

**UNIVERSIDADE ESTADUAL PAULISTA
CÂMPUS DE JABOTICABAL**

**DIAGNÓSTICO NUTRICIONAL DA RÚCULA PARA
NITROGÊNIO COM PROCESSAMENTO DIGITAL DE
IMAGENS**

Paulo Henrique Soares Silva

Engenheiro Agrônomo

Me. em Agronomia (Ciência do Solo)

Jaboticabal - São Paulo - Brasil

2021

**UNIVERSIDADE ESTADUAL PAULISTA
CÂMPUS DE JABOTICABAL**

**DIAGNÓSTICO NUTRICIONAL DA RÚCULA PARA
NITROGÊNIO COM PROCESSAMENTO DIGITAL DE
IMAGENS**

Discente: Paulo Henrique Soares Silva

Orientador: Prof. Dr. Arthur Bernardes Cecílio Filho

Coorientadores: Prof^a. Dra. Silvia Helena Modenese Gorla da Silva

Prof. Dr. José Carlos Barbosa

Tese apresentada à Faculdade de Ciências Agrárias e Veterinárias - Unesp, Câmpus de Jaboticabal, como parte das exigências para obtenção do título de Doutor em Agronomia (Produção Vegetal).

Jaboticabal - São Paulo - Brasil

2021

S586d Silva, Paulo Henrique Soares
Diagnóstico nutricional da rúcula para nitrogênio com
processamento digital de imagens / Paulo Henrique Soares
Silva. -- Jaboticabal, 2021
86 p.

Tese (doutorado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: Arthur Bernardes Cecílio Filho
Coorientadora: Silvia Helena Modenese Gorla da Silva

1. Aprendizado de máquina. 2. Cultivo sem solo. 3. Redes
neurais artificiais. 4. Visão artificial. 5. Eruca sativa. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo
autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: DIAGNÓSTICO NUTRICIONAL DA RÚCULA PARA NITROGÊNIO COM
PROCESSAMENTO DIGITAL DE IMAGENS

AUTOR: PAULO HENRIQUE SOARES SILVA

ORIENTADOR: ARTHUR BERNARDES CECILIO FILHO


COORIENTADOR: JOSÉ CARLOS BARBOSA

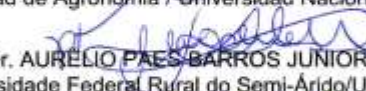
COORIENTADORA: SILVIA HELENA MODENESE GORLA DA SILVA

Aprovado como parte das exigências para obtenção do Título de Doutor em AGRONOMIA
(PRODUÇÃO VEGETAL), pela Comissão Examinadora:


Profa. Dra. SILVIA HELENA MODENESE GORLA DA SILVA (Participação Virtual)
Coordenadoria de Engenharia Agrônômica / UNESP/Registro


Dr. HUGO DO NASCIMENTO BENDINI (Participação Virtual)
Instituto Nacional de Pesquisas Espaciais-INPE / São José dos Campos/SP


Prof. Dr. JUAN WALDIR MENDOZA CORTÉZ (Participação Virtual)
Facultad de Agronomía / Universidad Nacional Agraria La Molina / Peru


Prof. Dr. AURELIO PAES BARROS JUNIOR (Participação Virtual)
Universidade Federal Rural do Semi-Árido/UFERSA / Mossoró/RN


Pesquisador Dr. ROBERTO DO FELHO FERRAZ BRANCO (Participação Virtual)
Centro de Análise e Pesquisa Tecnológica do Agronegócio de Horticultura / IAC(APTA) - Ribeirão Preto/SP

Jaboticabal, 25 de outubro de 2021

DADOS CURRICULARES DO AUTOR

PAULO HENRIQUE SOARES SILVA - O autor nasceu em Belém, estado do Pará, em 23 de outubro de 1991. Filho de José Raimundo Silva e Maria do Céu Raiol Soares. Foi alfabetizado na Escola Municipal 'Maria Fernandes', povoado do Buçuzinho, e cursou da 1ª a 4ª série na escola Vicente Leônico da Costa, vila do Trevinho. As demais séries do ensino fundamental até o 2º ano do ensino médio foram realizadas na Escola de Ensino Fundamental e Médio 'André Alves' - Anexo a Escola Estadual de Ensino Médio 'Profº. 'Galvão', ambos, na zona rural de Augusto Corrêa - PA. Finalizou o 2º grau na Escola Estadual de Ensino Fundamental e Médio 'Professor Bolívar Bordallo da Silva' (2009), Bragança - PA. Iniciou o curso de bacharelado em Agronomia, em março de 2011, na Universidade Federal Rural da Amazônia - UFRA, câmpus de Capitão Poço - PA. Durante o curso participou de projetos de extensão rural, estágio voluntário, comissão de organização de eventos técnicos-científicos, dias de campo, concursos de monitoria, publicou trabalhos científicos em revistas e eventos locais, regionais, estaduais, nacionais, etc. Foi bolsista de extensão e desenvolvimento rural em projetos cadastrados na pró-reitoria de extensão da UFRA (PROEX) - (PIEXAE/2013) e (PROEXT/2014). Obteve o título de Engenheiro Agrônomo em junho de 2016. Neste mesmo ano, iniciou o curso de mestrado (*Stricto Sensu*) em Agronomia (Ciência do Solo), na Universidade Estadual Paulista "Júlio de Mesquita Filho" - Faculdade de Ciências Agrárias e Veterinárias - Câmpus de Jaboticabal, concluindo em novembro de 2017. Durante o curso de mestrado foi voluntário no 'Programa Hortaliças Unesp', atuando como auxiliar de coordenação. Em março de 2018 ingressou no curso de doutorado (*Stricto Sensu*) em Agronomia (Produção Vegetal), na Universidade Estadual Paulista "Júlio de Mesquita Filho" - Faculdade de Ciências Agrárias e Veterinárias - Câmpus de Jaboticabal, com conclusão em 25 de outubro de 2021. Durante curso de doutorado coorientou estudantes de bacharelado em Agronomia, e, também participou como membro titular de bancas de defesa de trabalho de conclusão de curso. Foi diretor sociocultural e financeiro na Associação de Pós-graduandos da Unesp - Câmpus de Jaboticabal (2018 - 2021).

“A imaginação é mais importante que a ciência, porque a ciência é limitada, ao passo que a imaginação abrange o mundo inteiro”.

Albert Einstein

Aos meus pais Maria do Céu e José Raimundo, irmãos Ana Paula, Paulo Vitor, Isaac e Virgínia, e sobrinhos João Victor, Lorenzo, Ana Laura, Luiz Felipe e Murilo pelo apoio, incentivo e amor. Aos meus avós (Raimunda Lima e Lourenço Soares - *In memoriam*), pelo exemplo de vida e determinação.

DEDICO

AGRADECIMENTOS

Agradeço a Deus, por toda a sabedoria e proteção durante esse período que estive longe de pessoas importantes (familiares e amigos), por outro lado, Deus foi generoso e colocou pessoas que foram minha nova família, e, cuidadosamente me amparou nas dificuldades e conquistas, nele encontrei abrigo e juntos construímos o conhecimento.

Infinita gratidão aos meus pais, Maria do Céu Raiol Soares e José Raimundo Silva, que são meus maiores incentivadores, pois nada do que consegui seria possível sem a confiança e companheirismo dos dois, e, graças aos seus esforços tudo que tenho feito foi válido e prazeroso.

Aos meus irmãos Ana Paula, Paulo Vitor, Isaac e Virgínia obrigado por compreenderem minha ausência e pelo apoio constante, onde quer que eu vá levo um pedaço de cada um de vocês comigo.

Aos meus sobrinhos João Victor, Lorenzo, Ana Laura, Luis Felipe e Murilo, embora eu saiba que minha ausência não permitiu acompanhar a infância de vocês o tio ama muito e lamenta em ter abdicado desses momentos fantásticos somados aos melhores risos.

A minha noiva Ediene Soares e família pelo companheirismo, amor e respeito, e, sobretudo pela compreensão e paciência durante o tempo em que eu estive distante.

Ao meu padrinho e orientador Prof^o. Dr. Arthur Bernardes Cecílio Filho pela confiança, respeito, paciência, compreensão, e, principalmente pelo conhecimento repassado, serei eternamente grato pelo tempo e por tudo que fizestes por mim.

Aos meus coorientadores Dra. Sílvia Helena Modenese Gorla da Silva e Prof. Dr. José Carlos Barbosa, grato pelas contribuições científicas na pesquisa, apoio e compreensão necessária.

Aos meus ex-orientadores Dr. Eduardo Saldanha e Me. Henderson pelo incentivo, parceria e confiança.

Aos meus amigos Maria Gerleane, Roberta Mendes, Thiago Águas, Yane Freitas, Nayane Maia, Jonathan (Pôr-cê-lana), Jardel, Mayra Taniely, Maricélio Souza, Júlia das Mêrces, Isaías dos Santos e Solange Celestino por deixarem a vida mais leve, obrigado pelo incentivo e por acreditarem no meu potencial, é sempre muito bom poder contar com vocês.

À Carolina Seno e Camila Seno por serem meu porto seguro em Jaboticabal - SP, irmãos separados por olhos 'puxados', unidos pela tese, experimento, treino, gastronomia e mais outras coisas.

Ao meu grupo de pesquisa e também aos servidores da área experimental de Horticultura, em especial ao seu Inauro sempre disposto e proativo, muito obrigado por tudo.

À Universidade Estadual Paulista "Júlio de Mesquita Filho" - FCAV pela oportunidade, por contribuir com meu intelecto e promover meu crescimento profissional.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

SUMÁRIO

	Página
RESUMO.....	III
Palavras-chave.....	iii
ABSTRACT	IV
KEYWORDS	IV
LISTA DE TABELAS	V
LISTA DE FIGURAS	VII
CAPÍTULO 1 - CONSIDERAÇÕES GERAIS.....	1
1.1 INTRODUÇÃO	1
1.2 REVISÃO DE LITERATURA	2
1.2.1 A cultura da rúcula	2
1.2.2 Nitrogênio na planta	4
1.2.3 Avaliação do estado nutricional das plantas.....	7
1.2.4 Processamento digital de imagens no monitoramento nutricional de plantas ..	12
1.2.5 Aprendizado de máquina.....	15
1.2.6 Redes Neurais Artificiais	17
1.3 REFERÊNCIAS.....	20
CAPÍTULO 2 - RESPOSTA DA RÚCULA À CONCENTRAÇÃO DE NITROGÊNIO NA SOLUÇÃO NUTRITIVA	36
RESUMO	36
Palavras-chave.....	36
2.1 INTRODUÇÃO	37
2.2 MATERIAL E MÉTODOS	38
2.2.1 Época e caracterização do local.....	38
2.2.2 Tratamentos e delineamento experimental	39
2.2.3 Instalação e condução do experimento.....	39
2.2.4 Características avaliadas	40

2.2.5 Análise estatística	42
2.3 RESULTADOS E DISCUSSÃO	42
2.4 CONCLUSÕES	45
2.5 REFERÊNCIAS.....	46
CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGEM APLICADO AO MONITORAMENTO DE NITROGÊNIO EM RÚCULA.....	51
RESUMO.....	51
Palavras-chave.....	51
3.1 INTRODUÇÃO	52
3.2 MATERIAL E MÉTODOS	53
3.2.1 Época e caracterização do local.....	53
3.2.2 Tratamentos e delineamento experimental	54
3.2.3 Instalação e condução do experimento	54
3.2.4 Processamento digital de imagens (Experimento computacional)	55
3.2.5 Teor de nitrogênio foliar (N).....	59
3.2.6 Análise Estatística	59
3.3 RESULTADOS E DISCUSSÃO	60
3.4 CONCLUSÕES	66
3.5 REFERÊNCIAS.....	66

DIAGNÓSTICO NUTRICIONAL DA RÚCULA PARA NITROGÊNIO COM PROCESSAMENTO DIGITAL DE IMAGENS

RESUMO - A rúcula é a segunda hortaliça folhosa mais cultivada em hidroponia. Porém, há raros estudos sobre a adequação da concentração do nitrogênio (N) na solução nutritiva. Este nutriente é o segundo mais acumulado pela rúcula e afeta sobremaneira o crescimento, produtividade e qualidade desta hortaliça. Técnicas computacionais têm sido utilizadas na tentativa de avaliar o estado nutricional de plantas e prever, precocemente, a deficiência nutricional. O objetivo do trabalho foi avaliar concentrações de N (79,2; 118,8; 158,4 e 237,6 mg L⁻¹), presentes na solução nutritiva, no teor de N foliar, crescimento, produtividade, qualidade e a viabilidade do uso de imagens digitais na identificação precoce da deficiência de N em rúcula 'Folha Larga'. O experimento foi realizado em hidroponia, em delineamento experimental de blocos casualizados, com cinco repetições. No estudo da técnica computacional, aplicou-se o processamento digital de imagem (PDI) nas folhas novas, intermediárias e velhas, aos 11, 14, 17 e 20 dias após o início da Fase III de crescimento. O maior teor de nitrogênio foliar foi de 28,2 g kg⁻¹, alcançado com 186 mg L⁻¹ de N na solução nutritiva. O crescimento (número de folhas, área foliar, massa seca) e produtividade da rúcula foram máximos quando se usou a maior concentração de N na solução nutritiva. O teor de nitrato (qualidade da rúcula) foi máximo com 210,2 mg L⁻¹ de N (3527,70 mg kg⁻¹), mas na faixa aceitável para hortaliças. Assim, com base no crescimento, produtividade e qualidade da rúcula, recomenda-se o seu cultivo com 237,6 mg L⁻¹ de N na solução nutritiva. O PDI não foi capaz de identificar a deficiência de N precocemente. Os melhores resultados do PDI foram verificados nas folhas velhas, aos 20 dias na Fase III.

Palavras-chave: Aprendizado de máquina, cultivo sem solo, *Eruca sativa*, nitrato, redes neurais artificiais, visão artificial

ARUGULA NUTRITIONAL DIAGNOSIS FOR NITROGEN USING DIGITAL IMAGE PROCESSING

ABSTRACT - The arugula is the second most widely cultivated leafy vegetable in hydroponics. However, there are few studies on the adequacy of nitrogen (N) concentration in the nutrient solution. This nutrient is the second most accumulated by arugula, and greatly affects the growth, productivity, and quality of this vegetable. Computational techniques have been used in an attempt to assess the nutritional status of plants and to predict, early, nutritional deficiency. The objective of the study was to evaluate N (79.2; 118.8; 158.4 e 237.6 mg L⁻¹ of N) in nutrient solution on leaf N content, growth, yield, quality and the feasibility of using digital images for early identification of N deficiency in arugula 'Folha larga'. The experiment was conducted in hydroponics, in a randomized block design, with five repetitions. In the computational technique study, digital image processing (DIP) was applied to the young, intermediate, and old leaves at 11, 14, 17, and 20 days after the onset of Phase III growth. The highest leaf nitrogen content was 28.2 g kg⁻¹, reached with 186 mg L⁻¹ in the nutrient solution. The growth (number of leaves, leaf area, dry mass) and productivity of arugula were maximum when the highest concentration of N in the nutrient solution was used. The nitrate content (arugula quality) was maximum at 210.2 mg L⁻¹ (3527,70 mg kg⁻¹), but in the acceptable range for vegetables. Thus, based on the growth, productivity, and quality of arugula, it is recommended to grow it with 237.6 mg L⁻¹ in the nutrient solution. The PDI was not able to identify N deficiency early. The best PDI results were seen in the old leaves at 20 days in Phase III.

Keywords: Machine learning, soilless cultivation, *Eruca sativa*, nitrate, artificial neural networks, artificial vision

LISTA DE TABELAS

	Página
CAPÍTULO 2 - RESPOSTA DA RÚCULA À CONCENTRAÇÃO DE NITROGÊNIO NA SOLUÇÃO NUTRITIVA	36
Tabela 1. Concentração de nutrientes na solução nutritiva.....	40
Tabela 2. Resumo da análise de variância para altura da planta (AP), número de folhas (NF), área foliar (AF), massa seca da parte aérea (MSPA), teor foliar de nitrogênio (N), produtividade (PROD) e teor foliar de nitrato (NO ₃ ⁻) de rúcula em função da concentração de nitrogênio (N) na solução nutritiva.....	42
CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGEM APLICADO AO MONITORAMENTO DE NITROGÊNIO EM RÚCULA.....	51
Tabela 1. Temperatura, umidade relativa do ar e radiação solar durante o período de condução do experimento (período de três de julho a 16 de agosto de 2018).	53
Tabela 2. Características da rede neural para os experimentos computacionais executados.	57
Tabela 3. Teor foliar de nitrogênio (N) em função da concentração do nutriente na solução nutritiva e do tipo de folha (FV - folha velha; FI - folha intermediária; FN - folha nova) aos 20 dias na Fase III.	61
Tabela 4. Desempenho dos classificadores, nos conjuntos de testes, para classes com taxas de acerto maiores que 20%, na identificação do estado nutricional de nitrogênio em rúcula, em função da combinação de todos os fatores no Experimento I e das concentrações de nitrogênio (N) no Experimento II.	61
Tabela 5. Desempenho dos classificadores para classes com taxas de acerto maiores que 20%, na identificação de deficiência de nitrogênio em rúcula, em função da combinação de concentração de nitrogênio (N) e época de avaliação (Experimento III) e das concentrações de N (Experimento IV).	62

Tabela 6. Número de amostras por classe (n) e seu percentual em relação ao total (%) do estudo da matriz de confusão do experimento IV (concentrações de nitrogênio na solução nutritiva, na folha velha aos 20 dias na Fase III de crescimento) na capacidade do classificador em acertar o estado nutricional em nitrogênio da rúcula.....	64
Tabela 7. Teste de diagnóstico dos resultados do classificador para os grupos I e II aos 20 dias na Fase III de crescimento.	65

LISTA DE FIGURAS

	Página
CAPÍTULO 1 - CONSIDERAÇÕES GERAIS.....	1
Figura 1. Processo de segmentação em folha velha de rúcula (Deficiência de nitrogênio) .	08
Figura 2. Representação da arquitetura de uma rede neural MLP	19
 CAPÍTULO 2 - RESPOSTA DA RÚCULA À CONCENTRAÇÃO DE NITROGÊNIO NASOLUÇÃO NUTRITIVA	 36
Figura 1. Altura (A), número de folhas (B), área foliar (C) e massa seca da parte aérea (D) da rúcula em função da concentração de nitrogênio (N) na solução nutritiva.....	43
Figura 2. Teor de N foliar e produtividade (A) e nitrato foliar (B) da rúcula em função da concentração de nitrogênio (N) na solução nutritiva.....	44
 CAPÍTULO 3 - PROCESSAMENTO DIGITAL DE IMAGEM APLICADO AO MONITORAMENTO DE NITROGÊNIO EM RÚCULA	 51
Figura 1. Processo de segmentação (a) e extração dos histogramas (b).	56
Figura 2. Arquitetura da rede neural com valores de entrada (componentes principais), neurônios (processadores) e saída (classificação), nas soluções nutritivas (SN) com 79,2(1); 118,8(2); 158,4(3) e 237,6 mg L ⁻¹ de N (4), na folha velha (FV), aos 20 dias na Fase III de crescimento (E4).....	58
Figura 3. Pigmentação de folhas velhas (FV), intermediárias (FI) e novas (FN) de plantas de rúcula nas soluções nutritivas (SN) com 79,2(1); 118,8(2); 158,4(3) e 237,6 mg L ⁻¹ de N (4), aos 20 dias na Fase III de crescimento (E4).....	60

CAPÍTULO 1 - Considerações gerais

1.1 Introdução

A rúcula (*Eruca sativa* Miller), pertencente à família Brassicaceae, é de grande interesse não apenas no nível nutricional, mas também, pela indústria farmacêutica devido ao conteúdo de metabólitos secundários, principalmente glucosinolatos (Björkman et al., 2011; Kumar et al., 2011; Villatoro-Pulido et al., 2012). Além disso, a demanda nutricional de nitrogênio (N) pela cultura é alta (Monteiro et al., 2019) e associada ao curto ciclo vegetativo, a fertilização nitrogenada pode afetar a produtividade.

A demanda de N pelas culturas varia, especialmente, em função das diferenças espaciais nas condições de cultivo (LaRuffa et al., 2001), com isso, uma incompatibilidade entre o suprimento e a demanda pelo nutriente prejudica o crescimento e a produtividade (Tavakoli e Gebbers, 2019). Portanto, o fornecimento adequado pode garantir alta produtividade na colheita. Em deficiência, o N afeta o crescimento e o desenvolvimento da cultura e, por consequência, redução na produtividade (Kusano et al., 2011). Já em excesso, causa maior acúmulo de nitrato nas folhas, o que pode originar compostos carcinogênicos no organismo humano (Kyriacou e Roupheal, 2018; Barros Júnior et al., 2020).

Para interpretar o estado nutricional em N de uma planta, utiliza-se, via de regra, o teor do nutriente em um órgão representativo do metabolismo vegetal, em geral, a folha recém madura ou recém desenvolvida (Tavakoli e Gebbers, 2019). Procedimentos como envio ao laboratório, limpeza, secagem, moagem e digestão do tecido foliar e outras ações laboratoriais são necessárias previamente à quantificação do nutriente na amostra (Martins et al., 2007; Tavakoli e Gebbers, 2019). Além do custo, pode transcorrer muito tempo entre a coleta e o resultado final e, o retorno da resposta do laboratório, inviabilizando, muitas vezes, a ação de correção de deficiência ou diminuindo a sua eficiência (Argenta et al., 2002; Yuan et al., 2016).

Dada à complexidade operacional, o método da análise química do tecido foliar para predição do estado nutricional ainda encontra resistência dos produtores rurais como prática rotineira. Portanto, a avaliação do estado nutricional da cultura

como método tradicional de diagnóstico de nitrogênio no atual cenário da *Agricultura 4.0* não parece ser o mais adequado para obter o monitoramento em tempo real durante o crescimento das plantas.

Nos últimos anos, houve enorme avanço tecnológico nas áreas da informática e comunicação, o que vem sendo aplicado à agricultura digital e, atualmente, no cenário da *Agricultura 4.0*, trata-se de um novo modelo de produção em que máquinas, ferramentas e outros processos estarão conectados à internet por sistemas ciber-físicos, interagindo entre si e com a capacidade de operar e tomar decisões (Tessarini e Saltorato, 2018; Clercq et al., 2018).

Especificamente, para avaliação do estado nutricional de plantas, esforços estão sendo feitos para desenvolver e validar métodos como o processamento digital de imagem (PDI), que forneçam informações instantâneas, em qualquer etapa do desenvolvimento da cultura.

Pesquisas recentes, utilizando câmeras digitais, permitiram determinar os melhores parâmetros de cor que retratam o status de N na cultura do arroz (Yuan et al., 2012; Li et al., 2015; Sun et al., 2018). Dessa forma, evidencia-se que o PDI tem o potencial de correlacionar os teores de N foliar previamente determinados, com a cor da folha e, assim, permitirá rápida tomada de decisão quanto à fertilização nitrogenada, configurando-se para os produtores em um método simples, rápido e não destrutivo para o diagnóstico de N (Yuan et al., 2016; Baresel et al., 2017).

O objetivo deste trabalho foi avaliar o efeito de concentrações de nitrogênio no teor foliar, crescimento, produtividade, qualidade da rúcula e a viabilidade do uso de imagens digitais no diagnóstico do estado nutricional da cultura.

1.2 Revisão de Literatura

1.2.1 A cultura da rúcula

A rúcula é uma hortaliça folhosa pertencente à família Brassicaceae. Seu nome provém do italiano "ruccola", tendo como centro de origem a região do Mediterrâneo e Ásia Ocidental. Para o consumo humano, são utilizadas três

espécies: *Eruca sativa*, que possui ciclo de crescimento anual; *Diplotaxis tenuifolia* (L.) DC. e *Diplotaxis muralis* (L.) DC., ambas perenes (Pignone, 1996).

A espécie mais cultivada, no Brasil, é a *Eruca sativa*, representada, principalmente, pelas cultivares 'Cultivada e Folha Larga'. Porém, também se encontram cultivos em menor escala da espécie *Diplotaxis tenuifolia*, conhecida como rúcula selvática. Ressalta-se, ainda, que, as principais cultivares de rúcula apresentam diferenças quanto ao tipo de folha, que podem ter bordas lisas e até bastante recortadas (Morales e Janick, 2002; Sala et al., 2004).

A rúcula é uma hortaliça herbácea, porte baixo, atingindo altura de 15 a 20 cm no ponto de colheita, com folhas alongadas e de limbo profundamente recortado, coloração verde escura, pungência discreta e cheiro acentuado. Destaca-se pela sua composição nutricional rica em potássio, enxofre, ferro e vitaminas A e C (Gonzalez et al., 2006; Figueiredo et al., 2007; Freitas et al., 2017). Seu ciclo varia de 45 a 50 dias em virtude da época do ano em que é plantada, apresentando redução à medida que é exposta a dias mais ensolarados (Sediyama et al., 2007). As folhas tenras são muito apreciadas na forma de salada, principalmente, na região Centro-Sul do Brasil (Salles et al., 2017). Seu cultivo tem grande potencial no mercado nacional, cuja produção e consumo vêm aumentando em razão da facilidade de cultivo e aceitação pelos consumidores (Henz e Mettos, 2008).

Nos últimos anos, a rúcula tem apresentando acentuado crescimento, tanto no seu cultivo como no consumo, comparado com outras folhosas. No Brasil, é muito conhecida nos estados do sul e sudeste, principalmente entre os descendentes de italianos, espanhóis e portugueses, mas, atualmente, já é cultivada e consumida em todas as regiões (Grangeiro et al., 2011). Embora a rúcula seja adaptada à condição de clima mais ameno, existem na região norte e nordeste do Brasil pequenas áreas com essa folhosa.

A cultura necessita de temperaturas amenas para bom desenvolvimento e qualidade. Padulosi e Pignone (1997) indicam valores térmicos ótimos de 22 - 24°C durante o dia e 16 - 18°C durante a noite. De acordo com Sampaio et al. (2012), como a maioria das olerícolas, a rúcula está sensível a altas temperaturas; mas, apesar disso, tem sido plantada ao longo de todo o ano, em várias regiões do Brasil, apresentando algumas desvantagens como a emissão prematura do pendão floral e

folhas menores (Filgueira, 2007), mais rígidas, podendo apresentar maior pungência e sabor mais forte (Costa et al., 2011).

O conhecimento sobre a nutrição e o comportamento durante o crescimento e o desenvolvimento da cultura da rúcula são de suma importância para que se possam disponibilizar os nutrientes de forma prontamente assimilável, a fim de atingir sua máxima capacidade produtiva (Guimarães et al., 2019). De acordo com Steiner et al. (2011), a adubação nitrogenada e seu manejo são extremamente importantes, devendo-se ter informações específicas e claras sobre a melhor dose de nitrogênio a ser utilizada. Na literatura, as recomendações de adubação para a cultura da rúcula são semelhantes a várias outras hortaliças folhosas, muito provavelmente pela falta de estudo, principalmente relacionada com a demanda de nutrientes pela cultura (Purquerio et al., 2007; Grangeiro et al., 2011).

1.2.2 Nitrogênio na planta

A dinâmica do nitrogênio (N) no sistema solo-planta, com a consequente eficiência da utilização de N pela planta, é influenciada, principalmente, pelo sistema de cultivo, tipo de fertilizante, formas de manejo e condições edafoclimáticas (Figueiredo et al., 2007). Associado a essas condições, apresenta maiores dificuldades de manejo na produção agrícola, visto que é um dos nutrientes primários requerido em maior quantidade pelas plantas, principalmente nas culturas de ciclo muito curto, como as hortaliças folhosas. Logo, para obtenção de altas produtividades, aplicam-se altas doses, no entanto, nem sempre a aplicação é eficaz, pois grande parte do N é perdido.

No sistema hidropônico, o N é fornecido principalmente na forma nítrica, sendo absorvido na forma de íon nitrato (NO_3^-) ou de amônio (NH_4^+) (Taiz et al., 2017). Em concentrações muito altas, pode levar a planta a acumular nitrato (NO_3^-) e nitrito (NO_2^-), o que pode causar problemas em seres humanos, além de acarretar em lixiviação de N para águas subterrâneas causando poluição ambiental (Chang et al., 2013; Kraemer et al., 2015).

O excesso de NO_3^- e NO_2^- em hortaliças pode ocasionar efeitos nocivos à saúde do consumidor. O NO_3^- é uma forma de N absorvida pelas raízes e

armazenada nos vacúolos das células vegetais, podendo facilmente ser transformado em NO_2^- , que, em altas concentrações, causam danos nos organismos, principalmente em crianças, causando problemas como metahemoglobinemia, que é a falta de oxigênio no sangue, podendo ser letal aos seres humanos (Ahmed et al., 2017).

O efeito mais conhecido do N nas plantas é no crescimento, na intensidade da coloração verde das folhas e produção (Aguiar Júnior et al., 2010). Na cultura da rúcula, o N é o segundo nutriente mais acumulado (Grangeiro et al., 2011). De acordo com Pôrto et al. (2012), a dose adequada de N é variável de acordo com vários fatores, entre os quais se encontram a produtividade almejada, cultivar, manejo da cultura, fonte do nutriente e condições edafoclimáticas.

Os nutrientes minerais têm papel no metabolismo das plantas, de tal maneira que, nos casos em que um dos nutrientes não esteja em quantidade adequada, todo o metabolismo é prejudicado. Tais distúrbios, geralmente, podem ser identificados por sintomas no desenvolvimento das plantas, como clorose, necrose e crescimento reduzido (Malavolta, 2006).

Na planta, o N que é um nutriente presente em aminoácidos, amidas, proteínas, ácidos nucleicos, nucleotídeos, poliamidas e citocromos, trifosfato de adenosina, auxina, citocininas e clorofila (Malavolta 2006; Andrews et al., 2013; Zhang et al., 2013; Ahmed et al., 2017), é importante na respiração, multiplicação e divisão celular e, portanto, atua de modo direto no potencial produtivo da cultura (Nascimento et al., 2017).

A maior porção de N está na forma de proteínas, correspondendo a 85% do N total. Outras formas, como ácidos nucleicos (DNA e RNA), correspondem a cerca de 5%, e moléculas de baixo peso molecular de 5 a 10%, nos órgãos perenes, especialmente nas raízes (Brunetto et al., 2005). O restante compõe as formas inorgânicas como o NH_4^+ e o NO_3^- (Barker e Bryson, 2016).

Dessa forma, a disponibilidade de N é um dos fatores limitantes e mais comuns para o crescimento e desenvolvimento das plantas. De acordo com Coelho (2006), a falta de N atrasa a divisão celular, diminuindo a área foliar e o tamanho da planta. Na cultura da alface, por exemplo, uma das principais preocupações é poder verificar o status de N na planta precocemente, enquanto a deficiência de N ainda

pode ser sanada (Abdel-Rahman et al., 2010). Assim, o diagnóstico precoce desempenha um papel fundamental na nutrição da planta.

Se o suprimento do N for insuficiente ou excessivo, a capacidade fotossintética das plantas será severamente afetada, resultando em menor produtividade e baixa qualidade do produto final (Wang et al., 2018). No caso das hortaliças folhosas, o N afeta a produção de clorofila, refletindo na coloração verde das folhas, que é uma característica comercial importante observada pelo consumidor.

De acordo com Kamau et al. (2008), a aplicação continuada de N afeta a capacidade de absorção do nutriente pelas plantas, além de criar problemas ambientais. Para tanto, uma forma prática de determinar a deficiência de N na planta é por meio do diagnóstico visual. Porém, a sua precisão está limitada à experiência do técnico ou à subjetividade humana e, também, exige bastante trabalho para gerar um mapa de prescrição para ser utilizado no manejo da adubação (Romualdo et al., 2014).

Atualmente, os métodos para identificar possíveis deficiências nutricionais nas plantas consistem, principalmente, na análise do tecido foliar e diagnose visual (Prado, 2008; Aref, 2012). A identificação da deficiência ocorre quando o sintoma está em estágio muito avançado e a informação pode não ser útil para a correção da deficiência durante o ciclo de produção (Wu et al., 2007).

A diagnose visual está sujeita a erros de interpretação porque os sintomas visuais podem ocorrer simultaneamente e, também, podem ser confundidos com a existência de pragas ou doenças (Romualdo et al., 2014). No geral, os sintomas de deficiência de N começam como clorose das folhas, da ponta à base, como um padrão “V” invertido; com início na ponta das folhas velhas em direção à nervura central; deficiências severas causam necrose seguida de rasgo das folhas e afinamento dos caules (Taiz e Zeiger, 2006; Marschner, 2011).

Na cultura da rúcula, os primeiros sintomas de deficiência de N observados por Silva et al. (2021) foram o crescimento reduzido, com pecíolos e nervuras com coloração arroxeadas, e, ainda um amarelecimento intenso em toda folha velha, em alguns casos, apresentaram-se com as margens arroxeadas e necrosadas.

1.2.3 Avaliação do estado nutricional das plantas

O diagnóstico confiável do estado nutricional é uma parte essencial do manejo das culturas, pois o excesso e a deficiência de nutrientes podem causar danos graves e perda de produtividade.

A determinação precisa do estado nutricional pode não apenas impedir essas perdas, mas também, servir de base para o uso racional de suplementos nutricionais, preconizado pelos princípios da agricultura de precisão. Como resultado, o desperdício de recursos financeiros é evitado e os impactos ambientais são reduzidos (Barbedo, 2019a). Além disso, ferramentas computacionais como o processamento digital de imagem (PDI) para o monitoramento nutricional, pode ser disponibilizado como parte das ferramentas de apoio à decisão para a recomendação de adubação, o que pode ser particularmente valioso para agricultura.

A maneira mais comum de determinar o estado nutricional é visual, por meio de guias de cores das plantas que não permitem avaliações quantitativas rigorosas (Graeff et al., 2008) e são totalmente dependentes da subjetividade do ser humano. Outra forma, é através de avaliações mais precisas usando análises laboratoriais das folhas, que são demoradas e exigem a aplicação de métodos específicos para a correta interpretação dos dados (Dezordi et al., 2016; Cunha et al., 2016).

Sabe-se que, o sintoma da deficiência de N é uma clorose com início nas folhas velhas, o que possibilita o uso das propriedades espectrais do dossel da cultura para detectar essa deficiência (Baesso et al., 2007). De acordo com Wang et al. (2015), há correlação significativa entre o teor de N nas folhas das plantas e o conteúdo de clorofila no dossel verde. Portanto, a mudança no status do N da planta afeta diretamente o espectro da vegetação, com isso a mudança de cor da folha pode indicar se o N é suficiente ou não.

Nos últimos anos, com base em um modelo de cores adequado, o diagnóstico da nutrição das culturas pela tecnologia de processamento de imagem tornou-se um tópico importante sobre a visão de máquina em aplicações agrícolas (Wang et al., 2018).

A visão de máquina é uma tecnologia que tem no processamento de imagens importante fase, mas que inclui a aquisição de imagens, pré-processamento, segmentação e extração de recursos de imagem, análise e processamento de recursos de imagem (Mao et al., 2015). O processo de segmentação (Backeset al., 2009) é utilizado no sistema para separar a folha do fundo no processo de aquisição, para segmentar artefatos (ex. regiões danificadas das folhas) ou ainda áreas de interesse (padrões na imagem relacionado a falta de algum nutriente), ou seja, partes das folhas (Figura 1).

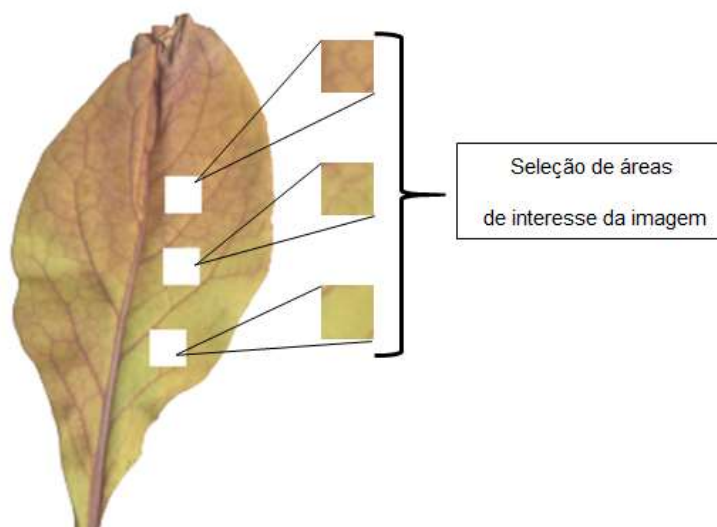


Figura 1. Processo de segmentação em folha velha de rúcula (Deficiência de nitrogênio) - Foto do autor.

Na literatura existem vários métodos de taxonomias para segmentação de imagens. No entanto, o mais tradicional é adotado por Gonzales e Woods (1993), que define três categorias de segmentação: limiar, segmentação baseada em arestas e regiões. Outros métodos são baseados em cores (Lim e Lee, 1990; Moreira, 1999), os que utilizam redes neurais artificiais e lógica nebulosa (Bezdek et al., 1999) e os baseados em algoritmos genéticos (Ankenbrandt et al., 1990).

O processo de segmentação seleciona regiões para análise de imagens. A etapa de extração do recurso consiste em métodos para avaliar as regiões das imagens para sua caracterização. Nesta etapa, a análise de textura considera a distribuição e organização dos pixels em uma determinada região da imagem. Nesse contexto, métodos que usam medidas como dimensão fractal e lacunaridade podem

medir a complexidade das imagens e gerar assinaturas digitais para caracterizar a imagem (Backes e Bruno, 2008).

Nos últimos anos, a análise espectral e o PDI têm sido amplamente utilizados no diagnóstico de N na planta. Esta tecnologia aumentou significativamente a eficiência do controle da estação de crescimento das culturas em campo de uma maneira eficaz e não destrutiva, proporcionando, assim, forte apoio da técnica para obtenção de elevadas produtividades, em ambiente favorável (Zhang et al., 2011; Miao et al., 2011). Técnicas avançadas como visão de máquina (Saberioon et al., 2013) e imagem espectral (Kutsanedzie et al., 2018) oferecem chance única de obter informações significativas, necessária para entender o manejo de N nos sistemas de produção agrícola.

A refletância espectral das culturas está bem correlacionada com o crescimento das plantas, portanto, tem o potencial de fornecer informações sobre o status de N (Raun et al., 2008). A tecnologia de imagem hiperespectral (HSI) é uma técnica recentemente desenvolvida que combina informações espectrais e espaciais simultaneamente. Estudos recentes demonstraram o potencial da tecnologia de imagem hiperespectral na pesquisa de nutrição de plantas (Vigneau et al., 2011; Yu et al., 2014). Embora a refletância seja diferente e dependendo das condições nutricionais, a curva de refletância tem uma forma de onda semelhante que dificulta a discriminação de valores críticos. Além disso, o estresse hídrico, doenças de plantas e pragas também influenciam na refletância de copas e folhas. E, contar apenas com características hiperespectrais dificulta a construção de um único modelo para determinar o estado nutricional para análises práticas (Chen et al., 2014).

A HSI combina imagem e espectroscopia em um único instrumento para permitir a aquisição de informações espectrais, espaciais e unidimensionais/bidimensionais simultaneamente de uma amostra, correspondendo à características internas e externas (Wang et al., 2018). O HSI, como uma ferramenta analítica poderosa, tem sido usado para avaliação em diversas aplicações de maneira não destrutiva.

A análise espectral é uma maneira não destrutiva de extrair grande quantidade de informações sobre uma amostra (Cozzolino et al., 2011). Com base

na assinatura espectral da planta ou do alimento, é possível quantificar pigmentos (Schlemmer et al., 2013; Dobrota et al., 2015), teor de água (Féret et al., 2011; Rallo et al., 2014), teor de nutrientes (Li et al., 2014; Nigon et al., 2015), parâmetros de qualidade (Stagakis et al., 2012; Jha et al., 2014) e presença de doenças e lesões (Cao et al., 2013; Mahlein et al., 2013), entre outras propriedades importantes de produtos agrícolas.

Uma outra alternativa, é a utilização de imagens digitais comumente usadas no diagnóstico de N, que não apenas registra informações espectrais e morfológicas, mas, também, fornece uma alternativa de baixo custo com resolução de imagem adequada. Estudos atuais demonstraram o valor das imagens digitais no diagnóstico de N, em particular para características extraídas de imagens digitais, fornecendo parâmetros efetivos no diagnóstico de N (Lee e Lee, 2013; Wang et al., 2014). Além disso, os dispositivos de imagem digital são portáteis e fáceis de operar para aquisição de dados e, posteriormente, permitem que o processamento de imagem digital forneça um contexto mais prático em termos de desenvolvimento futuro (Li et al., 2010; Wang et al., 2014).

A análise da imagem digital em cores no visível tem sido utilizada com sucesso no diagnóstico do crescimento das culturas e do estado nutricional de N (Pagola et al., 2009; Li et al., 2010). As imagens da câmera digital fornecem informações espectrais no comprimento de onda vermelho, verde e azul (RGB). As informações espectrais da imagem refletem as propriedades das superfícies de corte ou de fundo. As bandas RGB originais são transformadas em outros índices de cores, como espaço *Hue-Saturation-Intensity* (HSI), componentes de cores normalizados para aumentar a precisão na análise da vegetação (Lailiberte et al., 2007). Story et al. (2009) e Story et al. (2010) extraíram informações da área projetada do dossel e os identificou como promissores para a detecção oportuna da deficiência de cálcio na alfaca. A metodologia que eles desenvolveram foi capaz de identificar a deficiência de cálcio um dia antes da detecção visual humana.

Existem também algumas alternativas indiretas disponíveis para alguns nutrientes, como o medidor de clorofila (SPAD) (Balasubramaniam e Ananthi, 2016), mas esse também é um processo que deve seguir uma série de orientações como posição e tipo da folha, horário de coleta e etc (Jia et al., 2004) e as estimativas nem

sempre são precisas (Nauš et al., 2010). Assim, um esforço considerável foi dedicado ao desenvolvimento de novos métodos para detecção e estimativa de problemas nutricionais em plantas (Muñoz-Huerta et al., 2013; Ali et al., 2017).

A detecção e classificação automáticas de desordens nutricionais em vegetais têm recebido considerável atenção nas últimas duas décadas (Barbedo, 2013). Nas quais as imagens digitais, sempre estiveram entre as principais fontes de dados, tornaram-se cada vez mais dominantes, à medida que o uso de técnicas baseadas em aprendizado de máquina se generalizava (Singh et al., 2018; Barbedo, 2018ab). Diferentes tipos de imagens foram aplicadas às questões de fitossanidade, incluindo fluorescência da clorofila (Gorbe e Calatayud, 2012), nutrição de plantas (Romualdo et al., 2018), multiespectral (Borhan et al., 2017) e hiperespectral (Yu et al., 2014). Embora esses tipos de imagens, geralmente, transmitam mais informações do que as imagens convencionais de vermelho, verde e azul (RGB) (Bock et al., 2010), estas últimas foram empregadas com mais frequência devido ao baixo custo, portabilidade e disponibilidade de câmeras portáteis.

Entre os problemas agrícolas que podem se beneficiar dos avanços na visão e processamento de imagens por computador, a detecção e classificação de doenças de plantas é provavelmente a que mais recebeu atenção (Barbedo, 2013; Singh e Misra, 2017), mas estresses abióticos, como deficiências nutricionais, também tiveram consideráveis avanços.

Grande parte dos estudos de deficiência nutricional encontrados na literatura, emprega imagens capturadas por satélites (Meggio et al., 2010; Sims et al., 2013; Huang et al., 2015), aviões (Cilia et al., 2014; Quemada et al., 2014) ou veículos aéreos não tripulados (VANT) (Li et al., 2015; Severtson et al., 2016; Barbedo, 2019a) e ainda scanners de mesa (Romualdo et al., 2018), utilizado para obtenção do banco de imagens neste trabalho. No último caso, a digitalização é realizada em um ambiente fechado, em que as condições de digitalização permanecem constantes, reduzindo o efeito dos distúrbios externos durante o processo de aquisição da imagem, tendo a reprodução precisa da cor e do tamanho da amostra a ser garantida, porém, as etapas não são tão convenientes (Wang et al., 2018).

Comparada com uma câmera digital comum, a imagem digitalizada não inclui um plano de fundo complexo, informações multi-redundantes e ruído na imagem, o que pode reduzir o erro no processo de análise de imagem (Chen et al., 2014).

1.2.4 Processamento digital de imagens no monitoramento nutricional de plantas

O uso de tecnologias de processamento digital de imagens (PDI) tem sido empregado com o pressuposto de identificar reais necessidades de adequado manejo de adubação e identificar características capazes de correlacionar com a adubação nitrogenada, principalmente no que se diz respeito a cor da planta (Karchere Richardson, 2003; Felisberto et al., 2016).

Vários trabalhos utilizando processamento o PDI têm ganhado destaque com a utilização de câmeras fotográficas convencionais e scanner de mesa (Mercado-Luna et al., 2010; Moghaddam et al., 2010; Sulistyó et al., 2018a; Romualdo et al., 2018).

As câmeras digitais domésticas medem a intensidade da refletância nas bandas vermelha, verde e azul, de modo que elas prometem ser uma alternativa barata aos sensores multiespectrais para medir o status de N (Li et al., 2010). A refletância foliar é maior nas partes verde do que nas partes vermelhas do espectro, portanto, investiga-se a razão entre a intensidade da refletância verde e vermelha em relação às propriedades do dossel.

O reconhecimento automático de deficiências nutricionais é semelhante ao reconhecimento de doenças, pois o objetivo é identificar os sinais visuais que caracterizam o transtorno de interesse. Nos dois casos, há três problemas principais que podem ser enfrentados. A classificação, na prática é identificar corretamente a origem de um sinal ou sintoma desconhecido; detecção, que visa indicar a presença de um distúrbio direcionado, detectando seus sinais ou sintomas e por último a quantificação, que visa estimar a gravidade de um distúrbio direcionado (Barbedo, 2013). Todos os três problemas foram extensivamente explorados no caso de doenças; no caso de deficiências nutricionais, existem apenas alguns estudos

dedicados à classificação (Chen et al., 2014; Asraf et al., 2017; Culman et al., 2017; Ghosal et al., 2018).

O problema da classificação não chamou muita atenção porque existem apenas algumas deficiências que são econômica e socialmente relevantes, sendo o N de longe o mais importante. Vale ressaltar que, muitos estudos utilizam imagens para estimar o teor de clorofila (Yadav et al., 2010), que demonstrou estar diretamente relacionado ao N na planta. Assim, geralmente, o objetivo é simplesmente detectar ou quantificar aproximadamente uma dessas deficiências relevantes, sinais e sintomas que aparentemente não estão associados a esses distúrbios visados são simplesmente ignorados. Existem alguns problemas práticos associados a essa abordagem "não sistêmica", pois, os sinais de deficiência raramente aparecem isolados em ambientes não controlados (Barbedo, 2019b). Nos últimos anos, as câmeras digitais como ferramentas não destrutivas e baratas foram consideradas em pesquisas como uma alternativa aos sensores comerciais sofisticados e financeiramente inviáveis para o gerenciamento de culturas na agricultura e, assim, estimar o status de N nas lavouras.

Kawashima e Nakatani (1998) desenvolveram um algoritmo para estimar o teor de clorofila em folhas de trigo e centeio usando uma câmera de vídeo. Pagola et al. (2009) desenvolveram um índice de esverdeamento usando componentes RGB de imagens digitais coloridas para estimar o status N de folhas de cevada. Eles mostraram que a capacidade de detecção de deficiência na nutrição de N pelo índice era igual e, em alguns casos, superior ao medidor de clorofila SPAD-502. Rorie et al. (2011) realizaram um estudo para quantificar o verde das folhas de milho com uma câmera digital. Eles relataram um relacionamento próximo (normalmente $R^2 \geq 0,70$) entre o verde da folha e a concentração de N.

Li et al. (2010) estimaram o status N de duas cultivares de trigo usando câmeras digitais e dois sensores de cultivo ativos (GreenSeeker® e Yara N-sensor). Seus resultados mostraram que os valores de cobertura do dossel extraídos das imagens digitais estavam intimamente correlacionados ($R^2 > 0,86$) com o índice de vegetação da diferença normalizada (NDVI) dos sensores comerciais. Lee e Lee (2013) estimaram o crescimento do arroz e também o estado nutricional de N

usando uma câmera digital e concluíram que o dispositivo poderia ser empregado para esse fim.

Alguns estudos estão interessados em detectar o momento exato em que o estresse por nutrientes começa a afetar a planta. No entanto, as dificuldades de avaliar o estado nutricional de plantas no mesmo ciclo de cultivo são a motivação para propor abordagens adicionais em diferentes nutrientes (Luz et al., 2018). Os diferentes métodos de visão computacional são capazes de extrair informações quantitativas das imagens das folhas, como características relacionadas à cor e textura, que podem contribuir para uma análise mais precisa e cuidadosa da morfologia e fisiologia das plantas (Baesso et al., 2007; Plotze e Bruno, 2009; Casanova et al., 2009; Rossatto et al., 2011).

Para o PDI, as imagens são analisadas individualmente, com a identificação e mensuração das imagens classificadas com as respectivas percentagens de cada padrão de cor (Haim et al., 2012).

No caso específico da detecção e classificação de deficiências nutricionais, a ideia é prever diretamente o conteúdo do nutriente de interesse ou detectar indiretamente deficiências, prevendo o conteúdo de variáveis relacionadas (por exemplo, clorofila, concentração no caso de nitrogênio). Em resumo, a ideia é simplesmente encontrar o melhor ajuste entre duas variáveis, a maioria dos métodos baseados em regressão tem características semelhantes. As principais diferenças estão relacionadas ao tipo de imagem empregada e às variáveis de entrada.

A regressão linear é a técnica mais comum usada para a detecção de deficiências nutricionais, principalmente devido à sua simplicidade e ao fato de que, geralmente, há relação linear entre as variáveis-alvo e o parâmetro de entrada no modelo. O canal de cor verde é frequentemente usado como entrada, seja por si só (Saberioon et al., 2013) seja como parte das equações usadas para calcular uma variedade de índices de cores e vegetação.

No modelo de regressão de dois segmentos, desenvolvido por Story et al. (2010), para a detecção de deficiência de cálcio em alface, foram utilizadas quatro características (área do dossel projetada, entropia, energia e homogeneidade) como insumos, capazes de detectar o início do estresse um dia antes da visão humana. As plantas foram cultivadas em casa de vegetação com ambiente controlado e

submetidas a dois tratamentos com cálcio. O coeficiente de determinação entre as quatro características e o momento de aparecimento do estresse de cálcio foi de 0,97.

A abordagem adotada por Vakilian e Massah (2012) para detectar a deficiência de nitrogênio no pepino foi muito semelhante, pois as mesmas características (exceto a área projetada no topo da copa) foram usadas como insumos para um modelo de regressão de segmento duplo, e as plantas também foram submetidas a dois tratamentos. Os resultados também foram semelhantes, com o sistema baseado em visão de máquina detectando a deficiência dois dias antes dos observadores por humanos.

Também, existem algumas outras arquiteturas capazes de aproximações robustas de funções. Sulisty et. al (2018b) utilizaram um conjunto de redes neurais artificiais do tipo *Perceptron* multicamadas (MLP), para previsão de conteúdo de N, em que os recursos de entrada eram os canais de três espaços de cores (RGB, HSI e CIELab).

1.2.5 Aprendizado de máquina

Um sistema de visão artificial ou visão computacional pode ser definido como um conjunto de métodos e técnicas de sistemas de computador, capazes de interpretar uma imagem automática ou semi-automaticamente (Punam e Udupa, 2001). E são constituídos nas etapas: aquisição, segmentação de imagens, extração de características e classificação/identificação (Bruno, 2000; Gonzales e Woods, 1993).

Enquanto os modelos de regressão tentam aproximar uma função que explica uma variável de interesse, as técnicas de classificação visam rotular os dados de acordo com certos critérios. No caso de deficiências nutricionais, esse tipo de ferramenta pode ser usado de três maneiras diferentes (Barbedo, 2019a):

- **Categorização:** O objetivo é rotular uma imagem (ou região) identificando a origem de um sinal ou sintoma desconhecido. Esse problema de classificação pode ter qualquer número de classes.

- Detecção: Têm a intenção de identificar uma deficiência específica de suas manifestações visuais particulares; isso pode ser visto como um problema de classificação binária, sendo as duas classes definidas pela presença e ausência de deficiência nutricional.
- Quantificação: Têm por finalidade medir a gravidade da deficiência; Como isso geralmente é feito através da identificação e contagem de todos os pixels que contêm sinais de deficiência visual, isso também pode ser considerado um problema de classificação binária.

A detecção e quantificação são abordagens mais comuns, embora existam algumas investigações dedicadas à classificação. A variedade de técnicas de aprendizado de máquina aplicadas a esses problemas é alta, das quais podem ser citadas: redes neurais artificiais (RNA), máquinas de vetores suporte (SVM), análise discriminante (DA), k vizinhos mais próximos (kNN), lógica nebulosa (lógica fuzzy), classificadores estatísticos, algoritmos genéticos (GA) e florestas aleatórias (RF) (Barbedo, 2019a).

As redes neurais artificiais podem ser caracterizadas por uma ampla variedade de arquiteturas e topologias. Indiscutivelmente, a rede neural mais comum é a *perceptron* multicamadas (*Multilayer Perceptron* - MLP), treinada com o algoritmo *backpropagation* (Haykin, 2007). Culman et al. (2017) utilizaram uma única MLP para classificar imagens de dendezeiros em uma das quatro categorias possíveis (deficiência de nitrogênio, magnésio ou potássio); não foram fornecidos detalhes sobre as condições e a configuração sob as quais as 52 imagens RGB foram capturadas (as imagens foram adquiridas e disponibilizadas por terceiros); a precisão em média da classificação foi de 0,67. Embora, Sun et al. (2018) também aplicaram MLP ao problema do manejo da deficiência nutricional; em seu estudo, a rede neural foi utilizada como uma etapa intermediária no cálculo dos valores médios de impacto (MIV) de 14 características morfológicas e de cores diferentes. Que por sua vez, as MIV foram usadas como uma medida aproximada da eficácia dessas características na detecção de alterações na dinâmica temporal das folhas de arroz, submetidas a quatro tratamentos diferentes para cada nutriente (nitrogênio, potássio e fósforo); 4.281 imagens foram capturadas por um scanner de mesa com uma resolução de 300 pontos por polegada (dpi), levando em consideração uma

ampla gama de estágios do ciclo de vida, de folhas incompletas a senescentes; os autores apresentaram, para cada característica, o potencial de determinação da classe nutricional em termos de seu valor médio de impacto.

1.2.6 Redes neurais artificiais

De acordo com a literatura, há relatos de pesquisas empregando técnicas de redes neurais artificiais (RNA) desde 1945, por Mc - Cullock e Pitt, que desenvolveram um estudo comportamental do neurônio biológico com objetivo de criar um modelo matemático para o mesmo. Concluíram, desta pesquisa, a importância da área para implementação computacional do neurônio formal (Eberhart e Duvins, 1990).

As RNA são partes do campo científico da computação ligadas à inteligência computacional e buscam implementar modelos matemáticos que se assemelhem às estruturas biológicas (Braga et al., 2000). Assim, as RNA apresentam capacidade de adaptação dos seus parâmetros como resultado que advém da interação com o meio externo. Sua melhora é gradativa ao seu desempenho na busca da solução de um determinado problema (Ferneda, 2005).

As RNA são mecanismos computacionais que buscam realizar as mesmas funções da inteligência humana, tentando ser o mais similar possível, sendo tratada como uma ferramenta para construção de sistemas inteligentes informatizados. O método da RNA exige maior tempo de processamento e são considerados “caixas pretas”, devido à dificuldade encontrada na interpretação dos seus resultados (Ruiz et al., 2014).

A rede neural ocorre, então, pela interligação de vários “neurônios” artificiais, proporcionando, a transferência de dados entre eles e, assim, gerando a “pseudointeligência” (Tonsig, 2000; Silva, 2012). 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, conseqüentemente, os axiônios representam a saída ou o resultado da rede.

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

- O conhecimento é adquirido pela RNA através de um processo de aprendizado.
- 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.

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 e em projetos que envolvam memórias associativa (Haykin, 2007).

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, 2007; Miranda, 2011; Silva, 2012).

Existem vários tipos de redes neurais, como por exemplo, *Adaline*, *Regra Delta*, *Perceptron*, *Multilayer Perceptron* (MLP), *Recorrentes de Hopfield*, *Radial Basis Function* (RBFNN), *Auto-organizáveis de Kohonen*, *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, 2007). 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).

Na especificidade de cada camada, a camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características. Seus pesos seguem a codificação de características, pois são apresentados nos padrões de entrada e permitem que a rede crie sua própria representação (Tonsig, 2000).

As MLP (Figura 2) são aplicadas a problemas através do treinamento de forma supervisionada, onde a rede tem uma resposta que é comparada com a saída desejada, recebendo informações sobre o erro da resposta atual. Para minimização dos erros quadráticos, os algoritmos conhecidos capazes de fazer o treinamento são a regra delta generalizada e o *Backpropagation* (Haykin, 2007)




Figura 2. Representação da arquitetura de uma rede neural MLP (Soares e Silva, 2011).

Uma solução através da utilização de algoritmos de treino supervisionado pode se basear na heurística, do aprendizado por correção do erro da camada de saída, retropropagando para as camadas intermediárias da RNA. Na literatura, essa técnica é conhecida como *Backpropagation*.

A rede 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, 2007). Utiliza um algoritmo de

retropropagação do erro (*Error Backpropagation*) 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, 2007; Silva, 2012). Basicamente, os valores de entrada se propagam camada por camada à 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, 2007).

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 técnica de análise de componentes principais ou PCA (*Principal Component Analysis*) têm sido muito utilizada 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.

A PCA, é uma técnica da estatística multivariada de dados, sendo aplicada para seleção de atributos, diminuindo a dimensão dos neurônios da camada de entrada para a RNA e, assim, diminuindo o custo computacional (Silva, 2008).

1.3 REFERÊNCIAS

Abdel-Rahman EM, Ahmed FB, Van den Berg M (2010) Estimation of sugarcane leaf nitrogen concentration using in situ spectroscopy. **International Journal of Applied Earth Observation and Geoinformation** 12:52-57.

Aguiar Júnior RA, Guiscem J, Silva A, Figueiredo R, Chaves A, Paiva J, Santos F (2010) Interferência de doses de nitrogênio na produção de área foliar, biomassa fresca e seca de rúcula. **Horticultura Brasileira** 28:3970-3974.

Ahmed M, Rauf M, Mukhtar Z, Saeed NA (2017) Excessive use of nitrogenous fertilizers: an unawareness causing serious threats to environment and human health. **Environmental Science and Pollution Research** 24:26983-26987.

Ali MM, Al-Ani A, Eamus D, Tan DKY (2017) Leaf nitrogen determination using non-destructive techniques - A review. **Journal of Plant Nutrition** 40:928-953.

Andrews M, Raven JA, Lea PJ (2013) Do plants need nitrate? The mechanisms by which nitrogen form affects plants. **Annals of applied biology** 163:174-199.

Ankenbrandt CA, Buckles BP, Petry FE (1990) Scene recognition using genetic algorithms with semantic nets. **Pattern Recognition Letters** 11:285-293.

Aref F (2012) Evaluation of application methods and rates of zinc and boron on nitrogen, phosphorus and potassium contents of maize leaf. **Journal of plant nutrition**, 35:1210-1224.

Argenta G, Silva PRFD, Mielniczuk J, Bortolini CG (2002) Parâmetros de planta como indicadores do nível de nitrogênio na cultura do milho. **Pesquisa Agropecuária Brasileira**, 37: 519-527.

Asraf MH, Nur Dalila K, Amar Faiz ZA, Siti Aminah N, Nooritawati MT (2017) A fuzzy inference system for diagnosing oil palm nutritional deficiency symptoms. **ARPN Journal of Engineering and Applied Sciences** 12:3244-3250.

Backes AR, Bruno OM (2008) Fractal and multi-scale fractal dimension analysis: a comparative study of bouligand-minkowski method. **Journal Computer Science** 7:74-83.

Backes AR, Casanova D, Bruno OM (2009) Plant leaf identification based on volumetric fractal dimension. **International Journal of Pattern Recognition and Artificial Intelligence**, 23:1145-1160.

Baesso MM, Pinto FDADC, Queiroz, DMD, Vieira LBD, Alves EA (2007) Determinação do "status" nutricional de nitrogênio no feijoeiro utilizando imagens digitais coloridas. **Engenharia Agrícola** 27:520-528.

Balasubramaniam P, Ananthi VP (2016) Segmentation of nutrient deficiency in incomplete crop images using intuitionistic fuzzy C-means clustering algorithm. **Nonlinear Dynamics** 83:849-866.

Barbedo JGA (2013) Digital image processing techniques for detecting, quantifying and classifying plant diseases. **Springer Plus** 2:660.

Barbedo JGA (2018a) Factors influencing the use of deep learning for plant disease recognition. **Biosystems Engineering** 172, 84-91.

Barbedo JGA (2018b) Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. **Computers and Electronics in Agriculture** 153:46-53.

Barbedo JGA (2019a) Detection of nutrition deficiencies in plants using proximal images and machine learning: A review. **Computers and Electronics in Agriculture** 162:482-492.

Barbedo JGA (2019b) A review on the use of unmanned aerial vehicles and imaging sensors for monitoring and assessing plant stresses. **Drones** 3:40.

Baresel JP, Rischbeck P, Hu Y, Kipp S, Hu Y, Barmeier G, Mistele B (2017) Use of a digital camera as alternative method for non-destructive detection of the leaf chlorophyll content and the nitrogen nutrition status in wheat. **Computers and Electronics in Agriculture** 140:25-33.

Barker AV, Bryson GM (2016) Nitrogen. In Handbook of plant nutrition. **CRC Press**.

Barros Júnior AP, Cecílio Filho AB, Rezende BLA, Lins HA (2020) Nitrate accumulation in lettuce and rocket in response to nitrogen fertilization in intercropping. **Revista Caatinga** 33:260-265.

Bezdek JC, Keller J, Krisnapuram R, Pal N (1999) Fuzzy models and algorithms for pattern recognition and image processing. **Springer Science & Business Media** v.4.

Björkman M, Klingen I et al. (2011) Phytochemicals of Brassicaceae in plant protection and human health - Influences of climate, environment and agronomic practice. **Phytochemistry** 72:538-556.

Bock CH, Poole GH, Parker PE, Gottwald TR (2010) Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical Reviews in Plant Sciences** 29:59-107.

Borhan MS, Panigrahi S, Satter MA, Gu H (2017) Evaluation of computer imaging technique for predicting the SPAD readings in potato leaves. **Information Processing in Agriculture** 4:275-282.

Braga AP, Lurdemir TB, Carvalho ACPLF (2000) Redes Neurais Artificiais: Teoria e Aplicações. **Editora LTC**.

Brunetto G, Kaminski J, Melo GWBD, Gatiboni LC, Urquiaga S (2005) Absorção e redistribuição do nitrogênio aplicado via foliar em videiras jovens. **Revista Brasileira de Fruticultura** 27:110-114.

Bruno OM (2000) **Paralelismo em visão natural e artificial**. Universidade de São Paulo. 391 f. Tese (Doutorado em Ciências: Física aplicada (Física computacional) - USP, São Carlos.

Cao X, Luo Y, Zhou Y, Duan X, Cheng D (2013) Detection of powdery mildew in two winter wheat cultivars using canopy hyperspectral reflectance. **Crop Protection** 45:124-131.

Casanova D, Sá Junior JJM, Bruno OM (2009) Plant leaf identification using Gabor wavelets. **International Journal of Imaging Systems and Technology** 19:236-243.

Castro FCC (2010) **Predição Não-Linear de Séries Temporais - Redes Neurais Artificiais**. Dissertação (Mestrado) - PUCRS, Rio Grande do Sul.

Chang AC, Yang TY, Riskowski GL (2013) Changes in nitrate and nitrite concentrations over 24h for sweet basil and scallions. **Food Chemistry** 136:955-960.

Taiz L, Zeiger E, Møller IM, Murphy A (2017) Fisiologia e desenvolvimento vegetal. Artmed Editora.

Chen L, Lin L, Cai G, Sun Y, Huang T, Wang K, Deng J (2014) Identification of nitrogen, phosphorus, and potassium deficiencies in rice based on static scanning technology and hierarchical identification method. **PloSone** 9:1-17.

Cilia C, Panigada C, Rossini M, Meroni M, Busetto L, Amaducci S, Boschetti M, Picchi V, Colombo R (2014) Nitrogen status assessment for variable rate fertilization in maize through hyperspectral imagery. **Remote Sensing** 6:6549-6565.

Clercq M, Vats A, Biel A (2018) Agriculture 4.0: The future of farming technology. **Proceedings of the World Government Summit** 11-13.

Coelho AM (2006) Manejo da adubação nitrogenada na cultura do milho. **Embrapa Milho e Sorgo** (INFOTECA-E).

Costa CMF, Júnior SS, Arruda GR, Souza SBS (2011) Desempenho de cultivares de rúcula sob telas de sombreamento e campo aberto. **Semina: Ciências Agrárias** 32:93-101.

Cozzolino D, Cynkar WU, Shah N, Smith P (2011) Multivariate data analysis applied to spectroscopy: Potential application to juice and fruit quality. **Food Research International** 44:1888-1896.

Culman MA, Gómez JA, Talavera J, Quiroz LA, Tobón LE, Aranda JM, Garreta LE, Bayona CJ (2017) A novel application for identification of nutrient deficiencies in oil palm using the Internet of Things. **IEEE International Conference on Mobile Cloud Computing, Services, and Engineering** 169-172.

Cunha MLP, Aquino LA, Novais RF, Clemente, JM, Aquino, PM, Oliveira TF (2016) Diagnosis of the Nutritional Status of Garlic Crops. **Revista Brasileira de Ciência do Solo** 40:1-14.

Dezordi LR, Aquino LAD, Aquino RFBDA, Clemente JM, Assunção NS (2016) Diagnostic methods to assess the nutritional status of the carrot crop. **Revista Brasileira de Ciência do Solo** 40:1-16.

Dobrota C, Lazar L, Baciú C (2015) Assessment of physiological state of *Betula pendula* and *Carpinus betulus* through leaf reflectance measurements. **Flora-Morphology, Distribution, Functional Ecology of Plants** 216:26-34.

Eberhart R, Dovins R (1990). R. Neural Networks PC Tools - A Practical Guide. **Academic Press**, San Diego.

Felisberto PAC, Godoy LJG, Felisberto G (2016) Índices de cor da folha para monitoramento nutricional de nitrogênio em plantas de pimentão. **Revista Científica** 44: 207-216.

Féret JB, François C, Gitelson AA, Barry KM, Panigada C, Richardson AD, Jacquemoud S (2011) Optimizing spectral indices and chemometric analysis of leaf chemical properties using radiative transfer modeling. **Remote sensing of environment** 115:2742-2750.

Ferneda E (2005) Redes neurais e sua aplicação em sistemas de recuperação de informação. Documentação da faculdade de Filosofia Ciências e Letras de Ribeirão Preto. USP, Ribeirão Preto.

Figueiredo BT, Figueiredo RT, Guissem JM, Chaves AMS, Araujo JRG, Pereira CFM, Farias AS (2007) Produção de rúcula (*Eruca sativa* L.) cultivada em composto de esterco de ave e bovino puros e incorporados ao solo. **Cadernos de Agroecologia** 2:851-854.

Figueiredo CCD, Resck DVS, Gomes AC, Urquiaga S (2005) Sistemas de manejo na absorção de nitrogênio pelo milho em um Latossolo Vermelho no Cerrado. **Pesquisa Agropecuária Brasileira** 40:279-287.

Filgueira FAR (2007) **Novo manual de olericultura: agrotecnologia moderna na produção e comercialização de hortaliças**. Viçosa: UFV p. 293.

Freitas EMD, Giovanelli LB, Delazari FT, Santos MLD, Pereira SB, Silva DJ (2017) Arugulaproduction as a functionofirrigationdepthsandpotassiumfertilization. **Revista Brasileira de Engenharia Agrícola e Ambiental** 21:197-202.

Ghosal S, Blystone D, Singh AK, Ganapathysubramanian B, Singh A, Sarkar S (2018) An explainable deep machine vision framework for plant stress phenotyping. **Proceedings of the National Academy of Sciences** 115:4613-4618.

Gonzalez AF, Ayub RA, Reghin MY (2006) Conservação de rúcula minimamente processada produzida em campo aberto e cultivo protegido com agrotêtil. **Horticultura Brasileira** 24:360-362.

Gonzalez RC, Woods RE (1993) Digital image processing. Addison-Wesley, Reading, MA.

Gorbe E, Calatayud A (2012) Applications of chlorophyll fluorescence imaging technique in horticultural research: a review. **Scientia Horticulturae** 138:24-35.

Graeff S, Pfenning J, Claupein W, Liebig H P (2008) Evaluation of image analysis to determine the N-fertilizer demand of broccoli plants (*Brassica oleracea* var. botrytis var. italica). **Advances in optical technologies** 2008:1-8.

Grangeiro LC, Freitas FC, Negreiros, M. Z., Marrocos STP, Lucena RR, Oliveira RA (2011) Crescimento e acúmulo de nutrientes em coentro e rúcula. **Revista Brasileira de Ciências Agrárias** 6:11-16.

Guimarães NR, Souza RF, Silva AG, Bittar DY (2019) Adubação Nitrogenada Na Produção De Rúcula. **Ipê Agronomic Journal** 3: 44-55.

Haim PG, Zoffoli BC, Zonta E, Araújo AP (2012). Diagnose nutricional de nitrogênio em folhas de feijoeiro pela análise digital de imagens. **Pesquisa Agropecuária Brasileira** 47:1546-1549.

Henz GP, Mettos LM (2008) **Manuseio pós-colheita de rúcula**. Brasília, DF: Embrapa Hortaliças, 7 p. (Comunicado Técnico, 64).

Huang S, Miao Y et al. (2015) Satellite remote sensing-based inseason diagnosis of rice Nitrogen status in Northeast China. **Remote Sensing** 7:10646-10667.

Jha SN, Narsaiah K, Jaiswal P, Bhardwaj R, Gupta M, Kumar R, Sharma R (2014) Nondestructive prediction of maturity of mango using near infrared spectroscopy. **Journal of Food Engineering** 124:152-157.

Jia L, Chen X, Zhang F, Buerkert A, Römheld V (2004) Use of Digital Camera to Assess Nitrogen Status of Winter Wheat in the Northern China Plain. **Journal of Plant Nutrition** 27:441-450.

Kamau DM, Spiertz JH, Oenema O, Owuor PO (2008) Productivity and nitrogen use of tea plantations in relation to age and genotype. **Field crops research** 108:60-70.

Karcher DE, Richardson MD (2003) Quantifying turfgrass color using digital image analysis. **Crop Science** 43:943-951.

Kawashima S, Nakatani M (1998) An algorithm for estimating chlorophyll content in leaves using a video camera. **Annals of Botany** 81:49-54.

- Kraemer AR, Mendes F, Lajus CR, Sordi A, Cericato A, Luz GL (2015) Teores de nitrato em olerícolas submetidas a diferentes doses de ureia. **Unoesc & Ciência-ACET** 6:239-244.
- Kumar S, Jawaid T, Dubey SD (2011) Therapeutic plants of Ayurveda; a review on anticancer. **Pharmacognosy Journal** 3:1-11.
- Kusano M, Fukushima A, Redestig H, Saito K (2011) Metabolomic approaches toward understanding nitrogen metabolism in plants. **Journal of Experimental Botany** 62:1439-1453.
- Kutsanedzie FY, Chen Q, Hassan MM, Yang M, Sun H, Rahman MH (2018) Near infrared system coupled chemometric algorithms for enumeration of total fungi count in cocoa beans neat solution. **Food chemistry** 240:231-238.
- Kyriacou MC, Rouphael Y (2018) Towards a new definition of quality for fresh fruits and vegetables. **Scientia Horticulturae** 234:463-469.
- Lailiberte AS, Rango A, Herrick JE, Fredrickson EL, Burkett L (2007) An object-based image analysis approach for determining fractional cover of senescent and green vegetation with digital plot photography. **Journal of Arid Environments** 69:1-14.
- LaRuffa JM, Raun W.R, Phillips SB, Solie JB, Stone ML, Johnson GV (2001) Optimum field element size for maximum yields in winter wheat, using variable nitrogen rates. **Journal of Plant Nutrition** 24:313-325.
- Lee KJ, Lee BW (2013). Estimation of rice growth and nitrogen nutrition status using color digital camera image analysis. **European Journal of Agronomy** 48:57-65.
- Li F, Miao Y et al. (2014) Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. **Field Crops Research** 157:111-123.
- Li LT, Zhang M, Ren T, Li XK, Cong RH, Wu LS, Lu J (2015) Diagnosis of N nutrition of rice using digital image processing technique. **Journal of Plant Nutrition and Fertilizer** 21:259-268.
- Li Y, Chen D, Walker CN, Angus JF (2010) Estimating the nitrogen status of crops using a digital camera. **Field Crops Research** 118:221-227.

Lim YW, Lee SU (1990) On the color image segmentation algorithm based on the thresholding and the fuzzy c-means techniques. **Pattern recognition** 23:935-52.

Luz PHDC, Marin MA, Devecchio FFS, Romualdo LM, Zuñiga AMG, Oliveira MWS, Herling VR, Bruno OM (2018) Boron Deficiency Precisely Identified on Growth Stage V4 of Maize Crop Using Texture Image Analysis. **Communications in Soil Science and Plant Analysis** 49:159-169.

Mahlein AK, Rumpf T, Welke P, Dehne HW, Plümer L, Steiner U, Oerke EC (2013) Development of spectral indices for detecting and identifying plant diseases. **Remote Sensing of Environment** 128:21-30.

Malavolta E (2006). Manual de nutrição mineral de plantas. **Agronômica Ceres** 1: 638.

Marschner H (2011) Mineral Nutrition of Higher Plants. **Academic Press**.

Martins APL, Reissmann CB (2007) Material vegetal e as rotinas laboratoriais nos procedimentos químico-analíticos. **Scientia Agraria** 8:1-17.

Meggio F, Zarco-Tejada PJ, Núñez LC, Sepulcre-Cantó G, González MR, Martín P (2010) Grape quality assessment in vineyards affected by iron deficiency chlorosis using narrow-band physiological remote sensing indices. **Remote Sensing of Environment** 114:1968-1986.

Mercado-Luna A, Rico-García E, Lara-Herrera A, Soto-Zarazúa G, Ocampo-Velázquez R, Guevara-González R, Herrera-Ruiz G, Torres-Pacheco I (2010). Nitrogen determination on tomato (*Lycopersicon esculentum* Mill.) seedlings by color image analysis (RGB). **African Journal of Biotechnology** 9:33.

Miao Y, Stewart BA, Zhang F (2011) Long-term experiments for sustainable nutrient management in China. A review. **Agronomy for Sustainable Development** 31:397-414.

Miranda JI (2011) Processamento de imagens digitais: Métodos multivariados em Java. **Embrapa Informática Agropecuária**.

Moghaddam PA, Derafshi MH, Shayesteh M (2010). A new method in assessing sugar beet leaf nitrogen status through color image processing and artificial neural network. **Journal of Food, Agriculture and Environment** 8:485-489.

Monteiro LC, Aita C, Schirmann J, Pujol SB, Mezzalira AP, Paust KDS, Freiberg CM, Giacomini DA, Giacomini SJ (2019) Nitrogen supply to arugula from pig slurry composts in contrasting soils. **Horticultura Brasileira** 37:402-408.

Morales M, Janick J (2002) Arugula: A promising specialty leaf vegetable. Trends in new crops and new uses. **ASHS Press** 418-423.

Moreira J (1999) **Uma proposta de estruturação e integração de processamento de cores em sistemas artificiais de visão**. 285 f. Tese (Doutorado em Ciências: Física aplicada (Física computacional) - USP, São Carlos.

Muñoz-Huerta RF, Guevara-Gonzalez RG, Contreras-Medina LM, Torres-Pacheco I, Prado-Olivarez J, Ocampo-Velazquez RV (2013) A review of methods for sensing the nitrogen status in plants: advantages, disadvantages and recent advances. **Sensors** 13:10823-10843.

Nascimento MV, Junior RLS, Fernandes LR, Xavier RC, Benett KSS, Seleguini A, Benett CGS (2017) Manejo da adubação nitrogenada nas culturas de alface, repolho e salsa. **Journal of Neotropical Agriculture** 4:65-71.

Nauš J, Prokopová J, Řebíček J, Špundová M (2010) SPAD chlorophyll meter Reading can be pronouncedly affected by chloroplast movement. **Photosynthesis Research** 105:265-271.

Nigon TJ, Mulla DJ, Rosen CJ, Cohen Y, Alchanatis V, Knight J, Rud R (2015) Hyperspectral aerial imagery for detecting nitrogen stress in two potato cultivars. **Computers and Electronics in Agriculture** 112:36-46.

Padulosi S, Pignone D (1997) Rocket: A Mediterranean crop for the world. **International Plant Genetic Resources Institute** 101.

Pagola M, Oritiz R, Irigoyen I, Bustinece H, Barrenechea E, Aparicio-Tejo P, Lamsfus C, Lasa B (2009) New method to assess barley nitrogen nutrition status based on image colour analysis: comparison with SPAD-502. **Computers and Electronics in Agriculture** 65:213-218.

Pignone D (1996) Present status of rocket genetic resources and conservation activities. In: **Rocket A Mediterranean Crop for the World Report of the Workshop** 13-14.

Plotze OR, Bruno OM (2009) Automatic leaf structure biometry: computer vision techniques and their applications in plant taxonomy. **International Journal of Pattern Recognition and Artificial Intelligence** 23:247-262.

Pôrto ML, Puiatti M, Fontes PCR, Cecon PR, Alves JC, Arruda JA (2012) Produtividade e acúmulo de nitrato nos frutos de abobrinha em função da adubação nitrogenada. **Bragantia** 71:190-195.

PRADO RDM (2008). Nutrição de plantas: diagnose foliar em grandes culturas. **UNESP, GENPLANT** 3:391.

Punam KS, Udupa JK (2001) Optimum image thresholding via class uncertainty and region homogeneity. **IEEE Transactions on Pattern Analysis and Machine Intelligence** 23:689-706.

Purquerio LFV, Demant LAR, Goto R, Boas V, Lyra R (2007) Efeito da adubação nitrogenada de cobertura e do espaçamento sobre a produção de rúcula. **Horticultura Brasileira** 25:464-470.

Quemada M, Gabriel JL, Zarco-Tejada P (2014) Airborne hyperspectral images and ground-level optical sensors as assessment tools for maize nitrogen fertilization. **Remote Sensing** 6:2940-2962.

Rallo G, Minacapilli M, Ciraolo G, Provenzano G (2014) Detecting crop water status in mature olive groves using vegetation spectral measurements. **Biosystems engineering** 128:52-68.

Raun WR, Solie JB, Taylor RK, Arnall DB, Mack CJ, Edmonds DE (2008) Ramp calibration strip technology for determining midseason nitrogen rates in corn and wheat. **Agronomy Journal** 100:1088-1093.

Romualdo LM, Luz PHC, Baesso MM, Devechio FFS, Bet JA (2018) Spectral indexes for identification of nitrogen deficiency in maize. **Revista Ciência Agronômica** 49:183-191.

Romualdo LM, Luz PHC, Devechio FFS, Marin MA, Zúñiga AG, Bruno OM, Herling VR (2014) Use of artificial vision techniques for diagnostic of nitrogen nutritional status in maize plants. **Computers and electronics in agriculture** 104:63-70.

Rorie RL, Purcell LC, Mozaffari M, Karcher D E, King CA, Marsh M. C, Longer DE (2011). Association of “greenness” in corn with yield and leaf nitrogen concentration. **Agronomy Journal** 103:529-535.

Rossatto DR, Casanova D, Kolb RM, Bruno OM (2011) Fractal analysis of leaf-texture properties as a tool for taxonomic and identification purposes: a case study with species from Neotropical Melastomataceae (*Miconieae* tribe). **Plant Systematics and Evolution** 291:103-116.

Ruiz LFC, Caten AT, Dalmolin RSD (2014) Árvore de decisão e a densidade mínima de amostras no mapeamento da cobertura da terra. **Ciência Rural** 44:1001-1007.

Saberioon MM, Amin MSM, Aimrun W, Gholizadeh A, Anuar AAR (2013). Assessment of colour indices derived from conventional digital camera for determining nitrogen status in rice plants. **Journal of Food, Agriculture & Environment** 11:655-662.

Sala FC, Rossi F, Fabri EG, Rondino E, Minami K, Costa CD (2004) Caracterização varietal de rúcula. In CONGRESSO BRASILEIRO DE OLERICULTURA. **Resumos...** 22:1-6.

Salles JS, Steiner F, Abaker JEP, Ferreira TS, Martins GLM (2017) Resposta da rúcula à adubação orgânica com diferentes compostos orgânicos. **Journal of Neotropical Agriculture** 4:35-40.

Sampaio IMG, Silva FWA, Souza GT, Jesus PMM, Miranda TS, Gusmão SAL (2012) Biofertilizante na fitossanidade e produção de rúcula. IN: SEMINÁRIO ANUAL DE INICIAÇÃO CIENTÍFICA DA UFRA, **Anais...** Belém: UFRA, 10.

Schlemmer M, Gitelson A, Schepers J, Ferguson R, Peng Y (2013) Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. **International Journal of Applied Earth Observation** 25:47-54.

Sediyama MAN, Salgado LT, Pinto CLO (2007) Rúcula (*Eruca sativa*). In: Paula Júnior TJ, Venzon M (Coords.). **101 culturas: manual de tecnologias agrícolas**. Belo Horizonte: EPAMIG, p. 683-686.

Severtson D, Callow N, Flower K, Neuhaus A, Olejnik M, Nansen C (2016) Unmanned aerial vehicle canopy reflectance data detects potassium deficiency and green peach aphid susceptibility in canola. **Precision Agriculture** 17:659-677.

Silva IN (2012) Perceptron Multicamadas: Aspectos de Treinamento e aplicação em aproximação de funções. USP, São Carlos.

Silva PHS, Reis IS, Nascimento CS, Nascimento CS, Cecílio Filho AB (2021) Characterization of growth and visual symptoms of nitrogen, potassium and magnesium deficiencies in arugula. **Emirates Journal of Food and Agriculture** 33:575-582.

Sims NC, Culvenor D, Newnham G, Coops CC, Hopmans P (2013) Towards the operational use of satellite hyperspectral image data for mapping nutrient status and fertilizer requirements in Australian plantation forests. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing** 6:320-328.

Singh AK, Ganapathysubramanian B, Sarkar S, Singh A (2018) Deep learning for plant stress phenotyping: trends and future perspectives. **Trends in plant science** 23:883-898.

Singh V, Misra AK (2017) Detection of plant leaf diseases using image segmentation and soft computing techniques. **Information Processing in Agriculture** 4:41-49.

Soares PLB, Silva JP (2011) Aplicação de redes neurais artificiais em conjunto com o método vetorial da propagação de feixes na análise de um acoplador direcional baseado em fibra ótica. **Revista Brasileira de Computação Aplicada** 3:58-72.

Stagakis S, González-Dugo V, Cid P, Guillén-Climent ML, Zarco-Tejada PJ (2012) Monitoring water stress and fruit quality in an orange orchard under regulated deficit irrigation using narrow-band structural and physiological remote sensing indices. **ISPRS Journal of Photogrammetry and Remote Sensing** 71:47-61.

Steiner F, Pivetta LA, Castoldi G, Pivetta LG, Fioreze S (2011) Produção de rúcula e acúmulo de nitrato em função da adubação nitrogenada. **Revista Brasileira de Ciências Agrárias** 6:230-235.

Story D, Kacira M, Kubota C, Akoglu A (2009) Morphological and textural plant feature detection using machine vision for intelligent plant health, growth and quality monitoring. In **International Symposium on High Technology for Greenhouse Systems: GreenSys** 2009:299-306.

Story D, Kacira M, Kubota C, Akoglu A, An L (2010) Lettuce calcium deficiency detection with machine vision computed plant features in controlled environments. **Computers and Electronics in Agriculture** 74:238-243.

Sulistyo SB, Woo WL, Dlay SS, Gao B. (2018a) Building a globally optimized computational intelligent image processing algorithm for on-site inference of nitrogen in plants. **IEEE Intelligent Systems** 33:15-26.

Sulistyo SB, Wu D, Woo WL, Dlay SS, Gao B (2018b) Computational deep intelligence vision sensing for nutrient content estimation in agricultural automation. **IEEE Transactions on Automation Science and Engineering** 15:1243-1257.

Sun Y, Tong C, He S, Wang K, Chen L (2018) Identification of nitrogen, phosphorus, and potassium deficiencies based on temporal dynamics of leaf morphology and color. **Sustainability** 10:762.

Taiz L, Zeiger E (2006) *Plant Physiology*. Sinauer Associates, Sunderland.

Tavakoli H, Gebbers R (2019) Assessing nitrogen and water status of winter wheat using a digital camera. **Computers and electronics in agriculture** 157:558-567.

Tessarini G, Saltorato P (2018) Impactos da indústria 4.0 na organização do trabalho: uma revisão sistemática da literatura. **Revista Produção Online** 18:743-769.

Tonsig SL (2000) **Redes Neurais Artificiais Multicamadas e o Algoritmo Backpropagation**. Dissertação (Mestrado) - PUC, Campinas.

Vakilian KA, Massah J (2012) Design, Development and performance evaluation of a robot to early detection of nitrogen deficiency in greenhouse cucumber (*Cucumis*

Sativus) with machine vision. **International Journal of Agriculture: Research and Review** 2:448-454.

Vigneau N, Ecartot M, Rabatel G, Roumet P (2011) Potential of field hyperspectral imaging as a non-destructive method to assess leaf nitrogen content in Wheat. **Field Crops Research** 122:25-31.

Villatoro-Pulido M, Font R, Saha S, Obregón-Cano S, Anter J, Muñoz-Serrano A, Haro-Bailón A, Alonso Moraga A, Del Río-Celestino M (2012). In vivo biological activity of rocket extracts (*Eruca vesicaria* subsp. sativa (Miller) Thell) and sulforaphane. **Food and chemical toxicology** 50:1384-1392.

Wang Q, Zhou J, Wang X (2015) Diagnostic Technique of sugarbeet nitrogen nutrient status using SPAD-502 chlorophyll meter. **Chinese Agricultural Science Bulletin** 31:92-98.

Wang Y, Hu X, Hou Z, Ning J, Zhang Z (2018) Discrimination of nitrogen fertilizer levels of tea plant (*Camellia sinensis*) based on hyperspectral imaging. **Journal of the Science of Food and Agriculture** 98:4659-4664.

Wang Y, Wang D, Shi P, Omasa K (2014) Estimating rice chlorophyll content and leaf nitrogen concentration with a digital still color camera under natural light. **Plant methods** 10:1-11.

Wu J, Wang D, Rosen CJ, Bauer ME (2007) Comparison of petiole nitrate concentrations, SPAD chlorophyll readings, and QuickBird satellite imagery in detecting nitrogen status of potato canopies. **Field Crops Research** 101:96-103.

Yadav S, Ibaraki Y, Gupta SD (2010) Estimation of the chlorophyll content of micropropagated potato plants using RGB based image analysis. **Plant Cell, Tissue and Organ Culture** 100:183-188.

Yu KQ, Zhao YR, Li XL, Shao YN, Liu F, He Y (2014) Hyperspectral imaging for mapping of total nitrogen spatial distribution in pepper plant. **PloS one** 9:1-19.

Yuan W, Dejian W, Gang Z (2012) Nitrogen status diagnosis of rice based on a digital camera. **Chinese Agricultural Science Bulletin** 2012:24.

Yuan Y, Chen L, Li M, Wu N, Wan L, Wang S (2016) Diagnosis of nitrogen nutrition of rice based on image processing of visible light. **IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications (FSPMA)** 228-232.

Zhang F, Cui Z, Fan M, Zhang W, Chen X, Jiang R (2011) Integrated soil-crop system management: reducing environmental risk while increasing crop productivity and improving nutrient use efficiency in China. **Journal of Environmental Quality** 40:1051-1057.

Zhang X, Liu F, He Y, Gong X (2013) Detecting macronutrients content and distribution in oilseed rape leaves based on hyperspectral imaging. **Biosystem engineering** 115:56-65.

CAPÍTULO 2 - Resposta da rúcula à concentração de nitrogênio na solução nutritiva

RESUMO - O nitrogênio (N) é o segundo nutriente mais acumulado pela rúcula, o qual afeta sobremaneira o crescimento, produtividade e qualidade desta hortaliça. A rúcula é a segunda hortaliça folhosa mais cultivada em hidroponia; porém, não há estudos sobre como a concentração do N na solução nutritiva a afeta, tendo sido este o objetivo do presente estudo. Quatro concentrações (79,2; 118,8; 158,4 e 237,6 mg L⁻¹ de N) foram avaliadas em delineamento experimental de blocos casualizados, com cinco repetições. O maior teor de nitrogênio foliar foi de 28,2 g kg⁻¹, alcançado com 186 mg L⁻¹ de N na solução nutritiva. Máximos número de folhas, área foliar, massa seca e produtividade da rúcula 'Folha larga' foram obtidos com a maior concentração de N. O teor de nitrato (qualidade da rúcula) foi máximo com 210,2 mg L⁻¹ de N, mas na faixa aceitável para hortaliças. Com base no crescimento, produtividade e qualidade da rúcula, recomenda-se o seu cultivo com 237,6 mg L⁻¹ de N na solução nutritiva.

Palavras-chave: Cultivo sem solo, *Eruca sativa*, hidroponia, hortaliça folhosa, nitrato

2.1 INTRODUÇÃO

A rúcula (*Eruca sativa* Miller) é uma hortaliça folhosa bastante consumida *in natura*, na forma de saladas e em pizzas (Aguiar et al., 2014; Schiattone et al., 2018).

O crescimento da demanda de rúcula tem refletido em expansão da área cultivada e também na adesão de hidroponicultores. Entre as hortaliças folhosas, a rúcula é a segunda mais cultivada em hidroponia, atrás, em produção somente da alface (Matos et al., 2016). Entretanto, para o sucesso no cultivo de uma hortaliça em hidroponia, fazem-se necessários solução nutritiva adequada e correto manejo desta solução, por influenciarem diretamente na produção e na qualidade da cultura hidropônica (Genuncio et al., 2011; Guerra et al., 2011). Em soluções nutritivas para o cultivo de hortaliças folhosas, as concentrações de nitrogênio (N) são geralmente muito elevadas (Urlic et al., 2017) e, infelizmente, não se conhece uma solução nutritiva que tenha sido estabelecida segundo a demanda nutricional da rúcula. Em geral, usa-se a solução nutritiva recomendada para outras folhosas de forma genérica, conforme proposto por Furlani (1998) e Faquin e Furlani (1999).

Entre os nutrientes, o N é de extrema importância, por ser o segundo nutriente mais acumulado pela rúcula (Grangeiro et al., 2011), com efeito no crescimento e produtividade desta hortaliça, bem como na qualidade (Petropoulos et al., 2016). Pesquisas com N para cultura da rúcula em sistemas de cultivo sem solo, ainda são escassas, sendo mais comum estudos em condições de campo (Steiner et al., 2011; Yoruk et al., 2018; Barros Júnior et al., 2020; Silva et al., 2020).

Por outro lado, se alta disponibilidade de N pode incrementar a produtividade da rúcula, também pode afetar negativamente a sua qualidade. Hortaliças produzidas nesse tipo de sistema, empregando soluções nutritivas concentradas em N, podem acumular nitrato (NO_3^-) em excesso nas folhas (Andriolo, 2020). Embora, o acúmulo de NO_3^- dependa de diversos fatores, como manejo, quantidade e tipo de fertilizantes nitrogenados e a intensidade luminosa (Faquin, 2008), a disponibilidade de N é um dos principais fatores que afetam e contribuem no aumento de NO_3^- principalmente nas folhas da planta. No caso da rúcula, sendo a folha o produto consumido, deve-se ter atenção especial no monitoramento do N para evitar a

intoxicação do consumidor. Esse composto está associado à possibilidade de formação de compostos carcinogênicos e mutagênicos no organismo humano (Ranasinghe e Marapana, 2018; Moazeni et al., 2020).

Entre as hortaliças folhosas, a produção de rúcula para uso em saladas prontas está aumentando em resposta à demanda do mercado; entretanto, a rúcula é conhecida como uma espécie com hiperacumulação de nitrato, sendo necessário muita atenção, principalmente no manejo preciso da fertilização com nitrogênio (Di Mola et al., 2019). Dessa maneira, Cavarianni et al. (2008), estudaram concentrações de nitrogênio na solução nutritiva (60,8 - 243,5 mg L⁻¹) e verificaram resposta linear no teor de nitrato foliar da rúcula (3378 mg kg⁻¹), quando há o aumento na concentração de N na solução nutritiva, o que pode comprometer qualitativamente a hortaliça.

Diante do apresentado, o trabalho teve como objetivo avaliar o efeito da concentração de N da solução nutritiva na produtividade e qualidade da rúcula cultivada em hidroponia.

2.2 MATERIAL E MÉTODOS

2.2.1 Época e caracterização do local

O experimento foi conduzido de 3 de julho a 16 de agosto de 2018, em sistema hidropônico *nutrient film technique* (NFT), na UNESP, campus de Jaboticabal, São Paulo - Brasil, cujas coordenadas geográficas são 21°14'37.46" Sul, 48°17'07.85" Oeste, e altitude de 551 metros.

O clima da região é classificado como tropical com verão chuvoso e quente, e inverno seco e temperatura amena, com mês mais frio com temperatura média superior a 18°C, do tipo Aw segundo classificação de Köppen-Geiger (André e Garcia, 2015). Relativo ao período experimental, os dados climatológicos de temperatura máxima, média e mínima do ar foram 36,4°C, 28,5°C e 21,5°C, umidade relativa máxima, média e mínima foi de 64,7%, 38,6% e 13,1%, respectivamente, e radiação solar média e máxima de 16,1 e 726,3 MJ m⁻², respectivamente. Os dados

foram obtidos em uma microestação agrometeorológica instalada no interior da casa de vegetação da FCAV / UNESP, Jaboticabal - SP.

2.2.2 Tratamentos e delineamento experimental

Foram avaliados quatro tratamentos correspondentes à concentração de nitrogênio na solução nutritiva: 79,2; 118,8; 158,4 e 237,6 mg L⁻¹. O delineamento experimental foi o de blocos casualizados, com cinco repetições. A unidade experimental foi constituída por uma bancada com quatro canais de 1,3 m de comprimento. A área útil da unidade experimental para coleta de dados correspondeu aos dois canais centrais da bancada, excluindo-se a primeira e última planta de cada canal.

2.2.3 Instalação e condução do experimento

A rúcula 'Folha Larga' foi semeada no dia três de julho em placas de espuma fenólica com dimensões de 2 x 2 x 2 cm, previamente lavadas em água corrente por aproximadamente dez minutos, de modo a eliminar qualquer tipo de resíduo presente. Durante o período de germinação, essas placas permaneceram em casa de vegetação com sistema de aspersão sendo irrigadas somente com água (Fase I).

Oito dias após a semeadura (DAS), quando as plântulas apresentavam os cotilédones expandidos, as células da espuma fenólica foram individualizadas e as mudas foram transferidas para canais de polipropileno, com 5 cm de largura, em sistema NFT (Fase II). Os canais desta estrutura, denominada de "berçário" possuíam 5% de declividade. O fornecimento da solução nutritiva foi intermitente, alternando-se 15 minutos com e 15 minutos sem circulação (06h00 às 18h00). Este período correspondeu ao tempo de crescimento inicial das plantas, antes de seguirem para os canais definitivos. Nessa fase, foi utilizada a solução nutritiva completa proposta por Furlani (1998), com concentrações de 750g de nitrato de cálcio, 500g de nitrato de potássio, 150g de momoamônio fosfato e 400g de sulfato de magnésio heptahidratado; 1,76g de ácido bórico; 0,15g de sulfato de cobre; 1,5g

de sulfato de manganês; 0,30g sulfato de zinco; 0,10g de molibdato de amônio e 60 mL de Ferrilene para 1000 L de água.

Aos 24 DAS, quando apresentavam em média três folhas completamente expandidas, as mudas foram transplantadas para os canais de crescimento final, com 10 cm de diâmetro e 5% de declividade (Fase III), no espaçamento de 0,25 m entre canais e 0,05 m entre plantas. Utilizou-se a solução nutritiva proposta por Furlani (1998), com modificações para atendimento às concentrações de N na solução nutritiva (Tabela 1).

Tabela 1. Concentração de nutrientes na solução nutritiva.

SN	SM	NC	NK	MAP	CC	CK	MKP	NA	AN ²
mg L ⁻¹				g 1000L ⁻¹					ml 1000L ⁻¹
79,2	320	480	-	44	84	228	87	-	-
118,8	320	600	139	76,4	-	157	48,7	-	-
158,4	320	600	400	120	-	-	-	-	-
237,6	320	600	292	-	-	-	135	138	68

²Quantidade em ml 1000 dm⁻³; SN = Solução nutritiva; SM = Sulfato de magnésio; NC = Nitrato de cálcio; NK = Nitrato de potássio; MAP = Monoamônio fosfato; CC = Cloreto de cálcio; CK = Cloreto de potássio; MKP = Fosfato monobásico de potássio; NA = Nitrato de amônio e AN = Ácido nítrico.

Os micronutrientes foram aplicados conforme descrito anteriormente.

O bombeamento da solução foi realizado de maneira contínua por bombas submersas (uma por parcela) da marca Chosen®, modelo Power Head CX-300, com vazão de 1000 L h⁻¹. O acionamento das bombas foi controlado por um temporizador, com circulação da solução nutritiva das 07h00 às 18h00 (15 minutos com e 15 minutos sem circulação). Diariamente, foram monitorados o pH com o auxílio do pHmetro de bolso pHep®+ e a condutividade elétrica (CE) com o condutímetro digital DIST4. O pH foi mantido entre 5,5 e 6,5, utilizando-se hidróxido de sódio e ácido clorídrico, para aumentar e reduzir o pH, respectivamente. A solução nutritiva foi renovada quando a CE dos tratamentos atingia 70% da CE inicial (dS m⁻¹).

2.2.4 Características avaliadas

Para avaliação das características agronômicas da rúcula, foram coletados cinco conjuntos de 10 plantas, colhidas aleatoriamente na área útil de cada parcela.

Altura, número de folhas, área foliar, massa seca da parte aérea, teor de nitrogênio foliar, produtividade e teor de nitrato foram avaliados aos 20 dias após o início da Fase III. A altura da planta foi obtida usando-se fita métrica (0,5 cm acima do colo da planta até a folha mais alta), número de folhas por contagem e a área foliar por meio do integrador de área foliar LI-COR 3100. Para a obtenção da massa seca da parte aérea, as plantas foram lavadas e colocadas para secar em estufa com circulação forçada de ar a $65\pm 70^{\circ}\text{C}$ até atingirem massa constante, em seguida, pesada em balança semi-analítica com duas casas decimais.

A massa fresca das plantas foi obtida logo após a colheita, realizada entre 06h00 e 07h00. A produtividade foi estimada pelo produto da massa fresca e a densidade de plantio ($80 \text{ plantas m}^{-2}$). Na matéria seca da parte aérea, foi avaliado o teor de N foliar, segundo o método de Miyazawa et al. (2009).

Para determinação do teor de nitrato na parte aérea da rúcula, foram coletadas seis plantas ao acaso na área útil de cada parcela, entre 05h30 min e 06h30 min. O nitrato foi determinado de acordo com Mantovani et al. (2005), conforme descrito a seguir. Em tubos Falcon de 50 mL foram colocados 0,2 g de matéria seca de folhas e 20 mL de água deionizada. Os tubos permaneceram em banho-maria a $60\pm 5^{\circ}\text{C}$, por uma hora, período no qual foi feita agitação a cada 15 minutos. As amostras foram filtradas em papel-filtro de filtragem rápida. Deste extrato, foram tomados 5 mL e à ele adicionados 20 mL de água deionizada e 0,2 g de MgO. Foi realizada destilação para a conversão de amônio em amônia e o destilado foi descartado. Em seguida, no mesmo extrato foi adicionado 0,4 g de liga de Devarda para a redução de nitrato a amônio que, em meio alcalino, é convertido em amônia, a qual é arrastada pelos vapores e recolhida em béquer contendo 10 mL de solução de H_3BO_3 (20 g L^{-1}). A seguir, foi feita a quantificação de N na forma de amônio por meio de titulador automático (848 Titrino plus®) com solução padronizada de H_2SO_4 $0,00263 \text{ mol L}^{-1}$. O teor de nitrato obtido na massa seca de folhas foi convertido para mg de NO_3^- por kg de massa fresca, considerando-se 5% de massa seca na rúcula.

2.2.5 Análise estatística

Os dados obtidos foram submetidos à análise de variância (teste de F, $p < 0,05$). Realizou-se o estudo de regressão polinomial para concentração de N na solução nutritiva, escolhendo-se a equação com maior nível de significância e coeficiente de determinação. Utilizou-se o programa estatístico AgroEstat (Barbosa e Maldonado Júnior, 2015).

2.3 RESULTADOS E DISCUSSÃO

A concentração de N na solução nutritiva influenciou todas as variáveis avaliadas (Tabela 2).

Tabela 2. Altura da planta (AP), número de folhas (NF), área foliar (AF), massa seca da parte aérea (MSPA), teor foliar de nitrogênio (N), produtividade (PROD) e teor foliar de nitrato (NO_3^-) de rúcula em função da concentração de nitrogênio (N) na solução nutritiva.

N mg L^{-1}	AP cm	NF folhas planta ⁻¹	AF $\text{cm}^2 \text{ planta}^{-1}$	MSPA g planta ⁻¹	N g kg ⁻¹	PROD kg m ⁻²	NO_3^- g kg ⁻¹
79,2	30,73	12,30	463,56	2,34	23,7	2,74	1004,62
118,8	33,63	12,50	537,69	2,99	26,2	3,22	2083,58
158,4	35,49	13,95	655,45	3,50	27,9	3,60	3259,12
237,6	36,17	14,35	718,05	3,66	27,0	3,78	3391,06
Valores de F	10,26**	19,28**	14,8**	5,99**	13,22**	8,39**	41,17**
CV (%)	4,99	3,93	11,49	17,28	4,29	10,65	16,03

**Significativo a 1% de probabilidade ($p < 0,01$).

O número de folhas, a área foliar e a massa seca da parte aérea responderam positivamente ao incremento da concentração de N na solução nutritiva, com ajuste em modelo de equação linear, enquanto a altura de plantas teve seu máximo (37,7 cm) com 229,5 mg L^{-1} de N (Figura 1). Os máximos valores de número de folhas, área foliar, massa seca da parte aérea e altura foram 18% (+3 folhas por planta), 54% (+258,3 cm^2), 49% (+1,3 g) e 23% (+7 cm) maiores, respectivamente, que em plantas cultivadas com a menor concentração de N na solução nutritiva (79,2 mg L^{-1}).

No presente estudo, esse efeito foi notado na rúcula, pois o aumento da disponibilidade de N na solução nutritiva refletiu incrementando o teor de N foliar e, conseqüentemente, nas características biométricas (altura, número de folhas, área

foliar e massa seca da parte aérea), produtividade e qualidade da hortaliça. Os resultados confirmam informações de que a rúcula é muito responsiva à fertilização nitrogenada (Barros Júnior et al., 2011; Steiner et al., 2011; Grangeiro et al., 2011; Benett et al., 2015; Vieira Filho et al., 2017; Benett et al., 2019; Silva et al., 2020).




Figura 1. Altura (A), número de folhas (B), área foliar (C) e massa seca da parte aérea (D) da rúcula em função da concentração de nitrogênio (N) na solução nutritiva.

O maior teor de nitrogênio foliar foi de 28,2 g kg⁻¹, alcançado com 186 mg L⁻¹ de N na solução nutritiva (Figura 2A). Entretanto, esse teor foliar não representou a referência em concentração de N relacionado à máxima produtividade. Esta, que respondeu linear e positivamente ao aumento na disponibilidade de N na solução nutritiva, foi máxima (3,89 kg m⁻²) com 27 g kg⁻¹ de N foliar (Figura 2A), um incremento de 35% na produtividade da cultura em relação às plantas cultivadas em solução nutritiva contendo 79,2 mg L⁻¹ de N, com teor foliar de 23,6 g kg⁻¹ de N foliar.




Figura 2. Teor de N foliar (■) e produtividade (▲) (A) e nitrato foliar da rúcula em função da concentração de nitrogênio (N) na solução nutritiva.

A concentração de N que maximizou a produtividade da rúcula (237,6 mg L⁻¹ de N) foi superior à obtida por Cavarianni et al. (2011), 104 mg L⁻¹ de N (1,2 kg m⁻²). No entanto, a maior produtividade alcançada foi semelhante à verificada por Purquerio et al. (2007), correspondentes a 3,0 e 3,3 kg m⁻², em campo e ambiente protegido, respectivamente.

De acordo com Trani et al. (2014), teores adequados de N foliar para a rúcula estão entre 40 e 50 g kg⁻¹, os quais referem-se ao período de amostragem entre a metade e dois terços do ciclo. Os teores foliares do presente estudo foram obtidos na colheita e, provavelmente, esta seja a explicação para teores abaixo da faixa adequada, uma vez que não foram observados sintomas de deficiência, mesmo na menor concentração de N na solução nutritiva. O maior teor de N na massa seca da parte aérea foi obtido com uma concentração estimada de 186 mg L⁻¹ enquanto a maior produtividade foi observada com a maior concentração de N na solução nutritiva. Esse comportamento pode ser explicado pelo efeito da diluição do nutriente. De acordo com Maia et al. (2005), isso ocorre quando a taxa de crescimento relativo de matéria seca é superior à taxa de absorção relativa do nutriente, confirmado pela resposta no acúmulo de massa seca da rúcula, proporcionado pelo aumento na concentração de N na solução (Figura 1D).

Plantas bem nutridas com N apresentaram efeito positivo na produtividade de rúcula (Figura 2A), mas negativo sobre a qualidade (Figura 2B). Os resultados concordam com os observados por (Purquerio et al., 2007) e Steiner et al. (2011) e também que o suprimento de N é um dos principais fatores que promove maior

acúmulo de nitrato (Ceylan et al., 2002; Guadagnin et al., 2005; Barros Júnior et al., 2020). Esse conflito causado pela fertilização nitrogenada merece atenção de pesquisadores para o estabelecimento da concentração de N na solução nutritiva.

Conforme ajuste linear para médias de produtividade (Figura 2A), seu máximo não foi alcançado, podendo ser incrementada mediante aumento da concentração de N na solução nutritiva. Porém, o limite desta concentração não deve ser a capacidade da espécie em maximizar a produtividade; mas, sim, o teor de nitrato acumulado nas folhas de rúcula. Este composto está associado à possibilidade de formação de compostos carcinogênicos e mutagênicos no organismo humano (Tamme et al., 2010; Ahmed et al., 2017; Moazeni et al., 2020). Na maioria das dietas, as hortaliças, geralmente, contribuem com mais de 70% do nitrato total ingerido (Guadagnin et al., 2005).

No que diz respeito ao teor de nitrato, o Brasil não possui legislação referente à presença de nitrato em hortaliças, no entanto, a União Europeia estabeleceu para a rúcula produzida de outubro/março e abril/setembro, os teores máximos devem ser de 7000 e 6000 mg kg⁻¹ (peso fresco), respectivamente (UE, 2011). O teor de nitrato na massa fresca da parte aérea da rúcula considerando a concentração de 237,6 mg L⁻¹ que maximizou a produtividade, está abaixo do limite estabelecido para a cultura e não oferece nenhum risco a saúde.

O aumento da concentração de N na solução nutritiva proporcionou forte acúmulo de nitrato pela rúcula (Figura 2 B). O teor máximo de nitrato (3527,70 mg kg⁻¹) na massa fresca da parte aérea da rúcula foi obtido na concentração da solução nutritiva de 210,2 mg L⁻¹ de N, um incremento de 277% em relação ao obtido na menor solução nutritiva. Com 237,6 mg L⁻¹ de N, condição que maximizou a produtividade, o teor de nitrato foi de 3414,4 mg kg⁻¹.

2.4 CONCLUSÕES

O aumento na concentração de nitrogênio promove incremento do teor de nitrogênio foliar e, como consequência, maiores altura, número de folhas, área foliar, massa seca da parte aérea e produtividade.

Para o intervalo da concentração de nitrogênio na solução nutritiva estudado, o teor de nitrato não atinge o limite máximo estabelecido para rúcula e, então, a

maior concentração de N avaliada (237,6 mg L⁻¹) deve ser usada para maximizar a produtividade.

2.5 REFERÊNCIAS

Aguiar ATE, Gonçalves C, Paterniani MEAGZ, Tucci MLSA, Castro CEF (2014) Instruções Agrícolas para as Principais Culturas Econômicas. Campinas: IAC, **Boletim 200** 2-452.

Ahmed M, Rauf M, Mukhtar Z, Saeed NA (2017) Excessive use of nitrogenous fertilizers: an unawareness causing serious threats to environment and human health. **Environmental Science and Pollution Research** 24:26983-26987.

André RGB, Garcia A (2015) Alguns aspectos climáticos do município de Jaboticabal-SP. **Nucleus** 12:263-269.

Andriolo JL (2020) **Olericultura geral**. Fundação de Apoio a Tecnologia e Ciencia - Editora UFSM.

Barbosa JC, Maldonado Júnior W (2015) Experimentação agrônômica & AgroEstat: sistemas para análises estatísticas de ensaios agrônômicos. **Multipress**. p.76.

Barros Júnior AP, Cecílio Filho AB, Resende BLA, Lins HA (2020) Acúmulo de nitrato na alface e rúcula em resposta à adubação nitrogenada das culturas em consórcio. **Revista Caatinga** 33:260-265.

Barros Júnior AP, Cecílio Filho AB, Rezende BLA, Pôrto DR, Prado RDM (2011) Nitrogen fertilization on intercropping of lettuce and rocket. **Horticultura Brasileira** 29:398-403.

Benett KSS, Benett CGS, Santos GG, Costa E (2015) Effects of hydrogel and nitrogen fertilization on the production of arugula in successive crops. **African Journal of Agricultural Research** 10:2601-2607.

Benett KSS, Xavier RC, Benett CGS, Salomão LC, Seleguini A, Cantuario FS, Martins, AS (2019) Nitrogen Application in Arugula Culture. **Journal of Agricultural Science** 11:385-391.

Cavarianni RL, Cecílio Filho AB, Cazetta JO, May A, Corradi MM (2008) Concentrações de nitrogênio na solução nutritiva e horários de colheita no teor de nitrato em rúcula. **Revista Caatinga** 21:44-49.

Cavarianni RL, Corradi MM, Cecílio Filho AB, May A (2011) **Produção de Cultivares de Rúcula em Função da Concentração de Nitrogênio na Solução Nutritiva**. Disponível em: <http://www.abhorticultura.com.br/biblioteca/arquivos/Download/Biblioteca/44_417.pdf>. Acessado em outubro 15, 2020.

Ceylan S, Mordogan N, Cakici H, Yoldas F (2002) Effects of different nitrogen levels on the yield and nitrogen accumulation in the rocket. **Asian Journal of Plant Sciences** 1:482-483.

Di Mola I, Ottaiano L, Cozzolino E, Senatore M, Giordano M, El-Nakhel C, Sacco A, Roupael Y, Colla G, Mori M (2019) Plant-based biostimulants influence the agronomical, physiological, and qualitative responses of baby rocket leaves under diverse nitrogen conditions. **Plants** 8:522.

European Union (2011) Commission Regulation (EC) No 1258/2011 of 2 December 2011 amending Regulation (EC) No 1881/2006 as regards maximum levels for nitrates in foodstuffs setting. **Official Journal of the European Union** 320:15-17. Disponível em: <<https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:2011:320:0015:0017:EN:PDF>>. Acessado em outubro 15, 2020.

Faquin V, Andrade AT (2004) **Nutrição mineral e diagnose do estado nutricional de hortaliças**. Lavras: UFLA/FAEPE. 88p.

Faquin V, Furlani PR (1999) Cultivo de hortaliças de folhas em hidroponia em ambiente protegido. **Informe Agropecuário** 20:99-104.

Furlani PR (1998) **Instruções para o cultivo de hortaliças de folhas pela técnica de hidroponia - NFT**.

Genuncio GDC, Silva RAC, Sá NM, Mary W, Zonta E (2011) Produtividade de rúcula hidropônica cultivada em diferentes épocas e vazões de solução nutritiva. **Horticultura Brasileira** 29:605-608.

Grangeiro LC, Oliveira FCL, Negreiros MZ, Marrocos STP, Lucena RRM, Oliveira RA (2011) Crescimento e acúmulo de nutrientes em coentro e rúcula. **Revista Brasileira de Ciências Agrárias** 6:11-16.

Guadagnin SG, Rath S, Reyes FGR (2005) Evaluation of the nitrate content in leaf vegetables produced through different agricultural systems. **Food additives and contaminants** 22:1203-1208.

Guerra GMP, Luz JMQ, Haber LL, Silva MAD (2011) **Cultivo Hidropônico de Rúcula em Diferentes Concentrações de Solução Nutritiva, em Sistema NFT**. Disponível em: <
http://www.abhorticultura.com.br/biblioteca/arquivos/download/biblioteca/44_647.pdf
>. Acessado em setembro 15, 2020.

Maia CE, Morais ERC, Filho FDQP, Gueyi HR, Medeiros JF (2005). Teores foliares de nutrientes em meloeiro irrigado com águas de diferentes salinidades. **Revista Brasileira de Engenharia Agrícola e Ambiental** 9:292-295.

Mantovani JR, Cruz MCP, Ferreira ME, Barbosa JC (2005) Comparação de procedimentos de quantificação de nitrato em tecido vegetal. **Pesquisa Agropecuária Brasileira** 40:53-59.

Matos TS, Nascimento EC, Genuncio GC (2016) Consumo de rúcula está em plena expansão. **Revista Campo & Negócios**. Disponível em: <
<https://revistacampoenegocios.com.br/consumo-de-rucula-esta-em-plena-expansao/#:~:text=R%C3%BAcula%20hidrop%C3%B4nica&text=Atualmente%2C%20a%20r%C3%BAcula%20%C3%A9%20a,furos%20utilizados%20para%20o%20ma%C3%A7o>>. Acessado em outubro 20, 2020.

Miyazawa M, Pavan MA, Muraoka T, Carmo CAFS, Melo WJ (2009) Análise química de tecido vegetal. In: Silva FC (Ed.). **Manual de análises químicas de solos, plantas e fertilizantes**. 2. ed. Brasília: EMBRAPA, 191-233.

Moazeni M, Heidari Z, Golipour S, Ghaisari L, Sillanpää M, Ebrahimi A (2020) Dietary intake and health risk assessment of nitrate, nitrite, and nitrosamines: a Bayesian analysis and Monte Carlo simulation. **Environmental Science and Pollution Research** 1-13.

Petropoulos AS, Chatzieustratiou E, Constantopoulou E, Kapotis G (2016) Yield and quality of lettuce and rocket grown in floating culture system. **Notulae Botanicae Horti Agrobotanici Cluj-Napoca** 44: 603-612.

Purquerio LFV, Demant LAR, Goto R, Villas Boas RL (2007) Efeito da adubação nitrogenada de cobertura e do espaçamento sobre a produção de rúcula. **Horticultura Brasileira** 25:464-470.

Ranasinghe RASN, Marapana RAUJ (2018) Nitrate and nitrite content of vegetables: A review. **Journal of pharmacognosy and phytochemistry** 7:322-328.

Schiattone Mi, Viggiani R, Di Venere D, Sergio L, Cantore V, Todorovic M, Perniola M, Candido V (2018) Impact of irrigation regime and nitrogen rate on yield, quality and water use efficiency of wild rocket under greenhouse conditions. **Scientia Horticulturae** 229:182-192.

Silva PHS, Palaretti LF, Cecílio Filho AB, Silva YF (2020) Nitrogen levels via fertigation and irrigation depths in the arugula culture. **Horticultura Brasileira** 38:343-349.

Steiner F, Pivetta LA, Castoldi G, Pivetta LG, Fioreze S (2011) Produção de rúcula e acúmulo de nitrato em função da adubação nitrogenada. **Revista Brasileira de Ciências Agrárias** 6:230-235.

Tamme T, Reinik M, Roasto M (2010) Nitrates and nitrites in vegetables: occurrence and health risks. In *Bioactive Foods in Promoting Health*. **Academic Press** 307-321.

Trani PE, Purquério LFV, Figueiredo GJB, Tivelli SW, Blat SF (2014). **Calagem e adubação da alface, almeirão, agrião d'água, chicória, coentro, espinafre e rúcula**. Campinas: IAC. Disponível em: <http://www.iac.sp.gov.br/imagem_informacoestecnologicas/97.pdf>. Acessado em setembro 10, 2020.

Urlić B, Dumičić G, Romić M, Ban SG (2017) The effect of N and NaCl on growth, yield, and nitrate content of salad rocket (*Eruca sativa* Mill.). **Journal of plant nutrition** 40: 2611-2618.

Vieira Filho OS, Oliveira GQ, Biscaro GA, Motomiya AVA, Geisenhoff LO (2017) Fertirrigação com nitrogênio na cultura da rúcula. **Agrarian** 10:304-310.

Yoruk V, Durukan H, Sarac H, Demirbas A, Karakoy T (2018) The effects of different nitrogen doses on yield and nutrient uptake of rocket (*Eruca sativa*) plant. **Scientific Papers-Series B, Horticulture LXII**: 359-365.

CAPÍTULO 3 - Processamento digital de imagem aplicado ao monitoramento de nitrogênio em rúcula

RESUMO - Técnicas computacionais vêm sendo utilizadas na avaliação do estado nutricional de plantas, de modo a auxiliar no diagnóstico precoce da deficiência nutricional. Neste trabalho, o objetivo foi avaliar a aplicação do processamento digital de imagens (PDI) na identificação do estado nutricional de nitrogênio em rúcula, bem como o tipo de folha e época do ciclo. Assim, em rúcula cultivada em hidroponia, com solução nutritiva contendo 79,2; 118,8; 158,4 e 237,6 mg L⁻¹ de N, aplicou-se o PDI nas imagens das folhas novas, intermediárias e velhas, aos 11, 14, 17 e 20 dias após o início da Fase III de crescimento. O experimento foi realizado em blocos casualizados, com arranjo fatorial em parcelas subdivididas, com cinco repetições. A sequência decrescente do teor de nitrogênio nas folhas de rúcula, aos 20 dias na Fase III, foi das folhas novas, seguida de folhas intermediárias e velhas. A rúcula cultivada em solução nutritiva com 237,6 mg L⁻¹ de N, apresentou maior discriminação pelo classificador, com taxa de acerto de 95%, caracterizando-a com melhor estado nutricional. Em plantas cultivadas com 79,2, 118,8 e 158,4 mg L⁻¹ verificaram-se confusões entre essas classes pelo PDI, sugerindo-se indícios de deficiência em todas elas. Com esses níveis de N, o PDI não foi capaz de identificar a deficiência de N precocemente. Os melhores resultados do PDI foram verificados nas folhas velhas, aos 20 dias na Fase III. Para a componente de validade dos resultados, o classificador foi mais sensível (98,33%) do que específico (95%).

Palavras-chave: Aprendizado de máquina, Diagnose nutricional, *Eruca Sativa*, Redes neurais artificiais, Visão artificial

3.1 INTRODUÇÃO

As hortaliças folhosas estão presentes na dieta humana na forma *in natura* em vários tipos de saladas. Apresentam alto teor de fibras e também são fonte de vários macros e micronutrientes (Taffner et al., 2019). A rúcula (*Eruca sativa* Miller) destaca-se pelo sabor picante, resultado de glucosinolatos e outros compostos contendo enxofre (Piślewska-Bednarek et al., 2018). Além de seu valor na culinária, há evidências que os isotiocianatos formados durante a degradação dos glucosinolatos estejam envolvidos na prevenção do câncer (Halkier e Gershenzon, 2006). Dessa maneira, o cultivo da rúcula se tornou de importância econômica, social e nutricional para sociedade brasileira, necessitando de apoio técnico-científico para a viabilidade da cadeia produtiva. Entre as hortaliças folhosas, atualmente é a segunda mais cultivada em hidroponia, atrás somente da alface (Matos et al., 2016).

A rúcula é uma hortaliça de ciclo curto e com alta demanda nutricional. Dentre os nutrientes, o nitrogênio (N) é o segundo nutriente mais acumulado, cuja absorção aumenta gradativamente até a colheita (Grangeiro et al., 2011). Portanto, a cultura mostra-se responsiva à aplicação de N (Purquerio et al., 2007; Grangeiro et al., 2011; Vieira Filho et al., 2017; Silva et al., 2019); mas, há poucas informações na literatura sobre a fertilização nitrogenada desta hortaliça. O manejo correto da adubação é imprescindível para obtenção de alta produtividade, qualidade e sustentabilidade do sistema produtivo. Dessa forma, o desequilíbrio nutricional pode ser irreversível devido ao curto período de crescimento (Cecílio Filho et al., 2014).

Para avaliação do estado nutricional de hortaliças folhosas, folha diagnóstica ou a planta inteira são coletadas, envolvendo uma série de procedimentos desde a coleta, o preparo e envio da amostra ao laboratório, além da quantificação do nutriente no tecido vegetal (Boaretto et al., 1999; Carmo et al., 2000; Yuan et al., 2016). Todo esse processo, demanda tempo que, devido ao curto ciclo da rúcula, torna o processo tradicional de predição de N, muitas vezes, inadequado ou tardio para realização de correção da fertilização realizada (Mao et al., 2015).

No contexto dos avanços de tecnologias aplicadas à agricultura, há necessidade de desenvolver métodos alternativos que aliem precisão à rapidez do

diagnóstico (Yuan et al., 2016), a fim de otimizar a produção, ao mesmo tempo que reduz os custos operacionais e a poluição ambiental (Chlingaryan et al., 2018). Dessa forma, estudos vêm sendo realizados sobre o uso de técnicas computacionais, como processamento digital de imagens (PDI), juntamente com as técnicas do aprendizado de máquinas (AM) (Mitchell, 1997; Gonzalez e Woods, 2009; Xiong et al., 2019), aplicados à identificação de deficiências nutricionais (Yuan et al., 2016; Li et al., 2018; Sancho-Adamson et al., 2019; Amaral et al., 2019) de modo a auxiliar no diagnóstico precoce da desordem.

O trabalho teve como objetivo avaliar a eficácia da aplicação do processamento digital de imagens na identificação do estado nutricional de nitrogênio em rúcula, bem como o tipo de folha e época do ciclo que melhores são discriminados com a aplicação da técnica do PDI.

3.2 MATERIAL E MÉTODOS

3.2.1 Época e caracterização do local

O experimento foi conduzido de três de julho a 16 de agosto de 2018, em sistema hidropônico *nutrient film technique* (NFT), na UNESP, campus de Jaboticabal, São Paulo - Brasil, cujas coordenadas geográficas são 21°14'37.46" Sul, 48°17'07.85" Oeste, e altitude de 551 metros.

O clima da região é classificado como tropical chuvoso do tipo Aw segundo classificação de Köppen-Geiger com inverno seco e mês mais frio com temperatura média superior a 18°C (André e Garcia, 2015). Relativo ao período experimental, os dados climatológicos de máxima, média e mínima temperatura do ar (°C), umidade relativa do ar (%) e radiação solar (MJ m⁻²) foram obtidos em uma micro estação montada dentro da casa de vegetação, UNESP, Jaboticabal - SP (Tabela 1).

Tabela 1. Temperatura, umidade relativa do ar e radiação solar durante o período de condução do experimento (período de três de julho a 16 de agosto de 2018).

	Temperatura (°C)	Umidade relativa (%)	Radiação solar (MJ m ⁻²)
Máxima	36,4	64,7	-
Média	28,5	38,6	16,1
Mínima	21,5	13,1	-
Total	-	-	726,3

3.2.2 Tratamentos e delineamento experimental

Foram avaliados 16 tratamentos em delineamento de blocos casualizados com cinco repetições, em arranjo fatorial 4 x 4, com parcelas subdivididas, correspondentes às quatro concentrações de nitrogênio (N) na solução nutritiva (79,2; 118,8; 158,4 e 237,6 mg L⁻¹), quatro épocas de coleta para avaliação do estado nutricional em N (11, 14, 17 e 20 dias na Fase III) e três tipos de folhas (nova, intermediária e velha) como subparcelas ou fator secundário.

3.2.3 Instalação e condução do experimento

A rúcula 'Folha Larga' foi semeada no dia três de julho em placas de espuma fenólica com dimensões de 2 x 2 x 2 cm, previamente lavadas em água corrente, por aproximadamente dez minutos, de modo a eliminar qualquer tipo de resíduo presente. Durante o período de germinação, essas placas permaneceram em casa de vegetação com sistema de aspersão sendo irrigadas somente com água (Fase I).

Oito dias após a semeadura (DAS), quando as plântulas apresentavam os cotilédones expandidos, as células da espuma fenólica foram individualizadas e transferidas para canais de polipropileno, com 5 cm de largura, em sistema NFT (Fase II). Os canais desta estrutura, denominado de "berçário" possuíam 5% de declividade para recuperação da solução nutritiva ao reservatório. O fornecimento da solução nutritiva foi intermitente, alternando-se 15 minutos com e 15 minutos sem circulação. Nessa fase, foi utilizada a solução nutritiva completa proposta por Furlani (1998).

No dia 27 de julho (24 DAS), as mudas com três folhas foram transplantadas no espaçamento de 0,25 m entre canais e 0,05 m entre plantas, para os canais de crescimento final (Fase III), que apresentavam 10 cm de diâmetro e também 5% de declividade. Utilizou-se a solução nutritiva proposta por Furlani (1998) com modificações para atender às concentrações de N na solução nutritiva.

O bombeamento da solução foi realizado de maneira contínua por bombas submersas (uma por parcela) da marca Chosen®, modelo Power Head CX-300, com vazão de 1000 L h⁻¹. O acionamento das bombas foi controlado por um

temporizador, com circulação da solução nutritiva das 07h00 às 18h00. Diariamente, foram monitorados o pH com o auxílio do pHmetro de bolso e mantido entre 5,5 e 6,5, utilizando-se hidróxido de sódio e ácido clorídrico, para aumentar e reduzir o pH, respectivamente. A condutividade elétrica (CE) foi avaliada com um condutivímetro digital e a solução nutritiva foi renovada quando a CE do reservatório da parcela atingia 70% da CE inicial (dS m^{-1}) do fator concentração de N.

3.2.4 Processamento digital de imagens (Experimento computacional)

O processamento digital de imagens (PDI) foi composto por quatro fases de operacionalização: I- coleta e digitalização das amostras, II- segmentação e extração dos histogramas das imagens, III- seleção de atributos e IV- classificação, conforme proposto por Silva (2008).

Na fase I de aplicação do PDI, de cada época de avaliação do estado nutricional, foram coletadas, aleatoriamente, oito plantas de cada parcela. As folhas foram separadas e classificadas de acordo com a concentração de N (Fator 1), época (Fator 2) e tipo de folha (fator secundário). As folhas foram lavadas em água deionizada e secas com papel toalha, a fim de fornecer uma boa qualidade da imagem. As imagens das folhas das plantas foram obtidas utilizando-se de scanner de mesa convencional de alta resolução (9.600 dpi). As folhas foram digitalizadas com resolução horizontal e vertical de 1.200 dpi e armazenadas digitalmente com dimensões de largura e altura iguais a 10.200 x 14.040 pixels, salvas em formato de compressão JPEG (*Joint Photographics Experts Group*), para posterior processamento.

Na fase II do PDI, de cada imagem, foram extraídas (recortadas) 20 amostras, com o software ImageJ (Kimball e Mattis, 2012) (Figura 1a), com dimensões de 100 x 100 pixels, para cada combinação dos níveis dos fatores (4 concentrações de N x 4 Épocas x 3 tipos de folhas x 20 amostras) totalizando, portanto, 960 amostras ou recortes. As amostragens digitais foram coletadas na região de maior expressão do sintoma de deficiência e, quando não observados ou não existentes, foram coletadas nas regiões de maior incidência dos sintomas conforme as plantas deficientes.

Ainda na fase II, para cada amostra, foram extraídos os três componentes do sistema de cores RGB (*red*, *green* e *blue*) com 256 tons de cinza, com o software GIMP (Schneider et al., 2012). De cada componente, foram extraídos histogramas da distribuição de frequências dos níveis dos pixels na escala de cinza, variando de 0 (preto puro) a 255 (branco puro) (Figura 1b), também com o uso do software ImageJ (Kimball e Mattis, 2012).

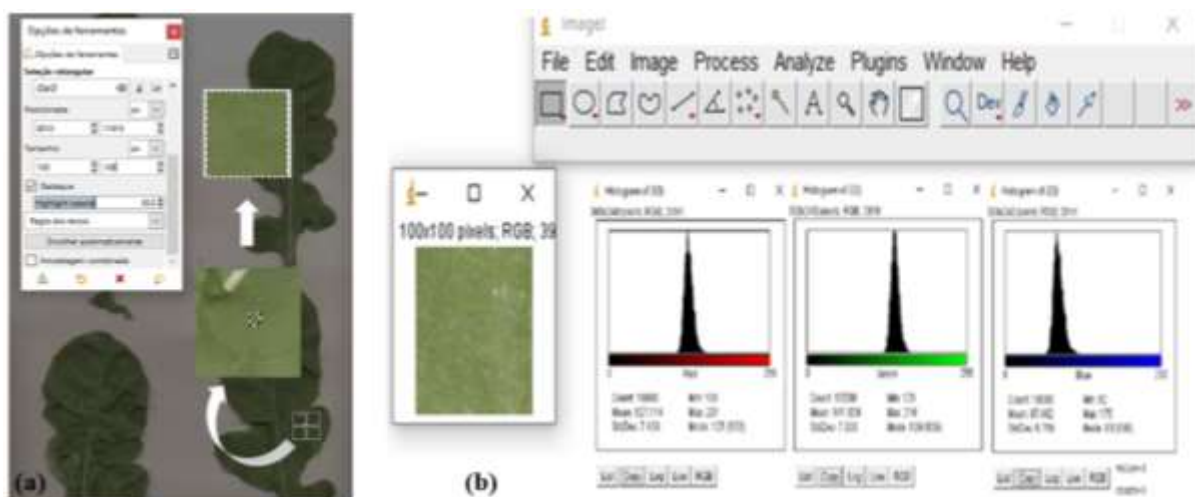


Figura 1. Processo de segmentação (a) e extração dos histogramas (b).

Os histogramas gerados foram armazenados digitalmente em arquivos textos no formato (.txt), onde, posteriormente, foram agrupados formando uma única base de dados, também armazenada em arquivo texto. Essa base de dados consistiu de 960 linhas, referentes ao número de amostras, onde cada linha conteve 769 variáveis, sendo 768 variáveis de entradas compostas pela frequência de cada nível de cinza para cada componente do sistema RGB $[256 \times 3]$ e uma variável de saída correspondente à classificação original da amostra de acordo com a combinação dos níveis dos fatores (classificação).

Foram realizados quatro experimentos computacionais, nomeados de I a IV. De início, montou-se uma base de dados com 48 classes de saídas (4 concentrações de N x 4 épocas x 3 tipos de folhas) (I). Em seguida, montou-se uma base de dados agrupando-se as quatro soluções nutritivas e retirando-se os rótulos de épocas e tipos de folhas (II). Posteriormente, de acordo com o desempenho dos classificadores gerados, foram restringindo-se as classes. De início, reduziu-se a base de dados combinando-se as quatro soluções nutritivas e as quatro épocas e

fixando-se as folhas velhas (4 concentrações de N x 4 épocas na folha velha) (III). Por último, optou-se por restringir também a época de coleta aos 20 dias na Fase III de crescimento, restando-se somente quatro classes de saídas (4 concentrações de N) (IV) (Tabela 2).

Tabela 2. Características da rede neural para os experimentos computacionais executados.

Experimento Computacional	Número de amostras	Componentes principais	Classes	Matriz de confusão
I	960	34	48	48 x 48
II	960	34	4	4 x 4
III	320	27	16	16 x 16
IV	80	23	4	4 x 4

Depois de selecionadas as componentes principais, a partir da matriz de correlação de dados, utilizaram-se essas componentes (Tabela 2) como vetores de entrada para a fase de classificação. Assim, os vetores foram compostos pelas variáveis de entrada (componentes principais) e uma variável de saída, representando os quatro níveis de variação nutricional (classes), quatro épocas e três tipos de folhas.

A partir da Fase III do PDI, a base de dados foi submetida ao software WEKA (Witten et al., 2017), onde a análise multivariada aplicada para a seleção de atributos, com a técnica de Análise de Componentes Principais (PCA), visou diminuir expressivamente o número de variáveis de entrada, substituindo-as por componentes principais selecionadas quanto ao grau de importância na classificação das saídas, sem prejuízo da informação biológica contida na variabilidade das respostas (Johnson e Wichem, 2002).

Por fim, na Fase IV, para a classificação das imagens utilizou-se uma técnica aprendizado de máquina, as redes neurais artificiais (RNA). O tipo de RNA utilizada foi a *Perceptron* multicamadas, treinadas com o algoritmo *backpropagation*, com uma camada intermediária (Figura 2). Foram utilizados os valores de 0,2 e 0,3 para as taxas de aprendizado e termo momentum (Haykin, 2007), respectivamente. Nesta etapa, também foi utilizada a ferramenta WEKA.

Em todos os experimentos computacionais, as RNA possuíram arquiteturas com três camadas. As camadas de entradas de cada um dos experimentos possuíram os números de neurônios iguais aos números de componentes principais

selecionadas. Já, os números de neurônios das camadas intermediárias foram calculados pela média aritmética entre o número de neurônio da camada de entrada e o número de classes. Por sua vez, as camadas de saída possuíram sempre os números de neurônios iguais ao número de classes de saídas de cada um dos experimentos executados (Tabela 2). A Figura 2 ilustra a arquitetura do experimento computacional IV. Para obter uma estimativa não viciada de erro do classificador, utilizou-se de técnicas de amostragem para manipulação dos conjuntos de treinamento e teste. Neste trabalho, foi considerada a metodologia *r*-partição-*cross-validation* (Efron e Gong, 1983; Efron e Tibshirani, 1993), que divide o conjunto de dados total, de tamanho n , em r partes mutuamente exclusivas (partições) de tamanhos iguais a n/r amostras. As amostras nas $(r - 1)$ partições são usadas para treinamento e a hipótese induzida é testada na partição remanescente. Este processo é repetido r vezes, cada vez considerando uma partição diferente para teste. O erro no *cross-validation* é a média dos erros calculados em cada uma das r partições de teste (Baranauskas, 2001).




Figura 2. Arquitetura da rede neural com valores de entrada (componentes principais), neurônios (processadores) e saída (classificação), nas soluções nutritivas (SN) com 79,2 (1); 118,8 (2); 158,4 (3) e 237,6 mg L⁻¹ de N (4), na folha velha (FV), aos 20 dias na Fase III de crescimento (E4).

Para verificar a consistência e a confiabilidade dos resultados, foram observadas as taxas de erro e acerto dos classificadores e as percentagens de acerto para cada classe (Sena Júnior et al., 2003).

Foi aplicado o teste diagnóstico (Galen e Gambino, 1975) nos resultados de classificação obtidos com a aplicação da técnica de RNA para o experimento IV (20 dias), a fim de verificar a sensibilidade e especificidade do modelo.

A sensibilidade é a capacidade que o modelo apresenta de detectar os indivíduos verdadeiramente positivos, ou seja, de diagnosticar corretamente o grupo de amostras com deficiência; também foi realizado o teste de especificidade, que é a capacidade que o modelo diagnóstico tem de detectar os verdadeiros negativos, isto é, de diagnosticar corretamente os indivíduos sem deficiência (Fleiss, 1981). No resultado do teste, o positivo representa a classe acerto, enquanto que o negativo representa as classes de erro. O valor de sensibilidade é encontrado a partir de $(a/(a+b))$ e a especificidade é encontrada a partir de $(d/(c+d))$, representando assim, a taxa de imagens do grupo com e sem deficiência corretamente classificadas.

3.2.5 Teor de nitrogênio foliar (N)

Aos 11, 14, 17 e 20 dias na Fase III do crescimento da rúcula, as folhas velhas, intermediárias e novas de plantas cultivadas em cada concentração de N na solução nutritiva que foram digitalizadas, foram embaladas em sacos de papel identificados e colocadas para secar em estufa com circulação forçada de ar a $65\pm 70^{\circ}\text{C}$ até atingir peso constante. Após a secagem, o material foi triturado em moinho tipo Willey e pesado (0,1 g). Realizou-se a digestão sulfúrica e determinou-se o teor de N de acordo com Miyazawa et al. (2009).

3.2.6 Análise Estatística

Os dados obtidos foram submetidos à análise de variância, com a aplicação do teste F ($p < 0,05$). Realizou-se o estudo de regressão polinomial aos fatores quantitativos, escolhendo-se a equação de mais alto grau com nível de significância e o teste de Tukey ($p < 0,05$) foi aplicado ao fator qualitativo. Para o efeito dos fatores

sobre os parâmetros avaliados nas épocas de amostragem, as análises estatísticas foram processadas utilizando-se o programa estatístico Sisvar (Ferreira, 2011).

3.3 RESULTADOS E DISCUSSÃO

O PDI foi capaz de separar classes do estado nutricional, principalmente nas plantas com deficiência de N. Por outro lado, não foi possível apontar, pelos níveis estudados de N na solução, plantas que apresentavam excesso de N (Figura 3).




Figura 3. Pigmentação de folhas velhas (FV), intermediárias (FI) e novas (FN) de plantas de rúcula nas soluções nutritivas (SN) com 79,2(1); 118,8(2); 158,4(3) e 237,6 mg L⁻¹ de N (4), aos 20 dias na Fase III de crescimento (E4).

Para todos os tipos de folha, conforme retratado na Figura 3, à medida que a concentração de N aumentou na solução nutritiva, houve diferença nos níveis de cor verde retratado pelo PDI, principalmente aos 20 dias na Fase III, confirmado pelo teor de N nos tipos de folhas (Tabela 3).

Tabela 3. Teor foliar de nitrogênio (N) em função da concentração do nutriente na solução nutritiva e do tipo de folha (FV - folha velha; FI - folha intermediária; FN - folha nova) aos 20 dias na Fase III.

Tipo de folha	Concentração de N na solução nutritiva (mg L ⁻¹)			
	79,2	118,8	158,4	237,6
	g kg ⁻¹			
FV	23,7 c	22,9 c	22,9 c	23,1 c
FI	28,6 b	28,8 b	29,7 b	30,1 b
FN	32,2 a	34,5 a	34,6 a	34,8 a

Médias com letras diferentes na coluna diferiram ($P < 0,05$), segundo o teste de Tukey.

No experimento I, considerando-se as concentrações de N, tipos de folhas e épocas de avaliação (48 classes), o classificador apresentou alta taxa de erro total (83,5%), não sendo eficiente na discriminação entre as classes. Entretanto, as maiores taxas de acertos entre as classes foram verificadas quando pertencentes à folha velha e a avaliação feita aos 20 dias de crescimento na Fase III (Tabela 4). Na mesma tabela, a ausência da época 1 de avaliação do estado nutricional (11 dias na Fase III do crescimento), devido ao baixo percentual de acertos pelo classificador, demonstrou ser esta inadequada para a distinção entre padrões do estado nutricional em N.

Tabela 4. Desempenho dos classificadores, nos conjuntos de testes, para classes com taxas de acerto maiores que 20%, na identificação do estado nutricional de nitrogênio em rúcula, em função da combinação de todos os fatores no Experimento I e das concentrações de nitrogênio (N) no Experimento II.

N (mg L ⁻¹)	Experimento I*			Experimento II	
	Folha	Época (dias)	Acerto (%)	N (mg L ⁻¹)	Acerto (%)
79,2	Velha	14	25	79,2	36
79,2	Velha	17	25	118,8	26
79,2	Velha	20	70	158,4	28
118,8	Velha	20	45	237,6	36
237,6	Nova	17	25		
237,6	Velha	20	80		

*Precisão detalhada por classe (6 de 48 classes).

Posteriormente, foi realizado o experimento II, retirando-se o rótulo dos fatores tipos de folhas e épocas de avaliação. Entretanto, as taxas de acerto foram baixas, com média de 31,5%, pois o classificador confundiu as classes avaliadas (Tabela 4), evidenciando que, existem diferenças entre os padrões desses fatores que foram omitidos, ou seja, não se consegue discriminar as variações de N, pelo PDI, independentemente do tipo de folha ou época de avaliação.

Realizou-se, então, o experimento III para verificar a discriminação entre concentrações de N e as épocas de avaliação. Novamente, uma alta taxa de erro total foi observada (71,6%), com maiores taxas de acertos aos 20 dias de crescimento na Fase III, independentemente da concentração de N na solução nutritiva (Tabela 5). Por fim, realizou-se o experimento IV somente com as classes de N, na folha velha, aos 20 dias na Fase III de crescimento, e verificou-se maior taxa de acerto médio total (67,5%), resultando, assim, no classificador com melhor desempenho. Maiores taxas de acertos foram verificadas nas classes com a maior concentração de N estudada (Tabela 5).

Tabela 5. Desempenho dos classificadores para classes com taxas de acerto maiores que 20%, na identificação de deficiência de nitrogênio em rúcula, em função da combinação de concentração de nitrogênio (N) e época de avaliação (Experimento III) e das concentrações de N (Experimento IV).

N (mg L ⁻¹)	Experimento III*		Experimento IV	
	Época (dias)	Acerto (%)	N (mg L ⁻¹)	Acerto (%)
79,2	14	30	79,2	65
79,2	17	25	118,8	40
79,2	20	50	158,4	70
118,8	20	40	237,6	95
158,4	14	30		
158,4	20	55		
237,6	14	40		
237,6	20	85		

*Precisão detalhada por classe (8 de 16 classes).

De acordo com os fatores analisados nas épocas iniciais de avaliação (11, 14 e 17 dias na Fase III), houve baixa taxa de acerto descrita pelo classificador, afirmando que o mesmo não conseguiu uma discriminação satisfatória entre as classes estudadas. No entanto, aos 20 dias na Fase III, para a solução de 237,6 mg L⁻¹ (Experimento IV), apresentou-se 95% de taxa acerto com o PDI, sendo explicado pela nítida eficiência no uso e distribuição de nitrogênio nos tipos de folhas nessa

época (Tabela 5).

Esse acontecimento pode ser explicado pelo fato de a cultura no início do ciclo apresentar um crescimento lento, associado também à baixa demanda por nutrientes durante esse período, refletindo diretamente na cor da folha e teor de N foliar na seguinte ordem $FN > FI > FV$, com alta redistribuição do nutriente na planta (Figura 3 e Tabela 3). Isso acontece, porque a demanda por nutrientes torna-se cada vez maior à medida que se aproxima do final do ciclo (Grangeiro et al., 2011), período que se conseguiu distinguir com maior exatidão a época e tipo de folha para o diagnóstico nutricional de N na rúcula com a aplicação do PDI.

De acordo com os quatro experimentos computacionais, tem-se que a época 4 (20 dias), a folha velha e $237,4 \text{ mg L}^{-1}$ de N na solução nutritiva é a melhor combinação dos níveis dos fatores estudados para reconhecimento automático do estado nutricional de N.

Na Tabela 6 estão apresentados os resultados da matriz de confusão para a média dos conjuntos de testes, em função da concentração de N na solução nutritiva (Experimento IV). A matriz de confusão decompõe as taxas de erros e acertos médios em cada classe (concentração de N), quantificando quantos exemplos da base foram corretamente classificados pelo modelo (diagonal principal) e quantos foram erroneamente classificados (valores dispersos da diagonal principal) (Cosme, 2002).

Independentemente da época, houve confusão entre as concentrações de N até $158,4 \text{ mg L}^{-1}$ pelos classificadores na avaliação do estado nutricional em N da rúcula e estas soluções foram agrupadas como deficientes em N (Grupo I), conforme diagnóstico do PDI no experimento IV (Tabelas 5 e 6). Essa confusão pode ser atribuída ao manejo da solução nutritiva, a qual era renovada sempre que a CE da solução atingia 70% da CE inicial. Este manejo pode ter propiciado que a solução nutritiva com $79,2 \text{ mg L}^{-1}$, mesmo correspondendo à metade da concentração de $158,4 \text{ mg L}^{-1}$, apresentasse condições de coloração da folha entre elas não distinguível pelo PDI.

Tabela 6. Número de amostras por classe (n) e seu percentual em relação ao total (%) do estudo da matriz de confusão do experimento IV (concentrações de nitrogênio na solução nutritiva, na folha velha aos 20 dias na Fase III de crescimento) na capacidade do classificador em acertar o estado nutricional em nitrogênio da rúcula.

N (mg L ⁻¹)	Parâmetros	79,2	118,8	158,4	237,6	Total
79,2	N	13	2	5	0	20
	%	65%	10%	25%	0%	100%
118,8	N	4	8	7	1	20
	%	20%	40%	35%	5%	100%
158,4	N	3	3	14	0	20
	%	15%	15%	70%	0%	100%
237,6	N	0	1	0	19	20
	%	0%	5%	0%	95%	100%

Maiores taxas de acerto na média dos conjuntos de testes de variação nutricional (teor foliar de N) foram observadas nas soluções com 158,4 (70%) e 237,6 mg L⁻¹ de N (95%), (Tabela 6), demonstrando a capacidade do classificador em identificar, com uma maior precisão o estado nutricional aos 20 dias na Fase III de crescimento, usando-se a folha velha.

De acordo com os resultados observados no estudo da matriz de confusão para a diagnose do estado nutricional da rúcula (experimento IV), pode-se sugerir a formação de dois grupos segundo a concentração de N. Grupo I, formado pelas soluções nutritivas com 79,2; 118,8 e 158,4 mg L⁻¹ de N, que se mostraram ineficientes para avaliar o estado nutricional da rúcula em N, havendo confusão do classificador em estabelecer se a planta possui ou não deficiência, se é ou não suficiente em N; e Grupo II, composto pela solução nutritiva com 237,6 mg L⁻¹ de N com alta eficiência (Tabela 6).

Para o teste de diagnóstico aplicado aos grupos I e II (Tabela 7), foi observado que a capacidade do classificador em identificar a presença de alguma deficiência nutricional nos grupos de amostragem, a sensibilidade, foi de 98% e a especificidade foi de 95%, que é a capacidade de identificar a ausência da deficiência. Desse modo, a classificação foi avaliada quantitativamente, observando-se que, o classificador foi mais sensível que específico, resultando em uma melhor classificação do grupo com deficiência que do grupo sem deficiência.

Tabela 7. Teste de diagnóstico dos resultados do classificador para os grupos I e II aos 20 dias na Fase III de crescimento.

Resultado do teste	Grupo I		Grupo II		Total	
Positivo	a	59	c	1	$a + b$	60
Negativo	b	1	d	19	$c + d$	20
Total	$a + b$	60	$c + d$	20	N	80

a - verdadeiro positivo, b - falso negativo, c - falso positivo, d - verdadeiro negativo e n - número de amostras.

Para o teste de sensibilidade, o classificador foi capaz de classificar corretamente as plantas com resultados positivo ao grupo atribuído (Grupo I), ou seja, as plantas que apresentavam deficiência, em função da menor proporção de falsos negativos identificados nas imagens; enquanto para o teste de especificidade tem-se que quanto menor a proporção de falsos positivos, maior é a especificidade do teste, ou seja, melhor identifica as plantas sem deficiência.

Evidencia-se um bom desempenho encontrado pelo classificador do Experimento IV com as RNA, verificado pela sensibilidade e especificidade do modelo. Esses resultados corroboram ao verificado por Luz et al. (2018) que, ao estudarem a análise de imagem para a identificação de deficiência de boro (B) em plantas de milho, verificaram que as folhas devidamente fertilizadas na solução de $0,60 \text{ mg L}^{-1}$ apresentaram uma taxa de classificação correta de 98% de acurácia na diferenciação entre folhas devidamente fertilizadas com B, de folhas com deficiência no estágio V4 de crescimento. Observa-se que, com os resultados obtidos, alcançaram-se altas taxas de sucessos nas discriminações da deficiência e suficiência, evidenciando, portanto, que essa é uma abordagem promissora para o diagnóstico nutricional, e corrobora com outros estudos recentes em nitrogênio (Romualdo et al., 2018; Zhang et al., 2020).

Quando aplicado o PDI para detecção nutricional em palma de óleo Asraf et al. (2012), verificaram bons desempenhos na classificação correta dos nutrientes, 71%, 100% e 69% para o fósforo, magnésio e nitrogênio, respectivamente. Em outras pesquisas, quando o PDI foi utilizado com a técnica de máquina de vetores de suporte (SVM), constatou-se que a precisão na detecção de doenças em folhas foi de 94,74%, com acurácia para a cultura do feijão, batata e tomate, iguais a 87,5, 96,43 e 82,15% (Arivazhagan et al., 2013). Araujo e Peixoto (2019), aplicando diversas combinações de técnicas de aprendizado de máquina para detecção

automática de doenças da soja com base na análise de cor, identificaram uma taxa de sucesso de 75,8%. Observa-se que, independentemente da técnica de classificação utilizada no PDI nas diferentes áreas agrônomicas, a precisão dos resultados torna o PDI favorável na identificação nutricional de plantas.

O uso do PDI mostra-se promissor no que diz respeito a fornecer conhecimento para um sistema automático de monitoramento, necessitando somente de um estudo maior com outras doses que estabeleçam níveis críticos do estado nutricional. Esse sistema poderá ser instalado em um dispositivo eletrônico, celular, por exemplo, que detectará a deficiência, transferindo as informações do monitoramento automaticamente. Pelo uso em dispositivos móveis, será acessível não só a grandes, mas também a pequenos e médios produtores, de maneira a evidenciar a importância destacada pela aplicação prática deste trabalho e se tornando um importante instrumento no diagnóstico do estado nutricional da rúcula.

3.4 CONCLUSÕES

O processamento digital de imagem não foi capaz de discriminar precocemente o estado nutricional da rúcula para nitrogênio.

O processamento digital de imagem foi capaz de discriminar plantas com deficiência em nitrogênio, na folha velha, somente aos 20 dias de crescimento na Fase III.

Quanto maior a concentração de nitrogênio na solução nutritiva, maior foi a taxa de acerto do classificador em discriminar plantas deficientes ou não em nitrogênio, segundo a imagem da folha velha.

O modelo gerado pelo classificador aos 20 dias, na folha velha, é altamente eficiente na identificação da deficiência (sensibilidade) e mais reduzido na identificação da ausência da deficiência (especificidade).

3.5 REFERÊNCIAS

Amaral ES, Silva DV, Anjos L, Schilling AC, Dalmolin ÂC, Mielke MS (2019) Relations hips between reflectance and absorbance chlorophyll indices with RGB

(*Red, Green, Blue*) image components in seed lings of tropical tree species at nursery stage. **New Forests** 50:377-388.

André RGB, Garcia A (2015) Alguns aspectos climáticos do município de Jaboticabal-SP. **Nucleus** 12:263-269.

Araujo JMM, Peixoto ZMA (2019) A new proposal for automatic identification of multiple soybean diseases. **Computers and Electronics in Agriculture** 167:1-9.

Arivazhagan S, Shebiah RN, Ananthi S, Varthini SV (2013) Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. *AgriculturalEngineeringInternational*: **CIGR Journal** 15:211-217. Disponível em: <<https://cigrjournal.org/index.php/Ejournal/article/view/2338>>. Acessado em setembro 15, 2020.

Asraf HM, Nooritawati MT, Rizam MS (2012) A comparative study in kernel-based support vector machine of oil palm leaves nutrient disease. **Procedia Engineering** 41:1353-1359.

Baranauskas JA (2001) **Extração automática de conhecimento por múltiplos indutores**. 205 f. Tese de Doutorado (Doutorado em Ciências de Computação e Matemática Computacional) - USP, São Carlos.

Boaretto AE, Chitolina JC, Raji BV, Silva FD, Tedesco MJ, Carmo CDS (1999) Amostragem, acondicionamento e preparação das amostras de plantas para análise química. Manual de análises químicas de solos, plantas e fertilizantes. 51-73p.

Carmo CDS, Araújo WS, Bernardi ADC, Saldanha MFC (2000) Métodos de análise de tecidos vegetais utilizados na Embrapa Solos (Embrapa Solos. Circular Técnica, 6), 41p.

Cecílio Filho AB, Maia MM, Cortez JWM, Rodrigues MA, Nowaki RHD (2014) Épocas de cultivo e parcelamento da adubação nitrogenada para rúcula. **Comunicata Scientiae** 5:252-258.

Cosme FCC (2002) Árvores de decisão. Disponível em: <<http://pt.scribd.com/doc/218178007/Arvores-de-decisao-doc>>. Acessado em agosto 20, 2020.

Efron B, Gong G (1983) A leisurely look at the boots trap, the jackknife, and cross-validation. **The American Statistician** 37:36-48.

Efron B, Tibshirani RJ (1993) Na Introduction to the Bootstrap.

Ferreira DF (2011) Sisvar: um sistema computacional de análise estatística. **Ciência e agrotecnologia** 35:1039-1042.

Fleiss JL (1981) Statistical methods for rates and proportions. **New York: John Wiley & Sons.**

Furlani PR (1998) Instruções para o cultivo de hortaliças de folhas pela técnica de hidroponia - NFT.

Galen RS, Gambino SR (1975) The predictive value and efficiency of medical diagnoses. J. Willey & Sons, New York.

Gonzalez RC, Woods RC (2009) Processamento digital de imagens. Pearson Educación.

Grangeiro LC, Oliveira FCL, Negreiros MZ, Marrocos STP, Lucena RRM, Oliveira RA (2011) Crescimento e acúmulo de nutrientes em coentro e rúcula. **Revista Brasileira de Ciências Agrárias** 6:11-16.

Halkier BA, Gershenzon J (2006) Biology and biochemistry of glucosinolates. **Annual Review of Plant Biology** 57:303-333.

Johnson RA, Wichern DW (2002) Applied multivariate statistical analysis. Upper Saddle River, NJ: Prentice hall.

Kimball S, Mattis P (2012) Gnu image manipulation program (gimp). The GIMP Development Team.

Li S, Liu X, Tian Y, Zhu Y, Cao Q (2018) Comparison RGB Digital Camerawith Active Canopy Sensor Basedon UAV for Rice Nitrogen Status Monitoring. In 2018 7th International Conference on Agro-geoinformatics (Agro-geoinformatics) 1-6.

Luz PHC, Marin MA, Devechio FFS, Romualdo LM, Zuñiga AMG, Oliveira MWS, Herling VS, Bruno OM (2018) Boron Deficiency Precisely Identified on Growth Stage V4 of Maize Crop Using Texture Image Analysis. **Communications in Soil Science and Plant Analysis** 49:159-169.

Mao H, Gao H, Zhang X, Kumi F (2015) Nondestructive measurement of total nitrogen in lettuce by integrating spectroscopy and computer vision. **Scientia Horticulturae** 184:1-7.

Mitchell TM (1997) Machine Learning, McGraw-Hill Higher Education. New York.

Miyazawa M, Pavan MA, Muraoka T, Carmo CAFS, Melo WJ (2009) Análise química de tecido vegetal. In: Silva FC (Ed.). **Manual de análises químicas de solos, plantas e fertilizantes**. 2. ed. Brasília: EMBRAPA, 191-233.

Piślewska-Bednarek M, Nakano RT, Hiruma K, Pastorczyk M, Sanchez-Vallet A, Singkaravanit-Ogawa S, Ciesiołka D, Takano Y, Molina A, Schulze-Lefert P, Bednarek P (2018) Glutathione transferase U13 functions in pathogen-triggered glucosinolate metabolism. **Plant Physiology** 176:538-551.

Purquerio LFV, Demant LAR, Goto R, Villas Boas RL (2007) Efeito da adubação nitrogenada de cobertura e do espaçamento sobre a produção de rúcula. **Horticultura Brasileira** 25:464-470.

Romualdo LM, Luz PHDC, Baesso MM, Devechio FDFDS, Bet JA (2018). Spectral indexes for identification of nitrogen deficiency in maize. **Revista Ciência Agronômica** 49:183-191.

Sancho-Adamson M, Trillas MI, Bort J, Fernandez-Gallego JÁ, Romanyà J (2019) Use of RGB vegetation indexes in assessing early effects of Verticillium Wilt of Olive in asymptomatic plants in high and low fertility scenarios. **Remote Sensing** 11:607.

Schneider CA, Rasband WS, Eliceiri KW (2012) NIH Image to ImageJ: 25 years of image analysis. *Nature methods* 9:671-675.

Sena Júnior DGD, Pinto FDADC, Gomide RL, Teixeira MM (2003) Avaliação de métodos automáticos de limiarização para imagens de plantas de milho atacadas por Spodopterafrugiperda. **Revista Brasileira de Engenharia Agrícola e Ambiental** 7:359-366.

Silva RMG, Guimarães MLC, Paiva KFS, Severo PJN, Santos E, Marcelino RMOS, Dias VB, Rocha JLA (2019). Frações de nitrogênio no solo e na fitomassa foliar de berinjela e rúcula sob doses de nitrogênio associadas à extratos de Nim. **Brazilian Journal of Development** 5:15896-15911.

Silva SHMG (2008) **Processamento digital de imagens para identificação da sigatoka negra em bananais utilizando análise de componentes principais e redes neurais artificiais**. 94 f. Tese de Doutorado (Doutorado em Agronomia - Energia na Agricultura) - Unesp, Botucatu.

Taffner J, Cernava T, Erlacher A, Berg G (2019) Novel insights into plant-associated archaea and their functioning in arugula (*Eruca sativa* Mill.). **Journal of advance dresearch** 19:39-48.

Vieira Filho OS, Oliveira GQ, Biscaro GAA, Motomiya AV, Geisenhoff LO (2017) Fertirrigação com nitrogênio na cultura da rúcula. **Agrarian** 10:304-310.

Witten IH, Frank E, Mark AH, Christopher JP (2017) Data mining: Practical machine learning tools and techniques.

Yuan Y, Chen L, Li M, Wu N, Wan L, Wang S (2016) Diagnosis of nitrogen nutrition of rice base donimage processing of visible light. In 2016 IEEE. International Conferenceon Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications (FSPMA) 228-23.

Zhang M, Zhou J, Sudduth KA, Kitchen NR (2020) Estimation of maize yield and effects of variable-rate nitrogen application using UAV-based RGB imagery. **Biosystems Engineering** 189:24-35.

Chlingaryan A, Sukkarieh S, Whelan B (2018) Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. **Computers and electronics in agriculture** 151: 61-69.

Xiong X, Zhang J, Guo D, Chang L, Huang D (2019) Non-Invasive Sensing of Nitrogen in Plant Using Digital Images and Machine Learning for Brassica Campestris ssp. Chinensis L. **Sensors** 19:2448.