

RESSALVA

Atendendo solicitação do(a)
autor(a), o texto completo desta tese
será disponibilizado somente a partir
de 16/05/2021.

UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CAMPUS DE JABOTICABAL

**MODELOS AGROMETEOROLÓGICOS PARA TOMADORES
DE DECISÃO EM 'SMART AGRICULTURE'**

Taynara Tuany Borges Valeriano

Engenheira Agrônoma Ma. Agronomia (Produção Vegetal)

2019

UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CAMPUS DE JABOTICABAL

**MODELOS AGROMETEOROLÓGICOS PARA TOMADORES
DE DECISÃO EM ‘SMART AGRICULTURE’**

Discente: Taynara Tuany Borges Valeriano

Orientador: Prof. Dr. Glauco de Souza Rolim

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

2019

Ficha catalográfica

V163m Valeriano, Taynara Tuany Borges
Modelos agrometeorológicos para tomadores de decisão
em "Smart Agriculture" / Taynara Tuany Borges
Valeriano. -- Jaboticabal, 2019
79 p.

Tese (doutorado) - Universidade Estadual Paulista
(Unesp), Faculdade de Ciências Agrárias e Veterinárias,
Jaboticabal

Orientador: Glauco de Souza Rolim

1. Agronomia. 2. Modelagem de informações. 3.
Fitopatologia. 4. Doenças fúngicas. 5. Irrigação agrícolas.

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).

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: MODELOS AGROMETEOROLÓGICOS PARA TOMADORES DE DECISÃO EM 'SMART AGRICULTURE'

AUTORA: TAYNARA TUANY BORGES VALERIANO

ORIENTADOR: GLAUCO DE SOUZA ROLIM

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


Prof. Dr. GLAUCO DE SOUZA ROLIM
Departamento de Ciências Exatas / FCAV / UNESP - Jaboticabal


Dra. GISÉLE MARIA FANTIN
Laboratório de Fitopatologia / Instituto Biológico - Campinas / SP


Prof. Dr. SILVIO APARECIDO LOPES
Fundo de Defesa da Citricultura / FUNDECITRUS - Araraquara/SP


Prof. Dr. JOSÉ EDUARDO BOFFINO DE ALMEIDA MONTEIRO (Videoconferência)
Empresa Informática Agropecuária / Campinas / SP


Prof. Dr. ALAN RODRIGO PANOSSO
Departamento de Ciências Exatas / FCAV-UNESP/Jaboticabal-SP

Jaboticabal, 16 de maio de 2019

DADOS CURRICULARES DO AUTORA

Taynara Tuany Borges Valeriano, nascida em 04 de julho de 1991 no município Araxá, Estado de Minas Gerais. Ingressou no curso de Engenharia Agrônoma no Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro, Campus Uberaba, em março de 2010. No mesmo campus, foi bolsista do Programa de Educação Tutorial (PET) durante a gestão 2011-2014. Em fevereiro de 2015 obteve o título de Engenheira Agrônoma. Iniciou o curso de mestrado no Campus de Jaboticabal, em agosto de 2015 onde em fevereiro de 2017 obteve o título de mestra em Agronomia (Produção Vegetal). Em março de 2017 ingressou no programa de doutorado em Agronomia (Produção Vegetal) do Campus de Jaboticabal, onde aproximadamente dois anos depois, defende sua tese para obtenção do título de doutora em Agronomia (Produção Vegetal). Durante o período de doutoramento desenvolveu a pesquisa em parceria com o Conselho de pesquisa em agricultura e análise da economia agrária – Centro de Pesquisa em Agricultura e Ambiente (CREA-AA) em Bologna – Itália, onde residiu entre setembro de 2018 a fevereiro 2019 como bolsista da fundação de Coordenação de Aperfeiçoamento de Nível Superior (CAPES). Ao longo de sua trajetória acadêmica seguiu as linhas de pesquisa em agrometeorologia e modelagem de cultivos agrícolas; formou parcerias com empresas privadas e órgãos públicos para o desenvolvimento de trabalhos com objetivo de atender necessidades da sociedade na busca de novas tecnologias para agricultura e o agronegócio brasileiro.

“A mente que se abre a uma nova ideia jamais voltará ao seu tamanho original”.

Albert Einstein

A minha mãe Magna Regina Borges que me criou com todo o amor, carinho e educação que se pode dar a um filho e sacrificou-se para que eu realizasse meu sonho.

A senhora, **DEDICO!**

A minha família, **OFEREÇO!**

AGRADECIMENTOS

Em primeiro lugar agradeço a Deus por ter sempre me amparado nas minhas escolhas para que não me arrependesse e nem desistisse delas, por mais difíceis que fossem.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Campus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Produção Vegetal) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ), pela concessão de bolsa (processo 141291/2017-6) e oportunidade de realizar um curso de pós-graduação.

Ao meu orientador Prof. Dr. Glauco de Souza Rolim que tenho uma admiração e consideração imensa pelo seu trabalho, bem como pela referência que é para todos nós, orientandos. Muito obrigado pelos ensinamentos passados, pela confiança em mim depositada e pelo laço de amizade criado.

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

Ao Consiglio per la Ricerca in Agricoltura e L'analisi dell' Economia Agraria (CREA) – Bologna, Itália, em especial ao diretor Dr. Marcello Donatelli, por ter me aceitado prontamente para a realização do doutorado sanduíche, por ter me recebido calorosamente e por ter oferecido todo o suporte para a realização da minha tese.

Ao meu coorientador do doutorado sanduíche Dr. Simone Bregaglio que tenho uma admiração e consideração imensa pelo seu trabalho. Muito obrigada por toda a confiança em mim depositada e paciência dedicada. Foram seis meses de muito aprendizado.

À toda minha família em especial minha mãe, Regina, minha irmã Gabriella, minha avó Anacleta (*in memoriam*), minha tia Rita, meus padrinhos Luiz e Joana, meus primos João Antônio e Juliana, meu padrasto Neirimar, meus afilhados, Luís Guilherme, Isadora e Adrian Lucas, minha afilhada de coração Estela e meu tio Lázaro, pela paciência e pela ausência em suas vidas, durante todos esses anos de estudos até aqui. Obrigado por vocês acreditarem em mim!

À minha tia Márcia que sempre foi minha referência e me inspirou a seguir o caminho de professora. Muito obrigada por todo suporte, apoio e dedicação.

À minha prima Stefany Souza, pela cumplicidade, lealdade, carinho e amizade de todos esses anos.

As minhas irmãs de coração, Rayeny Ávila, Sayeny Ávila e Kárita Almeida as quais sempre estiveram ao meu lado me apoiando e incentivando.

À minha família de Jaboticabal, Adão, Edgard, Larissa, Everton, Albertina, Mailson, Letícia, Luan e Karol, que fizeram meus dias mais felizes e preencheram todos os meus almoços de domingo amenizando a saudade de casa.

Aos meus amigos e parceiros do GAS e do departamento de Ciências Exatas, José Reinaldo, Victor Moreto, Lucas Aparecido, Kamila Menezes, Aline, Valter, Nayanni, Lígia, Mary Jane, Paulo, Gustavo, Fernando, Bruna, Ludhanna, Gabriela, Thiago, Maria Elisa, Mara. Obrigada pela convivência e troca de experiência durante esse tempo, vocês fizeram do departamento de exatas o melhor da UNESP.

Aos amigos de longa data, Isabela, Ana Cristhina, Cristina, que, mesmo de longe torceram por mim e entenderam minha ausência.

Ao Emmanuel Moreira, por todo amparo e carinho.

Aos membros da banca da defesa, Prof. Dr. Alan Panosso, Dr. Gisele Fantin, Dr. Eduardo Monteiro e Dr. Silvio Lopes, que muito contribuíram para a Tese.

Aos colegas do Departamento de Ciências Exatas, Zezé, Shirlei, Adriana, Prof. Peruzzi, Prof. Newton, Carlão e Vanessa, muito obrigada pela convivência durante esse tempo.

Aos amigos que ganhei durante o doutorado Sanduíche, Ana Claudia Azevedo, Ana Claudia, Vinícius, Henrique e Emanoele, vocês foram fundamentais para a minha adaptação em Bologna.

A todos que de alguma forma contribuíram para que chegasse hoje aqui, o meu muito obrigada!

SUMÁRIO

| | |
|---|-----------|
| CAPÍTULO 1 - Considerações Gerais | 3 |
| CAPÍTULO 2 - A model-based system to predict the suitability of weather conditions for orange rust disease of sugarcane | 8 |
| INTRODUCTION | 9 |
| MATERIAL AND METHODS..... | 11 |
| RESULTS | 20 |
| DISCUSSION..... | 28 |
| CONCLUSIONS | 32 |
| CAPÍTULO 3- Estimativa da Infestação de <i>Mahanarva fimbriolata</i> na cultura da cana-de-açúcar por meio de Redes Neurais Artificiais | 37 |
| INTRODUÇÃO | 38 |
| MATERIAL E MÉTODOS..... | 40 |
| RESULTADOS E DISCUSSÃO..... | 43 |
| CONCLUSÕES..... | 48 |
| CAPÍTULO 4 - EVAPO: A smartphone application to estimate potential evapotranspiration using cloud gridded meteorological data from NASA-POWER system | 51 |
| INTRODUCTION | 52 |
| MATERIAL AND METHODS..... | 53 |
| RESULTS AND DISCUSSION | 59 |
| CONCLUSIONS | 62 |

MODELOS AGROMETEOROLÓGICOS PARA TOMADORES DE DECISÃO EM 'SMART AGRICULTURE'

RESUMO - A agricultura no mundo caminha em alta velocidade para a próxima revolução verde, a chamada revolução da agricultura digital, que combina outras grandes áreas que revolucionaram a agricultura, como as técnicas de biotecnologia e agricultura de precisão. Estas técnicas foram essenciais para aumento da produtividade agrícola no mundo. Agora, a agricultura digital pode otimizar ainda mais a associação dos dados climáticos no planejamento de safras e no manejo de cultivos agrícolas. O conceito "Smart Agriculture" está inserido no universo da agricultura digital como uma linha promissora e necessária para o futuro sustentável da agricultura. Este trabalho apresenta estratégias de manejo para áreas produtoras de cana-de-açúcar, como (i) um sistema de modelo mecanístico para a previsão da susceptibilidade da doença fúngica, ferrugem alaranjada, baseado nas condições meteorológicas; (ii) estimativa da infestação de *Mahanarva fimbriolata* por meio de Redes Neurais Artificiais; (iii) um aplicativo de smartphone para estimar a evapotranspiração potencial utilizando dados meteorológicos em grid, provenientes do sistema NASA-POWER. As estratégias propostas neste trabalho mostraram-se eficientes e promissoras para aplicação prática. O modelo de ferrugem alaranjada simulou com acurácia o índice de severidade de ferrugem alaranjada, e proporcionou a expansão das simulações, com o objetivo de verificar a susceptibilidade da ocorrência da doença em grandes áreas produtoras de cana-de-açúcar, como Brasil, Índia e Austrália. A utilização de redes neurais artificiais para estimar níveis de infestação de *Mahanarva fimbriolata*, se mostrou como uma alternativa viável e promissora. A estimativa da evapotranspiração potencial, utilizando dados meteorológicos em grid provenientes da NASA-POWER, obteve resultados com alta acurácia e precisão, tornando assim, o aplicativo de smartphone desenvolvido uma ferramenta no auxílio do manejo de irrigação racional.

Palavras-Chave: agricultura digital, modelagem de pragas, modelagem de doenças, manejo de irrigação, dados em grid, *Sacharum spp.*

Modeling tools for stakeholders in Smart Agriculture

ABSTRACT - Agriculture in the world is moving at a high speed towards the next green revolution, the so-called digital agriculture revolution, which combines other major areas that have revolutionized agriculture, such as biotechnology and precision agriculture. These techniques were essential for increasing agricultural productivity in the world. Digital agriculture can now further optimize the association of climatic data in crop planning and crop management. The concept of "Smart Agriculture" is embedded in the world of digital agriculture as a promising and necessary line for the sustainable future of agriculture. This work presents management strategies for sugarcane producing areas, such as (i) a process-based model system for predicting the susceptibility of orange rust, based on weather conditions; (ii) estimation of infestation of *Mahanarva fimbriolata* by artificial neural networks; (iii) a smartphone application to estimate potential evapotranspiration using grid weather data from the NASA-POWER system. The strategies proposed in this work proved to be efficient and promising for practical application. The orange rust model accurately simulated the orange rust severity index, and provided the expansion of the simulations, with the objective of verifying the susceptibility of the disease occurrence in large areas of sugarcane production, such as Brazil, India and Australia. The use of artificial neural networks to estimate infestation levels of *Mahanarva fimbriolata* has been shown to be a viable and promising alternative. The estimation of potential evapotranspiration, using grid meteorological data from NASA-POWER, obtained results with high accuracy and precision, thus making the smartphone application developed a tool to aid rational irrigation management.

KEYWORDS: digital agriculture, pest modeling, disease modeling, irrigation management, gridded data, *Sacharum spp.*

CAPÍTULO 1 - Considerações Gerais

A agricultura é a atividade econômica que mais é influenciada pelas condições climáticas sendo que o clima afeta todas as etapas do cultivo, desde o preparo do solo para semeadura, até colheita, além dos controles fitossanitários, manejo de irrigação, transporte e armazenamento dos produtos. Qualquer alteração no clima terá um impacto sobre o crescimento e desenvolvimento da cultura, bem como na ocorrência de pragas e doenças nas plantas.

O aumento populacional e a demanda por alimentos incentivam cada vez mais os pesquisadores, profissionais da área e investidores, a compreender as relações entre o clima e a produção agrícola. Nesse âmbito surgem tecnologias e novos conceitos, como o de “Smart Agriculture”, para auxiliar no entendimento da relação entre clima e produção, visando soluções economicamente viáveis e sustentáveis.

O conceito de “Smart Agriculture” (agricultura inteligente – tradução livre) envolve a ciência de dados e uma combinação multidisciplinar de várias ferramentas para relacionar grande quantidade de dados e informações pertinentes auxiliando na gestão antecipada e automatizada das atividades agrícolas (Prototop e Shanoyan, 2016; Ribarics, 2016; Carolan, 2018).

Dentro do conceito de “Smart Agriculture”, um dos grandes desafios da comunidade científica é atender a crescente demanda por ferramentas que auxiliem os tomadores de decisão no manejo agrícola de forma mais sustentável. Este fato chama cada vez mais atenção para a necessidade de modelos de simulação confiáveis que identifiquem os riscos e estime a produtividade, assim como as perdas referentes aos estresses bióticos e os impactos causados na qualidade da produção (Bregaglio e Donatelli, 2015).

As perdas na produção agrícola devido a ocorrência de pragas e doenças pode chegar até aproximadamente 16% da produção mundial de alimentos (Oerke, 2006; Garret et al., 2013). O impacto causado por pragas e doenças é ainda incerto devido as mudanças no clima e ao elevado número de fatores ambientais e de manejo que interagem contribuindo para o aumento de epidemias (Coakley et al., 1999; Chakraborty e Newton, 2011). A quantificação destes impactos de pragas e doenças sob diferentes intensidades representa uma das questões de pesquisa mais

importantes para a modelagem de simulação agrícola (Savary et al., 2006; Whish et al., 2015).

Os modelos de simulação fornecem aos gestores de terras e formuladores de políticas uma ferramenta para extrapolar os resultados experimentais (Basso et al., 2013), auxiliam no manejo adequado das pragas e doenças, gerando alertas fitossanitários, resultando em menor custo de produção, menor contaminação do ambiente, melhoria na qualidade do produto agrícola além da diminuição no uso de defensivos agrícolas. Os modelos de simulação possibilitam ainda a previsão de disseminação potencial das doenças e pragas de plantas, aumentando ainda mais a contribuição da agrometeorologia para o controle fitossanitário racional.

O Brasil é o maior produtor mundial de cana-de-açúcar (*Saccharum* spp.) (FAO, 2018), o que faz com que a cana seja considerada um dos principais produtos do agronegócio brasileiro. Atualmente, conta com uma área plantada de mais de dez milhões de hectares. A produção nacional na última safra, 2017/2018, foi superior a 737 milhões de toneladas (IBGE, 2018). A importância consolidada da cana-de-açúcar para o mercado brasileiro exige que estratégias de manejo sejam desenvolvidas como modelos que simulem e estimem o impacto de pragas e doenças.

Devido a grande complexidade e do grande número de elementos que se interagem nos sistemas de produção, outro grande desafio dentro do conceito de “Smart Agriculture” está relacionado ao uso correto da água. A Agricultura é de longe o setor que mais demanda água, respondendo por cerca de 70% de toda a água retirada de rios e aquíferos em todo o mundo para produção agrícola (Siebert et al., 2013).

Ahmad e Prasad (2012) afirmam que 45% das áreas agrícolas do mundo sofrem com a seca. A quantidade de água em boa qualidade existente no ambiente é finita e sua disponibilidade diminui gradativamente devido ao crescimento populacional, à expansão das fronteiras agrícolas e à degradação do ambiente. Sendo a água um recurso indispensável à vida, é de fundamental importância a discussão das relações entre o homem e a água, uma vez que a sobrevivência das gerações futuras depende diretamente das decisões que hoje estão sendo tomadas. O uso da água de forma descontrolada pode comprometer os recursos hídricos (Silva et al.,

2016), além de elevar os custos da produção tornando o manejo adequado da irrigação racionalizada uma ferramenta fundamental e indispensável neste processo.

Neste contexto, as tecnologias associadas a “Smart Agriculture” são potencialmente os maiores aceleradores de tecnologias de produção agrícola desde a Revolução Verde, de acordo com o Fórum de Economia Mundial - World Economic Forum (2016). Esta fusão da ciência de dados e agricultura poderá ajudar produtores, pesquisadores e profissionais do setor a tomar decisões baseadas na otimização da produtividade, aumento da receita e minimização de custos (Rosenzweig et al., 2013; Capalbo et al., 2017; Antle et al., 2017; Rao, 2018).

Este estudo busca apresentar técnicas para abordagem “Smart Agriculture” com foco em áreas de cultivo da cana-de-açúcar. Nos próximos capítulos serão apresentadas ferramentas de suporte para auxílio na gestão de áreas agrícolas em geral (irrigação) e para o setor canavieiro (sistemas de suporte a decisão fitossanitária).

REFERÊNCIAS

- Ahmad P, Prasad MNV (2012) Environmental Adaptations and Stress Tolerance of Plants in the Era of Climate Change. Springer. 515 p.
- Antle JM, Jones JW, and Rosenzweig CE (2017) Next generation agricultural system data, models and knowledge products: Introduction, **Agricultural Systems**, 155: 179–185.
- Basso B, Cammarano D, Carfagna E (2013) Review of crop yield forecasting methods and early warning systems. In Proceedings of the First Meeting of the Scientific Advisory Committee of the Global Strategy to Improve Agricultural and Rural Statistics, FAO Headquarters, Rome, Italy, 18–19 July 2013.
- Bregaglio S, Donatelli MA (2015) A set of software components for the simulation of plant airborne diseases. **Environ. Model. Softw.** 72: 426–444.
- Capalbo SM, Antle JM, Seavert C (2017) Next generation data systems and knowledge products to support agricultural producers and science-based policy decision making, **Agricultural Systems**, 155:191-99.
- Carolan M (2018) **The Politics of Big Data: Corporate Agri-Food Governance Meets “Weak” Resistance**. In Agrienvironmental Governance as an Assemblage:

Multiplicity, Power, and Transformation, edited by Jeremie Forney, Chris Rosin, and Hugh Campbell, London: Routledge, 195–212.

Chakraborty S, Newton AC (2011) Climate change, plant diseases and food security: an overview. **Plant Pathol.** 60: 2-14.

Coakley SM, Scherm H, Chakraborty S (1999) Climate change and plant disease management. **Annu. Rev. Phytopathol.** 37: 399-426.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO (2018). Production. Disponível em: <http://faostat3.fao.org/home/E> Acesso em: 20 de ago. 2018.

Garrett KA, Dobson ADM, Kroschel J, Natarajan B, Orlandini S, Tonnang HEZ, Valdivia C (2013) The effects of climate variability and the color of weather time series on agricultural diseases and pests, and on decisions for their management. **Agric. For. Meteorol.** 170: 216-227.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE (2015) Estatísticas sobre Agricultura. Disponível em <http://www.sidra.ibge.gov.br/bda/agric/default.asp?z=t&o=11&i=P> Acesso em: 19 ago. 2018.

Oerke EC (2006) Crop losses to pests. **J. Agric. Sci.** 144: 31-43.

Protopop I, Shanoyan A (2016) Big Data and Smallholder Farmers: Big Data Applications in the Agri-Food Supply Chain in Developing Countries. **International Food and Agribusiness Management Review** 19 (A): 173–90.

Rao NH (2018) Big Data and Climate Smart Agriculture - Status and Implications for Agricultural Research and Innovation in India, **Proceedings of the Indian National Science Academy**, 1-32.

Ribarics P (2016) Big Data and Its Impact on Agriculture. **Ecocycles** 2 (1):33–34.

Rosenzweig C, Jones JW, Hatfield JL, Ruan AC, Boote KJ, Thorburn P, Antle JM, Nelson GC, Porter C, Janssen S, Asseng S, Basso B, Ewert F, Wallach D, Baigorria G, Winter JM (2013) The Agricultural Model Intercomparison and Improvement Project (AgMIP): Protocols and pilot studies, **Agricultural and Forest Meteorology**, 170: 166–182.

Savary S, Teng PS, Willocquet L, Nutter JRFW (2006) Quantification and modeling of crop losses: a review of purposes. **Annu. Rev. Phytopathol.** 44: 89–112.

Siebert S, Henrich V, Frenken K, Burke J (2013) **Update of the Global Map of Irrigation Areas to version 5**. Project report, 178 p.

Silva ECR, Alves FB, Silva IIS (2016) Irrigated agriculture in the Amazon context: A systematic approach to the use of water in a horticulture in the municipality of Atamira-PA. **Revista Internacional de Ciências** 6(1): 29–43.

Whish JPM, Herrmann NI, White NA, Moore AD, Kriticos DJ (2015) Integrating pest population models with biophysical crop models to better represent the farm ing system. **Environ Model. Softw.** 72: 418–425.

World Economic Forum (2016). The Global Risks Report, 11th Edition, World Economic Forum, Geneva, Switzerland, 103 pp.

CONCLUSÕES

Um dos custos mais elevados nas áreas agrícolas é o tratamento fitossanitário. A técnica de redes neurais se mostrou uma ferramenta viável na estimativa dos níveis de pressão populacional de *Mahanarva fimbriolata* na cultura da cana-de-açúcar. Essa ferramenta permite a tomada de decisão de entrada ou não de pessoal e equipamentos no campo em função dessas estimações.

Diversas metodologias baseadas nas estruturas das redes podem ser replicadas, como Multilayer Perception, Radial Basis Fuction e até mesmo por uma rede Linear. A rede Radial Basis Fuction com três camadas sendo a primeira com 10 neurônios, a segunda com 21 e a terceira com 3 neurônios, foi a que obteve um melhor desempenho neste estudo. Estudos para aprimorar as técnicas de machine learning como as redes neurais na estimativa de infestações de pragas ainda são necessárias, principalmente quando a pressão populacional é alta.

REFERÊNCIAS

Azevedo MA, Andrade Júnior VCA, Sousa Júnior AS, Santos AS, Cruz CD, Pereira S L, Oliveira AJM (2017) Eficiência da estimação da área foliar de couve por meio de redes neurais artificiais. **Horticultura Brasileira**, 35: 014-019.

Binoti DHB, Binoti MLMS, Leite HG (2014) Configuração de redes neurais artificiais para a estimação do volume de árvores. **Ciência da Madeira**, 5(1): 58-67.

Bregaglio S, Donatelli M (2015) A set of software components for the simulation of plant airborne diseases. **Environ. Model. Softw.** 72: 426–444.

Chakraborty S, Ghos R, Ghosh M, Fernandes CD, Charchar MJ (2004) Weather-based prediction of anthracnose severity using artificial neural network models. **Plant pathol.** 53: 375-386.

Chakraborty S, Newton AC (2001) Climate change, plant diseases and food security: an overview. **Plant Pathol.** 60: 2-14.

Coakley SM, Scherm H, Chakraborty S (1999) Climate change and plant disease management. **Annu. Rev. Phytopathol.** 37: 399-426.

Dinardo-Miranda LL (2014) **Nematoides e pragas da cana-de-açúcar**. Campinas: Instituto Agronômico.

Dinardo-Miranda LL, Ferreira JMG, Carvalho PAM (2001) Influência da época de colheita e do genótipo de cana-de-açúcar sobre a infestação de *Mahanarva fimbriolata* (Stal) (Hemiptera: Cercopidae). **Neotropical Entomology**, 30(1): 145-149.

Donatelli M, Magarey RD, Bregaglio S, Willocquer L, Whish JPM, Savary S (2017) Modelling the impacts of pests and diseases on agricultural systems, **Agricultural Systems**, 155:213-224.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO (2016). Production. Disponível em: <http://faostat3.fao.org/home/E> Acesso em: 20 de ago. 2016.

Foody GM (2004) Supervised image classification by MLP and RBF neural networks with and without an exhaustively defined set of classes. **Int. J. Remote Sensing**, 25(15): 3091-3104.

Gaudart J, GIUSIANO B, HUIART L (2004) Comparison of the performance of multi-layer perceptron and linear regression for epidemiological data. **Neural Comput. Appl.**, 24: 47-70.

Gillespie TJ, Sentelhas PC (2008) Agrometeorology and plant disease management: a happy marriage. **Scientia Agricola**, 65: 71-75.

Laxmi RR, Kumar A (2011) Forecasting of powdery mildew in mustard (*Brassica juncea*) crop using artificial neural networks approach. **Indian J. Agric. Sci**, 81:855-860.

Magarey RC, Neilsen WA, Magnanini AJ (2004) Environmental requirements for spore germination in the three sugarcane leaf pathogens. In: Conference of the Australasian Society of Sugar Cane Technologists held at Brisbane, Queensland, 1-7.

Newman JA, Gibson DJ, Parsons AJ, Thornley, JHM (2003) How predictable are aphid population responses to elevated CO₂. **J. Anim. Ecol.**, 52: 556–566.

Pereira AR, Angelocci LR, Sentelhas PC (2002) Agrometeorology: Fundamentals and practical applications. Agropecuária, Guaíba.

Raad A, Kalakech A, Ayache M (2012) Breast cancer classification using neural network approach: MLP and RBF. The 13th International Arab Conference on Information Technology ACIT'2012 Dec.10-13

Santos RB, Rupp M, Bonzi SJ, Fileti AM (2013) Comparison Between Multilayer Feedforward Neural Networks and a Radial Basis Function Network to Detect and Locate Leaks in Pipelines Transporting Gas. **Chemical Engineering Transactions**, 32:1375-1380.

Savary S, Teng PS, Willocquet L, Nutter JRFW (2006) Quantification and modeling of crop losses: a review of purposes. **Annu. Rev. Phytopathol.** 44: 89–112.

Stackhouse P (2010) Prediction of worldwide energy resource. NASA Langley Research Center. <https://power.larc.nasa.gov/> (accessed 13 Aug. 2018).

Vennila S, Singh G, Jha GK, Rao MS, Panwar H, Hegde M (2017) Artificial neural network techniques for predicting severity of *Spodoptera litura* (Fabricius) on groundnut. **Journal of Environmental Biology**, 38:1-8.

Whish JPM, Herrmann NI, White NA, Moore AD, Kriticos DJ (2015) Integrating pest population models with biophysical crop models to better represent the farming system. **Environ. Model. Softw.** 72: 418–425.

Yang X, Ming L, Chunjiang Z, Zheng Z, Yanlin H (2007) Early warning model for cucumber downy mildew in unheated greenhouses, **New Zealand Journal of Agricultural Research**, 50(5):1261-1268.

Yilmaz I, Kaynar O (2011) Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. **Experts Systems with Applications**, 38: 5958-5966.

Zanaty EA (2012) Support Vector Machines (SVMs) versus Multilayer Perception (MLP) in data classification. **Egyptian Informatics Journal**, 13(3): 177-183.