

RESSALVA

Atendendo solicitação do(a) autor(a), o texto completo desta dissertação será disponibilizado somente a partir de 18/02/2022.



ESTIMATIVA DE NITROGÊNIO EM *Annona emarginata* (Schltdl.) H. Rainer
UTILIZANDO ESPECTROSCOPIA NO INFRAVERMELHO PRÓXIMO (NIRS) -
UMA ABORDAGEM ESTATÍSTICA E COMPUTACIONAL

RAFAELA LANÇAS GOMES

**Dissertação de Mestrado apresentada
ao Instituto de Biociências, campus
de Botucatu, UNESP, para obtenção
do título de Mestre em Ciências
Biológicas (Botânica), Área de
concentração: Fisiologia Vegetal.**

UNESP - UNIVERSIDADE ESTADUAL PAULISTA

CÂMPUS DE BOTUCATU

INSTITUTO DE BIOCÊNCIAS

**ESTIMATIVA DE NITROGÊNIO EM *Annona emarginata* (Schltdl.) H. Rainer
UTILIZANDO ESPECTROSCOPIA NO INFRAVERMELHO PRÓXIMO (NIRS) -
UMA ABORDAGEM ESTATÍSTICA E COMPUTACIONAL**

RAFAELA LANÇAS GOMES

PROF^a DR^a GISELA FERREIRA

ORIENTADORA

PROF^o DR^o JOSÉ RAIMUNDO DE SOUZA PASSOS

CO-ORIENTADOR

**Dissertação de Mestrado apresentada
ao Instituto de Biociências, campus
de Botucatu, UNESP, para obtenção
do título de Mestre em Ciências
Biológicas (Botânica), Área de
concentração: Fisiologia Vegetal.**

**BOTUCATU - SP
- 2019 -**

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉC. AQUIS. TRATAMENTO DA INFORM.
DIVISÃO TÉCNICA DE BIBLIOTECA E DOCUMENTAÇÃO - CÂMPUS DE BOTUCATU - UNESP

BIBLIOTECÁRIA RESPONSÁVEL: ROSEMEIRE APARECIDA VICENTE-CRB 8/5651

Gomes, Rafaela Lanças.

Estimativa de nitrogênio em *Annona emarginata* (Schltdl.)
H. Rainer utilizando espectroscopia no infravermelho próximo
(NIRS) : uma abordagem estatística e computacional / Rafaela
Lanças Gomes. - Botucatu, 2020

Dissertação (mestrado) - Universidade Estadual Paulista
"Júlio de Mesquita Filho", Instituto de Biociências de
Botucatu

Orientador: Gisela Ferreira

Coorientador: José Raimundo de Souza Passos

Capes: 20303009

1. Plantas dos cerrados. 2. Bootstrap (Estatística).
3. Plantas - Nutrição. 4. Espectroscopia de infravermelho.
5. Análise espectral. 6. Redes neurais (Computação).

Palavras-chave: Aprendizado de máquinas; Bootstrap; Nutrição
mineral de plantas; Redes neurais artificiais; Índice
espectral de vegetação.

Agradecimentos

Á Deus, por ter colocado pessoas maravilhosas no meu caminho e me dado muitas oportunidades para seguir os meus sonhos.

Aos meus pais, avós, tia e irmão, que sempre me apoiaram em minhas decisões e acreditaram em mim, mesmo quando eu não acreditava.

Aos meus amigos Vitor Borges Pimenta, Carolina Aparecida Duarte Pereira Randovanovic, Hiran Tsai Sun e todos que me ajudaram a fazer este experimento acontecer e me apoiaram durante o mestrado.

Á minha família de laboratório, por toda a ajuda, apoio e companheirismo.

Ao Felipe Giroto Campos e a Marília Caixieta, por seus ensinamentos, e por me acompanhar durante todo o experimento e escrita.

Ao João Ricardo Favan e André Stefanini Jim pela ajuda e apoio com o equipamento e a programação.

Á todos os meus professores, que me guiaram a construir este caminho, em especial a professora Beatriz que me alfabetizou e aos professores Fábio e Isabela, cujas aulas de redação e as correções me proporcionaram base para conseguir escrever esta dissertação.

Ao professor José Raimundo de Souza Passos, meu mentor desde o meu primeiro ano, que me ensina até hoje a como ser um cientista.

Á professora Gisela Ferreira por ter me orientado e colaborado com a solução de todos os problemas que apareceram no caminho.

Ao programa de pós-graduação e á Capes, pelo apoio a pesquisa e a bolsa concedida.

Lista de abreviações:

ACP	Análise de Componentes Principais
CFS	<i>Correlation Based Feature Selection</i> (Seleção de Atributos Baseada em Correlação)
CSE	<i>Classifier Subset Evaluator</i> (Avaliador de Subconjunto Classificador)
E	Eficiência (índice criado)
FIR	<i>Far Infrared</i> (Infravermelho Distante)
FLD	Função Linear Discriminante
FQD	Função Quadrática Discriminante
IEV	Índice Espectral de Vegetação
LWIR	<i>Long-Wavelength Infrared</i> (Infravermelho de Ondas Longas)
MCC	<i>Multi Class Classifier</i> (Classificador Multi-Classe)
MIR	<i>Middle-Infrared</i> (Infravermelho Médio)
mSR	<i>Modified Simple Ratio</i> (Relação Simples Modificada)
MWIR	<i>Mid-Wavelength Infrared</i> (Infravermelho de Ondas Médias)
N	Nitrogênio
ND	<i>Normalized difference index</i> (Índice de Diferença Normalizada)
NDVI	<i>Normalized Difference Vegetation Index</i> (Índice de Diferença de Vegetação Normalizado)
NIR	<i>Near-Infrared</i> (Infravermelho Próximo)
NIRS	<i>Near-Infrared Spectroscopy</i> (Espectroscopia no Infravermelho Próximo)
PMC	<i>Perceptron</i> Multicamadas
PRI	<i>Photochemical Reflection Index</i> (Índice de Reflexão Fotoquímica)
PSND	<i>Pigment Specific Normalized Difference</i> (Diferença Normalizada Específica do Pigmento)
PSSR	<i>Pigment Specific Simple Ratio</i> (Relação Simples Específica de Pigmento)
R Log	Regressão Logística
RNA	Redes Neurais Artificiais
SR	<i>Simple Ratio</i> (Relação Simples)
SVM	<i>Suport Vector Machine</i> (Máquinas de Vetor Suporte)
SWIR	<i>Short-Wavelenght Infrared</i> (Infravermelho de Ondas Curtas)

Sumário:

1. Resumo	1
1.1. Abstract	2
2. Introdução Geral	3
1.1. Objetivos Gerais	6
1.2. Objetivos Específicos	6
3. Revisão Bibliográfica	7
3.1. Nutrição Mineral de Plantas	7
3.1.1. Tipos de Nutrientes	8
3.1.2. Sinais de Deficiência	8
3.1.3. Nitrogênio	9
3.2. Espectroscopia no Infravermelho Próximo (NIRS)	10
3.2.1. Funcionamento	11
3.2.2. A Reflectância Foliar	11
3.2.3. Vantagens e Aplicações em Ciências de Plantas	13
3.3. Aprendizado de Máquinas e Redes Neurais Artificiais	15
3.3.1. Como Máquinas Aprendem ?	16
3.3.2. O Neurônio Biológico	17
3.3.3. O Neurônio Artificial	18
3.3.4. WEKA	19
3.3.4.1. Alguns Algoritmos de Seleção de Atributos	19
3.3.4.2. Alguns Algoritmos de Classificação	21
3.3.5. Aplicações em Ciências de Plantas	22
3.4. análise Estatística	24
3.4. 1. Análise Multivariada	24
3.4.2. Simulação <i>Bootstrap</i>	25
3.4.3. Modelos Lineares Generalizados	25
3.5. Índices Espectrais de Vegetação	26
3.6. Família Annonaceae	27
3.6.1. Estudos Nutricionais com a Família	28
3.6.2. <i>Annona emarginata</i> (Schltdl.) H. Rainer	29
4. Capítulo 1 - Identificação da falta de nitrogênio em mudas de <i>Annona emarginata</i> (Schltdl.) H. Rainer antes do aparecimento de sinais visuais utilizando NIRS	31
4.1. Resumo	31
4.2. Introdução	33
4.3. Material e Métodos	34
4.4. Resultados	38
4.5. Discussão	44
4.6. Conclusões	49
4.7. Referências	49
5. Capítulo 2 - Aplicação de algoritmos de aprendizado de máquinas para identificação da falta de nitrogênio em mudas de <i>Annona emarginata</i> (Schltdl.) H. Rainer antes do aparecimento de sinais visuais utilizando NIRS e fotografias digitais	53

4.1. Resumo	53
4.2. Introdução	55
4.3. Material e Métodos	56
4.4. Resultados	59
4.5. Discussão	70
4.6. Conclusões	73
4.7. Referências	73
6. Considerações Finais	76
7. Referências Bibliográficas	77
8. Apêndices	
8.1. Apêndice A	95
8.2. Apêndice B	96

1. Resumo

O nitrogênio é um elemento mineral essencial para as plantas. Sua deficiência em fases iniciais do desenvolvimento pode gerar alterações fisiológicas e morfológicas que reduzem o crescimento e conflui na não expressão total do potencial genético vegetal. As técnicas mais difundidas para a quantificação do N nas plantas demandam tempo, são destrutivas e liberam compostos tóxicos para o ambiente. A NIRS (*Near-Infrared Spectroscopy* - Espectroscopia no Infravermelho Próximo), se apresenta como uma técnica alternativa, sendo indireta, mas instantânea, não destrutiva e que não utiliza reagentes químicos, mas necessita de calibração, que pode ser feita por métodos estatísticos e computacionais. Para mudas que são produzidas em viveiros, como as de *Annona emarginata* (Schltdl.) H. Rainer, é essencial manter o monitoramento de N, de forma rápida e não danosa, para garantir a qualidade e vigor das mudas. Desta forma, este trabalho visou detectar alterações na caracterização espectral foliar de *A. emarginata* em função do fornecimento de concentrações de nitrogênio e classificar as mudas em função dos níveis de nitrogênio, com base na caracterização espectral, utilizando algoritmos de aprendizado de máquinas e análise estatística multivariada. As mudas de *A. emarginata* (240) foram mantidas em sistema de hidroponia, com alterações na concentração de nitrogênio: 0 mg.L⁻¹ de N (T1); 52,5 mg.L⁻¹ de N (T2); 105 mg.L⁻¹ de N (T3) e 210 mg.L⁻¹ de N (T4), com 60 repetições (mudas) para cada tratamento. Após 45 dias nestas soluções, foram coletadas três folhas de cada planta, fotografadas e aferidas suas caracterizações espectrais. Foram testadas diversas combinações de técnicas de redução e de classificação estatísticas e de aprendizado de máquinas e propostos índices espectrais com os comprimentos de onda mais selecionados. Quanto às variáveis fisiológicas, foram analisadas as trocas gasosas, fluorescência e pigmentos foliares. Pela caracterização espectral, percebe-se um afastamento total das curvas de mudas com falta e sem falta de N. Conclui-se que a técnica NIRS pode ser aplicada para a detecção de variações na concentração de N nas folhas de plantas jovens (mudas), antes do aparecimento de sinais visuais e que técnicas estatísticas são melhores para se fazer a calibração do método do que técnicas de aprendizado de máquinas.

Palavras chave: redes neurais artificiais, aprendizado de máquinas, *perceptron* multicamadas, nutrição mineral de plantas, *bootstrap*, índice espectral de vegetação.

1.1. Abstract

Nitrogen is an essential mineral element for plants. Its deficiency in early stages of development can lead to physiological and morphological changes that reduce growth and result in the total non-expression of plant genetic potential. The most widespread techniques for quantifying N in plants are time consuming, destructive and release toxic compounds into the environment. Near-Infrared Spectroscopy (NIRS) is an alternative technique, being indirect, but instantaneous, non-destructive and does not use chemical reagents, but needs calibration, which can be done by statistical and computational methods. For seedlings that are produced in nurseries, such as those of *Annona emarginata* (Schltdl.) H. Rainer, it is essential to keep N monitoring fast and harmless to ensure seedling quality. Thus, this work aimed to detect changes in the leaf spectral characterization of *A. emarginata* as a function of nitrogen concentration supply and to classify seedlings as a function of nitrogen levels, based on spectral characterization, using machine learning algorithms and multivariate statistical analysis. 240 *A. emarginata* seedlings were maintained in a hydroponic system, with modifications in nitrogen concentration: 0 mg.L⁻¹ of N (T1); 52.5 mg.L⁻¹ of N (T2); 105 mg.L⁻¹ N (T3) and 210 mg.L⁻¹ N (T4), with 60 replications (seedlings) for each treatment. After 45 days in these solutions, three leaves of each plant were collected, photographed and their spectral characterizations was measured. Several combinations of reduction and classification techniques and machine learning techniques were tested and proposed spectral indexes. Regarding the physiological variables, gas exchange, fluorescence and leaf pigment were analyzed. Due to the spectral characterization, it is possible to observe a total deviation of the curves with the N lacking and non-lacking seedlings. It can be concluded that the NIRS technique can be applied to detect variations in N concentration in the leaves of seedlings before visual symptoms appear, and which statistical techniques are better for method calibration than machine learning techniques.

Key words: artificial neural networks, machine learning, multilayer perceptron, plant mineral nutrition, *bootstrap*, vegetation spectral indexes.

2. Introdução Geral

A família *Annonaceae* é uma das maiores famílias dos trópicos e sub-trópicos, tendo mais de 2500 espécies distribuídas pantropicalmente (ESCRIBANO; VIRUEL; HORMAZA, 2007), sendo uma das mais diversificadas presentes nas florestas tropicais (COUVREUR *et al.*, 2011). Ela possui grande importância ecológica e tem gerado interesse econômico em decorrência de espécies cujos metabólitos especializados tem grande ação anti inflamatória (ATTIQ, JALIL, HUSAIN, 2011) e potencial antiproliferativo em células cancerígenas (PIEME *et al.*, 2014) e de espécies com frutos de sabor agradável e elevado valor nutritivo.

Dentre seus gêneros, o *Annona* é o mais cultivado no Brasil, graças a algumas espécies de importância econômica, como a pinha, ou fruta-do-conde (*Annona squamosa* L.), a graviola (*Annona muricata* L.), a cherimóia (*Annona cherimola*, Mill.) e o híbrido atemoia (*Annona x atemoya* Mabb.), cujos frutos possuem elevado valor comercial e geram interesse tanto no mercado interno como no externo, principalmente o norte americano e europeu (SOBRINHO, 2010). Para a produção de mudas de *Annona*, todas as copas comerciais são enxertadas em espécies nativas (SOBRINHO, 2010).

Para o cultivo de atemoia, que nos últimos anos vem tendo a preferência dos consumidores graças a suas boas características (SOBRINHO, 2010), um dos porta-enxerto mais utilizados para a sua propagação é a *Annona emarginata* (Schltdl.) H. Rainer (TOKUNAGA, 2005), uma espécie nativa do Brasil que fornece resistência para diversas podridões de colo e raiz e coleobrocas (TOKUNAGA, 2005) e garante copa vigorosa (SCALOPPI JUNIOR, 2007).

O restabelecimento do tecido na região enxertada é afetado por diversos fatores, dentre eles, se destacam as características nutricionais do porta-enxerto (BARON *et al.*, 2016), o que torna o monitoramento nutricional em viveiros de mudas de *A. emarginata* de extrema importância, a fim de permitir a detecção de deficiências antes, ou pelo menos na fase inicial da manifestação de sinais visuais (sintomas).

Dentre os nutrientes essenciais exigidos pelas plantas, o nitrogênio (N) é um dos elementos-chave cuja demanda é relativamente grande em comparação com a de outros elementos (WANG *et al.*, 2017), e portanto seu monitoramento precisa ser efetivo, principalmente em culturas perenes, como as frutíferas. Ele é essencial em todas as fases do desenvolvimento das plantas (FERNANDES; ROSSIELO, 1995), pois faz parte da composição de proteínas e compostos orgânicos essenciais, dentre eles

clorofilas, ácidos nucléicos, aminoácidos, auxina, alcaloides, citocininas, e algumas enzimas como a *Rubisco* (ribulose-1,5-bisfosfato carboxilase oxigenase) (MAATHUIS, 2009; OSAKI *et al.*, 1993). A falta de N nas fases iniciais do desenvolvimento gera consequências para a planta, como alterações fisiológicas e morfológicas que reduzem seu crescimento e faz com que não expressem totalmente seu potencial genético (EVANS, 1989), o que justifica constante monitoramento deste elemento em viveiros.

A concentração foliar de N pode ser aferida de diversas formas. Os métodos mais comuns para se fazer esta análise são os diretos, como o de Kjeldahl (JONES, 1991), mas tais análises demandam tempo, utilizam compostos tóxicos ao meio, como ácido bórico e requerem coletas com avaliações destrutivas do vegetal (MALAVOLTA *et al.*, 1997).

Uma alternativa para a avaliação nutricional não destrutiva de plantas é a Espectroscopia no Infravermelho Próximo (*Near-Infrared Spectroscopy* - NIRS), uma técnica analítica que permite inferir de modo indireto os compostos de um material com base em sua reflectância (FERRARESI, 2012). A NIRS possibilita a detecção mais rápida das características nutricionais das plantas em relação a determinado elemento, evitando os inconvenientes das análises convencionais, como a destruição da massa de matéria seca da planta, o elevado tempo e custo necessários para a quantificação em laboratório especializado.

Para que ocorra bom funcionamento desta técnica, é necessário primeiro calibrar, já que é um método indireto (OTTO, 1999). Isto pode ser feito com diversos métodos. Como a resposta adquirida com o NIRS é multivariada, geralmente são utilizadas técnicas estatísticas de análise multivariada para a calibração, mas, atualmente, existem metodologias alternativas computacionais que podem ser empregadas, como as técnicas de aprendizado de máquinas, que consistem na modelagem do comportamento de um ser inteligente (FACELI *et al.* 2011).

Apesar da larga utilização na área biológica e botânica, existem poucos estudos que mostram a aplicação de aprendizado de máquinas e particularmente redes neurais artificiais para nutrição mineral de plantas, sendo esta, uma técnica potencialmente promissora para a área.

Quando o sinal de deficiência se torna visível, o dano, já estará estabelecido, o que muitas vezes pode ser irreversível, resultando em redução da produtividade. Uma vantagem da técnica NIRS é que como a resposta no infravermelho está associada a alterações nos compostos foliares (MAHLEIN, 2016), em alguns casos é possível

detectar alterações em sua caracterização espectral antes do aparecimento de sinais visíveis, possibilitando efetuar correções prevenindo reduções significativas na produtividade primária.

Dentre os avanços na área de nutrição mineral com NIRS, não existem relatos para a família *Annonaceae*, desta forma, fazer a avaliação do estado nutricional de mudas de anonáceas com esta técnica será de grande importância no manejo das áreas de produção, que estão em constante expansão, podendo ser uma ferramenta de grande interesse, uma vez que os próprios estudos nutricionais para esta família são escassos (ROZANE; NATALE, 2014).

O estudo da *A. emarginata* durante a fase de desenvolvimento inicial representa também um avanço no fornecimento de mudas melhor nutridas e adaptadas para serem utilizadas em áreas de recuperação ambiental, além de redução no tempo de viveiro para a produção de porta-enxertos, o que pode resultar em redução de custo da muda.

Deste modo, o estabelecimento de métodos rápidos, simples e não destrutivos para quantificar o nitrogênio em anonáceas, como o NIRS e aprendizado de máquinas, são importantes para avaliar precocemente deficiências nutricionais que possam resultar em danos no metabolismo e que, conseqüentemente, comprometam a sobrevivência e o desenvolvimento das plantas desde os estádios iniciais de desenvolvimento em viveiro.

Neste contexto e considerando a importância da espécie *A.emarginata*, esta dissertação teve o propósito de avaliar se a NIRS é efetiva para detectar variações de N em folhas de mudas de *A.emarginata*, empregando-se de técnicas de aprendizado de máquinas e análises estatísticas multivariadas.

6. Considerações Finais

Este estudo é inovador por aplicar NIRS em uma espécie nativa e arbórea com o intuito de averiguar o status nutricional de N, sendo o primeiro a associar NIRS,

aprendizado de máquinas e fotografias digitais a uma espécie do gênero *Annona*. Ele abre portas para novas aplicações de NIRS e aprendizado de máquinas em plantas da família Annonaceae.

As plantas desta família desempenharão um importante papel no futuro do controle biológico de pragas, sendo essenciais para a produção de extratos. Isso ocorre em decorrência de sua alta produção de alcaloides, que são moléculas nitrogenadas. Assim, o monitoramento de N nestas plantas é essencial para uma futura linha de produção de Annonáceas com o intuito da fabricação destes extratos. Desta forma, este trabalho é o começo da produção em silvicultura de precisão para esta família.

7. Referências Bibliográficas

ADHIKARI, A. DENERO, J. **Artificial Intelligence: Foundations of Computational Agents**, second edition, Cambridge University Press, 2017.

- Annona* in **Flora do Brasil 2020 em construção**. Jardim Botânico do Rio de Janeiro. Disponível em: <<http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB110243>>. Acesso em: 26 Nov. 2019
- AQUINO, C.F.; Salomão, L.C.C.; Azevedo, A.M. Fenotipagem de alta eficiência para vitamina A em banana utilizando redes neurais artificiais e dados colorimétricos. **Bragantia**, Campinas, v. 75, n. 3, p.268-274, 2016.
- ATTIQ, A.; JALIL, J.; HUSAIN, K. Annonaceae: Breaking the Wall of Inflammation. **Front. Pharmacol.** v.8 p.752-776. 2017. doi: 10.3389/fphar.2017.00752
- BACKHAUS, A.; BOLLENBECK, F.; SEIFFERT, U. Robust classification of the nutrition state in crop plants by hyperspectral imaging and artificial neural networks. Proceedings of the 3rd IEEE Workshop on Hyperspectral Imaging and Signal Processing: **Evolution in RemoteSensing** WHISPERS 2011, page 9. IEEE Press, 2011.
- BAIN, K.F.; VERGÉS A.; POORE, A.G.B. Using near infra red reflectance spectroscopy (NIRS) to quantify tissue composition in the seagrass *Posidonia australis*. **Aquatic Botany**, v.111, p.66–70, 2013.
- BARANOSKI, G.V.G.; ROKNE, J.G. . Efficiently simulating scattering of light by leaves. **The Visual Computer**, v.17, p.491–505, 2001.
- BARBOSA, Z.; SOARES, I.; CRISÓSTOMO, L.A. Crescimento e absorção de nutrientes por mudas de graviola. **Rev. Bras. Frutic.**, Jaboticabal - SP, v. 25, n. 3, p. 519-522, 2003.
- BARKER, A.V.; PILBEAM, D.J. **Handbook of plant nutrition**. CRS Press, v.2., 2015.
- BARON, D.; AMARO, A. C. E.; MACEDO, A. C.; BOARO, C. S. F.; FERREIRA, G.. Is *annona emarginata* capable of accumulate essential heavy metals without damages in the metabolism?. **Rev. Bras. Frutic.**, Jaboticabal , v. 39, n. 4, e-646, 2017 .
- BARON, D.; BRAVO, J.P.; MAIA, I.G.; PINA, A.; FERREIRA, G.. UGP gene expression and UDP-glucose pyrophosphorylase enzymatic activity in grafting annonaceous plants. **Acta Physiol Plant**, v.38, p.79, 2016.
- BARON, D.; FERREIRA, G. ; RODRIGUES, J. D. ; BOARO, C.S.F.; MACEDO, A. C.. Gs exchange, physiological indexes and ionic accumulation in *Annona emarginata* (Schltdl.) H. Rainer seedlings in nutrients solution. **Revista Brasileira de Fruticultura**, Jaboticabal-SP, v. 36, p. 361-376, 2013.

- BATISTA, M.M.F.; VIÉGAS, I.J.M.; FRAZÃO, D.A.C.; THOMAZ, M.A.A.; SILVA, R.C.L. EFEITO DA OMISSÃO DE MACRONUTRIENTES NO CRESCIMENTO, NOS SINTOMAS DE DEFICIÊNCIAS NUTRICIONAIS E NA COMPOSIÇÃO MINERAL EM GRAVIOLEIRAS (*Annona muricata*). **Rev. Bras. Frutic.**, Jaboticabal - SP, v. 25, n. 2, p. 315-318, Agosto 2003.
- BINOTI, D.H.B.; BINOTI, M.L.M.S.; LEITE, H.G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira (Braz. J. Wood Sci.)**, Pelotas, v. 05, n. 01, p. 58-67, Maio de 2014.
- BIRTH, S.G.; MCVEY, R.G. Measuring the color of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, v.60, p.640–643, 1968.
- BLACKBURN, G.A. Quantifying chlorophylls and carotenoids at leaf and canopy scale: an evaluation of some hyperspectral approaches. **Remote Sensing of Environment**, v.66, p.273–285, 1998.
- BLOOM, A. J. et al. Carbon dioxide enrichment inhibits nitrate assimilation in wheat and Arabidopsis. **Science**, v.328, p.899–903, 2010.
- BUCENE, L.C.; RODRIGUES, L.H.A. Utilização de redes neurais artificiais para avaliação de produtividade do solo, visando classificação de terras para irrigação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.8, n.2/3, p.326-329, 2004.
- BUCHANAN, GRUISSEM, JONES. **Biochemistry & Molecular Biology of Plants**. Rockville: American Society of Plant Physiologists (ASPP0), 2nd ed., 2015.
- BURNS, D.A., CIURCZACK, E.W. Handbook of Near Infrared Analysis. New York: Marcel Dekker, 2nd ed. 2001.
- CAJAL, S. R. Y. The Croonian Lecture: La Fine Structure des Centres Nerveux. **Proceedings of the Royal Society of London**, v. 55, n. 331-335, p. 444–468, 1 jan. 1894.
- CAMPOS, F. G.; BARON, D.; MARQUES, R.M. de ; FERREIRA, G. ; BOARO, C.S.F . Characterization of the chemical composition of the essential oils from *Annona emarginata* (Schltdl.) H. Rainer 'terra-fria' and *Annona squamosa* L.. **Revista Brasileira de Fruticultura** (Impresso), v. 36, p. 202-208, 2014.
- CARTER, G. A.; KNAPP, A. K. Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. **Am. J. Bot.** v.88, p.677-684, 2001. <https://doi.org/10.2307/2657068>

- CHATROU, L.W. et al. The natural history of Annonaceae. **Botanical Journal of the Linnean Society**, v.169, p.1–4, 2012.
- CHIDAMBARAM, S.; SRINIVASAGAN, K.G. **Optimization Approach for Feature Selection and Classification with Support Vector Machine**. In: Behera H., Mohapatra D. (eds) Computational Intelligence in Data Mining—Volume 1. Advances in Intelligent Systems and Computing, New Delhi:Springer, vol 410., 2016. https://doi.org/10.1007/978-81-322-2734-2_11
- CONSELHO ESTADUAL DO MEIO AMBIENTE, RIO GRANDE DO SUL. Decreto estadual CONSEMA n. 42.099 de 31 de dezembro de 2002. Declara as espécies da flora nativa ameaçadas de extinção no estado do Rio Grande do Sul e da outras providências, Palácio Piratini, Porto Alegre, Rio Grande do Sul, 31 dez. 2002, 2002.
- COSTA, A.M.; CARLOS, L.; SILVA, P.O.; BARBOSA, K.P.; RODRIGUES, C.R. . Nitrogen and Potassium Fertilization in the Initial Growth of *Annona crassiflora* Mart. **Floresta Ambient.**, Seropédica, v.26, n.2, e20170341, 2019.
- COSTA, S.L. da; CARVALHO, A.J.C. de; PESSANHA, P.G.O.; MONNERAT, P.H.; MARINHO, C.S. Produtividade da cultura da pinha (*Annona squamosa* L.) em função de níveis de adubação nitrogenada e formas de aplicação de boro. **Rev. Bras. Frutic.**, Jaboticabal , v. 24, n. 2, p. 543-546, Aug. 2002.
- COUVREUR, T.L.; PIRIE, M.D.; CHATROU, L.W.; SAUNDERS, R.M.; SU, Y.C.; RICHARDSON, J.E.; et al. . Early evolutionary history of the flowering plant family Annonaceae: steady diversification and boreotropical geodispersal. **J. Biogeogr.**, v.38, p.664–680, 2011. doi: 10.1111/j.1365-2699.2010.02434.x
- CURRAN, P.J.. Remote sensing of foliar chemistry. **Remote Sensing of Environment**, v.30, p.271–278, 1989.
- DONADIO, L. C. Situação atual e perspectivas das anonáceas. In: SÃO JOSÉ, A. R.; VILAS BOAS, I.; MARAIS, O. M.; REBOUÇAS, T. N. H. (Ed.). **Anonáceas: produção e mercado** (pinha, graviola, atemóia e cherimólia). Vitória da Conquista: Universidade Estadual do Sudoeste da Bahia, 1997. p.1-4.
- EFRON, B. **Bootstrap methods: Another look at the Jackknife**. Ann. Statistics, vol 7(1) p.1-26, 1979.
- EFRON, B.; TIBISHIRANI, R. J. **An introduction to the bootstrap**. New York: John Wiley & Sons, p. 642, 1993.

- ESCRIBANO, P.; VIRUEL M.A.; HORMAZA, J.I. Molecular analysis of genetic diversity and geographic origin within an ex situ germplasm collection of cherimoya by using SSRs. **J Am Soc Hortic Sci**, v.132, p.357–367, 2007.
- EVANS, J.R. Photosynthesis and nitrogen relationship in leaves of C3 plants. **Oecologia**, Berlim, v. 78, p.9-19, 1989.
- EVANS, S.M.; SINCLAIR, E.A.; POORE, A.G.B.; BAIN, K.F.; VERGÉS, A. Assessing the effect of genetic diversity on the early establishment of the threatened seagrass *Posidonia australis* using a reciprocal-transplant experiment. **Restoration Ecology**, v. 26, n. 3, pp. 570–580, May 2018.
- FACELI, K.; LORENA, A.; GAMA, J.; CARVALHO, A. Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina, **LTC**, 2011.
- FERNANDES, M.S.; ROSSIELLO, R.O.P. Mineral Nitrogen in Plant Physiology and Plant Nutrition. **Critical Reviews in Plant Sciences**, Boca Raton, v.14, n.2, p.111-148, 1995.
- FERNÁNDEZ, S.; VIDAL, D.; SIMÓN, E.; SUGRAÑES, L. Radiometric characteristics of *Triticum aestivum* cv. Astral under water and nitrogen stress. **International Journal of Remote Sensing**, London, v. 15, n. 9, p. 1867-1884, 1994.
- FERRARESI, Tatiana Maris et al . Espectroscopia de infravermelho na determinação da textura do solo. **Rev. Bras. Ciênc. Solo**, Viçosa , v. 36, n. 6, p. 1769-1777, 2012.
- FONSECA, E.L. da; ROSA, L.M.G.; FONTANA, D.C. Caracterização espectral de *Paspalum notatum* em diferentes níveis de adubação nitrogenada. **Pesquisa agropecuária brasileira**, Brasília, v.37, n.3, p. 365-371, mar. 2002.
- GALVEZ-SOLA L, GARCÍA-SÁNCHEZ F, PÉREZ-PÉREZ JG, et al. Rapid estimation of nutritional elements on citrus leaves by near infrared reflectance spectroscopy. **Frontiers in Plant Science**. v.6, a.571, 2015. doi:10.3389/fpls.2015.00571.
- GAMON, J.A.; PEÑEULAS, J.; FIELD, C.B. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**, v.41, p.35–44, 1992.
- GITELSON, A.A.; MERZLYAK, M.N. Spectral reflectance changes associate with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation. **Journal of Plant Physiology**, v.143, p.286–292, 1994.

- HAIR, Joseph F., Jr.. ANDERSON, Rolph E., TATHAM, Ronald L., BLACK William C. **Multivariate Data Analysis: with readings** (fourth edition). Upper Saddle River, New Jersey: Prentice Hall, 1995. 745 pp.
- HALL, M.A.. **Correlation-based feature selection for machine learning**. PhD thesis, Department of Computer Science, University of Waikato, Hamilto, New Zealand, 1998.
- HALL, M.A. Correlation-Based Feature Selection for Machine Learning. **Department of Computer Science**, v.19, 2000.
- HALL, M. A.; SMITH, L. A. . **Practical feature subset selection for machine learning**. In C. McDonald (Ed.), Computer Science '98 Proceedings of the 21st Australasian Computer Science Conference ACSC'98, Perth, 4-6 February, (pp. 181-191). Berlin: Springer, 1998.
- HAYKIN, S. **Redes Neurais: Principio e Prática**. 2. ed. Porto Alegre: Bookman, 2001.
- HODGKIN, A. L.; HUXLEY, A. F. A quantitative description of membrane current and its application to conduction and excitation in nerve. **The Journal of Physiology**. v.117, n.4, p.500–544, 1952.
- JACQUEMOUD, S.; USTIN, S. L. Leaf optical properties: a state of the art. in: **Proceedings of the 8th International Symposium Physical Measurements & Signatures in Remote Sensing**, 8–12 January 2001, CNES, Aussois, France. p.223-232, 2001.
- JASINSKI, S.; LÉCUREUIL, A.; DURANDET, M.; BERNARD-MOULIN, P.; GUERCHE, P. .Arabidopsis Seed Content QTL Mapping Using High-Throughput Phenotyping: The Assets of Near Infrared Spectroscopy. **Front. Plant Sci**. v.7, 2016. doi: 10.3389/fpls.2016.01682
- JENSEN, J.R.. **Remote sensing of the environment – An earth resource perspective**. [reprint.] edition. The MIT Press and MIT Press, Upper Saddle River, NJ, USA, 2002.
- JI-YONGA, S.; XIAO-BOA, Z.; JIE-WENA, Z.; HOLMES, M.; KAI-LIANGA, W.; XUEA, W.; HONGA, C. Determination of total flavonoids content in fresh Ginkgo biloba leaf with different colors using near infrared spectroscopy. **Spectrochimica Acta Part A**, v. 94, p. 271-276, Aug. 2012.
- JONES, J. B. Jr. **Kjeldahl method for nitrogen determination**. 1 ed. Athens: Micro-Macro Publishing, Inc., 1991.

- JOHNSON, R. ; WICHERN, D. **Applied Multivariate Statistical Analysis**. 6 Ed . Prentice Hall, New Jersey, 2014.
- KATZ, B. Nerve, muscle, and synapse. 5. ed. Nova York: McGraw-Hill, 1966.
- KAVATI, R. **Porta-enxertos em anonáceas**. In: FERREIRA, G. et al. (Eds.) Anonaceas: Propagação e produção de mudas. Botucatu: FEPAF, 2013. p. 111-123.
- KJELDAHL, J. Neue Methode zur Bestimmung des Stickstoffs in organischen Körpern (New method for the determination of nitrogen in organic substances). **Zeitschrift für analytische Chemie**, v.22, p.366-383, 1883.
- KOHAVI, R.; GEORGE, J. H. Wrappers for feature subset selection. **Artificial Intelligence**. v. 97, p.273-324, 1997.
- KOVÁCS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações**. 4. ed. São Paulo: Livraria da Física, 2006.
- KUMAR, Y.; SAHOO, G. Analysis of Parametric & Non Parametric Classifiers for Classification Technique using WEKA. **I.J. Information Technology and Computer Science**, v.7, p.43-49, 2012.
- LANG, C.; COSTA, F.R.C.; CAMARGO, J.L.C.; DURGANTE, F.M.; VICENTINI, A. Near Infrared Spectroscopy Facilitates Rapid Identification of Both Young and Mature Amazonian Tree Species. **PLoS ONE** 10(8):e0134521, 2015. doi:10.1371/journal.
- LAWLOR, D. W.; KONTTURI, M.; YOUNG A.T.. Photosynthesis by flag leaves of wheat in relation to protein, ribulose biphosphate carboxylase activity and nitrogen supply. **Journal of Experimental Botany**, v. 40, p. 43–52, 1989.
- LEBOEUF, M. et al. The phytochemistry of the Annonaceae. **Phytochemistry**, New York, v. 21, n. 12, p. 2783-2813, 1982.
- LE-CESSIE, S.; VAN-HOUWELINGEN, J.C. Ridge Estimators in Logistic Regression. **Applied Statistics**, v.41, p.191-201, 1992.
- LEPAGE, R.; BILLARD, L. **Exploring the limits of bootstrap**. New York: John Wiley & Sons, p.632, 1992.
- LEPINE, L.C.; OLLINGER, S.V.; OUIMETTE, A.P.; MARTIN M.E. Examining spectral reflectance features related to foliar nitrogen in forests: Implications for broad-scale nitrogen mapping. **Remote Sensing of Environment**. V. 173 p.174–186.2016.
- LIEBIG, J.. **Organic chemistry in its applications to agriculture and physiology**. Cambridge: J. Owen. 1841.

- LIMA, R.L.S.; FERREIRA, G.B.; WEBER, O.B.; CAZETTA, J.O.. Diagnose foliar da gravioleira (*Annona muricata* L.): efeito da posição de ramos e folhas. **Ciência e Agrotecnologia**. Editora da Universidade Federal de Lavras (UFLA), v. 31, n. 5, p. 1320-1325, 2007. Disponível em: <<http://hdl.handle.net/11449/30165>>.
- LOPES, S. **Bio**. 11. ed. São Paulo: Editora Saraiva, 2000. v. 1
- LOPES, J. C.; MELLO-SILVA, R. Diversity and characterization of Annonaceae from Brazil. **Rev. Bras. Frutic.**, Jaboticabal, v. 36, n. spe1, p. 125-131, 2014.
- LORENZI H. Árvores Brasileiras: manual de identificação e cultivo de plantas arbóreas nativas do Brasil. Vol. 3, 1. Ed. Nova Odessa, SP: Instituto Plantarum, 384 p. 2009.
- LU, F.; CHEN, Z.; LIU, W.; SHAO, H. Modeling chlorophyll-a concentrations using an artificial neural network for precisely eco-restoring lake basin. *Ecological Engineering*, v. 95, p. 422-429, Oct. 2016.
- MAAS, P.J.; KAMER, H.M.D.; JUNIKKA, L.; MELLO-SILVA, R.D.; RAINER, H. Annonaceae from Central-eastern Brazil. **Rodriguésia**, v.52, n.80, p.65-98, 2001.
- MAATHUIS, F.J. Physiological functions of mineral macronutrients. **Curr. Opin. Plant Biol.** v.12, p.250-258, 2009.
- MAHLEIN, Anne-Katrin. Plant Disease Detection by Imaging Sensors – Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping. **Plant Disease**, v.100, pp. 241-251, 2016. <https://doi.org/10.1094/PDIS-03-15-0340-FE>
- MALAVOLTA, E.; VITTI, G.C. & OLIVEIRA, S.A. **Avaliação do estado nutricional de plantas: Princípios e aplicações**. Piracicaba, Potafos, 1997. 308p.
- MANTARAS, D.; ARMENGOL, E. Machine learning from example: Inductive and Lazy methods. **Data & Knowledge Engineering**, v.25, p.99- 123, 1998.
- MANTOAN L.P.B.; FERREIRA, G.; BOARO, C.S.F. Chlorophyll a fluorescence in *Annona emarginata* (Schltdl.) H. Rainer plants subjected to water stress and after rehydration. **Scientia Horticulturae**, v.184, p.23–30, 2015.
- MARENCO, R.A.; LOPES, N.F. **Fisiologia Vegetal: fotossíntese, respiração, relações hídricas e nutrição mineral**. Viçosa: UFV, 2005. 439p.
- MARSCHNER, P. **Mineral nutrition of higher plants**. Australia: School of Agriculture, Food and Wine The University of Adelaide Australia, 3.ed., 2012, 651p.
- MAUSETH, J.D.. **Botany: an introduction to plant biology**. London: Jones and Bartlett Publishers International, 4th Edition, 2009.

- MCCULLOCH, P.; NELDER, J.A.. **Generalized Linear Models**. 2nd Edition, London: Chapman and Hall, 1989.
- MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of mathematical biophysics**, v. 5, n. 4, p. 115–133, dez. 1943.
- MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Belo Horizonte: UFMG, 2005. 297 p
- MITCHELL, T.M. Machine Learning. **McGraw-Hill**, 1997.
- MODENESE-GORLA DA SILVA, S.H. et al. Redes neurais artificiais e agricultura de precisão para recomendação de adubação da cultura da goiabeira. **Revista Brasileira de Agrocomputação**, v.2, n.1, p.37-42, Jun.2004.
- NAHAR, K. **Artificial Neural Network**. COMPUSOFT, v. 1, n. 2, dez. 2012.
- NASSAU, K. **The Physics and Chemistry of Color: The Fifteen Causes of Color**. Wiley & Sons, New York, 2001.
- NASSER, T; TARIQ; R.S. Big Data Challenges. **J Comput Eng Inf Technol**, v. 4, n.3, 2015.
- NELDER, J.A.; WEDDERBURN, R.W. Generalized linear models. **Journal of the Royal Statistical Society Series A**, v.135, n.3, p.370–384, 1972.
- OSAKI, M., SHINANO, T., TADANO, T. Effect of nitrogen, phosphorus, or potassium deficiency on the accumulation of ribulose-1,5-bisphosphate carboxylase/oxygenase and chlorophyll in several field crops. **Soil Sci. Plant. Nutr.** v.39, p.417-425, 1993.
- OTTO, M. Chemometrics: statistics and computer application in analitical chemistry. Chinchester: **wiley-VCH**. 1999.
- PAILLAT, J.; DAVRIEUX, F.; THURIÈS, L.; MOUSSARD, G.; AZAMI, A.; MARION, D. Sugarcane foliar diagnosis with near-infrared spectroscopy: determination of nitrogen and carbon contents. **Proceedings of the International Society of Sugar Cane Technologists**, volume 29, pp. 38-42, 2016.
- PANFORD, J.A.; MAN, J.M. Determination of oil content of seeds by NIR: influence of fatty acid composition on wavelength selection. **Journal of the American Oil Chemists' Society**, v.67, p.473-482, 1990.
- PATIL, J. K.; KUMAR, R. Advances in image processing for detection of plant diseases. **Journal of Advanced Bioinformatics Applications and Research**, 2. v. 2, n. 2, p. 135–141, 2011.

- PÉREZ-MARÍN, D.; TORRES, I.; ENTRENAS, J.A.; VEGA,M.; SÁNCHEZ, M.T. Pre-harvest screening on-vine of spinach quality and safety using NIRS technology. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v.207, p.242–250, 2019.
- PIEME, C.A.; KUMAR, S.G.; DONGMO, M.S.; MOUKETTE, B.M.; BOYOUUM, F.F.; NGOGANG, J.Y.; SAXENA, A.K. Antiproliferative activity and induction of apoptosis by *Annona muricata* (Annonaceae) extract on human cancer cells. **BMC Complementary and Alternative Medicine**, v.14, p.516-526, 2014.
- PINTO, A.C.Q.; CORDEIRO, M.C.R.; DE ANDRADE, S.R.M.; FERREIRA, F.R.; FILGUEIRAS, H.A.C.; ALVES, R.E.; KINPARA, D.J. *Annona* species. International Centre for Underutilized Crops, **University of Southampton**, Southampton, p 263, 2005.
- QIU-XIANG, Y. et al. Monitoring Rice Nitrogen Status Using Hyperspectral Reflectance and Artificial Neural Network. **Environ. Sci. Technol.**, v.41, p.6770-6775, 2007.
- RAMOS, J.P.S. Redes neurais artificiais na classificação de frutos: cenário bidimensional. **Ciênc. agrotec.**, Lavras. V.27, n.2, p.356-362, mar./abr., 2003.
- ROZANE, D.E.; NATALE, W. Calagem, adubação e nutrição mineral de Anonáceas. **Rev. Bras. Frutic.**, Jaboticabal, v. 36, n.spe1, p.166-175, 2014.
- ROSSATO, R.; PRETE, C. E.C.; CASTRO, C.; TOMM, G.O.; LEITE, R.S.; MANDARINO, J.M.G.; ARAÚJO, P.M.; CARVALHO, C. G. P. Predicting rapeseed oil content with near-infrared spectroscopy. **Pesq. agropec. bras.**, Brasília, v.48, n.12, p.1601-1604, dez. 2013. DOI: 10.1590/S0100-204X2013001200010
- ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring vegetation systems in the Great Plains with ERTS. In: **Proc. 3th Earth Resources Technology Satellite-1 Symposium**. Greenbelt, MD NASA, pp. 301– 317, 1974.
- SALISBURY, F.B.; ROSS, C.W.. **Plant physiology**. California: Wadsworth Publishing Company, 4 th Edition, 1992.
- SAVAZAKI, E.T. Efeito do Ácido Indolbutírico no enraizamento de estacas de três cultivares de atemóia (*Annona squamosa* L. x *Annona cherimola* Mill.) e formação da muda. In: FERREIRA, G. et al. (Eds.). **Anonáceas: Propagação e Produção de Mudas**. Botucatu:FEPAF, 2013, v.1, p.75-109.

- SCALOPPI JUNIOR, E.J. Propagação de espécies de Annonaceae com estacas caulinares. 2007. 92f. Tese (Doutorado) – Faculdade de Ciências Agrônômicas e Veterinária, Universidade Estadual Paulista, Jaboticabal, 2007.
- SIEMENS, B.J.; DAUN, J.K. Determination of the fatty acid composition of canola, flax, and solin by near-infrared spectroscopy. **Journal of the American Oil Chemists' Society**, v.82, p.153-157, 2005.
- SILVA, E.B.; FARNEZI, M.M.M. Limitações nutricionais para o crescimento de mudas de graviola em casa de vegetação em latossolo vermelho distrófico do norte de minas gerais. **Biosci. J.**, Uberlândia, v. 25, n. 6, p. 52-58, 2009.
- SILVA, I. N.; SPATTI, H. D.; FLAUZINO, R. A. Redes Neurais Artificiais: para engenharia e ciências aplicadas. São Paulo: **Artliber**, 2010. 399p.
- SIMS, D. A.; GAMON, J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, v. 81, n. 2, p. 337-354, 2002.
- SKOOG, D.A.; HOLLER, F.J.; NIEMAN, T.A. **Princípios de análise instrumental**. São Paulo: Bookman, 2002.
- SMIS, A.; MURGUZUR, F. J. A.; STRUYF, E.; SOININEN, E. M.; JUSDADO, J. G. H.; MEIRE, P.; BRÅTHEN, K.A.. Determination of plant silicon content with near infrared reflectance spectroscopy. **Front. Plant Sci.** v.5, sep. 2014.
- SOBRINHO, R.B. Potencial de exploração de anonáceas no Nordeste do Brasil. In: 17º Semana internacional da fruticultura, floricultura e agroindústria [**Anais...**] Fortaleza: Instituto Frutal, 2010.
- SOUZA, I.V.B.; SÃO-JOSÉ, A.R.; SILVA, J.C.G.; BOMFIM, M.P.; JESUS, J.S. . The development of custard apple flower bud under nitrogen and potassium nutrition. **Rev.Bras.Frutic.**, Jaboticabal, v.38, n.2, e-507, 2016.
- SOUZA, S. R.; FERNANDES, M. S. Nitrogênio. In: FERNANDES, M. S. (Ed.) **Nutrição Mineral de Plantas**. Viçosa: Sociedade Brasileira de Ciência do Solo, p.215-252, 2006.
- SUÁREZ, H. M.; DOPAZO, A.G.; LÓPEZ, L.D.; ESPINOSA, F. (2015). Identification of Relevant Phytochemical Constituents for Characterization and Authentication of Tomatoes by General Linear Model Linked to Automatic Interaction Detection (GLM-AID) and Artificial Neural Network Models (ANNs). **PLoS ONE**, 10(6), e0128566. <http://doi.org/10.1371/journal.pone.0128566>

- TALLADA, J.G.; RAMOS, M.A. Visible-near-infrared absorbance spectroscopy for rapid estimation of leaf nitrogen contents of Philippine rice cultivars. **Cogent Food & Agriculture**, v.4, 2018. <https://doi.org/10.1080/23311932.2018.1487254>
- TAIZ, L.; ZEIGER, E. Fisiologia vegetal. 6. ed., Artmed, 2017. 918 p.
- TOKUNAGA, T. **A cultura da atemoia**. 2.ed. Campinas: CATI, 2005. 80 p. (Boletim técnico)
- VAN KEMPEN, T. A. T. G; JACKSON, D. NIRS may provide rapid evaluation of amino acids. **Feedstuffs**, v. 68, p.12-15, 1996.
- VIECELLI, C.A. **Guia de deficiências nutricionais em plantas**. Toledo, PR: PUCPR Câmpus Toledo / Grupo Marista, 2017.
- WANG J, SHEN C, LIU N, et al. Non-Destructive Evaluation of the Leaf Nitrogen Concentration by In-Field Visible/Near-Infrared Spectroscopy in Pear Orchards. **Sensors**, Basel, , v.17, n.3, p 538. 2017. doi:10.3390/s17030538.
- WANG, Y.; HU,X.; JIN,G.; HOU,Z.; NING, J.; ZHANG, Z. Rapid prediction of chlorophylls and carotenoids content in tea leaves under different levels of nitrogen application based on hyperspectral imaging. **J Sci Food Agric**, v.99, p.1997–2004, 2018.
- WILLIAMS, P., NORRIS, K.. Near Infrared Technology in the agricultural and Food Industries. Minnesota: **AACC**. 1990.
- WITTEN, IH.; FRANK, E. **Data mining: pratical machine learning tools and techniques**. 2nd ed. Amsterdam; Boston, MA: Morgan Kaufman, 2005.
- WITTEN, I.H.; FRANK, E.; TRIGG, L.; HALL, M.; HOLMES, G.; CUNNINGHAM, S.J. . **Weka: Practical machine learning tools and techniques with Java implementations**. (Working paper 99/11). Hamilton, New Zealand: University of Waikato, Department of Computer Science, 1999.
- XU, L.; FU, H.; CAI,C.; SHE, Y. Quality Degradation of Chinese White Lotus Seeds Caused by Dampening during Processing and Storage: Rapid and Nondestructive Discrimination Using Near-Infrared Spectroscopy. **Journal of Analytical Methods in Chemistry**. Article ID 345352, v.2015, 7 p. 2015. <http://dx.doi.org/10.1155/2015/345352>
- ZENEBON, O.; PASCUET, N.S.; TIGLEA, P. (Coord.). **Métodos físico-químicos para análise de alimentos**. 4. ed. São Paulo: Instituto Adolfo Lutz, Secretaria de Estado da Saúde, 2008. 1020 p.

ZHANG, H. *et al.* Estimation of rice neck blasts severity using spectral reflectance based on BP-neural network. **Acta Physiologiae Plantarum**, v. 33, n. 6, p. 2461–2466, 18 maio, 2011.