

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
Faculdade de Ciências Agrárias e Tecnológicas
UNESP - Câmpus de Dracena
Departamento de Produção Vegetal

Vitória Costa Mingoranci

Graduanda em Engenharia Agrônômica

**USO DE REDES NEURAIS ARTIFICIAIS PARA
AVALIAÇÃO COMPARATIVA DO DESENVOLVIMENTO DE
MUDAS DE *Eucalyptus* spp. PRODUZIDAS EM TUBETES
DE POLIPROPILENO E EM BERÇO GERMINADOR
COMPOSTÁVEL A CAMPO**

Dracena - SP
2023

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
Faculdade de Ciências Agrárias e Tecnológicas
UNESP - Câmpus de Dracena
Departamento de Produção Vegetal

**USO DE REDES NEURAIS ARTIFICIAIS PARA
AVALIAÇÃO COMPARATIVA DO DESENVOLVIMENTO
DE MUDAS DE *Eucalyptus* spp. PRODUZIDAS EM
TUBETES DE POLIPROPILENO E EM BERÇO
GERMINADOR COMPOSTÁVEL A CAMPO**

Discente: Vitória Costa Mingoranci
Orientador: Dr. Rafael Simões Tomaz

Trabalho de Conclusão de Curso
apresentado à Faculdade de
Ciências Agrárias e Tecnológicas do
Câmpus de Dracena - UNESP, como
parte das exigências para graduação
em Engenharia Agrônômica.

Dracena - SP
2023

UNIVERSIDADE ESTADUAL PAULISTA
"JULIO DE MESQUITA FILHO"
FACULDADE DE CIÊNCIAS AGRÁRIAS E TECNOLÓGICAS
UNESP – CÂMPUS DE DRACENA

CERTIFICADO DE APROVAÇÃO

Título: *Uso de Redes Neurais Artificiais para avaliação comparativa do desenvolvimento de mudas de Eucalyptus spp. produzidas em tubetes de propágulo e em Berço Germinador Compartável a campo.*
Modalidade: **Atividades de pesquisa.**

Autor: Vitória Costa Mingoranci

Orientador (a): Dr. Rafael Simões Tomaz

Co-orientador(es): Dr. Ronaldo Cintra Lima

Número de Créditos: 12

Data da aprovação e correção de acordo com as sugestões da Banca: 07/06/2023



Rafael Simões Tomaz



Vitor C. M. Barretto



Luiz Aparecido Neto

DADOS CURRICULARES DO AUTOR

Vitória Costa Mingoranci, nascido em 22 de setembro de 2001, na cidade de Flórida Paulista/SP. Iniciou a graduação em Engenharia Agrônoma no ano de 2019, na Universidade Estadual Paulista “Júlio de Mesquita Filho”, na Faculdade de Ciências Agrárias e Tecnológicas (FCAT), câmpus localizado no município de Dracena/SP. Membro do Centro de Estudos de Biometria Aplicada à Fitotecnia desde 2019. Foi bolsista em três instituições de fomento à pesquisa, sendo a primeira do Programa Institucional de Bolsas de Iniciação Científica (PIBIC), a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) e a Agência Unesp de Inovação (AUIN). Com os resultados de pesquisas realizadas com a cultura do eucalipto, foi premiada com títulos honoríficos alcançando o 2º lugar dentre os trabalhos mais bem avaliados no “3º IMAST-*International Meeting of Agrarian Science and Technology*”, no ano de 2021. Recebeu ainda premiação na 1ª Fase do “XXXIV Congresso de Iniciação Científica da UNESP”, alcançando o 1º lugar dentre os trabalhos mais bem avaliados do evento e classificando para a 2ª Fase do Congresso. Foi membro da Comissão Organizadora do Evento de Extensão Universitária intitulado “1º Ciclo de Palestras Virtual da FCAT - Tecnologias na Cultura da Soja” no ano de 2020 e do Evento de Extensão intitulado “V Expedição da Engenharia Agrônoma”, realizado nas propriedades, institutos de pesquisa e empresas agropecuárias em 2022. Atuou como representante discente e bolsista do Ambiente de Inovação “Celeiro de Ideias” em parceria com a Agência Unesp de Inovação (AUIN), desenvolvendo ambientes mais fortes e inovadores.

DEDICATÓRIA

À minha admirável mãe, Adevita Costa Mingoranci e ao meu pai Silvio Deamo Mingoranci, que me educaram, guiando-me com sua sabedoria e me fornecendo as ferramentas necessárias para alcançar essa conquista, modelos inspiradores para minha vida pessoal e profissional.

AGRADECIMENTOS

Em primeiro lugar, expresso minha profunda gratidão a Deus, por abençoar-me com o dom da vida, por iluminar meus caminhos ao longo desta jornada e principalmente por me conceder saúde. Sua presença constante e Seu amparo foram fundamentais para superar os desafios que encontrei pelo caminho. Reconheço que cada tribulação foi essencial para me moldar, agradeço por ser o sustento por trás de todas as minhas conquistas.

Desejo estender meus agradecimentos aos meus amados pais, a minha admirável e batalhadora mãe, Adevita Costa Mingoranci e ao meu querido pai, Silvio Deamo Mingoranci. Através de sua educação valiosa, vocês me proporcionaram uma conquista de valor imensurável. Seu trabalho incansável, humildade, integridade e apreço pela vida me moldaram uma mulher forte e determinada. Sou grata por todo o amor, apoio e orientação que vocês me deram durante essa jornada.

Também gostaria de expressar minha gratidão ao meu irmão, Vinicius Costa Mingoranci, um exemplo notável de humildade, trabalho árduo e conhecimento. Sua presença em minha vida tem sido uma fonte constante de inspiração e encorajamento. Devo a vocês o que sou hoje e serei eternamente grata por todo ensinamento que recebi.

Agradeço aos meus avós, Dona Maria de Lourdes e Sr. Manoel Costa, que tornaram essa caminhada mais leve e enriquecedora. Aos meus primos, tio e tia, em especial minha querida segunda mãe, Jovita Bianco, que sempre esteve presente para me apoiar e me guiar ao longo dessa caminhada. Agradeço também a minha madrinha e amadas primas, Camila Bianco, e a Patrícia Bianco, por compartilharem comigo seu exemplo de cuidado com os detalhes e de dedicação para com as coisas e pessoas.

Expresso minha profunda gratidão aos meus colegas de classes, cuja contribuição foi fundamental para o meu aprendizado. Meus amigos de graduação, em especial a Munick Aragão, Beatriz Ré e o Rafael Postinguel, que estiveram ao meu lado durante toda essa jornada acadêmica, me ajudando e compartilhando comigo as experiências da vida universitária.

Quero agradecer ao meu orientador, Professor Doutor Rafael Simões Tomaz, pela sua paciência, ensinamentos, por me desafiar constantemente, sempre torcendo pelo meu crescimento profissional. Desde o início, sua orientação foi excelente, e sua contribuição nas bolsas de iniciação científica foi fundamental para todo reconhecimento, fruto dos esforços desempenhados durante anos de trabalho com o senhor.

Em especial, deixo minha admiração ao Professor Doutor Ronaldo Cintra Lima, um profissional exemplar, que sempre me acolheu com muito carinho e me proporcionou ensinamentos valiosos dentro e fora da sala de aula.

Agradeço ao Centro de Estudos de Biometria Aplicada à Fitotecnia, a qual, fiz parte desde o início da graduação, que me acolheu e deu diversos ensinamentos e experiências pessoais e profissionais. A Yanca Frias, que esteve ao meu lado desde o início e me apoiou até o final. A Thalia Valério, Arthur Lopes e Victor Hugo Cruz, que sempre se mostraram disponíveis para me auxiliar nas avaliações da minha iniciação científica. Minha gratidão a todas as pessoas que, de alguma forma, contribuíram para a realização dos projetos e que me auxiliaram durante a graduação, sou profundamente grata por toda a colaboração.

Agradeço ao Programa Institucional de Bolsas de Iniciação Científica (PIBIC), que financiou a minha primeira iniciação científica e presente trabalho. À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP)- Processo 2021/07776-0, que financiou a pesquisa que também foi elaborado a este trabalho. À Agência Unesp de Inovação (AUIN), agradeço pela concessão de duas bolsas, que incentivam o empreendedorismo e a inovação dentro do câmpus.

Por fim, gostaria de expressar minha gratidão à Faculdade de Ciências Agrárias e Tecnológicas (FCAT) da Unesp, em Dracena/SP, pelo ensino de qualidade e pelo corpo docente altamente qualificado que me capacitou como profissional. Agradeço todos os servidores, técnicos administrativos e técnicos de campo, em especial o Alan e o Adriano, que me proporcionaram grandes aprendizados e amizade ao longo do meu percurso acadêmico.

“No que diz respeito ao desempenho, ao compromisso, ao esforço, à dedicação, não existe meio termo. Ou você faz uma coisa bem-feita ou não faz” (Ayrton Senna).

RESUMO

Atualmente, a sustentabilidade tem se tornado uma questão frequente e importante. Medidas que visam reduzir os impasses para uma produção sustentável estão sendo cada vez mais adotadas, especialmente na produção das florestas plantadas. A cultura do eucalipto é amplamente utilizada na produção de papel e celulose, devido ao seu grande potencial de produtividade tornando o Brasil o segundo maior produtor do mundo. No entanto, a qualidade das mudas desempenha um papel fundamental no crescimento e sobrevivência das plantas pós-plantio. O uso de tubetes é predominante na produção de mudas de eucalipto no setor florestal. Nesse contexto, há uma necessidade de utilizar recipientes renováveis para substituir os tubetes convencionais. Além disso, a inteligência artificial tem desempenhado um papel cada vez mais importante no setor florestal, sendo aplicada em diversas áreas, como medição de volume, diâmetro e altura das árvores, identificação de incêndios florestais, doenças e análises de diversidade genética. As Redes Neurais Artificiais, em particular, são altamente adaptáveis e flexíveis, permitindo a compreensão e simulação das relações presentes nos sistemas complexos, como os ecossistemas florestais. Este trabalho teve por objetivo comparar o desempenho de árvores de *Eucalyptus* spp produzidas em tubete de polipropileno e em Berço Germinador Compostável em campo, por meio do método baseado em Redes Neurais Artificiais. As plantas foram provenientes de um sistema de produção em estufa agrícola e transplantadas a campo. Foram realizadas avaliações de altura e diâmetro. Na análise estatística, considerou-se o ajuste de modelos de crescimento, lineares e não lineares, incluindo os modelos Logístico, Gompertz e Von Bertalanffy. Além disso, foram utilizadas diferentes arquiteturas e predição de fenótipos pelas Redes Neurais Artificiais, considerando um conjunto do tipo MLP (Perceptron Multicamada) com o treinamento supervisionado com algoritmo backpropagation. Foram consideradas duas camadas ocultas e diferentes quantidades de neurônios, bem como o uso de métricas para avaliar a eficiência. Também foi avaliada a biodegradabilidade dos tubetes SIS BGC®. Os resultados indicam que o uso do tubete SIS BGC® não afetou o desenvolvimento e pode ser considerado uma alternativa ao tubete convencional. No entanto, a taxa de biocompostabilidade não atingiu a porcentagem determinada. Em resumo, os modelos de crescimento não lineares apresentaram um melhor ajuste dos dados e as Redes Neurais Artificiais foram consideradas modelos adequados para predição de altura e diâmetro de árvores da espécie eucalipto. Além disso, a quantidade de neurônios nas arquiteturas testadas das redes não influenciou o desempenho dos modelos.

Palavras-chave: Inteligência artificial; mensuração florestal; Sustentabilidade; agrotecnologia; inovação.

ABSTRACT

Currently, sustainability has become a frequent and important issue. Measures that aim to reduce the impacts for a sustainable production are being increasingly adopted, especially in the production of planted forest. The culture of eucalyptus is widely used in the production of paper and pulp, due to its great potential for productivity, making Brazil the second largest producer in the world. However, the quality of the seedlings plays a key role in the growth and survival of the plants post-planting. The use of tubes is predominant in the production of eucalyptus seedlings in the forestry sector. In this context, there is a need to use renewable containers to replace conventional tubes. In addition, artificial intelligence has been playing an increasingly important role in the forest sector, being applied in several areas, such as volume, diameter, and height measurement of trees, identification of forest fires, diseases, and analysis of genetic diversity. Artificial Neural Networks, in particular, are highly adaptable and flexible, allowing the understanding and simulation of the relationships present in complex systems, such as forest ecosystems. This work aimed to compare the performance of Eucalyptus spp trees grown in polypropylene tubes and in Compostable Germinating Cradle in the field, using the method based on Artificial Neural Networks. The plants came from a production system in an agricultural greenhouse and were transplanted to the field. Evaluations of height and diameter were performed. In the statistical analysis, we considered the adjustment of growth models, linear and non-linear, including the Logistic, Gompertz, and Von Bertalanffy models. In addition, different architectures and phenotype prediction by Artificial Neural Networks were used, considering a MLP (Multilayer Perceptron) type ensemble with supervised training with backpropagation algorithm. Two hidden layers and different numbers of neurons were considered, as well as the use of metrics to evaluate efficiency. The biodegradability of SIS BGC® tubes was also evaluated. The results indicate that the use of SIS BGC® cores did not affect development and can be considered an alternative to conventional cores. However, the biodegradability rate did not reach the determined percentage. In summary, the non-linear growth models presented a better fit to the data and the Artificial Neural Networks were considered suitable models for predicting the height and diameter of trees of the eucalypt species. Furthermore, the number of neurons in the tested network architectures did not influence the performance of the models.

Keywords: Artificial intelligence; forest measurement; sustainability; agrotechnology; innovation.

LISTA DE FIGURAS

Figura 1 — Representação de um neurônio biológico	22
Figura 2 — Modelo de um neurônio artificial.....	23
Figura 3 — Análise de regressão linear: (A) característica diâmetro e (B) altura.	39
Figura 4 — Exemplo de arquitetura de ANN com 2 neurônios em cada camada oculta.....	42
Figura 5 — Exemplo de arquitetura de ANN com 3 neurônios na primeira camada oculta e 7 neurônios na segunda camada oculta.	42
Figura 6 — Exemplo de arquitetura de ANN com 10 neurônios em cada camada oculta.....	42
Figura 7 — Métricas: (A) Coeficiente de determinação; (B) RMSE; (C) MSE; (D) MAE.	45
Figura 8 — Comparação entre curvas de crescimento ajustadas para tubete Convencional e SIS BGC pelo método da ANN, para as características: (A) diâmetro; (B) altura.....	47

LISTA DE FOTOS

Foto 1 — Recipientes: (A) Recipiente biodegradável SIS BGC; (B) tubete convencional ou de polipropileno.	27
Foto 2 — Estufa agrícola: (A) Experimento em estufa agrícola; (B) Análises para índice de clorofila	28
Foto 3 — Delimitação da área e dos blocos, com imagens do drone Phantom 4 V2.0.....	29
Foto 4 — Transplântio das mudas: (A) Retirada dos torrões; (B) Adubação de plantio; (C) Plantas alocadas nos berços; (D) Início da irrigação.....	30
Foto 5 — Tratos culturais. Controle de formigas cortadeiras com isca (A); Desrama (B).	31
Foto 6 — Avaliações com o Clinômetro: (A) Clinômetro; (B) Medição de altura.	31
Foto 7 — Desempenho do povoamento de eucalipto com os tubetes de polipropileno e SIS BGC®.....	38
Foto 8 — Resquícios do material: (A) Tubete SIS BGC® junto ao colo da planta de eucalipto; (B) Resquícios do tubete SIS BGC® após 749 dias de plantio a campo; (C) Material danificado pelo desenvolvimento da planta; Fragmentos do material (D).....	49
Foto 9 — Berço Germinador Seth®: (A) Produção de mudas com a tecnologia; (B) Conformação do BG Seth®.....	50

LISTA DE GRÁFICOS

Gráfico 1 — Modelo não linear logístico.....	40
Gráfico 2 — Modelo não linear de Von Bertalanffy	40
Gráfico 3 — Modelo não linear de Gompertz	41

LISTA DE TABELAS

Tabela 1 — Modelos avaliados	32
Tabela 2 — Métricas de ajuste dos valores preditos e observados	34
Tabela 3 — Arquitetura das Redes Neurais Artificiais, variáveis na camada de entrada, oculta e saída.....	35
Tabela 4 — Análise de variância para as características D – Diâmetro – e H – Altura de Planta – avaliadas aos 869 dias após o transplântio.	36
Tabela 5 — Coeficiente de determinação (R^2) dos modelos avaliados.....	39
Tabela 6 — Métricas avaliadas para cada arquitetura de rede para a característica altura.....	43

LISTAS DE ABREVIATURAS E SIGLAS

ANNs	<i>Artificial Neural Networks</i>
DAP	Diâmetro Altura do Peito
FV	Fonte de Variação
GEE	Gases de Efeito Estufa
GL	Grau de Liberdade
ILPF	Integração-Lavoura-Pecuária-Floresta
MAE	<i>Mean Absolute Error</i>
Mfpa	Massa Fresca de Parte Aérea
Mfr	Massa Fresca de Raiz
MLP	<i>Perceptron Multicamada</i>
MSE	<i>Mean Squared Error</i>
Mspa	Massa Seca de Parte Aérea
Msr	Massa Fresca de Raiz
MST	Massa Seca Total
ODS	Objetivos de Desenvolvimento Sustentáveis
QM	Quadrado Médio
RMSE	<i>Root Mean Squared Error</i>
RNAs	Redes Neurais Artificiais
SIS BGC®	Berço Germinador Compostável

LISTA DE SÍMBOLOS

Y_i	Valor observado para a variável de estudo
\hat{Y}_i	Valor predito
X_i	Valor original da particular covariável de entrada
$f(X_i)$	Valor normalizado de X_i
R^2	Coefficiente de determinação

SUMÁRIO

1 INTRODUÇÃO	15
2 OBJETIVOS	16
2.1 Objetivo Geral.....	16
2.1 Objetivos Específicos.....	16
3 REVISÃO DE LITERATURA	17
3.1 Cultivo do eucalipto e o setor florestal no Brasil	17
3.2 Recipientes para produção de mudas de florestais	18
3.3 Inteligência Artificial no setor florestal.....	20
3.4 Redes Neurais Artificiais.....	21
4. MATERIAL E MÉTODOS	26
4.1. Área de estudo	26
4.2. Recipientes	26
4.3. Clone	27
4.4. Delineamento experimental	27
4.4.1 Estufa agrícola	27
4.4.2. Campo.....	29
4.5 Análise dos dados	32
4.5.1 ANOVA.....	32
4.5.2 Ajuste de modelos de crescimento.....	32
4.5.3 Arquitetura e predição de fenótipo pela <i>Artificial Neural Network</i>	32
4.5.4 Análises das ANNs.....	33
4.5.5 Avaliação comparativa dos métodos.....	33
4.5.6 Avaliação comparativa entre arquiteturas	34
5 RESULTADOS E DISCUSSÃO	35
5.1 Anova.....	35

5.2 Modelagem de altura e diâmetro utilizando regressão	38
5.3 Redes Neurais Artificiais (ANNs)	41
5.4 Desafios no uso das Redes Neurais Artificiais	47
5.5 Biocompostabilidade do tubete SIS BGC®	48
6. CONCLUSÃO	52
REFERÊNCIAS.....	53

1 INTRODUÇÃO

O eucalipto é uma cultura que se espalhou rapidamente no Brasil devido sua adaptabilidade, e se tornou a principal fonte de matéria-prima para a indústria de papel e celulose. O país possui um grande potencial de produtividade devido ao clima tropical e subtropical e às condições favoráveis do solo para tal cultura. Atualmente, uma grande área é dedicada ao cultivo de eucalipto, representando a maior parte das árvores plantadas no país. O setor de árvores cultivadas desempenha papel crucial na redução das emissões de Gases de Efeito Estufa, armazenando grandes quantidades de dióxido de carbono equivalente em florestas produtivas e naturais, o que faz com que a cultura ganhe ainda mais destaque no país.

No setor florestal, o uso de tubetes é predominante na produção de mudas de eucaliptos e pinus devido às vantagens que oferece, como maior volume de mudas produzidas e eficiência nas operações. Com foco no desenvolvimento sustentável, e alinhado com os Objetivos de Desenvolvimento Sustentável (ODS), as comunidades científicas têm se dedicado à pesquisa e desenvolvimento de novos recipientes de fontes alternativas, incluindo recipientes biodegradáveis.

As redes neurais artificiais, também conhecidas como redes de aprendizado profundo ou “*Deep Learning*”, são modelos e métodos que envolvem normalmente modelos estatísticos não lineares. Elas são utilizadas para modelar uma ou várias variáveis quantitativas, categóricas ou combinações delas. À vista disso, em um estudo baseado em redes neurais artificiais, é necessário ajustar, a quantidade de neurônios e as funções de ativação específicas, de acordo com o problema em questão

Dessa forma, o objetivo desta pesquisa é realizar uma avaliação comparativa do desempenho de mudas de *Eucalyptus* spp. cultivadas em tubetes de polipropileno e em Berço Germinador Compostável, utilizando o método baseado em redes neurais artificiais.

2 OBJETIVOS

2.1 Objetivo Geral

Realizar uma avaliação comparativa de desempenho de árvores de *Eucalyptus* spp produzidas em tubete de polipropileno e em Berço Germinador Compostável, por meio do método baseado em Redes Neurais Artificiais.

2.1 Objetivos Específicos

- Realizar a comparação dos tratamentos Berço Germinador Compostável (SIS BGC®) e tubete de polipropileno.
- Realizar a comparação dos ajustes de modelos de crescimento.
- Realizar ajuste por meio de redes neurais artificiais, visando predição.
- Realizar avaliação de arquiteturas de redes neurais artificiais para predição.

3 REVISÃO DE LITERATURA

3.1 Cultivo do eucalipto e o setor florestal no Brasil

O gênero *Eucalyptus* é nativo da Austrália e sua introdução no Brasil aconteceu por volta do século XIX, no qual difundiu-se rapidamente devido a sua adaptabilidade com o clima favorável do país para essa cultura (VECHI; JÚNIOR, 2018). Tendo grande aceitação no país, tornou-se principal responsável pela matéria prima para a indústria de papel e celulose. Segundo o relatório de 2022 da Indústria Brasileira de Árvores (IBÁ), no ano de 2021 a produção de celulose cresceu 7,4%, sendo 22,5 milhões de toneladas de celulose produzidas, garantindo ao Brasil a posição de segundo maior produtor do mundo, atrás apenas dos Estados Unidos. Já a produção de papel subiu 4,2% tendo 10,7 milhões de toneladas de papel produzidas, classificando o país entre os dez maiores produtores de papel do mundo.

O Brasil possui um grande potencial de produtividade para o eucalipto devido ao clima tropical e subtropical na maior parte da extensão territorial do país e condição de solo favorável (JUNIOR; COLODETTE, 2013). O setor florestal apresentou 20,5% do crescimento do PIB de 2010 a 2021, tendo maior desempenho especificamente no ano de 2016, ressaltando sua importância na economia brasileira (IBÁ, 2022). O Brasil possui uma área de 7,53 milhões de hectares ocupados pelo cultivo do eucalipto, representando 75,8% da área total de árvores plantadas no país. Ainda, de acordo com IBÁ (2022), os maiores produtores são: Minas Gerais (2,24 milhões de hectares), São Paulo (0,98 milhões de hectares), Paraná (0,45 milhões de hectares), Mato Grosso do Sul (1,04 milhões de hectares), Santa Catarina (0,32 milhões de hectares) e Rio Grande do Sul (0,59 milhões de hectares).

O setor florestal contribui para geração de novos empregos, permite o consumo dos produtos que são gerados, assim como a exportação dos mesmos, colaborando, portanto, para o crescimento da economia nacional (VITAL 2007). Apesar de todas as dificuldades notórias dentro do mercado de trabalho para geração de empregos, principalmente por conta da pandemia, no ano de 2020 e 2021, aproximadamente 1,59 milhões de brasileiros se beneficiaram da criação de emprego desse setor de forma indireta e 553 mil postos de trabalho diretos também foram beneficiados (IBÁ 2022).

Atualmente, um sistema inovador vem sendo implementado dentro das atividades agrícolas. De acordo com a Rede Integração-Lavoura-Pecuária-Floresta, em estudo publicado por Polidoro *et al.* (2020) cerca de 17,43 milhões de hectares são áreas de Integração Lavoura-Pecuária-Floresta estimados na safra 2020/2021. Trata-se do modelo de cultivo, em que esses elementos são combinados de forma que todos possam crescer em harmonia, e de forma que haja uma sinergia entre os componentes desse sistema. Tal modelo apresenta as mais diversas vantagens, tais como: redução de pragas e plantas daninhas; aumento do bem-estar animal; melhoria nos atributos físicos, químicos e biológicos do solo, entre outros (BALBINO *et al.*, 2012). Além disso, a ILPF está intrinsecamente relacionada com o Plano de Agricultura de Baixa Emissão de Carbono em conjunto do Plano ABC+ com foco em aumentar a área de plantio com esse sistema até o ano de 2030, ganhando ênfase e sendo vista com bons olhos no desenvolvimento da sustentabilidade de diferentes produções em uma mesma área (IBÁ, 2022).

Dessa forma, o setor de árvores cultivadas no Brasil, é crucial para a diminuição dos impactos das emissões de Gases de Efeito Estufa (GEE), na qual, 9,93 milhões de hectares que são destinados a florestas produtivas cerca de 1,79 bilhão de toneladas de dióxido de carbono equivalente são estocados. As florestas naturais com cerca de 6 milhões de hectares com finalidade de conservação, estocam 2,67 bilhões de toneladas de dióxido de carbono equivalente (IBÁ, 2022).

3.2 Recipientes para produção de mudas de florestais

Garantir um desenvolvimento adequado das mudas constitui um fator crucial na produção e faz grande diferença para o seu posterior crescimento das plantas, uma vez que mudas de melhor qualidade apresentam maior sobrevivência no plantio (WENDLING *et al.*, 2021). No entanto, o setor de produção de mudas florestais ainda requer o desenvolvimento de tecnologias e práticas para que o sucesso no estabelecimento das mudas após o plantio em campo seja mais eficiente.

A utilização de tubetes para a produção de mudas provenientes do gênero *Eucalyptus* e *Pinus* é caracterizado como predominante no setor florestal, visto a presença de vantagens como maior volume de mudas a serem produzidas e adequação nas operações (LISBOA *et al.*, 2012).

Com foco no desenvolvimento sustentável e nas atuais realidades no mundo todo, como exemplo os Objetivos de Desenvolvimento Sustentável (ODS), no Brasil, criado pela Organização das Nações Unidas (ONU, 2023), o foco das comunidades científicas tem se destinado ao desenvolvimento de pesquisas que atendam e visem o desenvolvimento de novos recipientes com fontes alternativas (PAULA, 2022), sobretudo o uso de recipientes biodegradáveis.

O uso de tubetes como os provenientes de fontes renováveis ou biodegradáveis inclui inúmeras exigências na sua criação, principalmente em questões de morfologia, que geralmente são confeccionados em diferentes tamanhos, moldes, mas que sempre estejam de forma similar aos tubetes comuns (PEREIRA *et al.*, 2007; RESENDE; CHAER, 2010) e com materiais que tenham a infiltração de água.

De acordo com Aguiar *et al.*, (1989), novos recipientes de mudas têm sido testados com o intuito de inovar em relação ao saco plástico e ao tubete de polipropileno, entre eles, podemos citar os tubetes de plástico, bandejas de isopor, além do *Ellepot*[®] que foi utilizado em pesquisas com eucalipto, como trabalhos de Rodrigues *et al.*, (2020) e Gil; Silva; Simões (2021), na qual, evidenciam que mudas florestais nativas produzidas em diferente recipientes são responsáveis na produtividade efetiva em restauração florestal ativa.

Dentre os recipientes existentes, o que possui maior aceitação no mercado é o tubete de polipropileno, por proporcionar acondicionamento de grande número de mudas, fácil locomoção e automatização do processo de produção de mudas (CALDEIRA *et al.*, 2016). Entretanto, tais recipientes exigem mão de obra de retirar o torrão do eucalipto para posterior plantio. Além disso, as bandejas precisam ser lavadas, esterilizadas e ainda necessitam de espaço para serem armazenadas (WENDLING *et al.*, 2021). Ou seja, a adoção de tubetes de plásticos induz a um aumento no gasto com a logística da produção de mudas.

Em contrapartida, os tubetes biodegradáveis eliminam esses problemas, uma vez que o recipiente é plantado juntamente a muda, eliminando a necessidade de se retirar o torrão das mudas, a lavagem das bandejas, logística, entre outros (WENDLING *et al.*, 2021). Porém, tubetes SIS BGC[®] ainda estão em fase de análise para se buscar resultados adequados.

Nos plantios comerciais de eucalipto, a utilização de clones derivados de mudas cultivadas em tubetes convencionais de polipropileno, em biofábricas de

produção, constitui prática comum na maioria das empresas do setor florestal. A utilização desse sistema convencional de produção implica em um paradigma de produção no qual existe a necessidade de transporte dos tubetes do campo à biofábrica; mão de obra para o batimento e lavagem dos tubetes; além de despesas com armazenamento, entubetamento e desinfecção, por isso oferece diversas vantagens quando comparados a sacola de plástico utilizada em menor escala (CALDEIRA *et al.*, 2016).

Nesse sentido, a adoção de novas tecnologias, como o SIS BGC® ou Berço Germinador Compostável surge como alternativa viável que apresenta vantagens como embandejamento automático e a eliminação da necessidade da logística reversa dos tubetes, uma vez que o SIS BGC® pode ser plantado com a muda. Em adição, as pesquisas voltadas para o desenvolvimento de embalagens biodegradáveis para uso em viveiros estão sempre no dinamismo e focadas no componente sistema radicular, pois o mesmo deve apresentar-se em boas condições e não sofrer com intempéries, bem como a vantagem do plantio do tubete junto a muda, facilitando o desempenho pós plantio (GOMES *et al.*, 2003).

Segundo Carneiro (1995) o fator durabilidade da embalagem biodegradável também é um aspecto que deve ser levado em consideração, pois durante sua produção e uso em viveiros, não pode ocorrer da sua desintegração e quando levada a campo não poderá demorar para se decompor.

Como ressaltado por Artur Junior (2011), o uso de recipientes biodegradáveis ainda não constitui realidade no setor florestal brasileiro. No entanto, faz-se necessário repensar o uso de recipientes provenientes de fontes não renováveis, visando buscar um equilíbrio sustentável que proporcione ainda a redução do impacto ambiental direto e indireto causado pelo sistema convencional. A literatura é bastante carente no que concerne à eficiência do sistema, e as implicações da utilização do SIS BGC® para a planta (COSTA, 2018; JUNIOR *et al.*, 2011), assim como a respeito da degradação do compósito. Apenas Costa (2020) utilizou tal tecnologia para avaliação do desempenho de produção de mudas de aroeira.

3.3 Inteligência Artificial no setor florestal

A inteligência artificial é caracterizada como uma área da Ciência da Computação, que tem como objetivo permitir ao computador ou máquina a realização

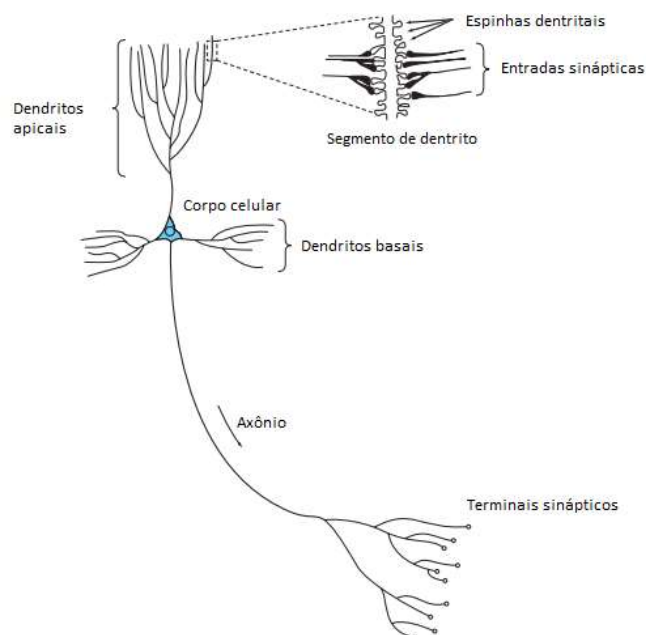
tarefas e/ou a solução de problemas (NORVIN; RUSSELL, 2013). O emprego da inteligência computacional tem sido aceita em diversas áreas, no melhoramento de plantas a aplicação de inteligência computacional vem sendo utilizado na seleção de variáveis (SILVA JUNIOR *et al.*, 2021), No setor florestal sua utilização se deu em análises de diversidades florística (CABACINHA; LAFETÁ, 2017), identificação de incêndios florestais (MAEDA *et al.*, 2009) e identificação de doenças (POONA; ISMAIL, 2013).

3.4 Redes Neurais Artificiais

De acordo com Russell *et al.* (1995) as ANNs – *Artificial Neural Networks* – ou redes neurais artificiais podem ser interpretadas como um modelo matemático para a representação das operações do cérebro, sendo que os elementos aritméticos da computação representam os neurônios e a rede corresponde à coleção de neurônios interconectados.

Os neurônios biológicos (Figura 1) caracterizados como constituintes estruturais do cérebro humano, são divididos em corpo celular, dendritos e o axônio, cada um possui sua função em específico, mas que dependem um do outro. Sendo assim, os dendritos são responsáveis por receberem os impulsos nervosos, ou seja, as informações, que posteriormente serão conduzidas para o corpo celular onde essas informações vão ser processadas e transmitidas como novos impulsos direcionados ao axônio que terão contato com outros dendritos dos próximos neurônios (SILVA, 2019). As conexões de neurônios com outros neurônios são conhecidas por sinapses, que possuem a capacidade de controlar a transmissão dos impulsos que são feitos pelos neurônios (CRUZ; NASCIMENTO, 2018; HAYKIN, 2001).

Figura 1 — Representação de um neurônio biológico

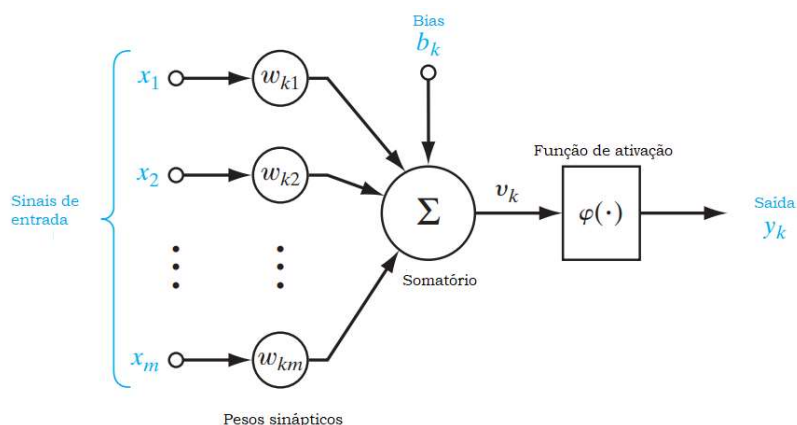


Fonte: Adaptado de Haykin (2004).

As ANNs são constituídas de unidades de processamento simples, denominadas neurônio artificial, sendo este composto por: um conjunto de conexões, cada uma delas com um peso; um elemento somatório capaz de somar as informações de entrada; e uma função de ativação com o intuito de restringir a amplitude da resposta, e disparar uma saída associada ao neurônio (BRAGA; LUDERMIR; CARVALHO, 2000). O neurônio artificial é a unidade básica de processamento das ANNs (HAYKIN, 2008), sendo uma estrutura projetada para funcionar de forma análoga ao neurônio biológico, apresentando as mesmas características e possuindo a capacidade de adquirir conhecimento.

Segundo McCulloch e Pitts (1943), a classificação do neurônio artificial (Figura 2) é feita por sinais de entrada (X_m) calculados por pesos sinápticos simulando as sinapses ($W_{k,m}$) conectados ao corpo celular artificial, que nada mais é que um somador (Σ) nos sinais de entrada, além de uma função de ativação $f(x)$ com a finalidade de controlar as amplitudes dos neurônios, e por fim um viés (b_k) com função de aumentar ou diminuir a entrada de ativação (HAYKIN, 2008).

Figura 2 — Modelo de um neurônio artificial



Fonte: Adaptado de Haykin (2004).

O termo rede neural, de acordo com Hastie, Tibshirani e Friedman (2008), tem sido utilizado para englobar um grande conjunto de modelos e métodos de aprendizagem que envolvem normalmente modelos estatísticos não lineares. Uma rede neural constitui-se de uma regressão em dois estágios (“*two-stage regression*”) ou um modelo de classificação, normalmente representado em um diagrama de rede. Essa categoria de rede pode ser utilizada para modelar uma ou múltiplas variáveis quantitativas, categóricas, ou combinações destas. Ainda, os autores ressaltaram que existe certa dificuldade do entendimento científico da metodologia, fazendo-a parecer algo mágico ou misterioso por parte de pesquisadores acostumados com uso de modelos determinísticos ou estocásticos. Özçelik *et al.* (2010) relataram que as ANNs são normalmente referidas como uma caixa preta (“*black-box*”), dado ao fato de seus coeficientes ou pesos não serem interpretáveis, e devido às suas propriedades tais como: a existência de camadas ocultas de neurônios e a utilização de funções não lineares para tratamento da informação. Os autores ressaltam ainda que embora na prática a ANN constitua-se de uma metodologia de modelagem matemática, não compreendemos ao certo como elas aprendem a solução de um problema particular, e como elas são capazes de extrapolar conclusões.

A dinâmica de um estudo baseado em ANN exige que, para cada problema, tenhamos que ajustar uma arquitetura de rede com número variável de camadas intermediárias ocultas, com quantidade de neurônios e funções de ativação específicas. Redes dessa natureza são referenciadas como redes neurais artificiais profundas, ou por meio do termo “*Deep Learning*” (GOODFELLOW; BENGIO;

COURVILLE, 2016), o qual, para fim de simplificação, será referenciada no texto simplesmente como ANN. Essas, algumas vezes são bastante simples, mas que dependendo do tipo de problema podem se tornar muito complexas. Sua utilização prática envolve processos de treinamento, aprendizado e validação; devendo-se considerar a arquitetura planejada anteriormente (SILVA; SPATTI; FLAUZINO, 2010). Uma das propriedades que torna as ANNs atraentes é a habilidade de detectar implicitamente relações não lineares dos dados sem a necessidade de especificação prévia de um modelo (MARTINS *et al.*, 2016), diferindo da abordagem por regressão. Além disso, a modelagem por meio da de ANN permite a inclusão de variáveis de diversas naturezas com certa facilidade. No entanto, a parte mais delicada da modelagem é a generalização, o desenvolvimento de um modelo que é confiável para prever os valores de saída usando um novo conjunto de dados (ÖZÇELIK *et al.*, 2010). Quando não modelada de forma adequada, a rede é suscetível ao chamado “*overfitting*”, o que faz com que a ANN memorize ou decore os exemplos individuais, em vez de “entender” e “encontrar tendências” no conjunto de dados.

De acordo com Haykin (2001) algumas as propriedades e capacidades que tornam as ANNs (*Artificial Neural Networks*) potencialmente úteis são: a não-linearidade, uma vez que um neurônio artificial pode utilizar funções lineares ou não-lineares; a adaptabilidade que é a capacidade da rede de adaptar suas estruturas a partir de modificações do “meio ambiente”; o mapeamento de entrada-saída, processo de adaptação visando minimização do erro realizado com base em exemplos de entrada e saída que são fornecidos à ANN; informação textual: própria estrutura e estado da rede influenciam na aprendizagem e na capacidade de generalização da ANN; tolerância a erro, o que confere robustez à predição; dentre outras propriedades.

De acordo com Zhou *et al.* (2018), devido à sua adaptabilidade e flexibilidade, as ANNs têm se tornado um método interessante para estudar e emular as relações existentes em sistemas complexos como os ecossistemas florestais. Segundo os autores elas têm sido capazes de lidar com estruturas de dados robustas e inter-relacionadas, e por tal motivo, tem se tornado um método popular entre os cientistas de dados. Elas detêm ainda a propriedade de serem pouco afetadas por “*outliers*” e por vieses existentes no conjunto de dados (SCRINZI; MARZULLO; GALVAGNI, 2007), as ANNs têm sido utilizadas para o ajuste de modelos e para previsão de tendências em problemas que envolvem, dentre outros, o manejo de recursos florestais (CASTAÑO-SANTAMARÍA *et al.*, 2013; WANG *et al.*, 2011).

Diversos exemplos de uso das ANNs são encontrados na literatura. Özçelik *et al.* (2010) utilizaram dois tipos de modelos de ANN visando a estimação de volume de madeira em quatro espécies florestais. Os autores concluíram que as ANNs apresentaram bons resultados no processo de estimação, sendo que uma rede específica apresentou resultados acurados e não viesados, referindo-se uma alternativa viável para estimação do volume de madeira, reduzindo inclusive o tempo de avaliações dendrométricas em campo. Embora apresente avanços quanto à utilização de ANN, este trabalho não é focado em análise genética.

Bhering *et al.* (2015) utilizaram ANNs para prever volume em eucalipto. A ANN foi modelada com uma camada de entrada, três camadas intermediárias e uma camada de saída. Para a entrada da ANN, os autores utilizaram estimativas de DAP. Nas camadas intermediárias, o número de neurônios por camada variou entre 1 a 10 neurônios na primeira camada, 1 a 20 na segunda camada e 1 a 8 e na terceira camada. A camada de saída consistia de um neurônio que refletia a estimativa de volume de madeira. Esse valor era conhecido no treinamento, mas desconhecido na validação. Foram consideradas 2100 plantas aos 3 anos de idade e 1400 plantas aos 6 anos de idade, no processo de treinamento da rede e 1400 plantas aos 3 e 6 anos de idade na validação. A melhor arquitetura de rede foi estabelecida por aquela com maior precisão média, considerando 43200 possibilidades investigadas. Para os dados aos três anos de idade, o melhor desempenho foi alcançado usando quatro neurônios na primeira camada oculta e apenas três neurônios na segunda camada oculta. Ambas as camadas apresentaram o melhor desempenho quando a função de ativação *tansig* foi utilizada. A ANN apresentou bons resultados para o processo de avaliação genética. Embora similares, tais resultados ainda se mostraram aquém daqueles obtidos por meio do método de modelos lineares. Após análise de dados, os autores concluíram que as ANN são potencialmente úteis, considerando como factível a sua utilização na estimação de fenótipos de volume individual de madeira em *Eucalyptus*. Embora focado em genética e melhoramento, e apresentar avanços com relação ao uso de ANN para tal fim, os autores não discutem os métodos por meio dos quais foram obtidas variâncias genéticas e herdabilidades por meio da ANN.

4. MATERIAL E MÉTODOS

4.1. Área de estudo

O estudo foi desenvolvido no município de Dracena - SP, na Faculdade de Ciências Agrárias e Tecnológicas da UNESP (FCAT UNESP), situado na longitude 51°32' W e latitude 21°29' S, localizado a 396 m de altitude. De acordo com a classificação de Köeppen, o clima predominante da região é do tipo Aw, e dados climáticos médios anuais: temperatura 24°C, umidade relativa 64% e precipitação pluvial de 1261 mm/ano.


4.2. Recipientes

Foi utilizado o recipiente biodegradável denominado Berço Germinador Compostável ou SIS BGC®, produzidos pela empresa Correia Neto (Foto 1A).

Esses recipientes apresentam estrutura semelhantes ao tubete convencional, porém com uma conformação diferente, presença de orifícios em sua lateral, projetado para ser mais leve que o tubete de polipropileno, além de ser possível plantá-lo junto com a muda.

Utilizou-se ainda o recipiente que é o tubete convencional, sendo ele conhecido como tubete de polipropileno (Foto 1B). Apresenta parede rígidas com capacidade volumétrica para 55 cm³ e com a necessidade de retirada da muda no momento do plantio.

Foto 1 — Recipientes: (A) Recipiente biodegradável SIS BGC; (B) tubete convencional ou de polipropileno.



Fonte: Elaborado pelo autor (2020).

4.3. Clone

O material genético utilizado foi um clone registrado, cultivar SUZA0217, proveniente da empresa Suzano Celulose e Papel, sendo um híbrido de *Eucalyptus grandis* W. Hill ex Maiden x *Eucalyptus urophylla* S.T. Blake.

As mudas utilizadas neste estudo, tanto as cultivadas no SIS BGC®, quanto as produzidas no sistema convencional, foram gentilmente cedidas pelo viveiro de produção de mudas Multi Mudas Brasil, situada na cidade de Andradina - SP.


4.4. Delineamento experimental

4.4.1 Estufa agrícola

A implantação do experimento foi realizada no dia 25 de agosto de 2020 e durante o período de 6 meses foi conduzido um experimento em vaso, em estufa agrícola (Foto 2A) dotado de sistema de irrigação, sob delineamento inteiramente casualizado em esquema fatorial 2x4 com 4 repetições, totalizando 64 unidades experimentais. Foi utilizado um vaso de 18 litros, no qual foi plantada uma única planta. Foram considerados os fatores: condição de plantio, com dois níveis, muda cultivada em tubete convencional de polipropileno e muda cultivada em recipiente do tipo SIS BGC® (e plantada com este) juntamente com o fator Adubação Fosfatada,

com 0, 3,5, 7,0 e 10,0 mg.kg⁻¹ de solo de superfosfato simples, de acordo com as recomendações técnicas procedidas da análise de solo.

Foto 2 — Estufa agrícola: (A) Experimento em estufa agrícola; (B) Análises para índice de clorofila



Fonte: Elaborado pelo autor (2020).

As mudas cedidas pelo viveiro Multi Mudas Brasil tinham cerca de 68 dias de idade, quando realizado o plantio. Em adição, várias análises foram realizadas nas mudas levando em consideração o desenvolvimento como altura, diâmetro do coleto, comprimento de raiz, massa fresca e seca da parte aérea e raiz. As mudas foram fenotipadas para as características: diâmetro do colo da muda (Dc), mensurada por meio de um paquímetro digital; altura da parte aérea da planta (H), obtida por meio de uma régua milimetrada. Em processo destrutivo, nos tempos especificados (45 e 90 dias), as mudas foram retiradas dos vasos e lavadas em água corrente sobre peneira a fim de separar a planta do solo. Nestas, foram avaliadas: comprimento da raiz (Cr), massa fresca de raiz (Mfr), massa seca de raiz (Msr), massa fresca da parte aérea ($Mfpa$), e massa seca de parte aérea ($Mspa$). Ainda, foi considerada a relação, a massa seca total $Mspa = Msr + Mspa = MST$. Para obtenção da massa seca, a parte aérea e as raízes foram mantidas em estufa a 65°C, até peso constante, visando a determinação de sua massa. Foi mensurado ainda o incremento de biomassa da raiz

e da parte aérea na unidade de tempo; e o conteúdo de macronutrientes na parte aérea das plantas, assim como o índice de clorofila (Foto 2B). Essa avaliação visou avaliar o impacto do SIS BGC[®] na absorção de nutrientes pela planta.

4.4.2. Campo

O experimento em campo foi instalado no dia 05 de fevereiro de 2021 e com duração de 2,4 anos, utilizando as mudas previamente alocadas nos vasos, e avaliadas pelo período de 105 dias. Para instalação em campo foi considerado um delineamento de blocos casualizados desbalanceado com espaçamento de 2,0 x 2,0 m. Em adição, considerou os tratamentos de recipientes SIS BGC[®] (Berço Germinador Compostável) e convencional (tubete de polipropileno), em três blocos estabelecidos como fonte de variação premeditada. Em cada bloco, foram alocadas plantas com tamanhos médios semelhantes, as que foram provenientes de casa de vegetação (Foto 3).

Foto 3 — Delimitação da área e dos blocos, com imagens do drone Phantom 4 V2.0



Fonte: Elaborado pelo autor (2023).

As plantas foram transplantadas com 172 dias de idade (aproximadamente 06 meses). No momento do transplante, as plantas foram retiradas dos vasos com o auxílio de um facão para retirada dos torrões (Foto 4A), além de receberem 200 g cada do formulado 06-30-06 (N-P-K) (Foto 34B) e alocadas nas covas (Foto 4C). Posteriormente, no período inicial chegando em até quinze dias as plantas foram mantidas com o auxílio da irrigação de microgotejamento, feito no local (Foto 4D).

Foto 4 — Transplântio das mudas: (A) Retirada dos torrões; (B) Adubação de plantio; (C) Plantas alocadas nos berços; (D) Início da irrigação.



Fonte: Elaborado pelo autor (2021).

Posteriormente, foram realizados tratos culturais como desrama, e o controle das principais pragas da cultura do eucalipto, sendo as formigas cortadeiras (*Atta* spp. e *Acromyrmex* spp.) e besouros desfolhadores, mais conhecido como besouro-amarelo do eucalipto (*Costalimaita ferrugínea*) (Foto 5). A campo, foram realizadas avaliações de altura de planta e diâmetro, aos 210, 363 e 869 dias de idade da planta, com auxílio de um clinômetro e da fita métrica para avaliação do diâmetro (Foto 6).

Foto 5 — Tratos culturais. Controle de formigas cortadeiras com isca (A); Desrama (B).



Fonte: Elaborado pelo autor (2021).

Foto 6 — Avaliações com o Clinômetro: (A) Clinômetro; (B) Medição de altura.



Fonte: Elaborado pelo autor (2023).

4.5 Análise dos dados

4.5.1 ANOVA

Foi realizada análise de variância, considerando o delineamento de blocos casualizados desbalanceado, devido ao número variável de parcelas experimentais dentro dos blocos.

4.5.2 Ajuste de modelos de crescimento

Foi considerado ainda o ajuste de curva de crescimento para os tratamentos avaliados nos tempos após o plantio, por meio de modelos não lineares. Foram avaliados os modelos de regressão linear e não linear apresentados na Tabela 1:

Tabela 1 — Modelos avaliados

Modelos	Equação
Linear	$Y = \text{tubete} + \text{tempo}$
Modelo Logístico	$Y = a. (1 + b^{(\exp(-c.\text{tempo}))})^{-1}$
Modelo Gompertz	$Y = a. \exp(-b.\exp(-c.\text{tempo}))$
Von Bertalanffy	$Y = a. (1 - b. \exp(-c.\text{tempo}))^3$

Fonte: Elaborado pelo autor (2023).

Em que:

Y , corresponde ao valor observado para variável em estudo (variável independente – D ou H);

Tempo, corresponde à variável dependente, tempo em dias após transplante;

a , b , e c , correspondem aos parâmetros do modelo sob estudo.

4.5.3 Arquitetura e predição de fenótipo pela *Artificial Neural Network*

Foram consideradas um conjunto de redes neurais artificiais do tipo MLP (*Perceptron Multicamada*) utilizando treinamento supervisionado com algoritmo *backpropagation*. Com respeito à topologia da rede, foram consideradas X_i covariáveis na camada de entrada, sendo i o número de covariáveis do experimento.

Foi considerado duas camadas intermediárias – quantidade obtida iterativamente –; cada qual com neurônios (também obtido iterativamente) totalizando 10 neurônios; e uma única camada de saída com um neurônio, sendo este o valor predito para os indivíduos avaliados no experimento. Na entrada da rede, para cada covariável, os dados serão normalizados por meio da função $f(X_i) = \frac{X_i - \min(X_i)}{\max(X_i) - \min(X_i)}$, sendo X_i o valor original da particular covariável de entrada, e $f(X_i)$, o valor normalizado de X_i . Foram utilizados 70% dos valores fenotípicos do experimento no processo de treinamento da ANN e os 30% restantes no processo de validação. A seleção da arquitetura da rede será realizada por meio de validação cruzada utilizando o método *k-fold* com $k = 10$ (*ten-fold*), com o intuito de selecionar a rede com melhor capacidade de generalização. Foi utilizado o algoritmo de treinamento *resilient backpropagation* (RIEDMILLER, 1994) e a função de ativação padrão do pacote camadas intermediárias.

4.5.4 Análises das ANNs

A modelagem das ANNs foi realizada por meio de rotinas de análise no software livre R (R CORE TEAM, 2022), utilizando os pacotes *neuralnet* e *H2O*. Outros pacotes foram testados, mas esses dois apresentaram resultados satisfatórios e auxiliaram na obtenção dos resultados do trabalho; especialmente o pacote *neuralnet*. O R constitui uma linguagem livre e um ambiente para estatística computacional, que dispõe de uma comunidade ativa constituída por pesquisadores das mais diversas áreas da ciência e que desenvolvem e disponibilizam pacotes (por meio de bibliotecas) para as mais diversas aplicações.

4.5.5 Avaliação comparativa dos métodos

A avaliação da eficácia da ANN será realizada por meio de métricas de ajuste dos valores preditos e observados, a citar: *Mean Squared Error* – MSE – ou erro quadrático médio, *Root Mean Squared Error* – RMSE – raiz do erro quadrático médio, *Mean Absolute Error* – MAE – ou erro absoluto médio, coeficiente de determinação – R^2 . Essas métricas são dadas por (Tabela 2):

Tabela 2 — Métricas de ajuste dos valores preditos e observados

Métricas	Equação
<i>Mean Squared Error</i>	$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2;$
<i>Root Mean Squared Error</i>	$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2};$
<i>Mean Absolute Error</i>	$\text{MAE} = \frac{1}{n} \sum_{i=1}^n Y_i - \hat{Y}_i ;$
Coefficiente de determinação	$R^2 = \frac{\sum(Y_i - \bar{Y})}{\sum(Y_i - \bar{Y})};$

Fonte: Elaborado pelo autor (2023).

em que Y_i corresponde ao valor observado no experimento, e \hat{Y}_i o valor predito pela ANN. O fator de concordância é uma medida adimensional que varia entre 0 e 1, de forma que maiores valores correspondem a maior consistência de ajuste. Como os resultados de outras métricas previstas anteriormente, proporcionaram resultados redundantes e condizentes, apenas essas três métricas, mais a herdabilidade da característica foi utilizada na apresentação dos resultados deste trabalho.

Ressalta-se que como a modelagem das ANN são realizadas por meio método iterativo, os resultados apresentados constituem média de 100 repetições. A cada processo de modelagem, a ANN, assim como os parâmetros estimados de herdabilidade e de erro são salvos. Os gráficos de predição apresentados, correspondem aos de uma rede salva com estimativas mais próximas da rede média.

4.5.6 Avaliação comparativa entre arquiteturas

Com o intuito de buscar arquiteturas mais simples capazes de solucionar o problema da construção de curvas de crescimento, foram testadas arquiteturas, a partir a partir do número de entradas e de saídas estudadas de forma empírica.

Dessa forma, foram avaliadas as arquiteturas apresentadas (Tabela 3).

Tabela 3 — Arquitetura das Redes Neurais Artificiais, variáveis na camada de entrada, oculta e saída

ANN	Variável de entrada	Disposição dos neurônios nas camadas ocultas	Nº de neurônios por camada			Variável de saída
			Entrada	Oculto	Saída	
01	Tubetes; Dias	2-2	2	4	1	DC ou H
02	Tubetes; Dias	2-3	2	5	1	DC ou H
03	Tubetes; Dias	2-8	2	10	1	DC ou H
04	Tubetes; Dias	3-2	2	5	1	DC ou H
05	Tubetes; Dias	3-7	2	10	1	DC ou H
06	Tubetes; Dias	10-10	2	20	1	DC ou H

ANN = Redes Neurais Artificiais; Tubetes= convencional e SIS BGC®; DC= Diâmetro do Coleto. H= Altura da planta. Fonte: Elaborado pelo autor (2023).

5 RESULTADOS E DISCUSSÃO

5.1 Anova

As avaliações de diâmetro e altura foram realizadas no experimento no decorrer do tempo. A última avaliação ocorreu aos 869 dias após o transplante. Referente à esta última avaliação, na Tabela 4, está apresentada a análise descritiva dos dados para as duas características avaliadas e na Tabela 5, os resultados da ANOVA.

Tabela 4 — Análise descritiva das variáveis Diâmetro -D e a Altura- H

Tubetes	Variáveis	Mínimo	Média	Mediana	Máximo	Desvio Padrão	CV%
SIS BGC®	D	98,68	161,03	154,38	219,63	30,49	18,93
	H	11,2	15,8	15,9	18	1,52	9,62
Convencional	D	117,8	160,7	156	206,9	22,43	13,96
	H	13,5	16,31	15,9	22	2,04	12,51

Fonte: Elaborado pelo autor (2023).

Tabela 4 — Análise de variância para as características D – Diâmetro – e H – Altura de Planta – avaliadas aos 869 dias após o transplântio.

FV	D			H	
	GL	QM	Pr(>F)	QM	Pr(>F)
Tubete	1	1,8	0,961	4,340	0,2374
Bloco	2	122,5	0,847	8,298	0,0736
Resíduo	63	738,6		3,050	

FV= Fonte de variação; GL= Grau de Liberdade; QM= Quadro Médio; Pr(>F)= Valor de P associado a estatística F. Fonte: Elaborado pelo autor (2023).

Constata-se que os valores de Pr (>F) não apresentaram significância para nenhuma das duas características. De acordo com MOREIRA et al. (2020), tal evidência implica que os tratamentos avaliados não se mostraram importantes para explicar o uso de modelo linear no variável desfecho (Altura ou diâmetro). Isso pois segundo ele, $Pr > 0,050$ significa que as variáveis independentes não possuem influência na variável depende.

Nesse sentido, nota-se que ao analisar as árvores de eucalipto a campo com 869 dias, com aproximadamente 2,4 anos de idade, a fonte de variação tubete, não influenciou o desenvolvimento das plantas em altura e em diâmetro do coleto, visto que não apresentou resultados significativos estaticamente. Isso indica que as planta com o tubete SIS BGC® foram capazes de extrair os nutrientes do solo e suprir suas necessidades independentemente da presença do tubete.

Dessa forma, esses resultados corroboram com o comportamento descrito por Costa (2020) em estudos realizados com a espécie de aroeira (*Schinus terebinthifolius*) no qual não foram evidenciadas diferenças estatísticas entre as duas tecnologias de tubetes utilizadas. Em seu estudo, também foram avaliadas as características D e H; no entanto, tais resultados foram encontrados em mudas em viveiro de produção. De qualquer forma, nossos resultados são concordantes, visto que as plantas que foram avaliadas a campo são provenientes também de um sistema de produção em viveiro/estufa agrícola.

Inicialmente, a principal diferença entre os tubetes de polipropileno e os tubetes de Berço Germinador Compostável (SIS BGC®) está principalmente relacionado com o manejo no momento do plantio da muda no campo, na qual, o tubete produzido em sistema convencional necessita da remoção da muda do

recipiente para que em seguida ser plantada no campo. Quando comparado com as sacolas de plásticos os tubetes são preferidos pela facilidade de manuseio, principalmente no que se diz respeito as operações em viveiro e campo (CALDEIRA *et al.*, 2016).

Caso não sejam tomados os devidos cuidados, tal manejo pode ocasionar injúrias mecânicas na planta como o choque pós-plantio e conseqüentemente dificultar o arranque inicial da muda. Tal sistema requer grandes custos de produção e manejo, bem como o uso de matérias primas de fontes não renováveis. Esse sistema implica no transporte dos tubetes do campo à biofábrica, após o plantio; além de todo processo de lavagem e desinfecção para posterior reutilização. Conforme Wedling e Dutra (2010), o sistema de tubetes biodegradáveis apresenta como vantagem a não necessidade do processo de limpeza, remoção das mudas dos tubetes para plantio, e nem a necessidade de retornar ao viveiro.

Em contraste com o tubete de polipropileno, o SIS BGC[®], pode ser considerado um substituto do tubete convencional, potencialmente capaz de substituir a logística reversa, visto que a muda pode ser plantada em conjunto com o tubete no campo. Em situação de campo, nossos resultados demonstraram que o desempenho das árvores de eucalipto foram os mesmos independente do recipiente utilizado (Foto 7). Nas avaliações, as árvores da bordadura foram desconsideradas da avaliação.

Foto 7 — Desempenho do povoamento de eucalipto com os tubetes de polipropileno e SIS BGC®



Fonte: Elaborado pelo autor (2023).

Visando investigar o comportamento de crescimento das plantas, foram procedidas a construção dos modelos de crescimento.

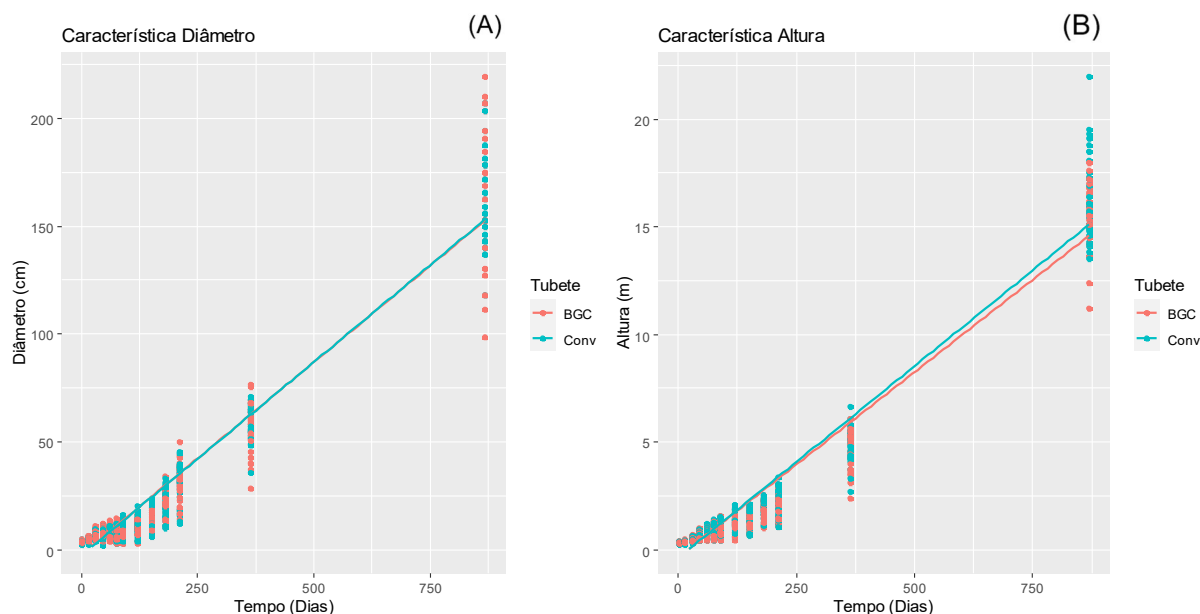
5.2 Modelagem de altura e diâmetro utilizando regressão

Dentre os modelos de ajuste de curva de crescimento, foram avaliados modelos de regressão linear e não linear. Visualmente, constata-se que modelo linear ajustado não se mostrou adequado para explicar as nuances do comportamento das árvores, no decorrer do tempo. Isto também é refletido pelas métricas obtidas para este modelo, se comparado com as dos modelos não lineares. Estes últimos, por sua vez, apresentaram comportamentos semelhantes, o que é refletido pelas métricas de comparação.

O resultado do coeficiente de determinação (R^2) dos modelos estudados está apresentado na Tabela 4. Para essa métrica, quanto mais próximo o valor do R^2 estiver de 1, melhor a associação entre os valores observados e preditos, os valores de R^2 se caracterizaram com alta correlação, visto que isso evidencia que o modelo que foi ajustado demonstra bem a variabilidade das características avaliadas e

prevendo corretamente (MENDONÇA *et al.*, 2021). Dessa forma, o R^2 variou entre 0,95 e 0,97, indicando que os modelos ajustados se mostraram bastante apropriados.

Figura 3 — Análise de regressão linear: (A) característica diâmetro e (B) altura.



Fonte: Dados da pesquisa do autor (2023).

Tabela 5 — Coeficiente de determinação (R^2) dos modelos avaliados.

Modelos	Altura	Diâmetro
	Coeficiente de determinação (R^2)	
Linear	0,9439	0,9367
Logístico	0,9765	0,9565
Von Bertalanffy	0,9777	0,9578
Gompertz	0,9776	0,9581


Fonte: Dados da pesquisa do autor (2023).

De acordo com Lawrence e Davis (2005), dentro do setor florestal o povoamento de árvores, a distribuição diamétrica e árvores individuais são as três classes utilizadas para associar o ajuste dos modelos de crescimento e produção. No entanto, indiferente do uso de tais classes, o emprego de modelos lineares e não-lineares se adequam para tal finalidade (CASTRO *et al.*, 2013).

Ainda, o uso de modelos não lineares é bem difundido no setor florestal tal fato pode ser evidenciado em trabalhos realizados como o de Rios (1997), Assis (1998) e Thiersch (1999). Como apresentado na Tabela 4, todos os ajustes se apresentaram de forma satisfatória, no entanto, quando se analisa as medidas de acurácia, em destaque o modelo não linear de Gompertz, os valores se apresentaram ligeiramente


maiores quando comparados aos outros dois tipos de modelos analisados, o mesmo foi evidenciado no trabalho realizado por Vendruscolo *et al.* (2015), que avaliou a modelagem por regressão de três modelos sendo o Logístico, Gompertz e Richards, além de modelos lineares, tendo com maior destaque o modelo de Gompertz na estimativa de árvores de *Tectona grandis* L.f. Ainda segundo esse autor os modelos não lineares foram superiores aos lineares.

Gráfico 1 — Modelo não linear logístico



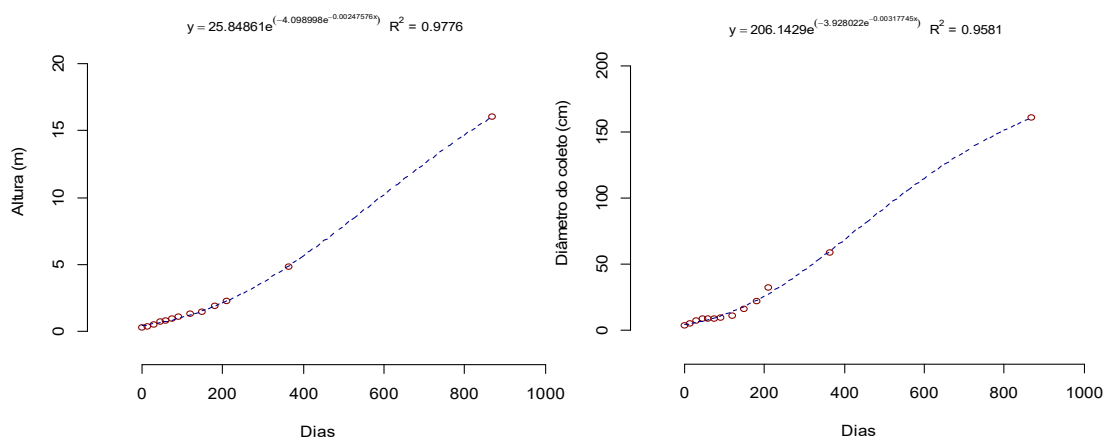
Fonte: Dados da pesquisa do autor (2023).

Gráfico 2 — Modelo não linear de Von Bertalanffy



Fonte: Dados da pesquisa do autor (2023).

Gráfico 3 — Modelo não linear de Gompertz



Fonte: Dados da pesquisa do autor (2023).


5.3 Redes Neurais Artificiais (ANNs)

Com o intuito de investigar diferenças entre o comportamento de crescimento das árvores produzidas com os dois tipos de tubetes, foi investigado a aplicabilidade da técnica de Redes Neurais Artificiais no ajuste de tais modelos.

Faz-se de suma importância utilizar o número ideal de neurônios na camada oculta, visando otimizar ainda mais o modelo das redes, evitando problemas tal como *overfitting* e *underfitting* (CUNHA NETO *et al.*, 2019). Segundo Silva Júnior (2021), no que se diz respeito a quantidade de neurônio presentes nas camadas ocultas ou intermediárias ainda não existe um consenso. No entanto, o que é considerado dentro da área das ciências agrárias um melhor número de neurônios para a resolução de problemas, geralmente, se é definido de forma empírica, isto significa, que se define alguma arquitetura com a quantidade de neurônio fixa em cada camada, e por meio iterações, estuda-se a variação nas respostas, de forma crescente, com o intuito de buscar uma melhor solução (CRUZ; NASCIMENTO, 2018).

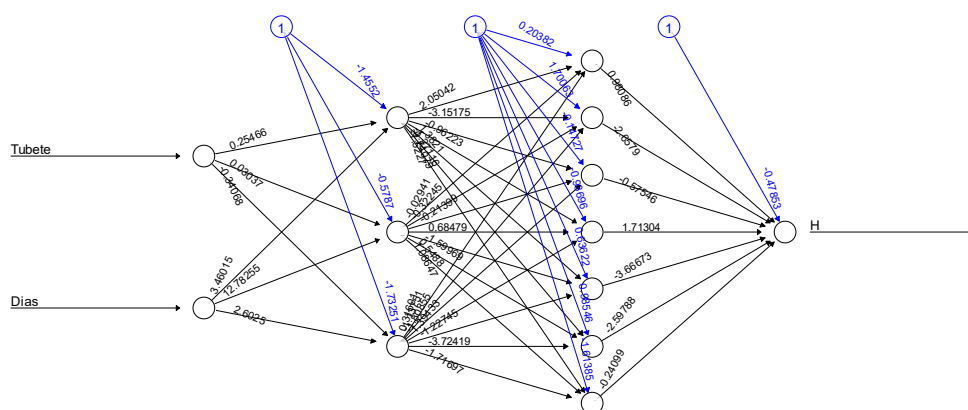
Com base nisso, foram testadas dessa forma arquiteturas com quatro neurônios (Figura 4) e cinco neurônios. Adicionalmente, foram avaliadas também arquiteturas com 10 neurônios (Figura 5) e 20 neurônios (Figura 6), considerando que alguns softwares estatísticos apresentam limitações de ajuste quando a quantidade de neurônios é pequena. Todas as redes ajustadas tiveram duas camadas ocultas, com a mesma quantidade de neurônios na camada de entrada (02 neurônios) e na camada de saída (01 neurônio), variando apenas a quantidade de neurônios nas camadas ocultas.

Figura 4 — Exemplo de arquitetura de ANN com 2 neurônios em cada camada oculta.



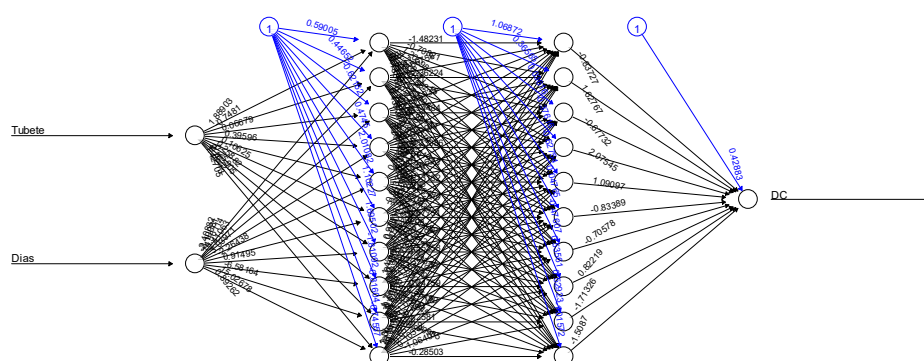
Fonte: Dados da pesquisa do autor (2023).

Figura 5 — Exemplo de arquitetura de ANN com 3 neurônios na primeira camada oculta e 7 neurônios na segunda camada oculta.



Fonte: Dados da pesquisa do autor (2023).

Figura 6 — Exemplo de arquitetura de ANN com 10 neurônios em cada camada oculta.



Fonte: Dados da pesquisa do autor (2023).

Durante a realização das análises dos dados obtidos neste estudo, foi observado que as arquiteturas apresentaram resultados estatisticamente iguais, ou seja, não houve diferenças significativas entre as arquiteturas em termos dos resultados obtidos.

Com base nos resultados apresentados na tabela 5, na qual, apresenta as métricas avaliadas para cada arquitetura de rede e para a característica altura, sendo R^2 , RMSE, MSE, MAE, todas as arquiteturas (2-2; 2-3; 2-8; 3-7) são igualmente eficazes em termos de desempenho. Isso implica que a escolha de uma arquitetura específica dentre as avaliadas não terá um impacto significativo nos resultados finais. Em adição, isso pode ser explicado devido ao fato dos valores das métricas serem ligeiramente diferentes, assim como o coeficiente de variação.

Tabela 6 — Métricas avaliadas para cada arquitetura de rede para a característica altura.

Métricas	Arquiteturas					
	2 - 2		2 - 3		2 - 8	
R^2	0,9655	± 0,0018	0,9653	± 0,0018	0,9649	± 0,0011
RMSE	3,6438	± 0,0016	3,6436	± 0,0016	3,6437	± 0,0015
MSE	13,2773	± 0,0119	13,2758	± 0,0117	13,2766	± 0,0108
MAE	1,7530	± 0,0007	1,7528	± 0,0007	1,7527	± 0,0006
	3 - 2		3 - 7		10 - 10	
R^2	0,9660	± 0,0017	0,9649	± 0,0012	0,9653	± 0,0009
RMSE	3,6439	± 0,0016	3,6439	± 0,0016	3,6436	± 0,0017
MSE	13,2780	± 0,0118	13,2778	± 0,0116	13,2757	± 0,0121
MAE	1,7531	± 0,0006	1,7527	± 0,0006	1,7528	± 0,0006

R^2 = Coeficiente de determinação; RMSE= Raiz do erro quadrático médio; MSE= Erro quadrático médio; MAE= Erro absoluto médio. Fonte: Dados de pesquisa do autor (2023).

A raiz do erro quadrático médio (RMSE) é uma métrica que avalia a média das diferenças quadráticas entre os valores observados e estimados. Quanto menor o valor do RMSE, maior é a precisão das estimativas, sendo considerada melhor quanto mais próxima de zero. Essa métrica é utilizada para avaliar a qualidade das previsões realizadas pelo modelo (Mehtatalo *et al.*, 2006). Para a característica altura, os valores do RMSE, variaram entre 3,6436 a 3,6439. Esses resultados denotam baixa variação entre as previsões das arquiteturas analisadas. A variação ocorrida implica em uma diferença métrica de 0,0003.

O mesmo acontece com a métrica MAE, que caracteriza modelos não negativos. Nesse sentido, quanto menor o valor dessa métrica, melhor é o desempenho do modelo (FACELI *et al.*, 2011). Ao comparar o RMSE e o MAE, a diferença entre essas duas métricas se deve ao fato que o RMSE atribui um peso maior em desvios maiores, enquanto o MAE apresenta pesos iguais para os desvios

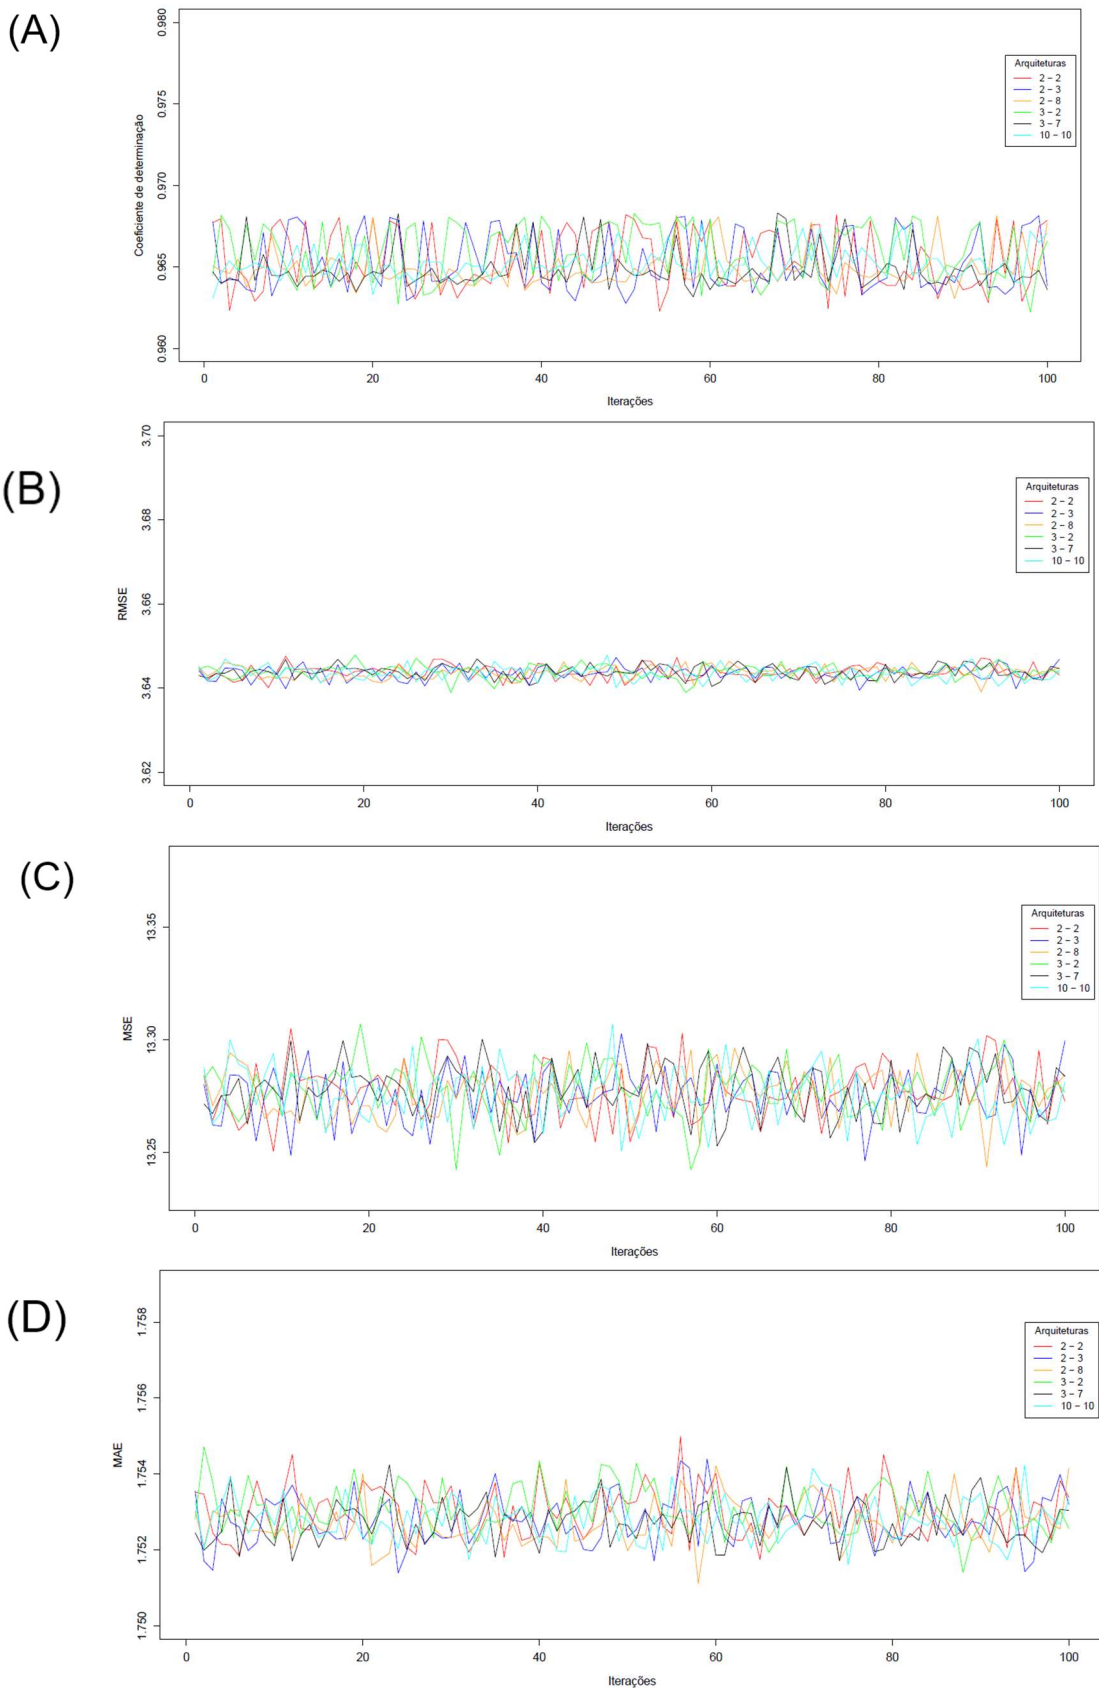
existentes (STENGHELE *et al.*, 2020). Em relação a métrica MSE, os valores variaram entre 13,2780 a 13,2757, obtendo uma variação de 0,0023.

Em estudos elaborados por (RODRIGUES, 2019), com uso de arquiteturas de redes neurais predição de diâmetro e volume de clones de eucalipto, o mesmo utilizou dessas métricas em seu estudo, assim como incluindo o RMSE e o MAE, apresentou valores satisfatórios na condição de avaliação do experimento, assim como o R^2 que apresentou variação entre 0,95%. Segundo o autor tais resultados se mostraram satisfatórios para a estimação de volumes de clones de eucalipto.

Assim como demonstrado na Figura 7, a disposição das iterações das diferentes arquiteturas de redes projetadas, confirma o que está evidenciado na Tabela 6. Isto é, as redes não apresentaram diferença entre si. Os resultados obtidos são provenientes de 100 iterações avaliadas, para cada uma das seis de arquiteturas testadas.

Além disso, foi observado apenas pequenas diferenças nos resultados das avaliações. Demonstrando que todas as arquiteturas tiveram um desempenho muito semelhante, independentemente da quantidade de neurônios em cada uma.

Figura 7 — Métricas: (A) Coeficiente de determinação; (B) RMSE; (C) MSE; (D) MAE.



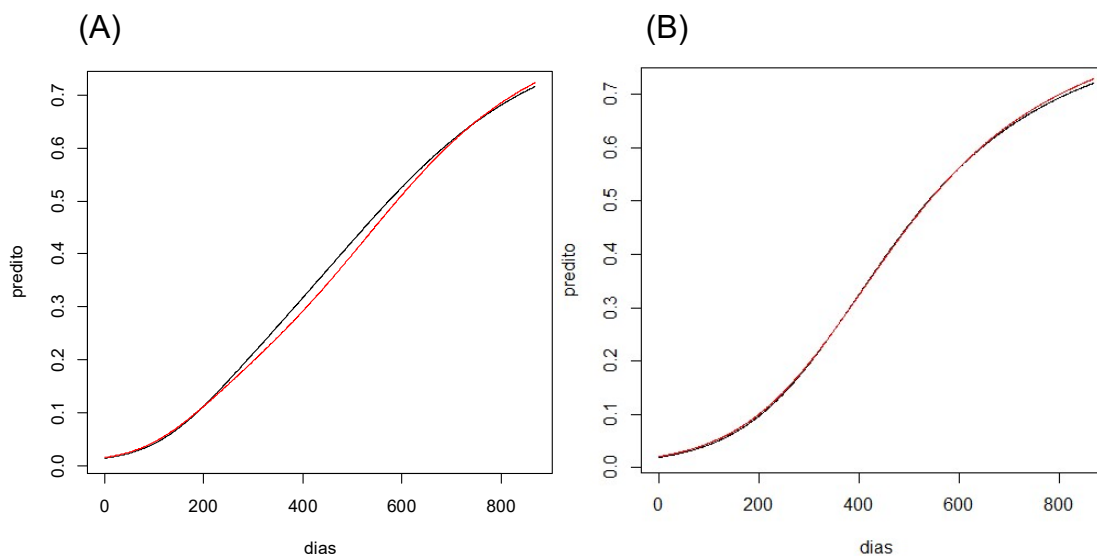
Fonte: Dados da pesquisa do autor (2023).

Um estudo realizado por Vendruscolo *et al.*, (2015) utilizaram uma análise de regressão e ANNs para prever a altura de árvores de eucalipto. As redes impõem um grande potencial para sua utilização, apresentando vantagens em relação a modelagem de regressão devido a capacidade de incluir variáveis categóricas durante o treinamento das redes. A eficácia das redes neurais também foi evidenciada na previsão de clones de eucalipto por Binoti *et al.*, (2015) em seu estudo. Eles utilizaram redes do tipo *Perceptron Múltiplas Camadas* (MLP), as quais também foram empregadas nessa pesquisa. De acordo com os autores as ANNs apresentaram resultados avançados no uso de técnicas para análise de povoamento de árvores de eucalipto, principalmente em questões de mensuração florestal.

Os resultados obtidos estão em consonância com o estudo feito por Gordens *et al.*, (2009), que demonstrou a viabilidade das redes neurais, especialmente devido à capacidade da inteligência artificial de analisar diferentes variáveis de locais e também de duas espécies distintas, *Eucalyptus spp.* e *Tectona grandis*. Os modelos preditivos gerados pelas redes neurais artificiais do tipo MLP apresentaram ótimo desempenho para a determinação de altura do eucalipto nas condições do estudo de Bueno *et al.*, (2020).

Portanto, comparando as curvas de crescimento ajustadas para tubete Convencional e SIS BGC[®] utilizando o método da ANN, pode-se observar que tanto para a característica altura quanto para diâmetro, as plantas se desenvolveram de forma muito semelhante e praticamente equiparada. Isso pode ser visualizado na Figura 8, onde a linha vermelha representa o tubete SIS BGC[®] e a linha preta representa o tubete convencional. Esses resultados evidenciam que a influência dos recipientes não interfere significativamente no desenvolvimento das plantas avaliadas em campo, no período de tempo avaliado.

Figura 8 — Comparação entre curvas de crescimento ajustadas para tubete Convencional e SIS BGC pelo método da ANN, para as características: (A) diâmetro; (B) altura



Fonte: elaborado pelo autor (2023).

5.4 Desafios no uso das Redes Neurais Artificiais

Diante dos resultados apresentados, nota-se a importância do conhecimento a respeito da utilização de métodos visando a modelagem de dados. Os resultados proporcionados pelas ANNs foram consistentes. Isso indica que o método de previsão por meio das ANNs deve, de fato, estar funcionando, uma vez que os resultados não se tratam de meros artefatos matemáticos ou estatísticos.

Algo que ainda merece ser mencionado diz respeito da prática associada ao uso de metodologias de inteligência artificial como a utilizada neste trabalho. Fomos capazes de notar que, mesmo fazendo uso de rotinas computacionais otimizadas para análise, os tempos computacionais podem constituir um impeditivo para utilização da tecnologia em larga escala, como prática de trabalho.

Um segundo ponto que também deve ser mencionado, diz respeito à complexidade do ajuste de um modelo da natureza como os avaliados neste trabalho. Infelizmente, a ferramenta ainda não é de fácil utilização para qualquer operador. O uso da ferramenta ainda implica na necessidade de conhecimentos básicos que envolvem programação em alguma linguagem como o R ou o Python, ou um software como o Matlab ou o Octave. Se por um lado, isto constitui um limitante, por outro lado, abre oportunidade de atuação em um nicho de mercado no qual ainda há falta de profissionais capacitados.

5.5 Biocompostabilidade do tubete SIS BGC®

O gerenciamento de resíduos vem ganhando ênfase no mundo, principalmente com o interesse da sociedade humana na diminuição da geração de resíduos. De acordo com a Norma Brasileira NBR 15448-2 da ABNT, as embalagens plásticas degradáveis e/ou de fontes renováveis, são aquelas que se desintegram em pedaços de 2 milímetros em um prazo máximo de 90 dias através da atividade de microrganismo aeróbios. Portanto, a partir dessa norma que é definido o que são embalagens biodegradáveis ou compostáveis.

A empresa desenvolvedora da tecnologia no ano de 2001, o tubete SIS BGC®, solicitou um ensaio para determinação da biodegradabilidade de materiais plásticos, o qual realizado no Instituto SENAI de Inovação em Engenharia de Polímeros localizado na cidade de São Leopoldo – RS.

O parecer emitido pelo instituto foi de que a amostra utilizada na conformação do tubete apresentou percentual de biodegradabilidade de 54,61% após o período de 189 dias de ensaio. No entanto, a amostra deve apresentar um percentual de biodegradabilidade de, no mínimo, 80% de seus constituintes orgânicos, após o término de 180 dias de ensaio, para que este seja considerado um material biodegradável, de acordo com a norma ABNT NBR 15448-2: 2008. A conclusão, portanto, foi de que a amostra analisada não atingiu aos requisitos mínimos de biodegradabilidade, em condições aeróbias controladas de compostagem.

Tal fato, também pôde ser evidenciado a campo. Na foto 8, nota-se a presença do material utilizado na conformação do tubete preso ao colo da planta de eucalipto após 749 dias de plantio a campo. Em contrapartida, mesmo que a presença do tubete não tenha dificultado o desenvolvimento do eucalipto, a disposição desse material no solo não atende os requisitos de um material considerado biocompostável. Bem como, é possível evidenciar alguns pilares da tecnologia, como resistência mecânica, inércia, na qual, a presença da tecnologia não afetou o desenvolvimento da planta e a fragmentação, pois o material se fragmentou e por tal motivo não impediu o avanço do ciclo da cultura.

Foto 8 — Resquícios do material: (A) Tubete SIS BGC® junto ao colo da planta de eucalipto; (B) Resquícios do tubete SIS BGC® após 749 dias de plantio a campo; (C) Material danificado pelo desenvolvimento da planta; Fragmentos do material (D).



Fonte: Elaborado pelo autor (2023).

Em contrapartida, a empresa ciente de tais resultados apresentados pelo Instituto SENAI de Inovação em Engenharia de Polímeros, realizou o aperfeiçoamento da tecnologia a fim de solucionar os problemas e desafios que foram impostos, com foco na proteção do meio ambiente e no baixo consumo de carbono. Dessa forma, a tecnologia que antes era chamada de SIS BGC® recebe a titulação de Tecnologia TecSeth e o tubete de BG Seth® ou Berço Germinador Seth® (BGSETH, [s.d.]). Como apresentado na Foto 9, a conformação oferecida mostra o corte de orifícios por todo o tubete.

Foto 9 — Berço Germinador Seth®: (A) Produção de mudas com a tecnologia; (B) Conformação do BG Seth®



Fonte: Fotografias gentilmente cedidas pela Correia Neto (2023).

A nova tecnologia, segundo o desenvolvedor, está fundamentada em cima de quatro pilares, atendendo a exigência do tripé da sustentabilidade, sendo eles: resistência mecânica, com foco na capacidade de adequar-se aos processos operacionais sofridos desde o viveiro ao campo sem que tenha a presença de danos em sua estrutura; a inércia, não atrapalhando o desenvolvimento da planta; a fragmentação, projetada apenas no campo, após o plantio da muda, oferecendo maior desenvoltura da muda a campo e por fim a biodegradação, sendo um material biodegradável (mais de 80% de biodegradabilidade) após 180 dias de descarte no solo respeitando as normas (BGSETH, [s.d.]).

De fato, o setor de produção de mudas florestais apresenta uma nova demanda no quesito de recipientes, que mais adiante, ocorrerá a intensificação no foco das pesquisas científicas voltada para a produção de mudas da espécie florestal em tubetes de fontes renováveis, assim como o uso de subprodutos de áreas urbanas e resíduos agropecuários como substrato na produção de tais mudas (WEDLING *et al.*, 2021). Os autores ressaltam ainda, que diversos estudos foram realizados nas

últimas quatro décadas para gerar novas perspectivas sobre a produção de mudas de eucaliptos, sendo por exemplo novas visões sobre as técnicas e sistemas de produção, e o emprego de recipientes suspensos e/ou biodegradáveis em viveiros de produção.

6. CONCLUSÃO

A presente pesquisa buscou avaliar o desempenho de árvores de *Eucalyptus* spp. produzidas em Berço Germinador Compostável (SIS BGC®) e tubete de polipropileno por meio dos métodos baseados em redes neurais artificiais. Os resultados indicam que o uso do tubete SIS BGC® não afetou significativamente o desenvolvimento do eucalipto. Entretanto, em relação a biocompostabilidade, observou-se que esse tipo de tubete utilizado nesta pesquisa, necessitou de aprimoramento, devido à baixa porcentagem da biocompostabilidade observada a campo. Além disso, novas pesquisas são necessárias para explorar o potencial dessa tecnologia aprimorada.

A comparação entre os ajustes de modelo de crescimento, lineares e não lineares, permitiu concluir que, os modelos não lineares utilizados no presente apresentaram um melhor ajuste aos dados analisados.

A aplicação de redes neurais funcionou de forma bem sucedida para a predição dos dados de altura e de diâmetro, indicando que as ANNs são modelos adequados para serem empregados na mensuração florestal.

Além disso, constatou-se que o uso de diferentes arquiteturas de redes neurais artificiais para a predição não teve influência significativa nos resultados, uma vez que todas apresentaram desempenho equivalente.

REFERÊNCIAS

ARTHUR JUNIOR, J. C.; GONÇALVES, J. L. de M. Uso de tubete e de minitubete de compósito de polihidroxibutirato mais pó de madeira na produção e no plantio de mudas seminais e clonais de eucalipto. [s. l.], 2011.

ASSIS, A. De. Acuracidade na estimativa de volumes comerciais de *Eucalyptus grandis* e *Eucalyptus urophylla*. Lavras: UFLA, 1998. 183p. Monografia, [s. l.], 1998.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 10520**: informação e documentação: citação em documentos: apresentação. Rio de Janeiro: ABNT, 2002. 7 p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 14724**: informação e documentação: trabalhos acadêmicos: apresentação. Rio de Janeiro: ABNT, 2002. 6 p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 15448-2**: Embalagens plásticas degradáveis e/ou de fontes renováveis - Parte 2: Biodegradação e compostagem - Requisitos e métodos de ensaio. Rio de Janeiro: ABNT, 2008. 10 p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 6023**: informação e documentação: referências: elaboração. Rio de Janeiro: ABNT, 2018. 74 p.

BALBINO, L. C.; CORDEIRO, L. A. M.; OLIVEIRA, P. De; KLUTHCOUSKI, J.; GALERANI, P. R.; VILELA, L. Agricultura sustentável por meio da integração lavoura-pecuária-floresta (ILPF). [s. l.], 2012.

BARBOSA, J. J.; SUZUKI, M. S.; SANTOS, R. S. **Manual de orientação na preparação de trabalhos acadêmicos**. Edição adaptada por Fábio S. Rosas para a Faculdade de Ciências Agrárias e Tecnológicas – FCAT. Dracena: [s.n.], 2020. 64 p. Disponível em: <http://www.dracena.unesp.br/bdr>. Acesso em: 03 abr. 2023.

BGSETH, O. BGSeth – Berço Germinador Seth – Tecnologia TecSeth. [s. l.], [s.d.].

BHERING, L. L.; CRUZ, C. D. Neural networks for predictin... - Google Acadêmico. [s.d.]. Disponível em: <https://scholar.google.com.br/scholar?q=BHERING,+L.+L.%3B+CRUZ,+C.+D.+Neural+networks+for+predicting+breeding+values+and&hl=pt-BR&as_sdt=0&as_vis=1&oi=scholart>. Acesso em: : 03 abr. 2023.

BINOTI, M. L. M. D. S.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. PROGNOSE EM NÍVEL DE POVOAMENTO DE CLONES DE EUCALIPTO EMPREGANDO REDES NEURAS ARTIFICIAIS. **CERNE**, [s. l.], v. 21, n. 1, p. 97–105, 2015.

BRAGA, A. de P.; LUDERMIR, T. B.; CARVALHO, A. C. P. de L. F. Redes neurais artificiais: teoria e aplicações. [s. l.], 2000.

CABACINHA, C. D.; LAFETÁ, B. O. Floristic diversity and equitability in forest fragments using artificial neural networks. **Ciência Florestal**, [s. l.], v. 27, p. 143–152, 2017.

CALDEIRA, M. V. W.; GONÇALVES, E. O.; WEDLING, I.; MARTINS, R. C. C. In: CALDEIRA, M. V. W. et al. **Silvicultura do eucalipto no Brasil**. Santa Maria: Ed. Da UFSM, 2016. Cap. 2, p. 47-81.

CARNEIRO, J. G. de A. Produção e controle de qualidade de mudas florestais. [s. l.], 1995.

CASTAÑO-SANTAMARÍA, J.; CRECENTE-CAMPO, F.; FERNÁNDEZ-MARTÍNEZ, J. L.; BARRIO-ANTA, M.; OBESO, J. R. Tree height prediction approaches for uneven-aged beech forests in northwestern Spain. **Forest Ecology and Management**, [s. l.], v. 307, p. 63–73, 2013.

CASTRO, R. V. O.; SOARES, C. P. B.; MARTINS, F. B.; LEITE, H. G. Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos. **Pesquisa Agropecuária Brasileira**, [s. l.], v. 48, p. 287–295, 2013.

COSTA, C. C. Evaluation of the morphological parameters of aroeira seedlings (*Schinus terebinthifolius* Raddi.) In biodegradable tubes. **Revista Ambientale**, [s. l.], v. 12, n. 3, p. 1–14, 2020.

COSTA, C. C. Preparação e caracterização de compósitos de polietileno de alta densidade com casca de arroz e oxibiodegradante para a produção de tubetes florestais. [s. l.], 2018.

CRUZ, C. D. RNA: aplicação em estudos de predição de valores fenotípicos. In: CRUZ, C. D.; NASCIMENTO, M. **Inteligência computacional aplicada ao melhoramento genético**. Viçosa: UFV, 2018. 414p.

CRUZ, C. D.; NASCIMENTO, M. Inteligência computacional aplicada ao melhoramento genético. **Viçosa, MG: Editora UFV**, [s. l.], 2018.

DA CUNHA NETO, E. M.; BEZERRA, J. C. F.; VERAS, H. F. P.; GOUVEIA, D. M.; ARAUJO, E. C. G.; SILVA, T. C. Estimativa do afilamento do fuste de indivíduos de eucalipto por meio de técnicas de inteligência artificial. **BIOFIX Scientific Journal**, [s. l.], v. 4, n. 2, p. 166–171, 2019.

DE AGUIAR, I. B.; VALERI, S. V.; BANZATTO, D. A.; CORRADINI, L.; ALVARENGA, S. F. Seleção de componentes de substrato para produção de mudas de eucalipto em tubetes. [s. l.], 1989.

DE MENDONÇA, L. M.; DE SOUZA GOMIDE, I.; DE SOUSA, J. V.; BLANCO, C. J. C. Modelagem chuva-vazão via redes neurais artificiais para simulação de vazões de uma bacia hidrográfica da Amazônia. **Revista de Gestão de Água da América Latina**, [s. l.], v. 18, n. 2021, 2021.

DE RESENDE, A. S.; CHAER, G. M.; ALEXANDER SILVA DE RESENDE, C.; CHAER, G. M. **Manual para recuperação de áreas degradadas por extração de piçarra na Caatinga**. [s.l.] : Seropédica: Embrapa Agrobiologia, 2010., 2010.

DE VECHI, A.; JÚNIOR, C. A. D. O. M. Aspectos positivos e negativos da cultura do eucalipto e os efeitos ambientais do seu cultivo. **Revista Valore**, [s. l.], v. 3, n. 1, p. 495–507, 2018.

distribution of forest carbon stocks with artificial neural network based on TM images and forest inventory data. **Acta Ecol. Sin.**, v. 31, p. 998–1008, 2011.

DOS REIS MARTINS, E.; DA SILVA BINOTI, M. L. M.; LEITE, H. G.; BINOTI, D. H. B.; DUTRA, G. C. Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias**, [s. l.], v. 11, n. 1, p. 33–38, 2016.

DUTRA, L. F.; WENDLING, I. Micropropagação e microestaquia de eucalipto. In: WENDLING, I.; DUTRA, L. F. (org.). **Produção de mudas de eucalipto**. Colombo: Embrapa Florestas, 2010. v. 1. p. 83-119.

FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. de L. F. De. Inteligência artificial: uma abordagem de aprendizado de máquina. [s. l.], 2011. Disponível em: <<https://repositorio.usp.br/item/002208293>>. Acesso em: 03 abr. 2023.

FERRAZ, M. V.; CEREDA, M. P.; IATAURO, R. A. Produção de mudas de petúnia comum em tubetes biodegradáveis em substituição aos sacos plásticos. **Revista Brasileira de Engenharia de Biosistemas**, [s. l.], v. 9, n. 1, p. 74–83, 2015.

G.; NASCIMENTO, M. Application of neural networks to predict volume in eucalyptus. **Crop Breeding and Applied Biotechnology**. Viçosa, v.15, p.125-131, 2015. genetic gains. **Sci. agric.** (Piracicaba, Braz.), Piracicaba, v. 71, n. 6, p. 494-498, 2014.

GIL, J. F. S.; DA SILVA, M. R.; SIMÕES, D. Restauração de uma mata ciliar: análise da produtividade efetiva das operações sob condições de incertezas. [s. l.], [s.d.].

GOMES, J. M.; COUTO, L.; LEITE, H. G.; XAVIER, A.; GARCIA, S. L. R. Crescimento de mudas de *Eucalyptus grandis* em diferentes tamanhos de tubetes e fertilização NPK. **Revista Árvore**, [s. l.], v. 27, p. 113–127, 2003.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning, ser. Adaptive computation and machine learning** MIT Press Cambridge, Massachusetts; London, 2016.

GORGENS, E. B.; LEITE, H. G.; SANTOS, H. D. N.; GLERIANI, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, [s. l.], v. 33, n. 6, p. 1141–1147, 2009.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. H.; FRIEDMAN, J. H. **The elements of statistical learning: data mining, inference, and prediction**. [s.l.] : Springer, 2009. v. 2

HAYKIN, S. **Kalman filtering and neural networks**. [s.l.] : John Wiley & Sons, 2004.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. New York: Prentice Hall, 2008.

HAYKIN, S. **Redes neurais: princípios e prática**. [s.l.] : Bookman Editora, 2001.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

IBÁ. (2022). Relatório Anual IBÁ. Disponível em: <<https://iba.org/datafiles/publicacoes/relatorios/relatorio-anual-iba2022-compactado.pdf>>. Acesso em: 03 abr. 2023.

ILPF em números - Rede ILPF. [s.d.]. Disponível em: <<https://redeilpf.org.br/ilpf-em-numeros/>>. Acesso em: 03 abr. 2023.

JÚNIOR, D. L.; COLODETTE, J. L. Importância e versatilidade da madeira de eucalipto para a indústria de base florestal. **Pesquisa Florestal Brasileira**, [s. l.], v. 33, n. 76, p. 429–438, 2013.

LAWRENCE, S.; DAVIS, J. **Forest management: to sustain ecological, economic, and social values**. [s.l.] : Waveland Press, 2005.

LISBOA, A. C.; SANTOS, P. S. Dos; OLIVEIRA NETO, S. N. De; CASTRO, D. N. De; ABREU, A. H. M. De. Efeito do volume de tubetes na produção de mudas de *Calophyllum brasiliense* e *Toona ciliata*. **Revista árvore**, [s. l.], v. 36, p. 603–609, 2012.

MAEDA, E. E.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E.; ARCOVERDE, G. F. B.; HANSEN, M. C. Predicting forest fire in the Brazilian Amazon using MODIS imagery and artificial neural networks. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 11, n. 4, p. 265–272, 2009.

MARTINS, M. T.; MARANGON, G. P.; COSTA, E. A.; DA SILVEIRA, B. D.; CUBAS, R.; CAVALLI, J. P. Estimação da altura de plantios florestais de eucalipto por regressão e redes neurais artificiais. **BIOFIX Scientific Journal**, [s. l.], v. 5, n. 1, p. 141–152, 2019.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, [s. l.], v. 5, p. 115–133, 1943.

MEHTÄTALO, L.; MALTAMO, M.; KANGAS, A. The use of quantile trees in the prediction of the diameter distribution of a stand. [s. l.], 2006.

MOREIRA, M. S.; RODRIGUES, M. P.; FERREIRA, C. F.; NIENOV, O. H. Regressão linear simples e múltipla. **Bioestatística quantitativa aplicada. Porto Alegre: UFRGS, 2020. Cap. 10, p. 197-216**, [s. l.], 2020.

NORVIG, P.; RUSSELL, S. Inteligência artificial. **Rio de Janeiro: Grupo GEN**, [s. l.], 2013.

Objetivos de Desenvolvimento Sustentável | As Nações Unidas no Brasil. [s.d.]. Disponível em: <<https://brasil.un.org/pt-br/sdgs>>. Acesso em: 15 abr. 2023.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; BROOKS, J. R.; WIANT JR, H. V. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of environmental management**, [s. l.], v. 91, n. 3, p. 742–753, 2010.

PAULA, Y. L. De. **Tubetes biodegradáveis a base de cera de abelha e resíduos da castanha-de-caju**. 2022. Master's Thesis - Universidade Federal do Rio Grande do Norte, [s. l.], 2022.

PEREIRA, C. S.; SILVA, A. A.; CARVALHO, S. J.; GUIMARÃES, R. J.; POZZA, E. A. Tubetes biodegradáveis produzidos com cera de abelha. [s. l.], 2007.

POLIDORO, J. C.; FREITAS, P. L. D.; HERNANI, L.; ANJOS, L. D.; RODRIGUES, R.; RIO, F. C.; ANDRADE, A.; RIBEIRO, J. The impact of plans, policies, practices and technologies based on the principles of conservation agriculture in the control of soil erosion in Brazil. . [s.l: s.n.]. Disponível em: <<https://www.authorea.com/users/313628/articles/444131-the-impact-of-plans-policies-practices-and-technologies-based-on-the-principles-of-conservation-agriculture-in-the-control-of-soil-erosion-in-brazil?commit=8ec3ada4c79b971cdae8146043d59676c3bc3e6d>>. Acesso em: 03 abr. 2023.

POONA, N. K.; ISMAIL, R. Discriminating the occurrence of pitch canker fungus in *Pinus radiata* trees using QuickBird imagery and artificial neural networks. **Southern Forests: a Journal of Forest Science**, [s. l.], v. 75, n. 1, p. 29–40, 2013.

R Core Team (2022). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Available online at <https://www.R-project.org/>.

RIEDMILLER M. (1994) Rprop - Description and Implementation Details. Technical Report. University of Karlsruhe.

RIOS, M. S. **A eficiência das funções polinomiais, da função spine cúbica e razões de volume para representar o perfil da árvore e estimar os sortimentos de *Pinus elliottii***. [s.l: s.n.].

RODRIGUES, W. Um Estudo de Predição de Volumes de Clones de Eucalipto Utilizando Redes Neurais Artificiais. Em: ANAIS DO 14º SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE 2019, **Anais**. Em: ANAIS DO 14º SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE.: Galoa, 2019. Disponível em: <https://proceedings.science/proceedings/100113/_papers/111606>. Acesso em: 03 abr. 2023.

RODRIGUES, V. A.; DE OLIVEIRA, A. M.; COELHO, K. C.; DEFENSOR, D. C. B.; DE NOVAES, A. B. EFEITOS DE COMPLEXO ORGÂNICO NA PRODUÇÃO DE MUDAS DE EUCALIPTO. Semana de Agronomia da UESB (SEAGRUS)-ISSN 2526-8406, [s. l.], v. 2, n. 1, 2020.

RUSSELL, S. J.; NORVIG, P.; CANNY, J. F. Malik, J.M.; EDWARDS, D.D. **Artificial intelligence: a modern approach**. Prentice hall Englewood Cliffs, 1995.

SCHUMACHER, M. V.; VIERA, M. **Silvicultura do eucalipto no Brasil**. [s.l.] : Fundação de Apoio a Tecnologia e Ciencia-Editora UFSM, 2016.

SCRINZI, G.; MARZULLO, L.; GALVAGNI, D. Development of a neural network model to update forest distribution data for managed alpine stands. *Ecological Modelling*, [s. l.], v. 206, n. 3, p. 331–346, 2007.

SILVA JÚNIOR, A. C. D. **Predição e importância de preditores em abordagens fundamentadas em inteligência computacional e aprendizado de máquinas**. 2021. Doutor em Genética e Melhoramento - Universidade Federal de Viçosa, Viçosa - MG, 2021. Disponível em: <<https://locus.ufv.br//handle/123456789/28761>>. Acesso em: 03 abr. 2023.

SILVA, G. N.; FERREIRA, R. A. D. C.; SANT' ANNA, I. C.; CARNEIRO, V. Q.;

SILVA, G. N.; TOMAZ, R. S.; SANT'ANNA, I. D. C.; NASCIMENTO, M.;

SILVA, I. N. Da; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. [s. l.], 2010.

SILVA, W. de M. Redes neurais artificiais como ferramenta para prognose de crescimento e melhoramento genético florestal. [s. l.], 2019.

STENGHELE, G.; SANTOS, J. A. A. Dos; MIURA, F. S.; PASA, L. A.; SCHMIDT, C. A. P. Previsão de Consumo de Energia Elétrica na Região Sudeste: Um Estudo de Caso Usando Sarima / Forecast of Electricity Consumption in the Southeast Region: A Case Study Using Sarima. **Revista FSA (Centro Universitário Santo Agostinho)**, [s. l.], v. 17, n. 2, p. 169–183, 2020.

THIERSCH, C. **Acuracidade dos modelos polinomiais para representar os perfis dos fustes de clones de *Eucalyptus grandis***. Universidade Federal de Lavras Lavras, 1999.

VENDRUSCOLO, D. G. S.; DRESCHER, R.; SOUZA, H. S.; MOURA, J.; MAMORÉ, F. M. D.; SIQUEIRA, T. da S. Estimativa da altura de eucalipto por meio de regressão não linear e redes neurais artificiais. **Revista brasileira de biometria**, [s. l.], v. 33, n. 4, p. 556–569, 2015.

VITAL, M. H. F. Impacto ambiental de florestas de eucalipto. [s. l.], 2007.

WANG, S. H.; ZHANG, M. Z.; ZHAO, P. A.; CHEN, J. X. Modelling the spatial

WEDLING, I.; DUTRA, L. F.; GABIRA, M. M.; VIEIRA, L. M.; DEGENHARDT, J. Produção de mudas de eucalipto. In: WEDLING, I. et al. **O eucalipto e a Embrapa: Quatro décadas de pesquisa e desenvolvimento**. Brasília: Embrapa Florestas, 2021. Cap. 22, p. 823-858.

ZHOU, R.; WU, D.; FANG, L.; XU, A.; LOU, X. A Levenberg–Marquardt backpropagation neural network for predicting forest growing stock based on the least-squares equation fitting parameters. **Forests**, [s. l.], v. 9, n. 12, p. 757, 2018.