

ALAN MARIO ZUFFO
JORGE GONZÁLEZ AGUILERA
ORGANIZADORES

PESQUISAS AGRÁRIAS E AMBIENTAIS

Volume VI



Pantanal Editora

2021

Alan Mario Zuffo
Jorge González Aguilera
Organizadores

PESQUISAS AGRÁRIAS E AMBIENTAIS
VOLUME VI



Pantanal Editora

2021

Copyright© Pantanal Editora

Editor Chefe: Prof. Dr. Alan Mario Zuffo

Editores Executivos: Prof. Dr. Jorge González Aguilera e Prof. Dr. Bruno Rodrigues de Oliveira

Diagramação: A editora. **Diagramação e Arte:** A editora. **Imagens de capa e contracapa:** Canva.com. **Revisão:** O(s) autor(es), organizador(es) e a editora.

Conselho Editorial

Grau acadêmico e Nome	Instituição
Prof. Dr. Adaylson Wagner Sousa de Vasconcelos	OAB/PB
Profa. Msc. Adriana Flávia Neu	Mun. Faxinal Soturno e Tupanciretã
Profa. Dra. Albys Ferrer Dubois	UO (Cuba)
Prof. Dr. Antonio Gasparetto Júnior	IF SUDESTE MG
Profa. Msc. Aris Verdecia Peña	Facultad de Medicina (Cuba)
Profa. Arisleidis Chapman Verdecia	ISCM (Cuba)
Prof. Dr. Arinaldo Pereira da Silva	UFESSPA
Prof. Dr. Bruno Gomes de Araújo	UEA
Prof. Dr. Caio Cesar Enside de Abreu	UNEMAT
Prof. Dr. Carlos Nick	UFV
Prof. Dr. Claudio Silveira Maia	AJES
Prof. Dr. Cleberton Correia Santos	UFGD
Prof. Dr. Cristiano Pereira da Silva	UEMS
Profa. Ma. Dayse Rodrigues dos Santos	IFPA
Prof. Msc. David Chacon Alvarez	UNICENTRO
Prof. Dr. Denis Silva Nogueira	IFMT
Profa. Dra. Denise Silva Nogueira	UFMG
Profa. Dra. Dennyura Oliveira Galvão	URCA
Prof. Dr. Elias Rocha Gonçalves	ISEPAM-FAETEC
Prof. Me. Ernane Rosa Martins	IFG
Prof. Dr. Fábio Steiner	UEMS
Prof. Dr. Fabiano dos Santos Souza	UFF
Prof. Dr. Gabriel Andres Tafur Gomez	(Colômbia)
Prof. Dr. Hebert Hernán Soto Gonzáles	UNAM (Peru)
Prof. Dr. Hudson do Vale de Oliveira	IFRR
Prof. Msc. Javier Revilla Armesto	UCG (México)
Prof. Msc. João Camilo Sevilla	Mun. Rio de Janeiro
Prof. Dr. José Luis Soto Gonzales	UNMSM (Peru)
Prof. Dr. Julio Cezar Uzinski	UFMT
Prof. Msc. Lucas R. Oliveira	Mun. de Chap. do Sul
Profa. Dra. Keyla Christina Almeida Portela	IFPR
Prof. Dr. Leandris ArgenteL-Martínez	Tec-NM (México)
Profa. Msc. Lidiene Jaqueline de Souza Costa Marchesan	Consultório em Santa Maria
Prof. Dr. Marco Aurélio Kistemann	UFJF
Prof. Msc. Marcos Pisarski Júnior	UEG
Prof. Dr. Marcos Pereira dos Santos	FAQ
Prof. Dr. Mario Rodrigo Esparza Mantilla	UNAM (Peru)
Profa. Msc. Mary Jose Almeida Pereira	SEDUC/PA
Profa. Msc. Nila Luciana Vilhena Madureira	IFPA
Profa. Dra. Patricia Maurer	UNIPAMPA
Profa. Msc. Queila Pahim da Silva	IFB
Prof. Dr. Rafael Chapman Auty	UO (Cuba)
Prof. Dr. Rafael Felipe Ratke	UFMS
Prof. Dr. Raphael Reis da Silva	UFPI
Prof. Dr. Ricardo Alves de Araújo	UEMA
Prof. Dr. Wéverson Lima Fonseca	UFPI
Prof. Msc. Wesclen Vilar Nogueira	FURG
Profa. Dra. Yilan Fung Boix	UO (Cuba)
Prof. Dr. Willian Douglas Guilherme	UFT

Conselho Técnico Científico

- Esp. Joacir Mário Zuffo Júnior
- Esp. Maurício Amormino Júnior
- Esp. Tayronne de Almeida Rodrigues
- Lda. Rosalina Eufrausino Lustosa Zuffo

Ficha Catalográfica

Dados Internacionais de Catalogação na Publicação (CIP)
(eDOC BRASIL, Belo Horizonte/MG)

P472 Pesquisas agrárias e ambientais [livro eletrônico] : volume VI / Organizadores Alan Mario Zuffo, Jorge González Aguilera. – Nova Xavantina, MT: Pantanal Editora, 2021. 133p.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

ISBN 978-65-88319-79-6

DOI <https://doi.org/10.46420/9786588319796>

1. Ciências agrárias – Pesquisa – Brasil. 2. Meio ambiente.
3. Sustentabilidade. I. Zuffo, Alan Mario. II. Aguilera, Jorge González.
CDD 630

Elaborado por Maurício Amormino Júnior – CRB6/2422



Pantanal Editora

Nossos e-books são de acesso público e gratuito e seu download e compartilhamento são permitidos, mas solicitamos que sejam dados os devidos créditos à Pantanal Editora e também aos organizadores e autores. Entretanto, não é permitida a utilização dos e-books para fins comerciais, exceto com autorização expressa dos autores com a concordância da Pantanal Editora.

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000.
Nova Xavantina – Mato Grosso – Brasil.
Telefone (66) 99682-4165 (Whatsapp).
<https://www.editorapantanal.com.br>
contato@editorapantanal.com.br

APRESENTAÇÃO

As áreas de Ciências Agrárias e Ciências Ambientais são importantes para a humanidade. De um lado, a produção de alimentos e do outro a conservação do meio ambiente. Ambas, devem ser aliadas e são imprescindíveis para a sustentabilidade do planeta. A obra, vem a materializar o anseio da Editora Pantanal na divulgação de resultados, que contribuem de modo direto no desenvolvimento humano.

O e-book “Pesquisas Agrárias e Ambientais Volume VI” é a continuação de uma série de volumes de e-books com trabalhos que visam otimizar a produção de alimentos, o meio ambiente e promoção de maior sustentabilidade nas técnicas aplicadas nos sistemas de produção das plantas e animais. Ao longo dos capítulos são abordados os seguintes temas: regressão quantílica na classificação de sítios florestais em povoamentos de *Pinus elliottii*, equações volumétricas mistas para árvores de *Pinus taeda* em diferentes espaçamentos, substratos para a produção de mudas de coentro, correlações e análise de trilha na qualidade de sementes de soja oriundas de plantas cultivadas em solos com diferentes níveis de fertilidade nitrogenada, desempenho agrônômico de duas cultivares de rúcula sob densidades de semeadura em sistema hidropônico, serraria e secagem da madeira: uma revisão, redes neurais artificiais aplicadas na estimativa da altura total de *Eucalyptus* sp., as espécies de *Desmodium* (Leguminosae) no herbário da Amazônia Meridional: potencialidades a pecuária, germinação de sementes armazenadas de *Hesperozygis ringens* (Benth.) Epling, micoparasitismo no controle biológico da ferrugem Asiática da soja (*Phakopsora pachyrhizi*), componentes produtivos de soja são influenciados por diferentes tipos de irrigação, e efectos de los oligogalacturónidos y sustrato orgánico en el comportamiento morfoproductivo de la habichuela Lina (*Vigna unicalata* L.). Portanto, esses conhecimentos irão agregar muito aos seus leitores que procuram promover melhorias quantitativas e qualitativas na produção de alimentos e do ambiente, ou melhorar a qualidade de vida da sociedade. Sempre em busca da sustentabilidade do planeta.

Aos autores dos capítulos, pela dedicação e esforços sem limites, que viabilizaram esta obra que retrata os recentes avanços científicos e tecnológicos na área de Ciência Agrárias e Ciências Ambientais Volume VI, os agradecimentos dos Organizadores e da Pantanal Editora. Por fim, esperamos que este e-book possa colaborar e instigar mais estudantes e pesquisadores na constante busca de novas tecnologias e avanços para as áreas de Ciências Agrárias e Ciências Ambientais. Assim, garantir uma difusão de conhecimento fácil, rápido para a sociedade.

Alan Mario Zuffo
Jorge González Aguilera


SUMÁRIO

Apresentação	4
Capítulo I	6
Uso da regressão quantílica na classificação de sítios florestais em povoamentos de <i>Pinus elliottii</i> , no Uruguai.....	6
Capítulo II	15
Equações volumétricas mistas para árvores de <i>Pinus taeda</i> em diferentes espaçamentos, no Paraná... 15	
Capítulo III	26
Substratos para a produção de mudas de coentro (<i>Coriandrum sativum</i> L. cv. Português)	26
Capítulo IV	33
Correlações e análise de trilha na qualidade de sementes de soja oriundas de plantas cultivadas em solos com diferentes níveis de fertilidade nitrogenada.....	33
Capítulo V	42
Desempenho agrônômico de duas cultivares de rúcula sob densidades de semeadura em sistema hidropônico no município de Uruçuí-PI	42
Capítulo VI	52
Serraria e Secagem da Madeira: Uma Revisão	52
Capítulo VII	63
Redes neurais artificiais aplicadas na estimativa da altura total de <i>Eucalyptus</i> sp.	63
Capítulo VIII	78
As espécies de <i>Desmodium</i> (Leguminosae) no Herbário da Amazônia Meridional: potencialidades a pecuária na região de Alta Floresta, Mato Grosso.....	78
Capítulo IX	96
Germinação de sementes armazenadas de <i>Hesperozygis ringens</i> (Benth.) Epling	96
Capítulo X	102
Micoparasitismo no Controle Biológico da Ferrugem Asiática da Soja (<i>Phakopsora pachyrhizi</i>).....	102
Capítulo XI	110
As características agrônômicas da soja são influenciadas pelo tipo de irrigação e aplicação de doses de potássio	110
Capítulo XII	119
Efectos de los oligogalacturónidos y sustrato orgánico en el comportamiento morfoproductivo de la habichuela Lina (<i>Vigna unicalata</i> L.).....	119
Índice Remissivo	131
Sobre os organizadores	133


Redes neurais artificiais aplicadas na estimativa da altura total de *Eucalyptus* sp.


Recebido em: 14/07/2021

Aceito em: 20/07/2021

 10.46420/9786588319796cap7

Aline Roja Rolmos¹ 

Lucas Kröhling Bernardi^{2*} 

Monica Fabiana Bento Moreira Thiersch³ 

Claudio Roberto Thiersch⁴ 

INTRODUÇÃO

O setor Florestal brasileiro se tornou um dos mais competitivos a nível global nos últimos anos e contribui determinadamente na movimentação da economia nacional. Em 2019 representou 1,3% de todo o PIB e 6,9% do PIB industrial. Contudo, neste mesmo período, a inflação do setor apresentou taxas de 6,77%, superiores à média nacional de 4,31% representados pelo Índice Nacional de Preços ao Consumidor - IPCA (IBÁ, 2020). Em outras palavras, os custos do setor Florestal cresceram 2,46% a mais do que o custo médio nacional, o que representa, então, um aumento no preço da atividade.

Mesmo com indicadores econômicos desfavoráveis, a atividade continua a apresentar resiliência, principalmente por sua posição como florestas mais produtivas do mundo. No entanto, para ganhar ainda mais representatividade mundial há muitos desafios a serem superados e oportunidades a serem desenvolvidas. Torna-se então, importante o fortalecimento da visão conjunta do setor, orientando a tomada de decisões numa perspectiva de curto, médio e longo prazo, em outras palavras, o Planejamento estratégico.

A operação de planejamento no negócio florestal pode representar a diferença entre o sucesso e o fracasso do empreendimento. Tendo em vista o horizonte da atividade com média de sete anos, a possibilidade de mudanças no cenário econômico é intrínseca. Através da predição de produção, do controle da redução de custos e da otimização das atividades, o exercício do planejamento tende a reduzir as incertezas, e aumentar as decisões assertivas.

Para ser bem-sucedido, é fundamental entender o comportamento do material, desta forma o gestor terá como saber se o crescimento da floresta está dentro do esperado ou se alguma medida mitigadora deverá ser adotada. Tais perspectivas são obtidas através de estimação de características das

¹ Engenheira Florestal.

² Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis, Departamento de Ciências Ambientais, Universidade Federal de São Carlos, *campus* Sorocaba.

³ Profa. Dra., Departamento de Administração, Universidade Federal de São Carlos, *campus* Sorocaba.

⁴ Prof. Dr. Departamento de Ciências Ambientais, Universidade Federal de São Carlos, *campus* Sorocaba.

* Autor correspondente: bernardilucas@estudante.ufscar.br

árvores, como área basal, volume etc. Atualmente uma vasta gama de métodos está disponível para estimativa destas informações, dentre eles se destacam as técnicas tradicionais de regressão amplamente utilizada e as redes neurais artificiais (RNAs), que ganharam olhares do setor florestal recentemente.

A medição da altura das árvores é motivo de discussões no meio da biometria, pelo fato de sua aferição ser feita indiretamente e por dificuldades na obtenção da medição em situação de vento ou por falta de visibilidade do topo da árvore em florestas densas, como é o caso de povoamento de eucalipto. Ademais, a operação é considerada por Binoti et al. (2013), componente significativo no custo do inventário florestal. Desta forma, o uso da hipsometria, em que se estima a altura das árvores não medidas na parcela a partir da relação de seu diâmetro a 1,3 m do solo (dap) com as alturas das medidas, é empregada como forma de reduzir o custo do inventário.

Por serem seres biológicos, as respostas de crescimento são influenciadas também por variáveis ambientais e silviculturais, como por exemplo o material genético, podendo ser empregada em regressões para aumentar a precisão das estimativas e o maior realismo dos dados. Uma abordagem alternativa que tem sido considerada promissora na estimativa da altura, consiste no emprego de RNAs (Binoti et al., 2013; Vendruscolo, 2015). Assim como a regressão clássica, esta é capaz de lidar com problemas complexos, modelando diversas variáveis, incluindo suas relações não lineares, e lidando com modelagem numérica e categórica (Haykin, 2001).

Sendo assim, ao considerar importante a correta expressão dos valores estimados, bem como, buscar otimizar o trabalho de coleta de dados em campo, este estudo tem como proposta comparar as redes neurais artificiais com um modelo hipsométrico genérico visando verificar a capacidade destes em estimar a altura total considerando diferentes intensidades amostrais.

Análise de Regressão

Frequentemente utilizada no meio florestal, a análise de regressão é usualmente empregada na estimativa de volume de madeira em função do diâmetro e da altura das árvores. No inventário florestal, as informações são obtidas a partir de unidades amostrais com função de representar o povoamento para que a qualidade das informações obtidas no levantamento de campo adquira importância (Couto et al., 1989). Entretanto a medição da altura das árvores é uma atividade onerosa e por ser tomada indiretamente, está sujeita a grandes erros, enquanto o diâmetro das árvores é uma medida muito mais facilmente obtida. Para contornar a dificuldade, o valor de altura total das árvores da parcela pode ser estimado com a aplicação de modelos matemáticos que estabelecem uma relação biométrica entre os diâmetros e alturas observados, conhecidas como equações hipsométricas (Thiersch, 2007).

Em um inventário florestal feito utilizando hipsometria, mede-se o diâmetro na altura do peito (dap) de todas as árvores da parcela e a altura total (ht) de algumas árvores (Couto et al., 1989; Thiersch, 2007). Desta maneira a coleta de dados é feita com maior facilidade e o resultado do inventário mantém qualidade.

Desde Trorey (1932), citado por Machado et al. (1994), vários modelos matemáticos foram desenvolvidos para representar a relação hipsométrica de povoamentos florestais. Alguns dos autores conhecidos por estudar modelos hipsométricos ditos empíricos são Couto et al. (1989), Cardoso (1989), Scolforo (1997), Bartoszeck et al. (2003) e Barros et al. (2002).

Ao se adotar a técnica, é necessário dedicar atenção à alguns fatores, a fim de evitar erros na estimação dos valores. Diversos autores apontam que a relação ht/dap é afetada por outras características do povoamento, em especial a idade, a qualidade do sítio expressa pela altura dominante das árvores, a densidade e por práticas silviculturais em geral. Diante deste fato, Barros et al. (2002) apontam a importância de selecionar corretamente o modelo que se adeque às necessidades do povoamento estudado, muitas vezes homogêneo em características silviculturais. A solução para este cenário pode ser encontrada na aplicação de modelos genéricos, que permite estimar a variável de interesse para um conjunto de informações oriundas de povoamento com características silviculturais homogêneas.

Barros et al. (2002) destacam aspectos positivos da aplicação de modelos genéricos quando confrontados com os tradicionais. Dentre eles está a redução no custo de processamento dos dados ao eliminar a necessidade de ajustar equações específicas para cada parcela, e o aumento na precisão dos ajustes por permitirem entradas de informações silviculturais. Por outro lado, Soares et al. (2004), aponta em seu estudo que apesar do potencial de utilização dos modelos genéricos, os modelos hipsométricos ajustados por parcela são mais acurados.

Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são técnicas computacionais que se inspiram na estrutura Neural do cérebro humano e modelam o relacionamento entre um arranjo de sinais de entrada e de saída com finalidade de desempenhar uma tarefa específica. Assim como o modelo biológico, este é formado por células de processamento simples interconectadas chamadas de Neurônios Artificiais, formando um paralelo de processamento massivo (Rede) capaz de adquirir conhecimento através da prática e resolver coletivamente problemas complexos e ambíguos. Este processo de determinação de valor para os parâmetros de entrada são chamados Aprendizado ou Treinamento (Lantz, 2015; Bishop, 1995).

A temática emergiu na década de 40 com o trabalho de Warren McCulloch e Walter Pitts, que resultou na publicação do artigo "*A Logical Calculus of the Ideas Immanent in Nervous Activity*" (Um Cálculo Lógico das Ideias Imanentes na Atividade Nervosa), considerado referência para os demais pesquisadores de RNA. Ainda nesta década, o neuropsicólogo Donald Hebb avançou mais ao defender a teoria da plasticidade sináptica em seu livro "*The Organization of Behavior*" (A Organização do Comportamento), em que analisa o processo de aprendizagem através de condicionamento psicológico em seres biológicos (HEBB, 1949). Suas conclusões são referidas como Regra de Hebb ou Teoria Hebbiana e são utilizadas no treinamento de diferentes tipos de redes.

O entusiasmo pelo campo de estudo continuou crescendo durante dos anos de 50 e 60. Em 1958, Frank Rosenblatt propôs um modelo inovador de rede chamado *Perceptron*, com apenas uma camada de processamento simples, desenvolvido para lidar com problemas de reconhecimento de padrões. O modelo foi amplamente aplicado nos anos que se sucederam, entretanto no final dos anos 60, foi desconstruído pelos pesquisadores Marvin Minsky e Seymour Papert ao apontar importantes limitações à aplicação do modelo em seu livro “*Perceptrons: an introduction to computational geometry*” (Perceptrons: Uma introdução à geometria computacional) (Widrow et al., 1990).

Em uma tentativa de melhorar o desempenho do *Perceptron*, Rosenblatt propôs a rede *Perceptron Multilayers* (com múltiplas camadas), que nada mais é do que uma rede do tipo Perceptron, com pelo menos uma camada intermediária. Com a necessidade de aplicar um algoritmo de treinamento mais sofisticado e com o aumento dos recursos computacionais disponíveis, Rosenblatt e os pesquisadores Geoffrey Hinton, and Ronald Williams introduziram o poderoso *Backpropagation*, (1986) método que possibilita a retro propagação do erro e ajuste dos pesos (LANTZ, 2015).

Nos anos 50 também, Marvin Minsky, junto com outros pesquisadores da neurociência, desenvolveu o primeiro neuro computador chamado de Snark, bem-sucedido ao ajustar peso automaticamente. Apesar disso, o Snark nunca executou um processamento (Widrow et al., 1990).

Ao mesmo tempo em que Rosenblatt estava desenvolvendo o *Perceptron*, Bernard Widrow junto com seus colegas de trabalho, estavam trabalhando na mesma linha (Widrow et al., 1990). Em 1962, Widrow propôs uma estrutura de rede com processamento paralelo, chamada *Adaline*. Diferente da *Perceptron*, que sofreu uma perda de credibilidade, esta continua a ser aplicada para programação de Redes. O termo *Adaline* vem de *ADaptive LINear Element* (Elemento Linear Adaptativo), e se refere a uma única unidade de processamento com não-linearidade de limiar, da mesma forma que o *Perceptron* (Lantz, 2015).

Segundo Haykin (2001), todas as RNAs, incluindo aquelas do tipo simples ou em múltiplas camadas, contêm um ou mais neurônios artificiais de processamento. O funcionamento da RNA basicamente consiste na alimentação dela por meio de *inputs* na camada de entrada, responsável somente por receber e transmitir estes sinais para as camadas ocultas, e estas então processam os *inputs* nos neurônios através da aprendizagem.

Aprendizado Supervisionado

Lantz (2015) explica que dado um conjunto de dados de entrada, o algoritmo de aprendizado supervisionado busca otimizar o modelo para encontrar uma combinação de valores das variáveis (o conjunto de pesos em se tratando de RNAs) que resulte na saída desejada. O termo “supervisionado” não se refere a um supervisor humano, mas sim ao fato de que os valores-alvo fornecem um jeito para rede identificar o quão bem ela está aprendendo a tarefa desejada. Este método é aplicado em Modelos de Previsão (*Predictive Model*), justamente em virtude da característica do algoritmo de encontrar uma

relação entre os *outputs* e as demais variáveis. O algoritmo mais comumente aplicado para o aprendizado supervisionado é o *Backpropagation*, mencionado no item anterior (Andrade, 2011; Lantz, 2015).

Aprendizado não-supervisionado

Opondo-se ao aprendizado supervisionado, o não supervisionado não utiliza um supervisor para observar o processamento. Enquanto o primeiro prevê o objetivo de interesse, neste modelo nenhuma variável é mais importante que outra. Em virtude das suas características, o modelo em que se aplica este método é o Modelo Descritivo (*Descriptive Model*). Segundo Andrade (2011), para que seja possível o aprendizado neste tipo de modelo, se faz necessária a apresentação de dados regulares. Por suas características, o modelo é indicado para problemas em que se identificam características estatísticas como a separação em classes.

Problemas de Dimensionamento

A definição da arquitetura da rede, em outras palavras, determinar o número de camadas e o número de neurônios presentes em cada camada, é parte fundamental no processamento. Segundo Braga et al. (2007), o número de neurônios presente em uma rede é diretamente proporcional a sua complexidade, naturalmente então, a estrutura da Rede é dependente da complexidade do problema em questão. O dimensionamento inadequado da Rede pode prejudicar o desempenho do processamento, ocasionando em problemas de generalização. Redes superdimensionadas levam ao problema conhecido como *overfitting*, e as subdimensionadas podem provocar o chamado *underfitting* (Haykin, 2001).

Como mencionado, *overfitting* pode ser resultado do superdimensionamento da arquitetura da rede, ao se utilizar um número superior de neurônios ou de camadas ao necessário para o treinamento da rede. Outro cenário que justifique o problema é o excesso de épocas aplicadas no treinamento, fazendo com que a rede memorize os padrões de treino e se torne incapaz de responder genericamente (Haykin, 2001).

Haykin (2001) explica o *underfitting* como sendo a incapacidade da rede expressar resultados acurados, resultante da insuficiência de treinamento. Ao contrário do problema de *overfitting*, redes sofrem *underfitting* quando sua arquitetura está dimensionada com baixo número de neurônios ou de camadas ou o treinamento foi feito utilizando baixo número de épocas (Haykin, 2001).

MATERIAIS E MÉTODOS

Os dados utilizados neste estudo são provenientes da medição de parcelas permanentes do inventário florestal contínuo (IFC), feito em povoamento clonal de eucalipto com 307,77 ha de área no interior do estado de São Paulo.

A base de dados contém 6.050 árvores medidas no total, das quais 1.636 contém informação de altura total, alocadas em 109 parcelas circulares de aproximadamente 400 m². De todas as árvores foram extraídos os dap e identificado o material genético. Mediu-se a altura de todos os indivíduos que compõem as 2 fileiras centrais (cerca de 12 medidas por unidade) e a altura das 3 árvores de maior dap, consideradas altura dominante (hdom). Todos os indivíduos foram devidamente categorizados utilizando-se as seguintes categorias: normal, falha, morta, quebrada, dominada, dominante e múltiplos fustes.

A partir da análise prévia por categorias, eliminaram-se as árvores classificadas como falha, morta, quebrada e dominada, buscando com isso retirar indivíduos com relação entre diâmetro e altura não modeláveis. Em seguida, os dados restantes foram segregados em duas bases, uma para treinamento da rede e processamento do ajuste hipsométrico, e outra para a validação. Para a separação das bases, aplicou-se uma sequência numérica aos dados de 1 a no máximo 15, em que aqueles alocados entre 1 e 10 seguiram para o treinamento e processamento, enquanto o restante foi utilizado na validação.

A fim de melhorar o desempenho no treinamento e aplicação da rede, o tipo de normalização aplicada foi a transformação linear, obedecendo à equação 1.

$$y_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

onde: y_i é o valor normalizado, x_i é o valor original, x_{\min} assume o valor mínimo de x e x_{\max} o valor máximo de x .

Como consequência ao processo de normalização nos valores de entrada da rede, temos que os valores de saída estão também limitados entre (-1 e 1). Desta forma, estes valores de saída foram então submetidos ao processo inverso de transformação, obtendo-se assim os valores originais de altura esperada.

Cenários

Com o objetivo de analisar a resposta de ambas as metodologias de estimativa sobre diferentes intensidades amostrais, foram testados os ajustes com intensidade de 4, 6, 8 e 10 valores de altura total por parcela.

A base de dados utilizada na validação para todos os cenários foi a mesma, com amplitude de no máximo 5 alturas totais por parcela.

Treinamento e avaliação da RNA

As redes treinadas para todos os cenários propostos neste estudo, com o objetivo de estimar as alturas das árvores a partir do dap correspondente e da influência do material genético, foram do tipo *Perceptron* simples, com uma camada de neurônios artificiais que recebe e processa os dados de entrada.

Em geral, quanto mais complexa for a arquitetura da rede, fazendo maior número de conexões, é possível que ela aprenda a lidar com problemas mais complexos também. Entretanto, o excesso de neurônios ajustados trás o risco do empobrecimento da generalização, além de aumentar o custo computacional do processamento (Haykin, 2001). A escolha é baseada então, na alta correlação entre as variáveis altura total e dap, eliminando a necessidade de complexar a arquitetura para atingir um resultado satisfatório. A arquitetura enxuta reduz o tempo de processamento para bases de dados grandes e favorece o dinamismo do processamento. A melhor RNA em número de neurônios artificiais foi determinada com base na avaliação do poder de estimativa da rede, ou seja, a correlação das alturas estimadas pela rede com as reais. Para isso foi treinado um número duas vezes superior ao número de variáveis de entrada, totalizando 18 redes. Aquela que forneceu menor erro de estimativa foi aplicada à generalização.

Como variável categórica, o material genético na sua forma bruta não consegue ser processado pela rede. Para tanto, a entrada foi ajustada no modelo numérico como *Dummy Variable*, transformando a informação nominal em uma combinação de 0 e 1 (Wonnacott et al., 1969).

Ajuste hipsométrico

O modelo hipsométrico ajustado para este estudo agrega a influência do material genético e da altura dominante na determinação da relação ht/dap, bem como, busca tornar imparcial a comparação entre as metodologias. A equação aplicada para representar a relação hipsométrica foi o modelo genérico de Curtis em sua forma linearizada, descrito pela equação 2.

$$\ln(ht_i) = \text{matgen} + b1 * \left(\frac{1}{dap}\right) + b2 * \ln(hdom) + \varepsilon \quad (2)$$

onde ht_i representa a altura total da árvore i ; dap é o diâmetro do tronco da árvore i a uma altura de 1,30 m do solo; hdom é a altura das árvores dominantes; e ε o erro associado do modelo.

Critérios de avaliação

A avaliação das estimativas fornecidas por ambas as metodologias foi feita com base na análise gráfica dos resíduos e do histograma de erros percentuais, bem como na análise do erro padrão residual ($S_{yx}\%$), valor que expressa a diferença quadrática média entre os valores reais e estimados e pode ser representado pela equação 3.

$$S_{yx}(\%) = \frac{100}{\bar{y}} \sqrt{\frac{\sum_{i=1}^n (y - \bar{y})^2}{n}} \quad (3)$$

onde $S_{yx}(\%)$ representa erro padrão da estimativa em porcentagem; y é o valor da altura observada; \bar{y} o valor de altura estimada e n indica o número de observações

Todo o processamento foi feito no *software* livre R, na versão 3.3.2, sendo que para o processamento das RNAs utilizou-se o pacote *neuralnet* (Fritsch et al., 2016).

RESULTADOS E DISCUSSÃO***Arquitetura da RNA***

Para Haykin (2001), a melhor prática quando se trata de dimensionar a arquitetura de uma RNA, é usar o menor número de nós que resultam em desempenho adequado em um conjunto de dados de validação. Na maioria dos casos, mesmo com apenas um pequeno número de neurônios escondidos a rede neural pode oferecer uma enorme quantidade de capacidade de aprendizagem.

Com base na simulação do desempenho das arquiteturas propostas por meio do erro padrão residual, definiu-se o número de neurônios ideal para compor a RNA, expresso junto à outras características inerentes ao processamento na Tabela 1.

Tabela 1. Características e desempenho das Redes Neurais selecionadas para estimar a altura dominante. Fonte: Os Autores.

RNA	I.A. (ht/ha)	Arquitetura	Entradas Categóricas	Treinamento		Generalização	
				S _{xy} (m)	S _{xy} (%)	S _{xy} (m)	S _{xy} (%)
A	4	6-1	MATGEN	0,862	3,452	1,110	4,704
B	6	2-1	MATGEN	0,964	3,938	1,107	4,693
C	8	14-1	MATGEN	0,929	3,810	1,113	4,715
D	10	3-1	MATGEN	0,929	3,810	1,113	4,715

I.A. = Intensidade Amostral; Arquitetura: Número de neurônios em cada camada; Entradas categóricas: MATGEN = Material Genérico

Graficamente representado na Figura 1, nota-se certa estabilidade no comportamento da performance da arquitetura, com exceção do ajuste com somente quatro amostras de altura total. Este responde de forma instável e com maiores oscilações quanto ao erro.

Há também discrepância em todos os casos para arquiteturas de neurônio único, onde o erro padrão residual é mais elevado e destoia do comportamento, demonstrando que este modelo é inadequado na estimativa da variável de interesse. Contudo faz-se importante atentar ao fato de que o aumento na complexidade da arquitetura não necessariamente implica em uma melhora na estimativa. Haja vista a arquitetura selecionada com dois neurônios apenas, para descrever o cenário B.




Figura 1. Gráfico do Erro Padrão Residual da Generalização para variação da arquitetura em número de neurônios nas intensidades amostrais de (a) Quatro, (b) Seis, (c) Oito e (d) Dez alturas. Fonte: Os Autores.

Erro Padrão Residual

O modelo hipsométrico normalizado na forma logarítmica fornece resultados também na forma logarítmica. Como forma de facilitar a comparação e o entendimento dos resultados, as estimativas foram transformadas para metros, unidade da variável de interesse ht, utilizando a solução deduzida por Furnival (1961), que propôs um índice de conversão descrito na equação 4.

$$IF = 2,3026 [V] S_1 \tag{4}$$

Os resultados do Erro Padrão Residual ($S_{yx}^0\%$) para cada situação Intensidade e Metodologia estão representados a seguir na Tabela 2.

Tabela 2. Erro padrão residual das RNAs e Índice de Furnival para o modelo hipsométrico genérico considerando diferentes intensidades amostrais. Fonte: Os Autores.

I.A. (ht/parcela)	S_{yx} (RNA) %	IF (Hipso) %
QUATRO	5.55	7.35
SEIS	4.86	6.74
OITO	4.85	6.71
DEZ	4.63	6.66

I.A. = Intensidade Amostral; RNA = Rede Neural Artificial; Hipso = Ajuste Hipsométrico

Este parâmetro indica o quão próximo os valores estimados são dos valores observados. Desta forma, quanto mais próximo de zero for o erro padrão residual ou o índice de Furnival de um ajuste, mais o valor estimado se aproxima do valor real, portanto melhor ele é (Rufino et al., 2010). Os processamentos da RNA e do ajuste hipsométrico apresentaram resultados abaixo de 8% sendo que a melhora no desempenho é progressiva com o aumento da intensidade amostral. O valor encontrado para S_{yx} neste estudo, por ser inferior a 10%, pode ser considerado adequado quando comparado à valores encontrados por outros autores utilizando metodologias tradicionais de estimativa (PONTES NETO 2012; SOUSA et al., 2013; BARROS et al., 2002).

Mesmo que haja melhora, com exceção da amostragem na intensidade de quatro indivíduos, a variação entre os demais resultados é diminuta, não ultrapassando a casa dos 0,2%. Entre as metodologias, a estimativa das RNAs se mostrou mais acurada do que o modelo genérico para a base ajustada.

Análise gráfica

A análise gráfica dos resíduos permite identificar tendências no comportamento dos valores estimados. Desta forma, ainda que os demais parâmetros sejam bons indicadores, este procedimento é decisivo na determinação da escolha mais adequada de estimativa. No entanto é necessário destacar que o procedimento de análise é visual, portanto, subjetivo, e deve ser feito em paralelo às demais análises estatísticas. A partir do gráfico também é possível verificar se há homogeneidade de variância.

A inspeção gráfica da dispersão dos resíduos (Figura 2) demonstra similaridade no comportamento de ambas as metodologias.

Em todos os modelos ajustados o erro de hora inflacionar, e outra hora deflacionar estiveram compreendidos entre 20 a -30%, no entanto a amplitude do desvio para o modelo genérico de Curtis foi mais acentuada (Figura 2), ainda assim permanecendo dentro esperado ao observar com os resultados obtidos por Barros et al. (2002) em seu estudo com modelos genéricos.

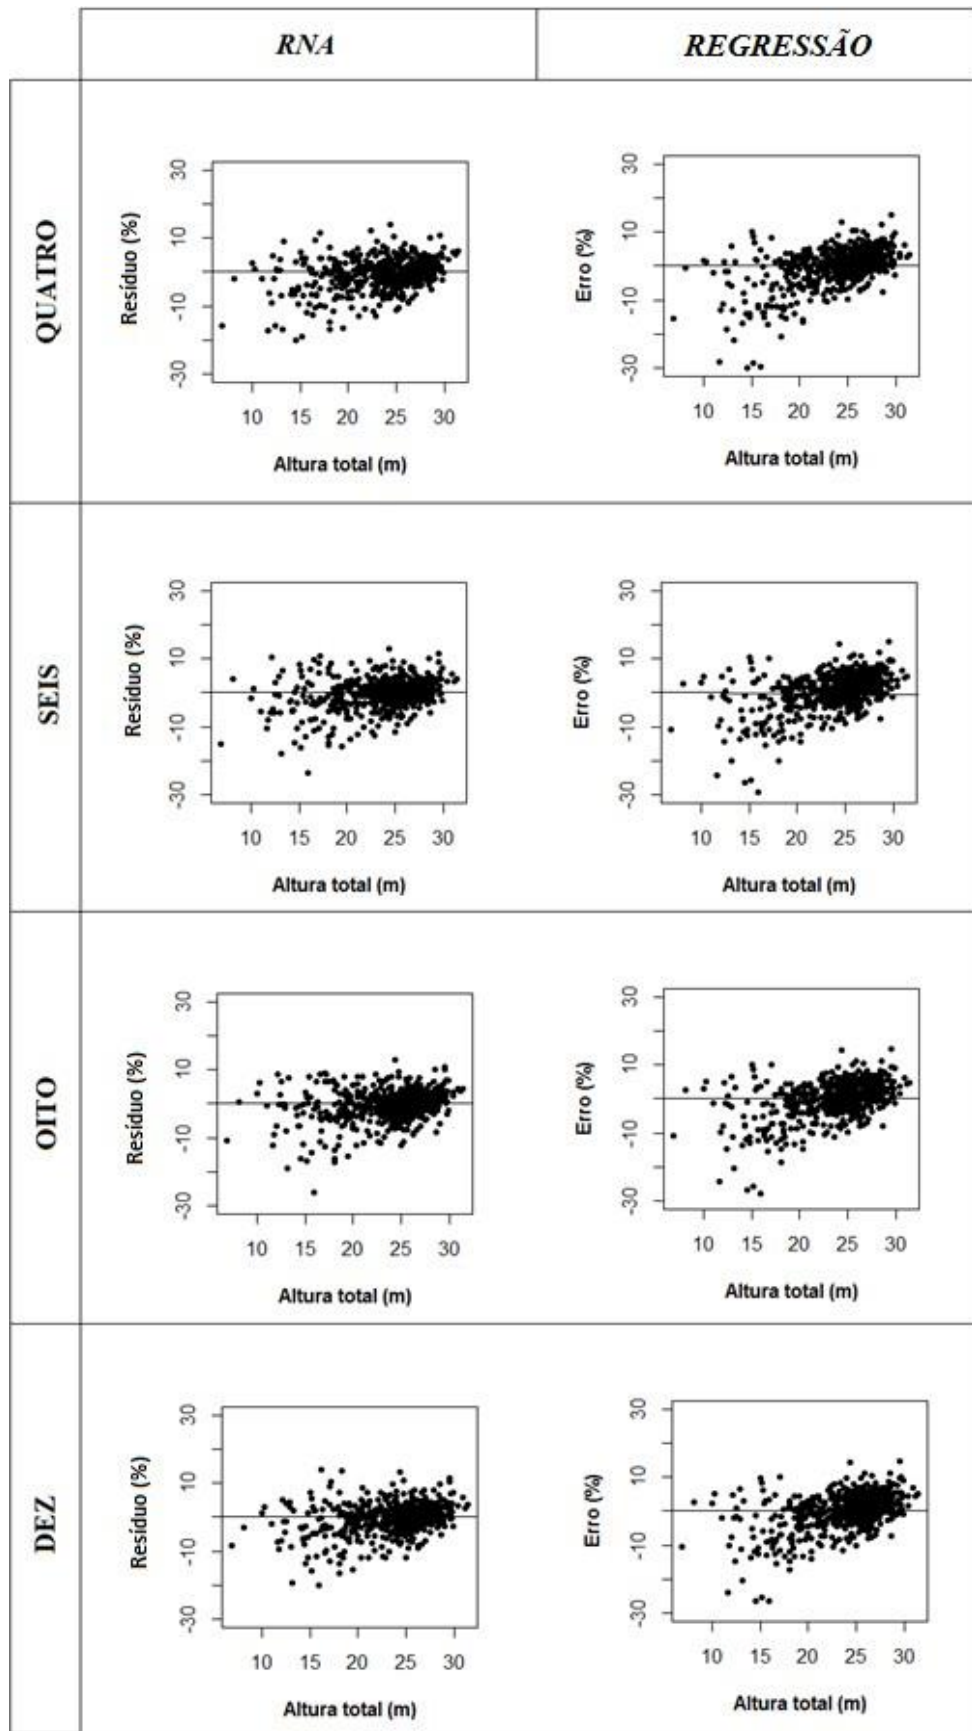


Figura 2. Gráficos de dispersão para cada intensidade amostral processada através do modelo genérico de Curtis. Fonte: Os Autores.




Figura 3. Histogramas da distribuição de resíduos para cada intensidade amostral processada através da Rede Neural Artificial e do modelo genérico de Curtis. Fonte: Os Autores.

Com um olhar mais atento, também se percebe que tanto o modelo genérico quanto as RNAs, apresentam tendenciosidade em superestimar os valores de Altura total na dispersão dos resíduos (Figura 2). Barros et al. (2002) afirmam que tal resultado é considerado inadequado.

Para Campos et al. (2013) a avaliação dos resíduos em forma de histogramas pode ser útil em situações em que há um grande número de observações, uma vez que somente os gráficos de dispersão podem levar ao risco de má interpretação em decorrência do risco de sobreposição dos pontos no gráfico (Vendruscolo et al. 2015). O histograma também demonstra se as estimativas descrevem um comportamento de distribuição normal.

Os histogramas de frequência dos erros para ambas as metodologias estimadoras, RNA e Regressão, apresentaram uma distribuição adequada segundo Vendruscolo et al. (2015), com as maiores frequências nas classes próximas a -10% e 10% de erro (Figura 2).

CONSIDERAÇÕES FINAIS

A investigação do desempenho das redes neurais artificiais dimensionadas quanto ao número de neurônios, demonstra que arquiteturas de único neurônio perdem notavelmente a capacidade de produzir boas estimativas. Entretanto não é necessário o uso de elevado grau de complexidade ao estimar variáveis com alta correlação, podendo até mesmo ser prejudicial quanto ao custo computacional que isto implica.

Conforme descrito na metodologia, a análise de desempenho das ferramentas na estimativa das alturas foi realizada primeiramente com relação ao menor erro padrão residual. No entanto, os erros padrões residuais encontrados para todos os tratamentos foram muito semelhantes. Ainda assim, considerando a variação na intensidade amostral, todas as RNAs ajustadas obtiveram resultados inferiores na fase de treinamento, significando maior eficácia na estimativa de acordo com este parâmetro de avaliação. Para o mesmo indicador, a intensidade amostral de quatro indivíduos por parcela apresenta desempenho destoante, enquanto as intensidades de 6, 8 e 10 não apresentam melhora notável.

Para o critério de análise gráfica, ambas as metodologias para qualquer das intensidades amostrais propostas demonstraram tendenciosidade para superestimar os valores de altura.

Não foi possível identificar melhora significativa na estimativa com o aumento na intensidade amostral, entretanto ficou claro que o desempenho tanto do modelo hipsométrico quanto da Rede Neural Artificial com somente quatro medições de altura, é inferior aos outros.

REFERÊNCIAS BIBLIOGRÁFICAS

Andrade LN (2011). Redes Neurais Artificiais Aplicadas na Identificação Automática de Áreas Cafeeiras em Imagens de Satélite. Departamento de Ciência da Computação, Universidade Federal de Minas Gerais (Dissertação), Belo Horizonte. 92p.

- Barros DA et al. (2002). Comportamento de modelos hipsométricos tradicionais e genéricos para plantações de *Pinus oocarpa* em diferentes tratamentos. Boletim de Pesquisa Florestal, (45): 3-28.
- Binoti DHB et al. (2013). Redução dos custos em inventário de povoamentos equiâneos. Agrária - Revista Brasileira de Ciências Agrárias, 8(1): 125-129.
- Binoti MLMS et al. (2013). Aplicação de Redes Neurais Artificiais para Estimação da Altura de Povoamentos Equiâneos de Eucalipto. Revista Árvore, 37(4): 639-645.
- Bishop CM (1995). Neural networks for pattern recognition. Oxford University Press, Inc., USA. 482p.
- Braga AP et al. (2007). Redes Neurais Artificiais: Teoria e Aplicações. 2 ed. Rio de Janeiro: LTC. 260p.
- Campos JCC et al (2013). Mensuração Florestal: perguntas e respostas. 4. ed. Viçosa: UFV, 605p.
- Couto HT et al. (1989). Mensuração e Gerenciamento de Pequenas Florestas. Documentos Florestais, (5): 1-37.
- Fritsch S et al. (2016). Neuralnet package: Training of Neural Networks. v. 1.33. CRAN: R Documentation.
- Furnival GM (1961) An Index for Comparing Equations Used in Constructing Volume Tables, Forest Science, 7(4): 337-341.
- Haykin S (2001). Redes neurais: princípios e prática. 2 ed. Porto Alegre: Bookman, 900p.
- Hebb DO (1949). The Organization of Behavior: a neuropsychological theory. Nova York: John Wiley and Sons. 335p.
- Indústria Brasileira de Árvores. Relatório anual IBÁ 2020. São Paulo, 2020. Disponível em: <https://iba.org/datafiles/publicacoes/relatorios/relatorio-iba-2020.pdf>. Acesso em: 23 dez. 2020.
- Lantz B (2015). Machine Learning with R. 2 ed. Birmingham: Packt Publishing. 452 p.
- Machado AS et al. (1994). Análise do comportamento da relação hipsométrica com respeito à idade para plantações de *Pinus elliottii* no Estado do Paraná. Cerne, 1(1): 5-12.
- Mendonça AR et al. (2015). Modelos Hipsométricos Generalizados Mistos na Predição da Altura de *Eucalyptus* sp. Cerne, 21(1): 107-115.
- Pontes Neto TP (2012). Comparação de Modelos Lineares e não Lineares em Relações Hipsométricas para Clones se *Eucalyptus* spp., no Polo Gesseiro no Araripe-PE. Departamento de Ciência Florestal, Universidade Federal Rural de Pernambuco (Dissertação), Recife. 75p.
- Rufino RF et al. (2010). Ajuste de Modelos Hipsométricos para um Povoamento de Eucalipto Conduzido Sobre o Sistema de Rebrotas. Enciclopédia Biosfera, 6(10): 1-10.
- Soares TS et al. (2004). Uso de Diferentes Alternativas para Viabilizar a Relação Hipsométrica no Povoamento Florestal. Revista Árvore, 28(6): 845-854.
- Sousa GTO et al. (2013). Relações Hipsométricas pra *Eucalyptus urophylla* conduzidos sob regime de alto fuste e talhadiano Sudoeste da Bahia. Scientia Plena, 9(4): 1-8.

- Thiersch CR (2007). Uma Nova Proposta Metodológica para Cubagem Rigorosa e Ajuste de Modelos Hipsométricos. Departamento de Ciências Florestais, Universidade Federal de Lavras (Tese), Lavras. 36p.
- Vendruscolo DGS et al. (2015). Estimativa da altura de eucalipto por meio de regressão não linear e redes neurais artificiais. *Revista Brasileira de Biometria*, 33(4): 556-569.
- Widrow B et al. (1990). 30 years of adaptative neural networks: perceptron, madaline, and backpropagation. *Proceedings of the IEEE*, 78(9): 1415-1442.
- Wonnacott TH et al. (1969). *Introductory statistics*. Nova York: John Wiley and Sons. 269p.

ÍNDICE REMISSIVO

A

altura de plantas, 27, 29, 31, 32, 48
 aprendizagem, 65, 66, 70
 armazenamento, 41, 96, 97, 98, 99, 100, 101

B

biodiversidade, 78
 bioproductos, 122, 127

C

Cachaza, 120, 121, 123, 124, 125, 126, 127, 128
 clima, 6, 7, 16, 26, 34, 43, 96, 110, 111
 coentro, 4, 26, 27, 28, 29, 30, 31, 32
 correlación, 120, 122, 126, 127, 128
 curvas anamórficas, 7, 8

D

densidades, 4, 41, 42, 43, 45, 46, 47, 48, 49
 desdobro, 56, 57, 58, 60, 61, 62
 desempenho, 4, 22, 43, 46, 47, 48, 49, 58, 66,
 67, 68, 70, 72, 76, 79, 110, 111, 114, 117
Desmodium, 4, 78, 79, 80, 82, 83, 84, 85, 86, 87,
 88, 89, 90, 91, 92, 93, 94
 deterioração, 96, 98, 99

E

efeito misto, 16
 envelhecimento acelerado, 33, 35, 38, 39, 40
Eruca sativa M., 42

F

fORAGEIRAS, 79, 80, 87, 88, 90, 92, 93, 94

G

germinação, 4, 33, 35, 36, 38, 39, 44, 96, 97, 98,
 99, 100, 101, 105, 113, 117

H

habichuela, 4, 119, 120, 122, 123, 124, 125, 126,
 127, 128, 129
 HERBAM, 80, 81, 82, 83, 86, 87, 90, 91, 94
Hesperozygis ringens, 4, 96, 97, 100, 101
 hidroponia, 42, 43, 44, 48

I

índice de sítio, 7, 8, 10, 14
 Intensidade Amostral, 70, 72
 irrigação, 4, 110, 111, 113, 114, 115, 116, 117,
 118

L

Lecanicillium muscarium, 107
 leguminosas, 78, 79, 90, 92, 93, 94, 103, 119

M

magnetismo, 117
 maquinário, 56
Metarhizium, 105, 107
 micoparasitismo, 4, 102, 104
 modelo hipsométrico, 64, 69, 71, 72, 76
 modelos de dupla entrada, 15, 17, 22
 modelos de simples entrada, 15, 17, 20, 22
 mudas, 4, 26, 27, 28, 29, 30, 31, 32, 44, 50, 51,
 117, 118

N

nitrogênio, 33, 34, 41, 79, 80, 91, 111

P

plantios florestais, 53
 potássio, 35, 42, 50, 110, 111, 113, 116
 produtos de madeira, 53

R

regressão, 4, 6, 7, 8, 9, 10, 11, 12, 13, 15, 34, 36,
 40, 64, 77
 regressão quantílica, 4, 6, 7, 8, 9, 10, 11, 12, 13
 rendimento, 40, 56, 57, 58, 60, 62, 111

S

Simplicillium lanosoniveum, 105, 107, 109
 soja, 4, 33, 34, 35, 37, 38, 39, 40, 41, 101, 102,
 103, 104, 105, 106, 107, 108, 109, 110, 111,
 113, 114, 115, 116, 117, 118
 superdimensionamento da arquitetura da rede,
 67

T

tecnologia, 40, 58, 100

tetrazólio, 33, 35, 36, 38, 39



Trichoderma asperellum, 105, 107, 109

U

ureia, 34

SOBRE OS ORGANIZADORES



  **Alan Mario Zuffo**

Engenheiro Agrônomo, graduado em Agronomia (2010) na Universidade do Estado de Mato Grosso (UNEMAT). Mestre (2013) em Agronomia - Fitotecnia (Produção Vegetal) na Universidade Federal do Piauí (UFPI). Doutor (2016) em Agronomia - Fitotecnia (Produção Vegetal) na Universidade Federal de Lavras (UFLA). Pós - Doutorado (2018) em Agronomia na Universidade Estadual de Mato Grosso do Sul (UEMS). Atualmente, possui 158 artigos publicados/aceitos em revistas nacionais e internacionais, 124 resumos simples/expandidos, 59 organizações de e-books, 33 capítulos de e-books. É editor chefe da Pantanal editora e revisor de 18 revistas nacionais e internacionais. Contato: alan_zuffo@hotmail.com.



  **Jorge González Aguilera**

Engenheiro Agrônomo, graduado em Agronomia (1996) na Universidad de Granma (UG), Bayamo, Cuba. Especialista em Biotecnologia (2002) pela Universidad de Oriente (UO), Santiago de Cuba, Cuba. Mestre (2007) em Fitotecnia na Universidade Federal do Viçosa (UFV), Minas Gerais, Brasil. Doutor (2011) em Genética e Melhoramento de Plantas na Universidade Federal do Viçosa (UFV), Minas Gerais, Brasil. Pós - Doutorado (2016) em Genética e Melhoramento de Plantas na EMBRAPA Trigo, Rio Grande do Sul, Brasil. Professor Visitante na Universidade Federal de Mato Grosso do Sul (UFMS) no campus Chapadão do Sul (CPCS), MS, Brasil. Atualmente, possui 62 artigos publicados/aceitos em revistas nacionais e internacionais, 29 resumos simples/expandidos, 40 organizações de e-books, 25 capítulos de e-books. É editor da Pantanal Editora e da Revista Agrária Acadêmica, e revisor de 19 revistas nacionais e internacionais. Contato: j51173@yahoo.com, jorge.aguilera@ufms.br.



Pantanal Editora

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000
Nova Xavantina – Mato Grosso – Brasil
Telefone (66) 99682-4165 (Whatsapp)
<https://www.editorapantanal.com.br>
contato@editorapantanal.com.br

