

INSTITUTO FEDERAL DE EDUCAÇÃO CIÊNCIA E TECNOLOGIA DE MINAS
GERAIS - *CAMPUS* SÃO JOÃO EVANGELISTA
BACHARELADO EM ENGENHARIA FLORESTAL

Gleiciane Santos Souza

**TRATAMENTOS PRÉ-GERMINATIVOS, VOLUME DE TUBETES E REDES
NEURAS ARTIFICIAIS NA PROPAGAÇÃO DE SABONETEIRA**

São João Evangelista

2021

GLEICIANE SANTOS SOUZA

**TRATAMENTOS PRÉ-GERMINATIVOS, VOLUME DE TUBETES E REDES
NEURAS ARTIFICIAIS NA PROPAGAÇÃO DE SABONETEIRA**

Trabalho de conclusão de curso apresentado ao Instituto Federal de Minas Gerais - *Campus* São João Evangelista, como exigência parcial para obtenção do título de Bacharel em Engenharia Florestal.

Orientador: Prof. Dr. Bruno Oliveira Lafetá

São João Evangelista

2021

S237t Souza, Gleiciane Santos.

Tratamentos Pré-Germinativos, Volume de Tubetes e Redes Neurais Artificiais
na Propagação de Saboneteira. – 2021.

25 f. : il.

Orientador: Dr. Bruno Oliveira Lafetá

Trabalho de Conclusão de Curso (TCC) – Instituto Federal de
Ciência e Tecnologia de Minas Gerais – *Campus* São João Evangelista

1. Germinação. 2. Inteligência Artificial. 3. Mudas. 4. Sementes.

I. Título.

CDD 634.9

Ficha Catalográfica – Bibliotecária Nirley Dias Leandro CRB 6 2394

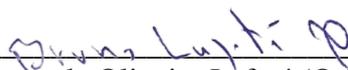
GLEICIANE SANTOS SOUZA

**TRATAMENTOS PRÉ-GERMINATIVOS, VOLUME DE TUBETES E REDES
NEURAS ARTIFICIAIS NA PROPAGAÇÃO DE SABONETEIRA**

Trabalho de conclusão de curso apresentado
ao Instituto Federal de Minas Gerais –
Campus São João Evangelista, como
exigência parcial para obtenção do título de
Bacharel em Engenharia Florestal.

Aprovada em 04/08/2021

BANCA EXAMINADORA



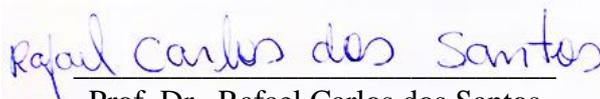
Prof. Dr. Bruno de Oliveira Lafetá (Orientador)

Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – *Campus São
João Evangelista*



Profa. Dra. Natália Rizzo Fonseca

Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – *Campus São
João Evangelista*



Prof. Dr. Rafael Carlos dos Santos

Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – *Campus São
João Evangelista*

A Deus, a minha mãe Elza C. Santos por todo amor, orações, apoio, carinho e incentivo. Ao meu pai Luiz (in memoriam).

Dedico.

AGRADECIMENTOS

Primeiramente agradeço a Deus e a Maria Santíssima pela proteção, força, por todas as bênçãos e por me concederem o dom da sabedoria durante essa caminhada.

Agradeço a minha querida mãe Elza, pessoa mais importante da minha vida, por todo amor e por estar sempre ao meu lado me encorajando e intercedendo a Deus por mim.

Aos colegas e amigos pelo apoio e alegrias proporcionadas durante essa trajetória.

Ao Professor Dr. Bruno Oliveira Lafetá, pela orientação, paciência e amizade.

Ao Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais - *Campus* São João Evangelista pela oportunidade.

Por fim, a todos que de alguma forma contribuíram para realização deste trabalho.

RESUMO

O objetivo do presente trabalho foi avaliar o efeito de diferentes volumes de tubetes e de pré-tratamentos na germinação e crescimento de *Sapindus saponaria*, além da possibilidade de aplicação de redes neurais artificiais (RNA) na estimativa da biomassa de mudas. Adotou-se delineamento inteiramente casualizado no esquema fatorial 3×2 , sendo estudado três volumes de tubetes (T1 – 53 cm³; T2 – 180 cm³ e T3 – 280 cm³) e dois tratamentos pré-germinativos (A1 – Testemunha: sementes com tegumento intacto e A2 – Escarificação mecânica do tegumento com esmeril elétrico). Realizaram-se análise de variância, teste Tukey e modelagem por RNA. Os tubetes de 53 cm³ foram os mais operacionalmente recomendados para a produção de mudas até os 250 dias de idade. A escarificação mecânica favoreceu a velocidade de germinação (IVG = 1,47), embora tenha apresentado estatisticamente o mesmo percentual de sementes germinadas da testemunha na contagem final. A rede de múltiplas camadas (MLP) forneceu as estimativas mais precisas da massa seca de parte aérea, com perda de qualidade preditiva do componente radicular. Conclui-se que a escarificação de sementes com esmeril elétrico e tubetes de 53 cm³ podem ser recomendados para maximizar a homogeneidade, velocidade da germinação e produção de mudas da espécie. A arquitetura MLP de RNA pode ser recomendada para estimar de forma simultânea as massas secas de parte aérea e do sistema radicular de mudas de *S. saponaria*.

Palavras-chave: Germinação. Inteligência artificial. Mudas. Sementes.

ABSTRACT

This work aimed to evaluate the effect of different tubes volumes and pre-treatments on the germination and growth of *Sapindus saponaria*, in addition to the possibility of applying artificial neural networks (ANN) to estimate seedlings biomass. Completely randomized design in a 3×2 factorial scheme was adopted, with three tubes volumes (T1 – 53 cm³; T2 – 180 cm³ e T3 – 280 cm³) of two pre-germinative treatments (A1 - witness: seeds with intact integument and A2 – mechanical scarification of the integument with electric grinding). Analysis of variance, Tukey test and RNA modeling were performed. The 53 cm³ tubes were the most operationally recommended suitable for seedlings production up to 250 days of age. Mechanical scarification favored germination speed (IVG = 1.47), although it presented statistically the same percentage of germinated seeds as the control in the final count. Multilayer network (MLP) provided the most accurate estimates of shoot dry mass, with loss of predictive quality of the root component. It is concluded that seed scarification with electric grinding and 53 cm³ tubes can be recommended to maximize the homogeneity, germination speed and seedling production of the species. RNA MLP architecture can be recommended to simultaneously estimate the dry masses of aerial part and root system of *S. saponaria* seedlings.

Keywords: Germination. Artificial intelligence. Seedlings. Seeds.

SUMÁRIO

1	INTRODUÇÃO.....	9
2	REFERENCIAL TEÓRICO.....	10
2.1	Tubetes.....	10
2.2	Redes neurais artificiais (RNA).....	11
2.2.1	Redes neurais artificiais de múltiplas camadas (MLP).....	11
2.2.2	Redes neurais artificiais de base radial (RBF).....	12
3	METODOLOGIA.....	13
4	RESULTADOS E DISCUSSÃO.....	16
5	CONCLUSÕES.....	22
	REFERÊNCIAS.....	23

1 INTRODUÇÃO

A crescente necessidade de reposição florestal tem estimulado a coleta de sementes e produção de mudas de espécies nativas. Parte dessa necessidade é proveniente de intervenções ambientais que exercem forte pressão sobre o ambiente e de eventuais problemas ecológicos causados pela extração de bens não renováveis.

Sapindus saponaria L., conhecida popularmente por saboneteira ou saboeiro, pertence à família Sapindaceae e ocorre em florestas pluviais e semi-decíduais nas regiões tropicais da América (MARTINS et al., 2011; OLIVEIRA et al., 2012). É uma espécie utilizada em programas de recuperação de áreas degradadas e paisagismo, suas sementes são empregadas no artesanato e a madeira para a confecção de brinquedos e construção civil (OLIVEIRA et al., 2012).

Espécies do gênero *Sapindus* são fontes de saponinas para uso farmacológico e cosmético, bem como, no tratamento de feridas na pele, úlceras e inflamações (GARCIA et al., 2012; MARTINS et al., 2011).

As sementes de *S. saponaria* apresentam dormência tegumentar, dificultando com frequência a germinação e produção de mudas em viveiros florestais (OLIVEIRA et al., 2012). O tegumento impermeável oferece uma resistência física ao crescimento do embrião, restringindo a entrada de oxigênio e água na semente, essenciais para o início do processo germinativo (ALBUQUERQUE et al., 2007).

A plântulas de *S. saponaria* após a sementeira emergem em um tempo médio de 20 a 40 dias, sendo que, a sua germinação ocorre de moderada a baixa (LORENZI, 2009). Métodos práticos e eficazes para a superação da dormência aumentam a germinação e favorecem o estabelecimento e produção de mudas em escalas comerciais, um exemplo é a escarificação física do tegumento (LAFETÁ et al., 2019).

Diversos aspectos técnicos devem ser analisados para a otimização da produção de mudas, contudo, muitas vezes negligenciados em virtude da falta de planejamento e/ou conhecimento silvicultural. A escolha de um tamanho apropriado dos tubetes é fundamental para a otimização da produção de mudas em viveiros florestais.

O desenvolvimento de metodologias para a estimativa de biomassa de mudas é uma necessidade constante para a melhoria contínua da produtividade em viveiros florestais. Informações de biomassa permitem a avaliação da qualidade das mudas, balanço nutricional e melhor planejamento da cadeia produtiva. Na busca por novas opções para estimativa eficiente e segura de atributos biométricos se destaca a inteligência artificial.

As Redes Neurais Artificiais (RNA) representam uma abordagem alternativa para o desenvolvimento de modelos preditivos, capazes de aprender tendências de dados e padrões complexos (HAYKIN, 2001; SCRINZI et al., 2007). Frequentemente, tem exibido desempenho superior a análises estatísticas clássicas, como a regressão. Isto se deve às suas próprias características de tolerância a falhas ou ruídos, analogia neurobiológica, habilidade de aprendizagem, memória distribuída e associativa, capacidade de autoadaptação e generalização (BRADSHAW et al., 2002; MONJEZI et al., 2010; PANDORFI et al., 2011). As arquiteturas de rede mais comuns são as de múltiplas camadas (*Multilayer Perceptron* – MLP) e de base radial (*Radial basis function* – RBF).

Mediante ao exposto, as seguintes hipóteses foram testadas: i) a existência de interação entre o volume de tubetes e os tratamentos pré-germinativos para a *S. saponaria*. ii) modelagem por RNA fornece estimativas precisas de aspectos biométricos de mudas. Logo, o objetivo do presente trabalho foi avaliar o efeito de diferentes volumes de tubetes e de pré-tratamentos na germinação e crescimento de *S. saponaria*, além da possibilidade de aplicação de RNA na estimativa da biomassa de mudas.

2 REFERENCIAL TEÓRICO

2.1 Tubetes

O recipiente onde a muda é produzida pode influenciar no crescimento e arquitetura do sistema radicular e conseqüentemente, no estabelecimento das plantas em campo (PAULINO et al., 2003). Os tubetes são os recipientes mais utilizados para a produção de mudas de eucalipto no Brasil e, também, são empregados na propagação de espécies nativas (FERRAZ e ENGEL, 2011).

STURION e ANTUNES (2000), afirmam que ao fazer o uso de tubetes para o desenvolvimento de mudas tem-se o benefício da redução de custos através do seguimento de operações, redução de estímulos físicos e o uso de materiais mais leves em viveiro. Existem inúmeros recipientes os quais podem ser usados para a formação de mudas, mas os tubetes trazem eficácia em relação a demanda de menor quantia de substrato, por utilizarem menor espaço de produção, minimizarem os custos de transporte e de estruturação no plantio e também por serem reutilizáveis (Dias et al., 2016).

ABREU et al. (2015), relatam que o uso de tubetes para produção de mudas contribui para a logística de campo, pois os mesmos possuem menor volume e peso em relação

aos sacos plásticos. Esse fator propicia cada vez mais o uso de tubetes no lugar dos sacos plásticos, para a produção de espécies florestais. DUARTE et al. (2016), constataram em seus estudos que o tamanho dos tubetes tem influência direta no valor da produção de mudas em viveiros.

Existem distintos volumes, tamanhos e formatos de tubetes, que podem ser usados para propagar inúmeras espécies (LISBOA et al., 2012). É importante ressaltar que o volume de recipiente estimula a taxa de sobrevivência das mudas, sendo então, fundamental a realização de pesquisas para definir o volume de tubete propicio ao desenvolvimento de cada espécie (Cruz et al., 2016).

2.2 Redes neurais artificiais (RNA)

As Redes Neurais Artificiais (RNA) são um conjunto técnicas baseadas em princípios matemáticos que simulam o design e processamento de informações do sistema nervoso humano (BLACKARD e DEAN, 1999; BORSATO et al., 2009; MAEDA et al., 2009). As redes neurais são formadas por unidades simples de processamento (neurônios artificiais) e podem solucionar problemas de natureza linear ou não, entre uma ou múltiplas variáveis de entrada e de saída (BORSATO et al., 2009).

As redes neurais já foram utilizadas com sucesso em diversas áreas do setor florestal, aprimorando técnicas de mensuração (SILVA et al., 2009). Além disso, essa ferramenta computacional pode ser utilizada na gestão florestal (SCRINZI et al., 2007), na modelagem ecofisiológica do crescimento (LAFETÁ, 2012), na previsão de incêndios florestais (KUPLICH, 2006), na classificação de cobertura florestal (BLACKARD e DEAN, 1999), nas estimações de área foliar específica, clorofila e volume de árvores (LAFETÁ et al., 2012; SILVA et al., 2009).

Para definir a rede neural com melhor capacidade de generalização é importante testar sua eficiência em classificar corretamente padrões não incluídos durante o treinamento (FERNANDES et al., 2004).

2.2.1 Redes neurais artificiais de múltiplas camadas (MLP)

Para uma melhor aproximação de funções de ativação são aplicadas as redes neurais do tipo múltiplas camadas (MLP). Essas redes extraem informações paralelas de sua estrutura e repartem, desenvolvendo habilidade de assimilar e difundir o conhecimento obtido, sendo

assim capaz de decifrar problemas relevantes (BINOTI et. al., 2013; BRAGA et. al, 2007; HAYKIN, 2001).

Segundo Valença (2011), a rede de múltipla camada (MLP) é considerada uma propagação da rede perceptron simples, pois a mesma acrescenta pelo menos uma camada intermediária a sua estrutura. Redes MLP são constituídas de: uma camada de entrada que é responsável pela apresentação das variáveis, uma ou mais camadas ocultas que tem a função de processamento e uma camada de saída, na qual são apresentados os resultados.

Na MLP a camada intermediária identifica os padrões de dados não lineares, por meio de várias funções de estímulos, tendo entre as mais usuais as funções lineares, logística e tangente hiperbólica (Braga et al., 2007).

De acordo com Braga et al. (2007), para mensuração de altura e massa seca de mudas nativas por meio de redes múltiplas camadas é necessário a realização do ajuste do padrão de rede neural dos pesos sinápticos, esse processo repetitivo pelo qual acontece o ajuste é denominado aprendizagem ou treinamento.

2.2.2 Redes neurais artificiais de base radial (RBF)

As redes neurais artificiais de base radial (RBF) recebem esse nome devido ao uso de funções de bases radiais como a gaussiana, que corresponde a função da distância existente entre os vetores de entrada e suas as regiões centrais em direção a camada oculta e no equilíbrio dos dados que se encontram internamente para a camada de saída (BRAGA et al., 2000).

Braga et al. (2000) e Haykin (2001), concluíram que uma RBF possui três camadas, onde: a primeira é denominada a camada de entrada responsável pela conexão as redes, a segunda uma camada oculta, sendo essa única (que estimula a função de ativação gaussiana) responsável pela alteração não linear das entradas e a terceira camada de saída sendo essa linear, composta por um único neurônio e encarregada de fornecer resposta da rede.

As redes neurais de base radial são totalmente conectadas do tipo *feedforward*. e no espaço de alta dimensão as RBF utilizam um ajuste de curvas por meio de aproximação (HAYKIN, 2001).

3 METODOLOGIA

Caracterização experimental

A coleta de frutos foi realizada em árvores de *S. saponaria* situadas no município de São João Evangelista-MG, sob as coordenadas de 18°32'4,99" de latitude Sul e 42°45'17,64" de longitude Oeste (Datum Sirgas 2000), em área de fragmento florestal do Instituto Federal de Minas Gerais. O tipo climático da região é o Cwa pela classificação do sistema internacional de Köppen (KÖPPEN, 1936), com médias anuais de temperatura e precipitação de 20,2° C e 1.377 mm, respectivamente (INMET, 2020).

As árvores selecionadas apresentavam altura total de 5 a 7 m, diâmetro a 1,30 m do solo superior a 20 cm e nenhum sinal aparente de danos ocasionadas pelo ataque de insetos ou doenças. Os frutos foram coletados diretamente nas copas com auxílio de podão aéreo, restringindo-se àqueles de coloração marrom. Posteriormente, foram acondicionados em sacos de papel Kraft e submetidos à triagem manual, isolando as sementes dos frutos e eliminando-se o material que possuía alguma atrofia ou injúria a fim de se obter uma melhor qualidade e pureza física dos lotes.

O teor de água das sementes foi determinado pelo método da estufa a $105 \pm 3^\circ\text{C}$ por 24 h, com quatro repetições de 25 unidades.

As sementes após a triagem foram desinfestadas com hipoclorito de sódio (NaClO), com 2,0 % de cloro ativo, a 5,0 % (v/v) durante três minutos, depois lavadas com água destilada e colocadas para secar durante dez minutos sobre papel toalha. Optou-se pelo NaClO por se tratar de um composto químico contra proliferação bacteriana.

O trabalho foi realizado em casa de sombra com tela de monofilamento malha para 50% de sombreamento. Adotou-se delineamento inteiramente casualizado no esquema fatorial 3×2 , sendo estudado os efeitos de três volumes de tubetes redondos, rígidos e de polipropileno com fundo aberto (T1 – 53 cm³; T2 – 180 cm³ e T3 – 280 cm³) e de dois tratamentos pré-germinativos (A1 – Testemunha: sementes com tegumento intacto e A2 – Escarificação mecânica do tegumento com esmeril elétrico). Para processo de escarificação as sementes foram pressionadas manualmente em esmeril com rotação contínua de 2800 rpm, na região oposta ao eixo-embriônico até o desgaste do tegumento, evitando, contudo, danificar o embrião.

A escolha do pré-tratamento A2 na experimentação decorreu do seu estímulo à germinação de *S. saponaria* (LAFETÁ et al., 2019). As características dos tubetes estão apresentadas na Tabela 1. A unidade experimental foi constituída por 25 sementes.

Tabela 1 - Características dos tubetes utilizados no experimento

Características	T1 (53cm ³)	T2 (180cm ³)	T3 (280cm ³)
Peso (g)	9	20	40
Diâmetro interno (mm)	28	52	52
Diâmetro externo (mm)	34	63	64,5
Furo (mm)	12	10	14
Altura (cm)	125	131	190
Capacidade (cm ³)	53	180	280
Número de estrias	6	8	8

Fonte: Elaborado pela autora, 2021.

A propagação se deu no sistema de canteiro suspenso e a semeadura foi realizada sobre a superfície do substrato comercial Mecplant[®]- Classe A, enriquecido com formulado de liberação controlada Osmocote[®] 15-9-12 de NPK (2 g.kg⁻¹). Esse substrato possui em sua composição casca de pinus com capacidade de retenção de água de 60,0 % (p/p).

As avaliações foram realizadas diariamente até a contagem final e estabilização de todos os atributos estudados (trigésimo nono dia), registrando os percentuais de sementes germinadas (G, protrusão de radícula superior a 1,0 cm) e de emissão da parte aérea (EPA). As sementes não embebidas foram consideradas duras, pois mantiveram o aspecto de recém semeadas. Calculou-se o índice de velocidade da germinação (IVG) conforme a metodologia proposta por Maguire (1962), utilizando-se a fórmula abaixo.

$$IVG = \frac{N_1}{D_1} + \frac{N_2}{D_2} + \dots + \frac{N_n}{D_n}$$

Em que:

N_1 = número de sementes germinadas na 1^o contagem;

D_1 = número de dias para a 1^o contagem;

N = número de sementes germinadas na última contagem;

D = número de dias para a última contagem.

Aos 250 dias após instalação experimental, foram mensurados a altura (H, cm) e o diâmetro do coleto (DC, mm) das mudas com auxílio de régua milimetrada e paquímetro digital de precisão 1/10 mm. Assumiu-se como altura a distância linear da base do coleto até o ápice

vegetal. As massas secas da parte aérea (MSPA, g) e do sistema radicular (MSR, g) das mudas foram obtidas após lavagem e secagem a 65°C em estufa de circulação forçada de ar até peso constante; a pesagem foi realizada com balança digital de 0,0001 g de precisão.

Os dados foram submetidos às análises de normalidade de resíduos segundo Lilliefors, homogeneidade por Cochran e os testes F e de Tukey.

Modelagem via redes neurais artificiais

A fim de se obter uma rede neural generalista para a estimativa simultânea das massas secas de parte aérea e de raiz, realizou-se o agrupamento das massas secas em uma única variável categórica denominada VCP. Para a estimativas das massas secas, estabeleceu-se a relação funcional utilizando-se variáveis preditoras numéricas (H e DC) e categóricas (Tubetes: T1 – 1; T2 – 2 e T3 – 3; Pré-tratamentos: A1 – 1 e A2 – 2; VCP: MSPA – 1 e MSR – 2).

Foram utilizadas redes anteroalimentadas (*feedforward*), treinadas por meio do algoritmo da retropropagação do erro (*backpropagation*), ou seja, durante o treinamento da rede foram realizados cálculos partir da camada de entrada da rede para a de saída e o erro propagado para camadas anteriores. Em todos os pré-processamentos foram realizadas a normalização e equalização dos dados. Os dados foram divididos em grupos de treinamento (80 % das amostras), teste (10 % das amostras) e validação (10 % das amostras) utilizando o método randômico de amostragem.

Treinaram-se 1.000 RNA, sendo 500 *Multilayer Perceptron* (MLP) e 500 *Radial Basis Function* (RBF). Destas foram selecionadas duas de cada tipo com base nos desvios dos valores estimados e observados. Para se evitar problemas de *overfitting*, o treinamento das redes foi interrompido logo no momento de aumento de desvios, conforme Bradshaw et al. (2002) e Maeda et al. (2009).

O número ótimo de camadas intermediárias e de neurônios por camada, geralmente, não é conhecido *a priori*. Uma vez definidos a arquitetura e os parâmetros de aprendizado, a rede neural artificial é treinada de forma interativa. Portanto, a definição da arquitetura das redes foi otimizada pela ferramenta *Intelligent Problem Solver* (IPS) do *software* Statística 7.0 (STATSOFT, 2007).

Os pontos que extrapolaram a tendência geral de cada tratamento não foram eliminados a fim de verificar a capacidade das redes neurais artificiais em lidar com *outliers* ou ruídos. A avaliação da acurácia das estimativas de massas secas contemplou as estatísticas de

erro relativo, Raiz Quadrada do Erro Médio (RQEM), tendenciosidade em módulo (|Bias|), teste *t* pareado e análise gráfica de resíduos percentuais.

Todas as análises estatísticas foram realizadas ao nível de significância de 5% de probabilidade. Estas foram efetuadas com auxílio do *software* Statistica 7.0 (STATSOFT, 2007).

4 RESULTADOS E DISCUSSÃO

Germinação e aspectos biométricos

O teor de água das sementes de *S. saponaria* foi de 12,7 %. O efeito estatístico pelo teste F ($p \leq 0,05$) foi observado em nível de interação (volume de tubetes \times tratamentos pré-germinativos) apenas para a germinação (Tabela 2). Verificaram-se diferenças significativas entre os volumes de tubetes para a MSPA e entre tratamentos pré-germinativos para este atributo e emissões IVG. As médias de emissão de parte aérea, diâmetro do coleto, altura e massa seca do sistema radicular foram de $18,6389 \pm 9,9199\%$, $0,2974 \pm 0,0451\text{mm}$, $11,4750 \pm 1,8939\text{ cm}$ e $0,3085 \pm 0,1963\text{ g}$, respectivamente.

Tabela 2 - Resumo da análise de variância dos atributos avaliados durante a propagação seminal de *S. saponaria*

F.V.	G.L.	----- Q.M. -----						
		G	EPA	IVG	DC	H	MSPA	MSR
T	2	31,0104 ^{ns}	268,3657 ^{ns}	0,0038 ^{ns}	0,0017 ^{ns}	8,9170 ^{ns}	0,0544 [*]	0,0667 ^{ns}
A	1	168,0104 ^{ns}	26,7407 ^{ns}	0,1496 [*]	0,0003 ^{ns}	3,6248 ^{ns}	0,0808 [*]	0,0053 ^{ns}
T x A	2	214,1979 [*]	27,1713 ^{ns}	0,0518 ^{ns}	0,0016 ^{ns}	4,4410 ^{ns}	0,0020 ^{ns}	0,0248 ^{ns}
Resíduo	18	46,9572	91,4167	0,0262	0,0022	2,8974	0,0130	0,0388
CV _{exp} (%)		8,07	51,30	11,62	15,82	14,83	21,58	63,84

^{*}, ^{ns} significativo e não significativo a 5% de probabilidade pelo teste F. T = Volume de tubetes; A = tratamentos pré-germinativos; CV_{exp} = coeficiente de variação experimental; G = germinação; EPA = emissão da parte aérea; IVG = índice de velocidade da germinação; DC = diâmetro do coleto; H = altura; MSPA = massa seca de parte aérea e; MSR = massa seca do sistema radicular. Fonte: Elaborado pela autora, 2021.

O desdobramento da interação significativa relacionada à germinação se encontra na Tabela 3. O tubete de 53 cm³ pode ser recomendado para estimular a germinação de *S. saponaria*. Esta decisão se baseia na premissa de que um tubete menor propicia menores custos de substrato, de irrigação e de fertilização. Além disso, a produção individual de massa seca de parte aérea das mudas foi maior quando utilizaram os tubetes de 53 cm³ e 180 cm³.

Tabela 3 - Médias dos atributos avaliados durante a propagação seminal de *S. Saponaria*

Tratamentos pré-germinativos	Volume de tubetes			IVG
	T1 (53 cm ³)	T2 (180 cm ³)	T3 (280 cm ³)	
	----- Germinação -----			
A1	90,0 Aa	76,0 Bab	80,9 Ab	1,31 B
A2	83,8 Aa	90,0 Aa	89,0 Aa	1,47 A
MSPA	0,6 a	0,5 ab	0,4 b	

Médias seguidas pela mesma letra maiúscula na coluna e minúscula na linha não diferem entre si pelo teste F e Tukey, respectivamente, a 5,0 % de significância estatística. A1 = testemunha: sementes com tegumento intacto. A2 = escarificação mecânica do tegumento com esmeril elétrico. MSPA = massa seca de parte aérea. IVG = índice de velocidade da germinação. Fonte: Elaborado pela autora, 2021.

Não se observou diferenças significativas ($p > 0,05$) do percentual de germinação entre os tratamentos pré-germinativos com uso dos tubetes de 53 e 280 cm³ para os lotes de sementes em estudo. Tal resultado possui grande relevância prática, pois o tratamento testemunha foi o menos oneroso e laborioso, pois não emprega pré-tratamentos como o A2, que utiliza a escarificação mecânica do tegumento com esmeril elétrico. Ressalta-se a importância de testes preliminares para a análise da qualidade germinativa e eventual definição de pré-tratamento para a propagação seminal em amplas escalas comerciais.

Por outro lado, enfatiza-se que a maior homogeneidade e velocidade da germinação foram observadas no pré-tratamento A2 (IVG = 1,47). Este pré-tratamento pode ser indicado para viveiros que utilizam de forma eficiente suas tecnologias e espaço. Observou-se maior permeabilidade à água quando friccionou as sementes em esmeril elétrico, provocando alterações estruturais no tegumento, o que incitou a germinação. Considera-se ainda, que este procedimento pode ser viabilizado para maiores lotes de sementes, devido a sua operacionalidade e rendimento. É importante considerar a necessidade de mais estudos sobre a germinação e produção de mudas *S. saponaria* visando complementar informações sobre sua propagação, que ainda não se encontra descrita nas Regras para Análises de Sementes - RAS (BRASIL, 2009).

Aplicação de redes neurais artificiais

As redes apresentaram funções de ativação não lineares nas camadas intermediárias e de saída (Tabela 4). O comportamento sigmoideal na camada de saída foi observado somente na rede MLP1. Salienta-se que tendências não lineares possibilitam às camadas sucessivas a capacidade de solucionar os problemas complexos no espaço de entrada (BRAGA et al., 2007).

Tabela 4 - Caracterização das Redes Neurais Artificiais (RNA) para a estimação simultânea das massas secas de parte aérea (MSPA, g) e de raiz (MSR, g) das mudas de *S. saponaria* aos 250 dias.

RNA	n	Arquitetura	Função de Ativação	
			Intermediária	Saída
MLP1	48	10-4-1	Tangencial	Tangencial
MLP2	48	10-9-1	Exponencial	Identidade
RBF1	48	10-15-1	Gaussiana	Identidade
RBF2	48	10-14-1	Gaussiana	Identidade

MLP = múltiplas camadas. RBF = base radial. n = número de observações. Fonte: Elaborado pela autora, 2021.

Os valores médios de RQEM para as arquiteturas MLP e RBF foram de 35,59% e 42,18%, respectivamente (Tabela 5). Em geral, durante o treinamento foram observados baixos valores de Bias. Maior amplitude dos erros relativos foi observada na rede RBF1 durante a fase de treinamento, reduzindo nas demais fases. Os dados observados e estimados foram estatisticamente semelhantes entre si pelo teste *t* em todas as redes construídas ($p > 0,05$), exceto durante o teste da MLP1 ($p \leq 0,05$). Portanto, esta rede não foi selecionada para a análise gráfica subsequente.

Tabela 5 - Precisão das Redes Neurais Artificiais (RNA) para a estimação simultânea do volume (V , cm^3) e das massas secas de parte aérea (MSPA, g) e de raiz (MSR, g) das mudas de *S. saponaria* aos 250 dias.

RNA	Fases	RQEM%	Bias%	Erros relativos (%)			teste <i>t</i> <i>p</i>
				Máximo	Media	Mínimo	
MLP1	Treinamento	21,11	0,84	1628,18	43,20	-45,86	0,76
	Teste	12,24	9,49	-1,33	-11,89	-30,75	0,01
	Validação	65,25	23,46	274,93	52,78	-34,15	0,34
MLP2	Treinamento	32,06	0,07	1598,74	49,78	-59,13	0,99
	Teste	13,94	2,14	31,14	4,08	-11,61	0,69
	Validação	68,92	19,15	221,04	39,28	-46,85	0,47
RBF1	Treinamento	39,10	< 0,01	313,33	27,17	-93,62	1,00
	Teste	30,21	7,10	104,33	10,23	-36,18	0,54
	Validação	55,35	20,43	200,46	46,99	-41,92	0,33
RBF2	Treinamento	40,13	< 0,01	8652,59	176,69	-87,36	1,00
	Teste	34,35	13,87	57,85	-2,31	-78,26	0,28
	Validação	53,91	2,68	152,27	14,08	-51,98	0,90

MLP = múltiplas camadas . RBF = base radial. p = valor de probabilidade.

A distribuição dos resíduos percentuais das redes selecionadas para a análise gráfica se encontra na Figura 1. Para melhor visualização da distribuição de resíduos, os valores de 1.598,74% (DC = 0,19 mm) e 8.652,59% (DC = 0,19 mm) foram omitidos dos gráficos referentes às redes MLP2 e RBF2, respectivamente. A rede RBF1 não apresentou tal ponto discrepante, demonstrando capacidade em lidar com ruídos ou valores atípicos durante a modelagem. A homocedasticidade foi verificada em todas as arquiteturas testadas. Diante da complexidade fisiológica envolvida no acúmulo de massa seca vegetal (TAIZ e ZEIGER, 2013), especialmente de material seminal, o desempenho preditivo da modelagem foi considerado satisfatório.

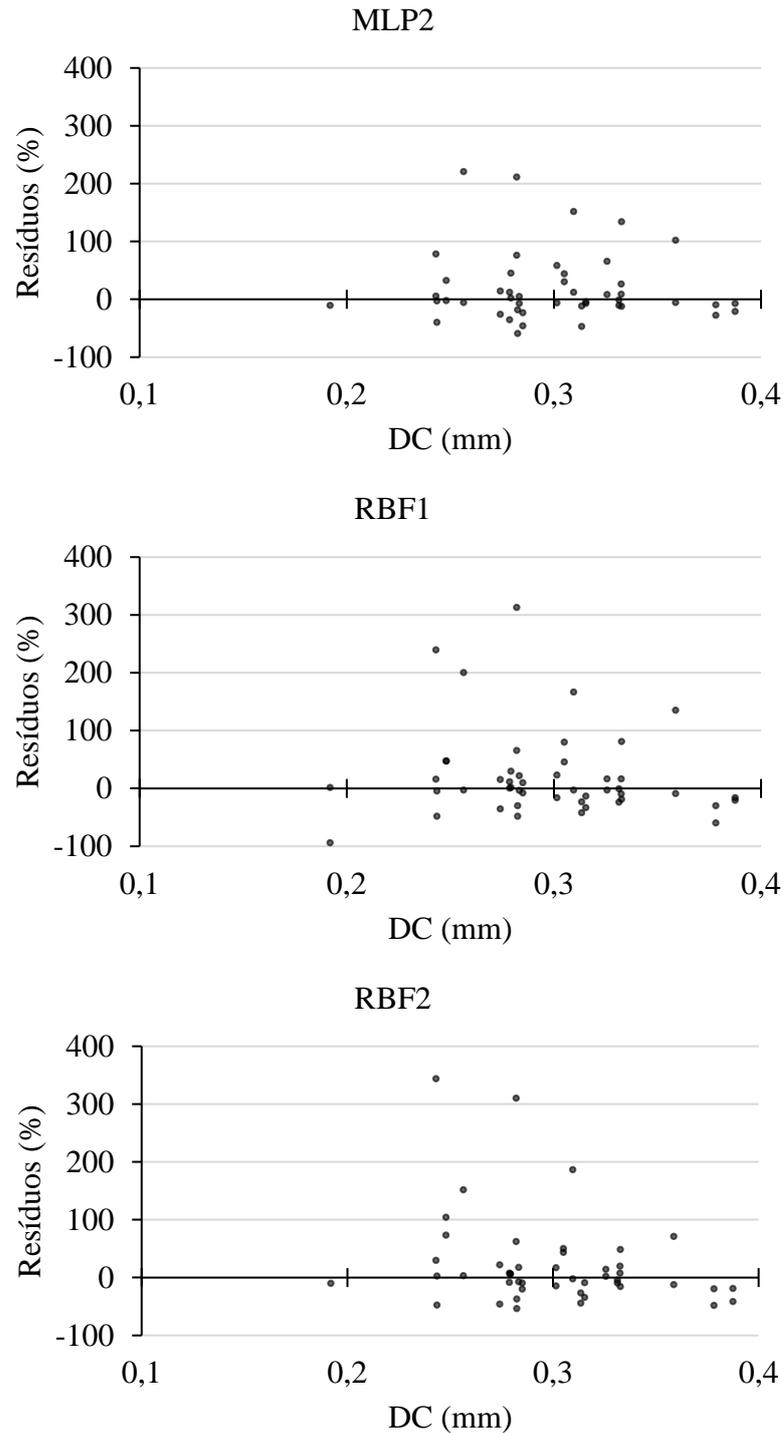


Figura 1 - Representação da distribuição dos erros percentuais em função do diâmetro à altura do coleto (DC) para as Redes Neurais Artificiais (RNA) construídas para estimar simultaneamente o volume (V , cm^3) e as massas secas de parte aérea (MSPA, g) e de raiz (MSR, g) das mudas de *S. saponaria* aos 250 dias. MLP = *Multilayer perceptron*. RBF = *Radial Basis Function*.

Os dados estimados e observados pelas redes estão apresentados na Figura 2. As redes geraram estimativas estatisticamente similares, embora uma desvantagem observada tenha sido a perda na precisão ao estimar a massa seca individual do sistema radicular das mudas de *S. saponaria*. A rede MLP2 foi um pouco mais precisa para a estimativa da massa seca de parte aérea, sendo constituída por menos neurônios na camada intermediária, reduzindo a possibilidade de *overfitting*; a fase de treinamento das redes teve menos que 200 ciclos.

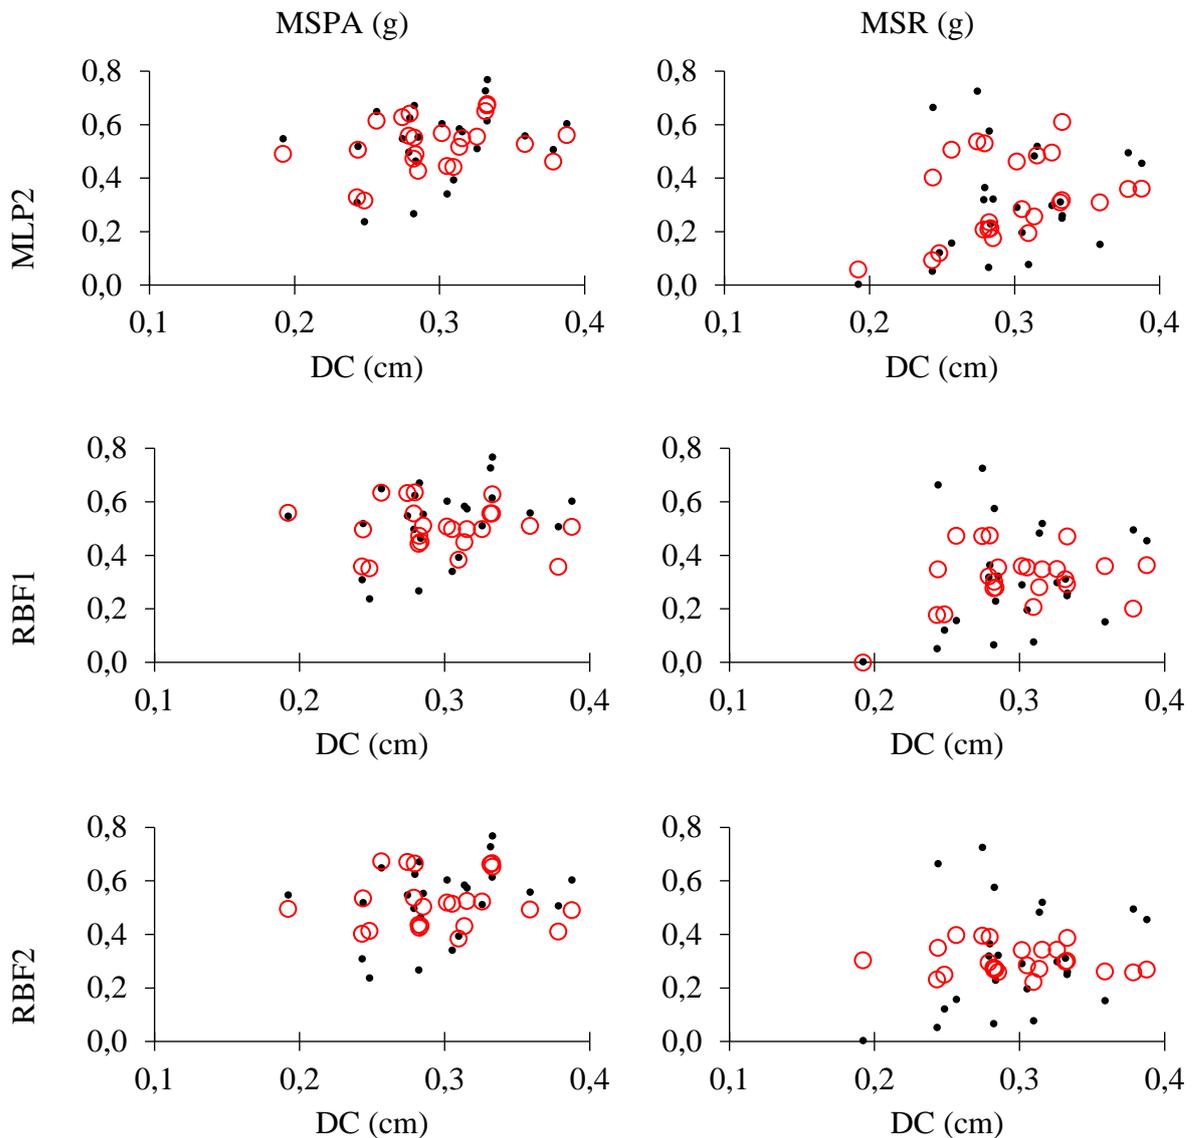


Figura 2 - Estimação simultânea das massas secas de parte aérea (MSPA, g) e de raiz (MSR, g) das mudas de *S. saponaria* aos 250 dias. RBF = *Radial Basis Function*. Pontos pretos = valores observados. Círculo vermelhos = valores estimados.

A capacidade de generalização e conectividade da arquitetura MLP permitiu que se utilizasse apenas uma rede para realizar a estimação simultânea das massas secas de parte aérea e do sistema radicular das mudas de *S. saponária* aos 250 dias. Informações sobre a biomassa de mudas são essenciais para melhor planejamento no balanço nutricional e logístico para a propagação vegetal (NOVAIS et al., 2007).

Ressalta-se que métodos tradicionais estatísticos implicariam em realizar análise de regressão para cada atributo estimado. Os resultados obtidos fornecem subsídios importantes para o desenvolvimento de futuras pesquisas que contemplem a modelagem biométrica vegetal, sobretudo, em viveiro florestal destinado a produção de mudas de espécies nativas ou exóticas aplicando inteligência artificial.

5 CONCLUSÕES

Recomenda-se o tubete de 53 cm³ para a propagação seminal de *S. saponaria* em casa de sombra até os 250 dias.

A escarificação mecânica do tegumento das sementes com esmeril elétrico é recomendada para maximizar a homogeneidade e velocidade da germinação de *S. saponaria* por viveiristas.

A interação entre volume de tubetes e tratamentos pré-germinativos para a *S. saponaria* foi verificada apenas para o atributo germinação.

Recomenda-se a arquitetura MLP de RNA para estimar de forma simultânea as massas secas de parte aérea e do sistema radicular de mudas de *S. saponaria*.

REFERÊNCIAS

- ABREU, A. H. M.; LELES, P. S. S.; MELO, L. A.; FERREIRA, D. H. A.; MONTEIRO, F. A. S. Produção de mudas e crescimento inicial em campo de *Enterolobium contortisiliquum* produzidas em diferentes recipientes. **Floresta**, v. 45, n. 1, p. 141-150, 2015.
- ALBUQUERQUE, K. S.; GUIMARÃES, R. N.; ALMEIDA, I. F.; CLEMENTE, A. C. S. Métodos para a superação da dormência em sementes de sucupira-preta. **Ciência e Agrotecnologia**, v. 31, n. 6, p. 1716-1721, 2007.
- BINOTI, M. L. M. da S.; Binoti, D. H. B.; Leite, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore** v. 37, 639-645, 2013.
- BLACKARD, J. A.; DEAN, D. J. Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. **Computers and Electronics in Agriculture**, v. 24, p. 131-151, 1999.
- BORSATO, D.; NOBREGA, M. M.; MOREIRA, M. B.; DIAS, G. H.; SILVA, R. S. S. F.; BONA, E. Aplicação de redes neurais artificiais na identificação de gasolinas adulteradas comercializadas na região de Londrina – Paraná. **Química Nova**, v. 32, n. 9, p. 2328- 2332, 2009.
- BRADSHAW, C. J. A.; DAVIS, L. S.; PURVIS, M.; ZHOU, Q.; BENWELL, G. L. Using artificial neural network to model the suitability of coastline for breeding by New Zealand furseals (*Arctocephalus forsteri*). **Ecological Modelling**, v. 148, p. 111-131, 2002.
- BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro, RJ. Editora LTC, 262 p. 2000.
- BRAGA, A. P.; CARVALHO, A. P.; LUDERMIR, T. B. **Redes neurais artificiais: Teoria e aplicações**. 2 ed. Rio de Janeiro: LTC, 2007. 226p.
- BRASIL. Regras para análise de sementes. Ministério de Agricultura, Pecuária e Abastecimento. Secretaria Nacional de Defesa Agropecuária, Brasília, DF: Mapa/ACS, 2009. 395p.
- CRUZ, F. R. da S.; ANDRADE, L. A. de; FEITOSA, R. C. Produção de Mudas de Umbuzeiro (*Spondias tuberosa* Arruda Câmara) em Diferentes Substratos e Tamanho de Recipientes. **Ciência Florestal**, Santa Maria, v. 6, n. 1, p. 69-80, jan-mar, 2016.
- DIAS, I. M.; BARRETO, I. D. de C.; FERREIRA, R. A. Efeito de Dosagens de Fertilizantes Fosfatado na Determinação de Volume Ótimo de Produção de Mudas de Espécies Florestais Nativas. **Scientia Agraria Paranaensis**, v. 15, n. 14, p. 471-475, out-dez, 2016.
- DUARTE, Marciel Lelis. Tubetes E Substratos Na Produção De Mudas De Cássia-Rosa (*Cassia Grandis* L.F) E Canafístula (*Cassia Ferruginea* (Schrad.) Schrader Ex Dc). **Locus UFV**. Viçosa, Minas Gerais, 2016.

FERNANDES, A. M.; UTKIN, A. B.; LAVROV, A. V.; VILAR, R. M. Development of neural network committee machines for automatic forest fire detection using lidar. **Pattern Recognition**, v. 37, p. 2039-2047, 2004.

FERRAZ, A. V.; ENGEL, V. L. Efeito do tamanho de tubetes na qualidade de mudas de jatobá (*Hymenaea courbarili* L. var. *stilbocarpa* (Hayne) Lee et Lang.), ipê-amarelo (*Tabebuia chrysotricha* (Mart. Ex DC.) Sandl.) e guarucaia (*Parapiptadenia rígida* (Benth.) Brenan). **Revista Árvore**, v. 35, n. 3, p. 413-423, 2011.

GARCIA, A.; RHODEN, S. A.; RUBIN FILHO, C. J.; NAKAMURA, C. V.; PAMPHILE, J. A. Diversity of foliar endophytic fungi from the medicinal plant *Sapindus saponaria* L. and their localization by scanning electron microscopy. **Biological Research**, v. 45, p. 139-148, 2012.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001. 900p.

INSTITUTO NACIONAL DE METEOROLOGIA - INMET. **Banco de Dados Meteorológicos para Ensino e Pesquisa**. Brasília. Disponível em: <<http://www.inmet.gov.br/>>. Acesso em 10 dez. 2020.

KÖPPEN, W. **Das geographische system der klimate**. Berlin: Gerbrüder Bornträger, 1936. 44p.

KUPLICH, T. M. Classifying regenerating forest stages in Amazônia using remotely sensed images and a neural network. **Forest Ecology and Management**, v. 234, p. 1-9, 2006.

LAFETÁ, B. O. **Eficiência nutricional, área foliar e produtividade de plantações de eucalipto em diferentes espaçamentos estimados com redes neurais artificiais**. 2012. 76f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina-MG, 2012.

LAFETÁ, B. O.; NASCIMENTO, L. A.; AZEVEDO, C. H. S.; PENIDO, M. A. P.; OLIVEIRA, L. F. R. Fitotoxicidade do mercúrio sobre a qualidade fisiológica em sementes de saboneira (*Sapindus saponária* L.) submetidas à escarificação mecânica. **Caderno de Ciências Agrárias**, v. 11, p. 1-6, 2019.

LAFETÁ, B. O.; SANTANA, R. C.; NOGUEIRA, G. S.; PENIDO, T. M. A.; COUTO, L. Área foliar específica e clorofila em eucalipto estimadas por redes neurais artificiais. **Biomassa e Energia**, v. 5, n. 1, p. 67-75, 2012.

LISBOA, A. C.; LELES, P. S. S.; OLIVEIRA NETO, S. N. O.; CASTRO, D. N.; ABREU, A. H. M. Efeito do volume de tubetes na produção de mudas de *Calophyllum brasiliense* e *Toona ciliata*. **Revista árvore**, Viçosa, v.36, n. 4, p.603-609, 2012.

LORENZI, H. **Árvores Brasileiras: manual de identificação e cultivo de plantas arbóreas nativas do Brasil**. Nova Odessa: Instituto Plantarum, 2009. 368 p.

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**, v. 11, p. 265-272, 2009.

MAGUIRE, J. D. Speed of germination aid in selection and evaluation for seedling and vigour. **Crop Science**, v. 2, n. 2, p. 176-177, 1962.

MARTINS, C. C.; ZUCARELI, C; COIMBRA, R. A. Procedimentos de colheita dos frutos na qualidade fisiológica de sementes de *Sapindus saponaria* Mart. **Semina**, v. 32, n. 1, p. 1825-1830, 2011.

MONJEZI, M.; BAHRAMI, A.; VARJANI, A. Y. Simultaneous prediction of fragmentation and flyrock in blasting operation using artificial neural networks. **International Journal of Rock Mechanics & Mining Sciences**, v. 47, p. 476-480, 2010.

NOVAIS, R. F.; ALVAREZ, V. H.; BARROS, N; F.; FONTES, R. L. F.; CANTARUTTI, R. B.; NEVES, J. C. L. **Fertilidade do solo**. 1 ed. Viçosa: Sociedade Brasileira de Ciência do Solo, 2007. 1017p.

OLIVEIRA, L. M.; BRUNO, R. L. A.; SILVA, K. R. G.; SILVA, V. D. M.; FERRARI, C. S.; SILVA, G. Z. Germinação e vigor de sementes de *Sapindus saponaria* L. submetidas a tratamentos pré-germinativos, temperaturas e substratos. **Ciência Rural**, v. 42, n. 4, p. 638-644, 2012.

PANDORFI, H.; SILVA, I. J. O.; SARNIGHAUSEN, V. C. R.; VIEIRA, F. M. C.; NASCIMENTO, S. T.; GUISELINI, C. Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura. **Revista Brasileira de Zootecnia**, v. 40, n. 3, p. 676-681, 2011.

PAULINO, A. F.; MEDINA, C. C.; NEVES, C. S. V. J.; AZEVEDO, M. C. B.; HIGA, A. R.; SIMON, A. Distribuição do sistema radicular de árvores de acácia-negra oriundas de mudas produzidas em diferentes recipientes. **Revista Árvore**, v. 27, n. 5, p. 605-610, 2003.

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

SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-1139, 2009.

STATSOFT, INC. Statistica (data analysis software system), version 7. Disponível em: <<http://www.statsoft.com>>, 2007.

STURION, J.A.; GRAÇA, L.R.; ANTUNES, J.B.M. Produção de mudas de espécies de rápido crescimento por pequenos produtores. Colombo: **Embrapa Florestas**, 2000.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. 5 ed. Porto Alegre: Artmed, 2013. 954p.

VALENÇA, M. **Fundamentos das redes neurais**: exemplo em java. 2º. Edição, Revisando e ampliando. Olinda, PE: Livro rápido, 2011. 386 p.