Y. *et al.* **Validation of artificial neural network techniques in the estimation of nitrogen concentration in rape using canopy hyperspectral reflectance data**. International Journal of Remote Sensing, v.30, n.17, p.4493-4505, 2009.

WEZEL, A. *et al.* (2014). **Agroecological practices for sustainable agriculture: A review**. Agronomy for Sustainable Development, v.34, n.1, 20p., 2014.

XIE, C. Q. *et al.* **Spectral reflectance response to nitrogen fertilization in field grown corn**. International Journal of Agricultural and Biological Engineering, v. 11, p.118-126, 2018.

XUE, J; SU, B. **Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications.** Journal of Sensors, v.2017:1353691, 2017.

YANG, W. *et al.* **Greenness identification based on HSV decision tree.** The Journal of the China Agricultural University. Information Processing in Agriculture, v.2, p.149–160, 2015.

YI, Q. *et al.* **Evaluating the performance of PC-ANN for the estimation of rice nitrogen concentration from canopy hyperspectral reflectance.** Remote Sensing Journal v.31, n.4, p.931-940, 2010.

ZHANG, H. *et al.* **Prediction of crude protein content in rice grain with canopy spectral reflectance.** Plant, Soil and Environment Journal, v. 58, p.514–520, 2012.

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 Journal, v.10, p. 824, 2018.