

LEONARDO PEQUENO REIS

**MODELAGEM DE FLORESTA INEQUIÂNEA: REDES NEURAIAS
ARTIFICIAIS APLICADAS EM UMA FLORESTA MANEJADA NO LESTE DA
AMAZÔNIA**

Tese apresentada à Universidade Federal
de Viçosa, como parte das exigências do
Programa de Pós-Graduação em Ciência
Florestal, para obtenção do título de
Doctor Scientiae.

VIÇOSA
MINAS GERAIS - BRASIL
2017

**Ficha catalográfica preparada pela Biblioteca Central da Universidade
Federal de Viçosa - Câmpus Viçosa**

T

R375m
2017
Reis, Leonardo Pequeno, 1984-
Modelagem de florestas inequiâneas : redes neurais
artificiais aplicadas em uma floresta manejada no leste da
Amazônia / Leonardo Pequeno Reis. – Viçosa, MG, 2017.
x, 79f. : il. ; 29 cm.

Orientador: Agostinho Lopes de Souza.
Tese (doutorado) - Universidade Federal de Viçosa.
Inclui bibliografia.

1. Florestas. 2. Florestas - Inovações tecnológicas.
3. Inteligência artificial. 4. Amazônia. I. Universidade Federal de
Viçosa. Departamento de Engenharia Florestal. Programa de
Pós-graduação em Ciência Florestal. II. Título.

CDD 22 ed. 634.9

LEONARDO PEQUENO REIS

**MODELAGEM DE FLORESTA INEQUIÂNEA: REDES NEURAIS
ARTIFICIAIS APLICADAS EM UMA FLORESTA MÃNEJADA NO LESTE DA
AMAZÔNIA**

Tese apresentada à Universidade Federal
de Viçosa, como parte das exigências do
Programa de Pós-Graduação em Ciência
Florestal, para obtenção do título de
Doctor Scientiae.

APROVADA: 02 de março de 2017



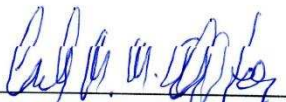
Marcio Leles Romarco de Oliveira
(UFVJM)



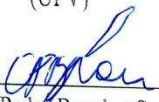
Pedro Christo Brandão
(UFV)




Helio Garcia Leite
(Coorientador)
(UFV)



Carlos Moreira Miquelino Eleteo Torres
(UFV)



Carlos Pedro Boechat Soares
(Coorientador)
(UFV)



Agostinho Lopes de Souza
(Orientador)
(UFV)

A **Deus** que me deu o dom da vida
Ao meu amor e eterna namorada **Pamella**
Reis
Eu dedico

AGRADECIMENTOS

A Deus que me abençoa todos os dias e me dá forças para seguir em frente e vencer todos os obstáculos.

À Pamella Reis minha esposa e eterna namorada, por sempre confiar e me apoiar em todos os momentos.

À minha família, meus queridos pais Ivanildo e Eliete, minha irmã Fabrícia, meus sobrinhos Lucas e Cauê que me apoiam em todos os meus projetos e sempre estiveram ao meu lado.

À Universidade Federal de Viçosa, pela oportunidade de realizar este curso de Ciência Florestal e aperfeiçoar meus conhecimentos;

À Embrapa Amazônia Oriental, pelo apoio financeiro por meio do projeto Segundo Ciclo de Corte: EMBRAPA - 03.12.00.030.00.00 e CNPq 483831/2011-5.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de pós-graduação;

Ao meu Orientador Prof. Agostinho Lopes de Souza, pela amizade e sabedoria repassada com elevada competência, o tenho com maior estima como professor, pesquisador e pessoa.

Aos coorientadores Prof. Carlos Boechat, Prof. Helio Leite e Dr. Lucas Mazzei, pela orientação, paciência e tempo dedicado a este Trabalho.

À banca de defesa Prof. Carlos Boechat, Prof. Helio Leite, Prof. Marcio Leles Romarco de Oliveira, Prof. Carlos Moreira Miquelino Eleto Torres e Dr. Pedro Christo Brandão pelas contribuições de grande ajuda para este Trabalho;

Ao pesquisador Dr. Ademir Ruschel, pela dedicação por suas considerações na produção dos artigos.

A todos os amigos da pós-graduação, pelas conversas produtivas e momentos de descontração, em especial Liniker e Lyvia.

À Coordenação da pós-graduação, em especial ao Alexandre pela eficiência e ajuda quando precisei.

"Conócete. Acetate. Supérate"

Santo Agostinho

Um indivíduo com o pensamento de um ser isolado vivendo em um mundo hostil, tenta com a sua natureza egoísta, obter vantagens em detrimentos de outros, mas quando a prisão sem trancas em que vive é retirada da sua visão, o mundo torna-se a pequena nave sustentada por aqueles que acreditam que iram terminar essa jornada, deixando para trás a esperança da vida eterna.

RESUMO

REIS, Leonardo Pequeno, D.Sc., Universidade Federal de Viçosa, março de 2017. **Modelagem de floresta inequiânea: redes neurais artificiais aplicadas em uma floresta manejada no leste da Amazônia.** Orientador: Agostinho Lopes de Souza. Coorientadores: Carlos Pedro Boechat Soares e Helio Garcia Leite

O manejo florestal praticado na Amazônia não considera a modelagem de florestas tropicais como subsídio técnico e econômico nas decisões silviculturais. A problemática em relação a esse fato é a possível superexploração de poucas espécies que compõem a maior parte da intensidade de corte, quando os planos de manejo florestal não estimam a recuperação da floresta ao longo do tempo. Assim, as decisões sobre a intensidade e o ciclo de corte adequado não apresentam fundamentos baseados na dinâmica florestal. Isso poderia ser contornado por meio do emprego de modelos de crescimento e produção apropriados para a prognose dos estoques futuros, utilizando a dinâmica florestal como base na parametrização. Esses modelos também podem ser usados para avaliar a dinâmica florestal e perturbações naturais. Por tanto, novas técnicas de modelagem em florestas tropicais são necessárias para garantir a sustentabilidade dessa atividade. Nesse cenário, o objetivo foi modelar uma floresta colhida seletivamente, há mais de 30 anos, utilizando Redes Neurais Artificiais (RNA), para subsidiar decisões silviculturais sobre o manejo florestal na Amazônia. Para atender a esse objetivo, a tese foi dividida em quatro artigos. Em todas as modelagens foram utilizados os dados do campo experimental localizado na Floresta Nacional do Tapajós, à altura do Km 67 (55° 00' W, 2° 45' S) da Rodovia BR-163, Cuiabá-Santarém, no município de Belterra, estado do Pará, Brasil. Predomina na área o bioma Amazônia e a tipologia Floresta Ombrófila Densa de terra firme. Em 1979, foi realizada a colheita seletiva com intensidade de $72,5 \text{ m}^3 \text{ ha}^{-1}$, em uma área de 64 ha. Em 1981, foram instaladas aleatoriamente e inventariadas 36 parcelas permanentes (50 m x 50 m). Nove medições sucessivas foram realizadas na área, em 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 e 2012. Para avaliar a modelagem foram utilizadas as estatísticas de correlação ($r_{Y\hat{Y}}$), raiz quadrada do erro quadrático médio (RQEQM) e o coeficiente Kappa (usado para avaliar a saída categórica de mortalidade e sobrevivência). Também foi analisada a dispersão dos erros percentuais (Erro %). No primeiro artigo o objetivo foi estimar o recrutamento após a colheita de madeira, empregando redes neurais artificiais. A modelagem do recrutamento com RNA seguiu a tendência dos dados observados ao longo dos 31 anos, sendo obtido com a melhor rede um RQEQM de 35,6%

e $r_{Y\hat{Y}}$ de 0,89. No segundo artigo o objetivo foi modelar o crescimento das árvores individuais em uma floresta manejada na Amazônia, utilizando redes neurais artificiais. Todas as RNA, com índice de competição semi-independentes da distância e sem índice, apresentaram correlação acima de 99% e RQEQM menor que 11%. A modelagem do crescimento com RNA pode ser usada com precisão para auxiliar no manejo de florestas tropicais por seguir a tendência dos dados observados. No terceiro artigo o objetivo foi estimar a sobrevivência e a mortalidade de árvores individuais em floresta colhida seletivamente, utilizando redes neurais artificiais. O coeficiente Kappa geral ficou abaixo de 8% em todas as RNA (classificação “pobre”), mas todas as redes ficaram acima de 55% na classificação da sobrevivência (classificação “boa”). A RNA estimou com maior precisão a sobrevivência individual de árvores, mas isso não ocorreu com a mortalidade, que é um evento mais raro que a sobrevivência. No quarto artigo o objetivo foi empregar autômatos celulares com regra de evolução em redes neurais artificiais, para projetar a distribuição diamétrica. Todas as RNA apresentaram a correlação acima de 99% e RQEQM abaixo de 17%. A projeção em todos os períodos analisados não apresentou diferença estatística a 5% de significância em relação à observada, demonstrando que a projeção seguiu a tendência da dinâmica da distribuição diamétrica. A modelagem utilizando redes neurais artificiais para prognosticar o recrutamento, o crescimento, a sobrevivência e a distribuição diamétrica de floresta tropical colhida seletivamente seguiu a tendência dos dados observados, com elevada precisão no recrutamento, no crescimento individual de árvores, na sobrevivência e na distribuição diamétrica, e pode ser utilizada para subsidiar as decisões silviculturais no manejo florestal sustentável na Amazônia.

ABSTRACT

REIS, Leonardo Pequeno, D.Sc., Universidade Federal de Viçosa, March, 2017. **Modeling of uneven-aged forest: artificial neural networks applied in a forest managed in the east of the Amazon.** Adviser: Agostinho Lopes de Souza. Co-adviser: Carlos Pedro Boechat Soares and Helio Garcia Leite.

Forest management practiced in the Amazon rain forest does not consider the modeling of tropical forests as a technical and economic support in silvicultural decisions. The problem in this regard is the possible overexploitation of few species that compose a greater part of the cut intensity, when sustainable forest management plans do not estimate the forest recovery over time. Thus, decisions on intensity and the appropriate cutting cycle do not present grounds based on forest dynamics. This could be overcome by using suitable models that predict future inventories using forest dynamics as the basis for parameterization. Such models can also be used not only for modeling, for the purpose of forest harvesting, but for assessing forest dynamics and natural disturbances. Therefore, new modeling techniques in tropical forests are necessary to guarantee the sustainability of this activity. In this scenario, the thesis aims to model a forest selectively harvested over 30 years using Artificial Neural Networks (ANN) to support silvicultural decisions on forest management in the Amazon rain forest. To meet this goal, the thesis was divided into four articles. In all the modelings were used the experimental field data located in Floresta Nacional do Tapajós (Tapajós National Forest), at Km 67 (55° 00' W, 2° 45' S) of the road Rodovia BR-163, Cuiabá-Santarém, in the municipality of Belterra, state of Pará, Brazil. The Amazon biome and the typology Dense Ombrophilous Forest of solid ground predominate in the area. In 1979 a selective harvest was carried out, with an intensity of 72.5 m³ ha⁻¹ in an area of 64 ha. In 1981, 36 (50 m x 50 m) permanent plots were installed at random and inventoried. Nine successive measurements were carried out in the area in 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010, and 2012. To evaluate the modeling were used the correlation statistics ($r_{Y\hat{Y}}$), root-mean-square error (RMSE), model efficiency coefficient (EM), and the Kappa coefficient (used to evaluate the categorical output of mortality and survival). Also analyzed was the dispersion of percentage errors (Error %). The first article aimed to estimate the recruitment after the harvest of wood using an Artificial Neural Network model. The modeling of recruitment with ANN followed the trend of the data observed over the 31 years, obtaining with the best ANN RMSD of 35.6% and of 0.89. The objective of the second article was to model

the growth of individual trees in a forest managed in the Amazon using Artificial Neural Networks. All ANN with a semi-distance-independent competition index and without index presented a correlation above 99% and RMSD lower than 11%. ANN growth modeling can be efficiently used to aid in the management of tropical forests by following the trend of data observed and presenting high accuracy. The third article aimed to estimate the survival and mortality of individual trees in a selectively harvested forest using Artificial Neural Networks. The overall Kappa coefficient was below 8% for all ANNs (ranked “poor”) but all ANNs were above 55% in the survival classification (ranked “good”). ANN estimates the individual survival of trees more accurately but this does not occur with mortality, which is a rarer event than survival. The article chapter aimed to use cellular automata with evolution rule in Artificial Neural Networks to design diametric distribution. All ANN showed a correlation above 99% and RMSD below 17%. The projection in all the periods analyzed did not show statistical difference at 5% of significance in relation to the one observed, demonstrating that the projection followed the trend of the diametric distribution dynamics. Modeling using Artificial Neural Networks to predict recruitment, growth, survival, and diameter distribution of selectively harvested tropical forest followed the trend of data observed, with high precision in individual tree growth and diameter distribution, and can be used to support silvicultural decisions in sustainable forest management in the Amazon rain forest.

SUMÁRIO

1. INTRODUÇÃO GERAL.....	1
2. OBJETIVO GERAL	5
3. REFERÊNCIAS BIBLIOGRÁFICAS.....	6
ARTIGO I.....	8
MODELAGEM DO RECRUTAMENTO DE ÁRVORES POR REDES NEURAIAS ARTIFICIAIS APÓS A COLHEITA DE MADEIRAS EM FLORESTA NO LESTE DA AMAZÔNIA.....	8
1. Introdução	9
2. Material e métodos.....	10
2.1. Área de estudo.....	10
2.2. Variáveis e dados usados no treinamento e teste das redes neurais	11
2.3. Treinamento e avaliação das RNA.....	12
3. Resultados	14
4. Discussão	18
5. Conclusões	20
Referências bibliográficas.....	21
ARTIGO II.....	24
PROGNOSE DO DIÂMETRO DE ÁRVORES INDIVIDUAIS NO LESTE DA AMAZÔNIA UTILIZANDO REDES NEURAIAS ARTIFICIAIS ¹	24
1. Introdução	25
2. Material e Métodos	26
2.1. Área de estudo.....	26
2.2. Variáveis e dados usados no treinamento e teste das redes neurais	27
2.3. Treinamento e avaliação das RNA.....	30
3. Resultados	32
4. Discussão	35
5. Conclusões	37
Referências bibliográficas.....	38
ARTIGO III	43
REDES NEURAIAS ARTIFICIAIS PARA ESTIMAR A MORTALIDADE E SOBREVIVÊNCIA DE ÁRVORES INDIVIDUAIS APÓS A COLHEITA DE MADEIRA NA AMAZÔNIA.....	43
1. Introdução	44
2. Material e métodos.....	46
2.1. Área de estudo.....	46
2.2. Variáveis e dados usados no treinamento e teste das redes neurais	46

2.3. Treinamento e avaliação das RNA.....	50
3. Resultados.....	52
4. Discussão	56
5. Conclusões	59
Referências bibliográficas.....	59
ARTIGO IV	63
PROGNOSE DA DISTRIBUIÇÃO DE DIÂMETROS NO LESTE DA AMAZÔNIA UTILIZANDO REDES NEURAIIS ARTIFICIAIS	63
1. Introdução	64
2. Material e métodos.....	66
2.1. Área de estudo.....	66
2.2. Autômato celular e Redes Neurais Artificiais.....	66
3. Resultados e Discussão	69
4. Conclusões	74
Referências bibliográficas.....	74
CONCLUSÃO GERAL.....	79

1. INTRODUÇÃO GERAL

O manejo florestal sustentável (MFS) praticado atualmente na Amazônia, que utiliza a exploração de impacto reduzido, pode garantir a produção madeireira de forma sustentável econômica, ecológica e social, se for executado como especificado nas normas vigentes. Essa sustentabilidade vem explicitada na Lei nº 11.284/2006 (BRASIL, 2006), que conceitua o manejo florestal como a administração da floresta para a obtenção de benefícios econômicos, sociais e ambientais, respeitando-se os mecanismos de sustentação do ecossistema.

De acordo com os princípios e critérios do FSC (Forest Stewardship Council) e as diretrizes do ITTO (International Tropical Timber Organization), um dos pré-requisitos do MFS é colher produtos florestais sem exceder a taxa de regeneração da floresta, isso significa calcular e implementar uma produção sustentada para colheita florestal (HIGMAN et al., 2015). Braz et al. (2012) enfatizaram que o conceito de manejo de florestas não estará completo, em qualquer plano de manejo, se não contiver uma previsão razoável de quanto a floresta pode recuperar dentro de um intervalo de tempo. Por isso, modelos de crescimento e produção são importantes, como um guia de corte nos planos de manejos florestais sustentáveis (PMFS).

Para garantir sustentabilidade, o manejador deve utilizar um sistema silvicultural apropriado aos recursos naturais existentes e que considera as taxas de crescimento, recrutamento e mortalidade. Portanto, é importante a construção de modelos de crescimento e produção, baseados na dinâmica florestal para indicar a intensidade de corte (IC) e ciclo de corte (CC), dependendo do crescimento das espécies florestais. Sendo esse um dos maiores desafios para o manejo florestal praticado na Amazônia.

Por isso, modelos de simulação que descrevem a dinâmica florestal tanto de áreas manejadas ou não, são imprescindíveis para se prescrever intensidades de colheita e ciclos de corte adequados para cada localidade ou região. Esses modelos podem prever a produção futura da floresta, e com isso pode-se observar a resposta da comunidade florestal em relação a determinadas opções silviculturais (ALDER e SILVA, 2001).

Modelos são simplificações da realidade que retratam o conhecimento atual em uma dada área do conhecimento. A modelagem de crescimento e produção florestal abrange desde modelos estatísticos simples de povoamento, pela relação do diâmetro ou altura média com a idade do povoamento, até modelos que utilizam as distâncias entre árvores, índices de sítio e área basal do povoamento para empiricamente simular a competição entre árvores por água, luz e nutrientes (VANCLAY, 1994).

Os modelos de crescimento e produção podem ser classificados como: de povoamento total, de árvores individuais e de distribuição diamétrica, cada um é empregado de acordo com o nível de detalhe desejado (CAMPOS e LEITE, 2013).

No modelo de povoamento total, que geralmente é empregado em floresta equiânea, a prognose fundamenta-se em variáveis do povoamento, como idade (I), altura dominante (Hdom.), índice de sítio (S), diâmetro médio (q) e em produções como o número de árvores (N - árvores ha⁻¹), a área basal (G - m² ha⁻¹), o volume (V - m³ h⁻¹) e a biomassa (B - t ha⁻¹). Tendo pouca utilização em florestas inequiâneas, por não explicarem diretamente a variação do tamanho das árvores dentro do povoamento (CAMPOS e LEITE, 2013) e se apoiarem em variáveis de difícil acesso em povoamentos florestais inequiâneas, tais como idade e índice de sítio (SANQUETTA et al., 1996).

Já os modelos de distribuição diamétrica, estimam a densidade (árvores ha⁻¹) por classe de diâmetro nas idades presentes e futuras. Fundamentam-se em funções de densidade de probabilidade (fdp), como a função Weibull e matrizes de probabilidade (transição). A Cadeia de Markov é uma matriz de transição muito empregada em florestas inequiâneas nas pesquisas, obtendo resultados que seguem a tendência inicial da estrutura diamétrica (BUONGIORNO e MICHE, 1980; HIGUCHI, 1987; AZEVEDO et al., 1994; SANQUETTA et al., 1996; PULZ et al., 1999; TEIXEIRA et al., 2007; VASCONCELOS et al., 2009), isso por considerar o ingresso, a mortalidade e a passagem de árvores entre as classes diamétricas. Apesar de não considerar as mudanças de ingresso e mortalidade ao longo do tempo, fica limitado a pequenos períodos de projeção.

O modelo de árvore individual apresenta resultados mais precisos para simular florestas inequiâneas, nesse modelo a árvore é a unidade básica de modelagem usada para simular crescimento e a mortalidade, considerando algum nível de competição (índice de competição), com isso aproxima-se mais da complexidade do ecossistema de florestas inequiâneas, além de ser sensível a intervenções antrópicas.

Vanclay (1994) distingue dois tipos de modelos de árvores individuais: os que são espacialmente explícitos, que se utilizam da localização espacial da árvore para a modelagem; e os não espacialmente explícitos que se utilizam da localização na parcela que a árvore está. O primeiro modelo pode utilizar índices de competição (IC) dependentes da distância e semi-independentes da distância. Já o segundo, somente o índice de competição independentes da distância.

Apesar dessa importância, existem poucos modelos para florestas tropicais amazônicas, destacando-se o CAFOGROM, um modelo cohort (ALDER e SILVA, 2001), e o SYMFOR

como um modelo de árvore individual (PHILLIPS e van GARDINGEN, 2001 a, b). O CAFOGROM se baseia em funções empíricas para projetar o desenvolvimento de grupos de árvores (cohorts) de vários tamanhos, organizados em grupos de espécies, e considera os processos de crescimento em diâmetro, mortalidade e ingressos. Estes grupos são também diferenciados em árvores sadias (não-danificadas) e danificadas, e em árvores do dossel superior e do sub-bosque (ALDER, 1995).

Estes modelos não são espacialmente explícitos e não consideram as mudanças de crescimento causada pelo manejo. Eles podem fazer previsões da produção, mas terão pouca sensibilidade aos detalhes de alternativas silviculturais ou estratégias de manejo, particularmente, em termos de níveis de danos da colheita, estruturas espaciais criadas na floresta e mudanças na composição de espécies (AZEVEDO et al., 2008).

O SYMFOR é mais sensível aos efeitos do manejo no crescimento e no rendimento futuro de florestas tropicais. A estrutura do SYMFOR é composta de modelos de processos naturais (ecológicos) e de manejo florestal (silviculturais). A finalidade do modelo é simular a maneira como as árvores individuais entram no povoamento (recrutamento), crescem e saem do povoamento (mortalidade). Sendo um modelo indicado para prever os futuros rendimentos em florestas tropicais.

Muito embora o monitoramento de florestas exploradas na Amazônia brasileira já vem sendo realizado há mais de três décadas, um olhar mais detalhado sobre a recuperação de espécies, alvo do manejo ainda é incipiente, junto com a modelagem em nível de árvore individual e distribuição diamétrica aplicando novas técnicas.

Os modelos testados em nível de árvore individual para o manejo de florestas nativas não apresentam estimativas adequadas ao longo do tempo. Principalmente pela característica estocástica das variáveis mortalidade e recrutamento, que se diferenciam entre as espécies que compõem a comunidade florestal.

Uma alternativa na prognose da comunidade florestal por povoamento total, árvores individuais e distribuição diamétrica é o uso das Redes Neurais Artificiais (RNA). As redes são modelos computacionais inspirados no sistema nervoso dos seres vivos, que formam um conjunto de unidades de processamento paralelo, caracterizadas por neurônios artificiais interligados por um grande número de interconexões (SILVA et al., 2010). Isso torna a RNA uma ferramenta adequada para a prognose de florestas manejadas pelas suas propriedades e capacidades inerentes como: não-linearidade, capacidade de aprendizagem (supervisionado ou não supervisionado), habilidades de generalização, adaptabilidade e organização de dados (HAYKIN, 2001; SILVA et al., 2010).

Para atender o objetivo de modelar uma floresta colhida seletivamente utilizando redes neurais artificiais, a tese foi organizada em quatro artigos:

Artigo I: Modelagem do recrutamento de árvores por redes neurais artificiais após a colheita de madeiras em floresta no leste da Amazônia

Artigo II: Prognose do diâmetro de árvores individuais no leste da Amazônia utilizando redes neurais artificiais

Artigo III: Redes neurais artificiais para estimar a mortalidade e sobrevivência de árvores individuais após a colheita de madeira na Amazônia.

Artigo IV: Prognose da distribuição diamétrica no leste da Amazônia utilizando redes neurais artificiais.

2. OBJETIVO GERAL

Modelar o recrutamento, o crescimento, a sobrevivência, a mortalidade e a distribuição diamétrica em uma floresta colhida seletivamente, há mais de 30 anos, utilizando Redes Neurais Artificiais, para subsidiar decisões silviculturais sobre o manejo florestal na Amazônia.

3. REFERÊNCIAS BIBLIOGRÁFICAS

ALDER, D. **Growth modelling for mixed tropical forests**. Oxford Forestry Institute Tropical Forestry Paper 30, 231 pp. 1995.

ALDER, D.; SILVA, J.N.M. Sustentabilidade da produção volumétrica: Um estudo de caso na Floresta Nacional do Tapajós com o auxílio do modelo de crescimento CAFOGROM. In: SILVA, J.N.M; SILVA, S.M.A. da; YARED, J.A.G. **A silvicultura na Amazônia Oriental: contribuições do projeto Embrapa/DFID**. Belém: Embrapa Amazônia Oriental. p. 459. 2001.

AZEVEDO, C. P., SOUZA, A. L., CAMPOS, J. C. C., PAULA-JUNIOR, G. G. D. Predição da distribuição diamétrica da floresta atlântica pelo emprego da matriz de transição. **Revista Árvore**, Viçosa, v.18, n.3, p.179-193, 1994.

AZEVEDO, C. P.; SANQUETTA, C. R.; SILVA, J. N. M.; MACHADO, S. A. Efeito de diferentes níveis de exploração e de tratamentos silviculturais sobre a dinâmica da floresta remanescente. **Floresta**, Curitiba, v. 38, p. 277-293, 2008.

BRASIL. LEI Nº 11.284, DE 2 DE MARÇO DE 2006. Dispõe sobre a gestão de florestas públicas para a produção sustentável; institui, na estrutura do Ministério do Meio Ambiente, o Serviço Florestal Brasileiro - SFB; cria o Fundo Nacional de Desenvolvimento Florestal – FNDP. **Diário Oficial da União**, Brasília, 02 de março de 2006

BRAZ, E. M. ; SCHNEIDER, P. R. ; MATTOS, P. P. ; SELLE, G.L. ; THAINES, F.; RIBAS, L. A. ; VUADEN, E. . Taxa de corte sustentável para manejo das florestas tropicais. **Ciência Florestal**, Santa Maria, v. 22, p. 137-145, 2012.

BUONGIORNO, J.; MICHIE, B. R. A matrix model of uneven-aged forest management. **Forest Science**, Bethesda, v.26, n.4, p.609-625, 1980.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. Viçosa: Ed. UFV, 2013. 605 p.

HAYKIN, S. **Redes neurais: princípios e práticas**. Porto Alegre: Bookman, 2001. 900 p.

HIGMAN, S.; MAYERS, J.; BASS, S.; JUDD, N.; NUSSBAUM, R. **Manual do manejo florestal sustentável**. Trad.: NARDELLI, A. M. B. Ed.: UFV, 2015. 398 p.

HIGUCHI, N. **Short-term growth of na undisturbed tropical moist Forest in the Brazilian Amazon**. Michigan: Michigan State University, 1987. 129p. (Thesis-PhD).

PHILLIPS, P.D.; VAN GARDINGEN, P.R. **The SYMFOR framework for individual-based spatial ecological and silvicultural forest models**. SYMFOR technical notes Series no. 8, the university of edinburgh. 22 p. 2001a.

PHILLIPS, P.D.; van GARDINGEN, P.R. **The SYMFOR Framework for Modelling the effects of Silviculture on the Growth and Yield of tropical Forests**. In: The proceedings of IUFRO 4.11 Conference: Forest Biometry, Modelling and information Science, university of Greenwich, 25-29 June 2001. 12 p. 2001b.

PULZ, F. A.; SCOLFORO, J. R. S.; MELLO, J. M.; OLIVEIRA, A. D.; OLIVEIRA FILHO, A. T. Acuracidade da predição da distribuição diamétrica de uma floresta inequiânea com a matriz de transição. **Cerne**, Lavras, v. 5, n.1, p. 1-14, 1999.

SANQUETTA, C. R.; BRENA, D. A.; ANGELO, H.; MENDES, J. B. Matriz de Transição para Simulação da Dinâmica de Florestas Naturais sob Diferentes Intensidades de Corte. **Ciência Florestal**, Santa Maria - RS, v. 6, n.1, p. 65-78, 1996.

SILVA, I. N.; SPATTI, D. H.; FLAUZIN, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 396 p.

TEIXEIRA, L. M.; CHAMBERS, J. Q.; SILVA, A. R.; LIMA, A. J. N.; CARNEIRO, V. M. C.; SANTOS, J.; HIGUCHI, N. Projeção da dinâmica da floresta natural de terra firme, região de Manaus-AM, com o uso da Cadeia de Transição Probabilística de Markov. **Acta Amazonica**, v. 37, p. 377-384, 2007.

VANCLAY, J. K. **Modelling forest growth and yield: applications to mixed tropical forests**. Oxford: CAB International, 1994. 312 p.

VASCONCELOS, S. S. de; HIGUCHI, N.; DOLIVEIRA, M. V. N. Projeção da distribuição diamétrica de uma floresta explorada seletivamente na Amazônia Ocidental. **Acta Amazonica**, v. 31, p. 71-80, 2009.

ARTIGO I

MODELAGEM DO RECRUTAMENTO DE ÁRVORES POR REDES NEURAIS ARTIFICIAIS APÓS A COLHEITA DE MADEIRAS EM FLORESTA NO LESTE DA AMAZÔNIA

Resumo

A modelagem do recrutamento em florestais tropicais é importante para estudos de sustentabilidade do manejo florestal, por dar subsídio adequado a recuperação do estoque de madeira. O objetivo do trabalho foi estimar o recrutamento após a colheita de madeira, empregando um modelo de rede neural artificial (RNA). A área de estudo está localizada na Floresta Nacional do Tapajós (55° 00' W, 2° 45' S), Pará. Em 64 ha da área de estudo, em 1979, foi realizada colheita intensiva de 72,5 m³ ha⁻¹. Em 1981 foram instaladas, aleatoriamente, 36 parcelas permanentes de 50 m x 50 m. Essas parcelas foram mensuradas em 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 e 2012. Para modelar o recrutamento foram consideradas as variáveis da subparcela alvo e a sua vizinhança. As estimativas obtidas no treino e na generalização da RNA foram avaliadas pelas estatísticas: correlação ($r_{Y\hat{Y}}$) e raiz quadrada do erro quadrático médio (RQEQM), sendo obtido RQEQM 35,6% e $r_{Y\hat{Y}}$ 0,89. Foi possível modelar a tendência do recrutamento ao longo do tempo em florestas tropicais, após a colheita de madeira.

Palavras-Chave: Ingresso, Inteligência artificial, Manejo Florestal.

MODELING OF TREE RECRUITMENT BY ARTIFICIAL NEURAL NETWORKS AFTER WOOD HARVEST IN A FOREST IN EASTERN AMAZON

Abstract

The modeling of recruitment in tropical forests is important for studies of forest management sustainability, for giving adequate subsidies to the recovery of wood stock. The objective of the work was to estimate the recruitment after wood harvest, using a model of artificial neural network (ANN). The study area is located in the Tapajós National Forest (55° 00' W, 2° 45' S), Pará. In 64 ha of the study area, in 1979, an intensive harvest of 72.5 m³ ha⁻¹ was carried out. In 1981, 36 permanent plots of 50 m x 50 m were randomly installed. These plots were measured in 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 and 2012. To model the recruitment the variables of target subplot and its neighborhood were considered. The estimates obtained in the training and generalization of ANN were evaluated by statistics: correlation

($r_{Y\hat{Y}}$) and root mean square error (RMSE) being obtained RMSE 35.6% and $r_{Y\hat{Y}}$ 0.89. It was possible to model the recruitment tendency over the time in tropical forests, after the wood harvest.

Keywords: Ingrowth, Artificial intelligence, Forest management.

1. Introdução

Na atividade do manejo florestal, a análise da regeneração das espécies após a colheita é importante para formular técnicas que subsidiem boas práticas. A avaliação do recrutamento das espécies da comunidade alvo, principalmente das que são colhidas, pode ser um bom indicativo de sustentabilidade. Esse recrutamento é o futuro das próximas colheitas, portanto, a regeneração econômica florestal, após a colheita, depende do estabelecimento da regeneração natural das espécies comerciais (REIS *et al.*, 2014).

O recrutamento ou ingresso é o processo pelo qual, considerando um diâmetro mínimo de inclusão, as árvores não mensuradas numa ocasião presente são incluídas nas medições feitas em anos subsequentes (ROSSI *et al.*, 2007). Modelar e estimar o recrutamento para as futuras colheitas é importante na prescrição da intensidade de corte e no tamanho do ciclo de corte, praticado por grupo de espécie ou por espécie, considerando que esse recrutamento é muito variado por espécie e ao longo do tempo. Desconsiderar o recrutamento pode resultar em previsão tendenciosa de crescimento da floresta e seu rendimento futuro (ZHANG *et al.*, 2012).

A modelagem do recrutamento pode ser feita empregando modelos estáticos ou dinâmicos (VANCLAY, 1994). A abordagem estática não considera muitos detalhes sobre as condições da comunidade na sua construção e prediz uma quantidade constante de recrutamento ao longo do tempo. Além disso, é menos sensível aos efeitos ou impactos da colheita e são empregados em projeção de tabela de povoamentos e em métodos matriciais (ROSSI *et al.*, 2007). Já os modelos dinâmicos, são mais abrangentes, usando mais variáveis do povoamento, como a densidade, composição florística, crescimento, podendo usar variáveis vinculadas à intensidade de colheita.

Uma alternativa para a modelagem do recrutamento é o uso das redes neurais artificiais (RNA). As aplicações desta técnica de inteligência computacional na área florestal têm ganhado alta relevância por apresentar resultados de sucesso, como: modelagem da distribuição diamétrica (DIAMANTOPOULOU *et al.*, 2015), otimização de índice de competição (RICHARDS *et al.*, 2008), estimação do volume de árvores (BINOTI *et al.*, 2009; BINOTI *et al.*, 2014), predição de incêndios florestais na Amazônia (MAEDA *et al.*, 2009), classificação de estágios sucessionais na Amazônia (KUPLICH, 2009), estimação da altura de árvores

(DIAMANTOPOULOU, 2012), modelagem da mortalidade de árvore individual em floresta ineqüânea (CASTRO *et al.*, 2015) e prognose da produção de povoamento equiâneo (BINOTI *et al.*, 2015).

Sendo o recrutamento de difícil modelagem, por causa do tamanho das parcelas, intervalo de tempo entre os inventários, tamanho mínimo de inclusão, variabilidade de regeneração e da grande diversidade de espécies (ROSSI *et al.*, 2007), a hipótese é que haverá ganhos consideráveis na prognose com uso das RNA, pelas suas propriedades e capacidades inerentes como: não-linearidade, capacidade de aprendizagem (supervisionado ou não supervisionado), habilidades de generalização, adaptabilidade e organização de dados (HAYKIN, 2001; SILVA *et al.*, 2010).

O objetivo do trabalho foi modelar o recrutamento de espécies após a colheita de madeiras na Floresta Nacional do Tapajós utilizando redes neurais artificiais para subsidiar decisões silviculturais no manejo de florestas nativas.

2. Material e métodos

2.1. Área de estudo

A área de estudo está localizada na Floresta Nacional do Tapajós, à altura do Km 67 (55° 00' W, 2° 45' S) da Rodovia BR-163, Cuiabá-Santarém. Insere-se no bioma Amazônia e a tipologia é Floresta Ombrófila Densa de terra firme que é classificada como floresta alta sem babaçu (*Orbignya barbosiana* Burret). O clima da região é tropical úmido com temperatura média anual de 25 °C e é classificado como Ami pelo sistema de Köppen (CARVALHO, 1980; REIS *et al.*, 2010). A umidade relativa média é de 86% e a precipitação média anual é de 2.100 mm. Apresenta topografia plana a ondulada, com ocorrência de solo tipo Latossolo Amarelo Distrófico (COSTA FILHO *et al.*, 1980).

Na Floresta Nacional do Tapajós e particularmente na área de estudo, Costa Filho *et al.* (1980) mencionam a colheita de quatro espécies de alto valor comercial: pau-rosa (*Aniba roseodora* Ducke), maçaranduba (*Manilkara huberi* (Ducke) A. Chev.), freijó (*Cordia goeldiana* Huber) e cedro (*Cedrela odorata* L.) na década de 1940.

Em 64 ha da área de estudo, em 1975, foi realizado um inventário a 100% de intensidade das espécies madeireiras com DAP \geq 15 cm e, posteriormente, em 1979, realizada uma colheita intensiva de 64 espécies madeireiras, as quais acumularam em média um volume colhido de 72,5 m³ ha⁻¹ (COSTA FILHO *et al.*, 1980).

As espécies que se destacaram em volume colhido foram: *Hymenaea courbaril* L., *Carapa guianensis* Aubl., *Manilkara huberi*, *Lecythis lurida* (Miers) S. A. Mori., *Bertholletia*

excelsa Humb. & Bonpl., *Astronium lecointei* Ducke, *Goupia glabra* Aubl., *Virola michelii* Heckel, *Erismia uncinatum* Warm. e *Terminalia amazonia* (J. F. Gmel) Exell, que juntas representaram 47,4% do volume total extraído (COSTA FILHO *et al.*, 1980; REIS *et al.*, 2010). A colheita foi executada sob dois tratamentos: corte de todas as árvores com DAP ≥ 45 cm em 39 ha; e corte das árvores com DAP ≥ 55 cm, em 25 ha (COSTA FILHO *et al.*, 1980). Entretanto, os tratamentos foram considerados conjuntamente, formando apenas uma comunidade, visto a alta similaridade constatada nas comparações realizadas (REIS *et al.*, 2010).

Em 1981 foram instaladas, aleatoriamente, 36 parcelas permanentes de 50 m x 50 m cada uma. Nessas parcelas, todas as árvores com DAP ≥ 5 cm foram identificadas botanicamente *in loco*. Ocorreram remedições nas parcelas permanentes em 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 e 2012.

2.2. Variáveis e dados usados no treinamento e teste das redes neurais

As parcelas permanentes foram divididas em dois grupos, um grupo de 29 parcelas para o treinamento das RNA e outro de 7 parcelas, para a generalização das redes treinadas, perfazendo 80% de dados para o treinamento e 20% para a generalização.

Para modelar o recrutamento foram consideradas as variáveis da própria subparcela alvo e a sua vizinhança, nessas subparcelas as variáveis de entrada usadas foram: área basal ($G - m^2 ha^{-1}$), densidade ($N - \text{árvores } ha^{-1}$), período de tempo (anos) entre as medições (P), período de tempo (anos) em relação a colheita de madeiras (PC), classe de floresta (Floresta madura – FM , Floresta em construção (FC) e clareira (C)), incremento periódico anual em diâmetro ($IPA_{dap} - mm \text{ ano}^{-1}$) e o diâmetro máximo (cm), como medida de competição.

A definição da vizinhança tem como base uma grelha bidimensional constituída a partir da subparcela alvo de 10 x 10 m, em uma parcela de 50 x 50 m (Figura 1), essa parcela dividida em 25 subparcelas. Foi considerado na modelagem as diversas variáveis contidas na zona de influência do recrutamento. Isso porque, não somente as características da subparcela alvo influenciam no recrutamento, mas também o entorno dessa subparcela em uma determinada zona de influência.

Cada subparcela alvo obteve oito subparcelas vizinhas. Para a vizinhança das subparcelas de borda foram consideradas subparcelas “invisíveis” para compor o total de oito subparcelas vizinhas. As variáveis das subparcelas “invisíveis” foram representadas como a média das subparcelas contidas na parcela.

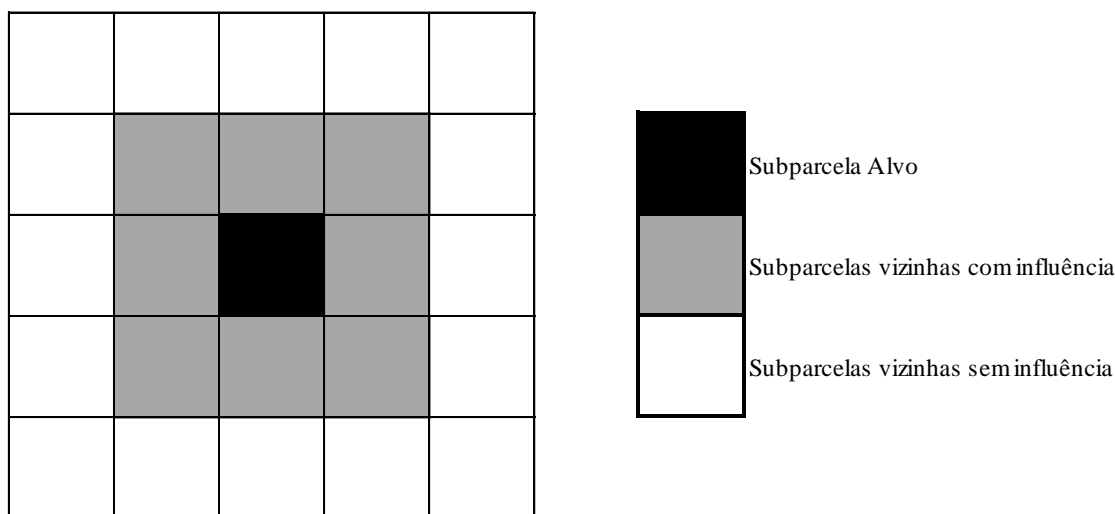


Figura 1. Representação da zona de influência da subparcela alvo da modelagem. Parcela de 50 x 50 m dividida em 25 subparcelas de 10 x 10 m.

Figure 1. Representation of the influence zone of the target subplot of modeling. Plot of 50 x 50 m divided into 25 subplots of 10 x 10 m.

As classes de floresta foram definidas conforme Silva *et al.* (2005):

1. Floresta madura: a subparcela apresenta pelo menos uma árvore com diâmetro igual ou maior que 40 cm.
2. Floresta em construção: a subparcela apresenta pelo menos uma árvore com diâmetro igual ou maior que 10 cm e menor que 40 cm.
3. Clareira: há uma abertura no dossel, de pelo menos 50% da área da subparcela, e poucas ou nenhuma árvore com diâmetro maior que 10 cm presentes na subparcela. Quando existirem, as copas se projetam para fora do limite da subparcela.

2.3. Treinamento e avaliação das RNA

O treinamento da RNA consiste na aplicação de um conjunto de passos ordenados com intuito de ajustar os pesos e os limiares de seus neurônios. Assim, tal processo de ajuste, também conhecido como algoritmo de aprendizagem, visa sintonizar a rede para que as suas respostas estejam próximas dos valores desejados (SILVA *et al.*, 2010).

Para modelar o recrutamento da comunidade total, foram treinadas 1800 RNA, 300 para cada composição de variáveis com a vizinhança e 300 RNA sem utilização da zona de vizinhança, sendo essa a RNA mais simples no processo de modelagem (Tabela 1).

Tabela 1. Variáveis utilizadas no treinamento das redes neurais artificiais (RNA) em uma floresta após colheita florestal.

Table 1. Variables used in the training of artificial neural networks (ANN) in a forest after forest harvest.

RNA	Variáveis de Entrada	Número de treinamentos	Saída
1	$G, N, P, PC, CF, IPA_{dap}, dap_{máx}, G_1, G_2, G_3, G_4, G_5, G_6, G_7, G_8, N_1, N_2, N_3, N_4, N_5, N_6, N_7, N_8, IPA_{dap1}, IPA_{dap2}, IPA_{dap3}, IPA_{dap4}, IPA_{dap5}, IPA_{dap6}, IPA_{dap7}, IPA_{dap8}, dap_{máx1}, dap_{máx2}, dap_{máx3}, dap_{máx4}, dap_{máx5}, dap_{máx6}, dap_{máx7}, dap_{máx8}$	300	NR
2	$G, N, P, PC, CF, IPA_{dap}, dap_{máx}$	300	NR
3	$G, N, P, PC, CF, IPA_{dap}, dap_{máx}, G_1, G_2, G_3, G_4, G_5, G_6, G_7, G_8$	300	NR
4	$G, N, P, PC, CF, IPA_{dap}, dap_{máx}, N_1, N_2, N_3, N_4, N_5, N_6, N_7, N_8$	300	NR
5	$G, N, P, PC, CF, IPA_{dap}, dap_{máx}, IPA_{dap1}, IPA_{dap2}, IPA_{dap3}, IPA_{dap4}, IPA_{dap5}, IPA_{dap6}, IPA_{dap7}, IPA_{dap8}$	300	NR
6	$G, N, P, PC, CF, IPA_{dap}, dap_{máx}, dap_{máx1}, dap_{máx2}, dap_{máx3}, dap_{máx4}, dap_{máx5}, dap_{máx6}, dap_{máx7}, dap_{máx8}$	300	NR
Total		1800	

G : Área basal ($m^2 ha^{-1}$); N : número de árvores ha^{-1} ; P : período em anos entre medições; PC : período em anos após a colheita; CF : classe de floresta, composta por Floresta Madura, Floresta em Construção e Clareiras (entrada categórica); IPA_{dap} : Incremento periódico anual em diâmetro ($mm ano^{-1}$); $dap_{máx}$: Diâmetro máximo encontrado na subparcela (mm); NR : número de árvores recrutadas; 1, 2, 3,...,8: Variáveis das subparcelas vizinhas.

No treinamento foi utilizada a arquitetura *feedforward* de camadas múltiplas, o Perceptron multicamadas (MLP). Foi utilizada a ferramenta *Intelligent Problem Solver* (IPS) do software Statistica 13 (STATSOFT, INC, 2016) para a escolha das funções de ativação (Identidade, Logística, Tangente hiperbólica e exponencial) da camada intermediária e de saída. No treinamento foi utilizado somente uma camada escondida e o intervalo do número de neurônios nessa camada foi definido pelo método de Fletcher-Gloss (SILVA *et al.*, 2010). O

intervalo do número de neurônios de acordo com o número de variáveis de entrada e saída é dado pela seguinte equação:

$$2 \cdot \sqrt{n} + n_2 \leq n_1 \leq 2 \cdot n + 1 \quad (1)$$

Sendo n é o número de entradas da rede, n_1 é a quantidade de neurônios na camada escondida e n_2 é a quantidade de neurônios na camada de saída.

O máximo definido pelo método foi para evitar memorização dos dados de entrada (*overfitting*) ou extrair informação insuficientemente no treinamento (*underfitting*).

Para cada treinamento foram retidas cinco redes, dessas escolheu-se uma por treinamento pela correlação entre os valores estimados e observados. Na escolha e comparação das RNA a serem usadas na prognose foram avaliadas, no treinamento e na generalização, a estatística de correlação entre os valores estimados e reais ($r_{Y\hat{Y}}$) e a raiz quadrada do erro quadrático médio (RQEQM). Também foi realizada a análise gráfica da dispersão dos erros percentuais (Erro %) em relação aos valores observados:

$$Erro \% = \frac{(\hat{Y} - Y)}{Y} \cdot 100 \quad (2)$$

Sendo, \hat{Y} : valores estimados pelas RNA; Y : valores observados nas parcelas permanentes, S^2 : variância, $Cov.$: covariância e n o número de observações, segue que:

$$r_{Y\hat{Y}} = \frac{Cov(Y, \hat{Y})}{\sqrt{S^2(Y)S^2(\hat{Y})}} \quad (3)$$

$$RQEQM = 100 \cdot \bar{Y}^{-1} \sqrt{n^{-1} \sum_{i=1}^n (Y_i - \hat{Y})^2} \quad (4)$$

3. Resultados

As variáveis de entrada que mais se correlacionaram com o recrutamento foram o período de tempo entre as medições (P) e o período de tempo após a colheita florestal (PC), ficando acima de 25% (Tabela 2). A única variável que não apresentou correlação significativa foi dap máximo da subparcela. O número de árvores ha^{-1} e a área basal (G) apresentaram correlações

negativas e o *IPA* em diâmetro correlação positiva, apesar de todas essas apresentarem correlações significativas, ficaram abaixo de 20%.

Tabela 2. Correlação linear entre as variáveis de entrada e saída usadas no treinamento e teste das RNA. *NR*: número de árvores recrutadas; *G*: Área basal ($m^2 ha^{-1}$); *N*: número de árvores ha^{-1} ; *P*: período em anos entre medições; *PC*: período em anos após a colheita; *IPA_{dap}*: Incremento periódico anual em diâmetro ($mm ano^{-1}$) e *dap_{máx}*: Diâmetro máximo encontrado na subparcela (mm).

Table 2. Linear correlation between the input and output variables used in the training and ANN testing. *NR*: number of recruited trees; *G*: basal area ($m^2 ha^{-1}$); *N*: number of trees ha^{-1} ; *P*: period in years between measurements; *PC*: period in years after harvest; *IPA_{dap}*: annual periodic increment in diameter ($mm year^{-1}$) and *dap_{máx}*: Maximum diameter found in the subplot (mm).

Variáveis	<i>NR</i>	<i>PC</i>	<i>P</i>	<i>N</i>	<i>G</i>	<i>IPA_{dap}</i>	<i>dap_{máx}</i>
<i>NR</i>	1,0000						
<i>PC</i>	0,2682*	1,0000					
<i>P</i>	0,3468*	0,8050*	1,0000				
<i>N</i>	-0,1743*	-0,0150 ^{ns}	-0,0339*	1,0000			
<i>G</i>	-0,0469*	0,1448*	0,1138*	0,2632*	1,0000		
<i>IPA_{dap}</i>	0,2008*	-0,3636*	-0,3483*	-0,1455*	-0,1257*	1,0000	
<i>dap_{máx}</i>	-0,0181 ^{ns}	0,1201*	0,0968*	0,0701*	0,8957*	-0,1056*	1,0000

* $p < 0,05$.

Todas as RNA testadas, com diferentes entradas e arquiteturas, apresentaram correlações simples acima de 80% e uma raiz quadrada do erro quadrático médio abaixo de 45% (Tabela 3). A RNA que resultou em melhor desempenho para estimar o recrutamento (RNA1, Figuras 2 e 3) foi a RNA 1 que apresentou maior correlação e menor RQEQM no teste, essa rede utilizou todas as variáveis estruturais e de dinâmica das subparcelas. A que apresentou o pior resultado foi a RNA 6, com menor correlação e maior RQEQM, essa rede utilizou o diâmetro máximo da subparcela como variável de entrada para inferir sobre a competição na subparcela.

Tabela 3. Medidas de precisão do treinamento e teste das redes neurais artificiais (RNA) na estimativa de recrutamento de árvores. $r_{Y\hat{Y}}$: Coeficiente de correlação; RQEQM: raiz quadrada do erro quadrático médio (%).

Table 3. Training precision measurements and test of artificial neural networks (ANN) in the estimation of tree recruitment. $r_{Y\hat{Y}}$: correlation coefficient; RMSE: root mean square error (%).

RNA	Indexador	Arquitetura	RQEQM (%)	$r_{Y\hat{Y}}$	RQEQM (%)	$r_{Y\hat{Y}}$	Funções de ativação	
							Camada intermediária	Camada de saída
1	2	MLP 41-61-1	34,8791	0,9027	35,6462	0,8932	Tangencial	Exponencial
2	1	MLP 9-18-1	43,1114	0,8489	38,4479	0,8723	Logística	Exponencial
3	5	MLP 17-33-1	46,6002	0,8177	38,5054	0,8732	Logística	Logística
4	5	MLP 17-32-1	41,4371	0,8621	35,9185	0,8908	Logística	Exponencial
5	3	MLP 17-28-1	38,1384	0,8825	36,0299	0,8900	Tangencial	Logística
6	3	MLP 17-35-1	43,0030	0,8493	39,0262	0,8692	Logística	Exponencial

As redes neurais artificiais treinadas podem ser obtidas através do contato com o autor pelo email: leonardoqueenoreis@gmail.com

O recrutamento estimado das RNA ajustaram-se com o recrutamento observado (Figura 2 e 3), apesar de alguns *outlier* no recrutamento, representados pelos pontos mais afastados da linha de tendência. A RNA 1 apresentou o melhor ajuste, os dados estimados e observados seguem a mesma tendência, tanto no treinamento como no teste.

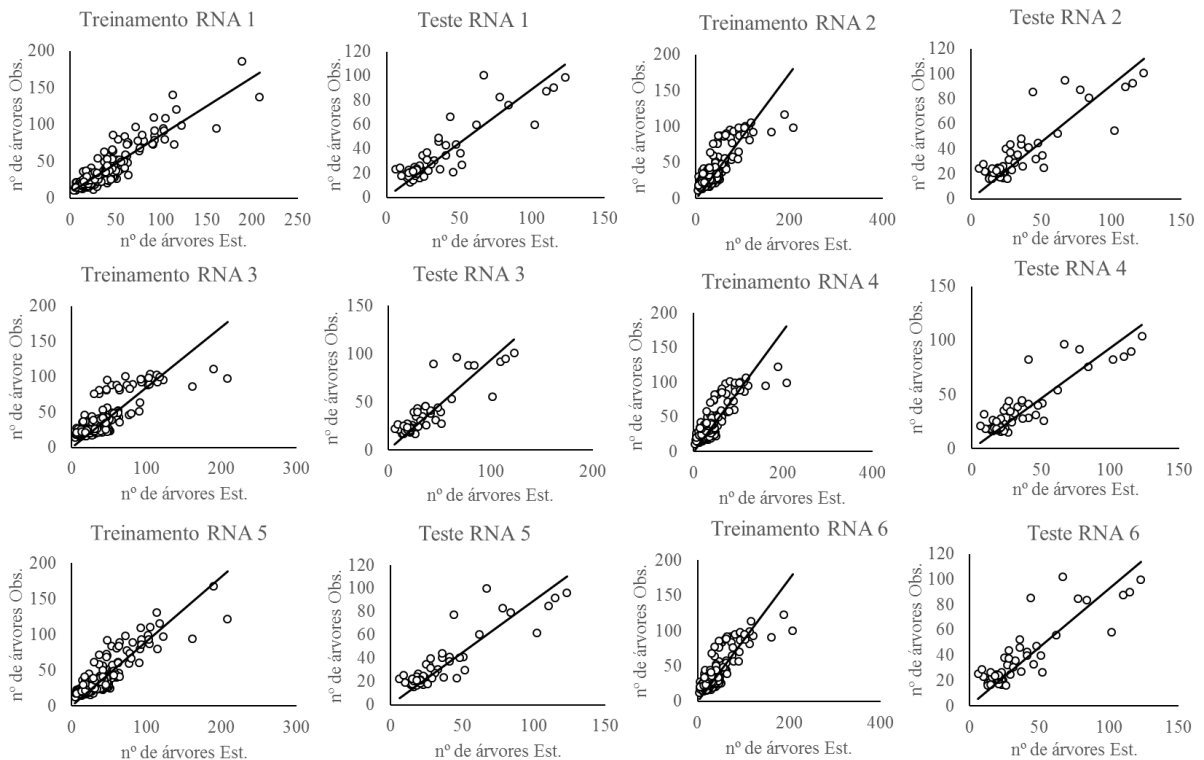


Figura 2. Estimativas de árvores recrutadas do treinamento e teste das redes neurais artificiais (RNA).

Figure 2. Estimates of training recruited trees and testing of artificial neural networks (ANN).

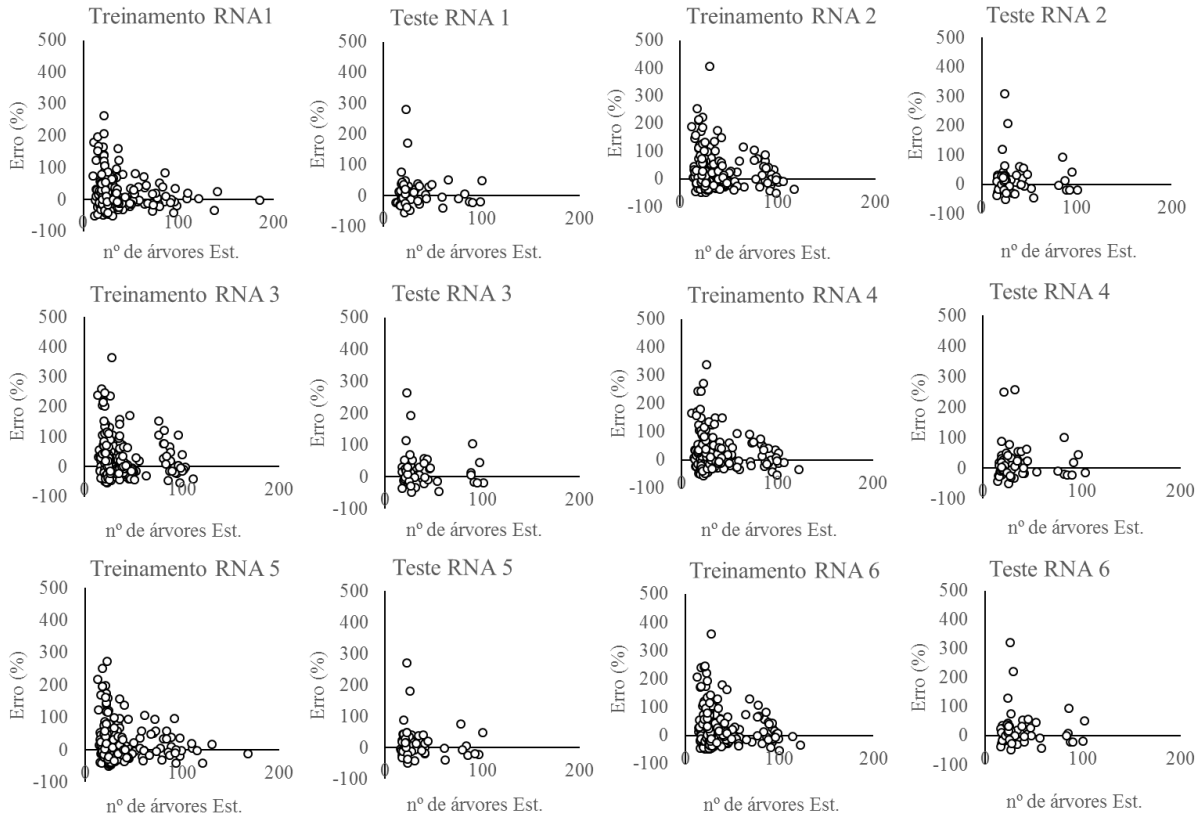


Figura 3. Distribuição dos erros percentuais do treinamento e teste das RNA.

Figure 3. Distribution of the training percentage errors and ANN testing.

Utilizando a RNA 1, que obteve as melhores estimativas de recrutamento, ao longo do tempo, após a colheita, os dados estimados seguiram a tendência de recrutamento observada (Figura 4), com um pequeno desvio nos primeiros períodos (1981 a 1987).

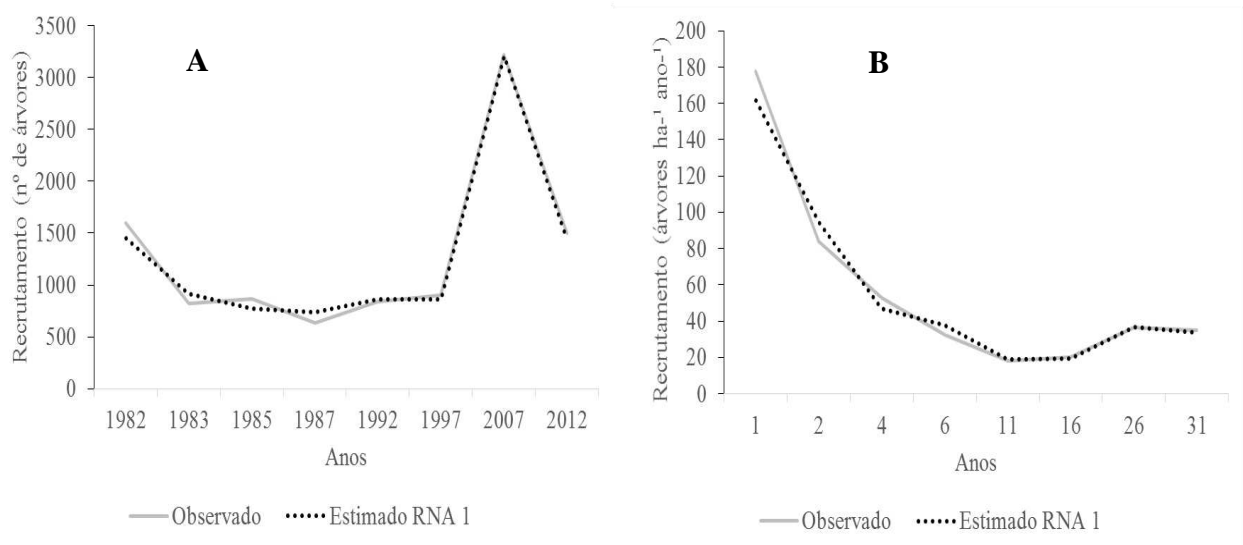


Figura 4. Recrutamento observado e estimado após a colheita florestal (A) e taxa de recrutamento observado e estimado após a colheita florestal (B).

Figure 4. Observed and estimated recruitment after forest harvest (A) and observed and estimated recruitment rate after forest harvest (B).

4. Discussão

Com o uso de todas as variáveis tanto estruturais como de dinâmica, a RNA 1 apresentou as melhores estimativas de recrutamento, apesar da diferença da correlação e RQEQM ser de menos de 3% em comparação da RNA1 com as outras redes. Isso demonstrou a grande capacidade de aprendizado das RNA em extrair informações com poucas variáveis (HAYKIN, 2001; SILVA *et al.*, 2010).

A RNA 2, rede mais simples que utilizou somente as variáveis da própria subparcela, sem o uso das subparcelas de vizinhança, gerou também resultados bem próximos aos da RNA 1 que utilizou todas as variáveis das subparcelas de vizinhança (Tabela 3), com uma diferença na correlação de 0,02% e no RQEQM de 3%. Porém, apresentou maior tendenciosidade de superestimar o recrutamento nos dados de teste (Figura 3), possivelmente por não ter a influência de variáveis da vizinhança. Apesar disso foi a rede mais simples o que garante maior praticidade no seu uso.

A variável de vizinhança de maior influência foi a densidade de árvores, estimada pela RNA 3, que apresentou a menor diferença, com menos de 1% no RQEQM, comparada com a RNA 1 (Tabela 3). Isso pode ter ocorrido devido a correlação negativa e significativa de árvores ha⁻¹ em relação ao recrutamento (Tabela 2). Quanto maior o número de árvores estabelecidas

na subparcela, maior será a competição por espaço, nutrientes, água e luz em termos de recrutamento.

A segunda e a terceira variáveis com maior influência foram o Incremento Periódico Anual em *dap* (IPA_{dap}) e a área basal (G), respectivamente, estimadas pela RNA 5 e RNA 4. A área basal e o IPA são as variáveis mais utilizadas na estimativa do recrutamento em diversos estudos de modelagem florestal (ROSSI *et al.*, 2007; AZEVEDO *et al.*, 2008; KLOPCIC *et al.*, 2012), a primeira como medida de densidade, representando ocupação em termos de biomassa, sendo significativamente correlacionada com o recrutamento de forma negativa (KLOPCIC *et al.*, 2012). Quanto maior a área basal, maior a competição e fechamento de dossel, diminuindo o recrutamento com o passar do tempo após a colheita (Figura 4B).

O IPA_{dap} representa a produtividade do crescimento das subparcelas, sendo correlacionado positivamente (Tabela 2) com o recrutamento (AZEVEDO *et al.*, 2008). As subparcelas com maior IPA_{dap} , são formadas por clareiras e florestas em construção, as mesmas que apresentam maiores recrutamentos, por possuir menor competição e maior entrada de radiação solar ativando o banco de plântulas e de sementes (REIS *et al.*, 2014)

A RNA 6 resultou no pior desempenho na estimativa do recrutamento, com correlação menor e RQEQM maior que a RNA 2, a rede mais simples. Isso ocorreu devido à baixa representatividade e influência do diâmetro máximo, como medidor de competição, com uma correlação não significativa na influência do recrutamento (Tabela 2). Também sendo uma variável redundante já que a variável categórica (Classe de floresta), que é influenciada pelo diâmetro máximo da subparcela, fez parte de todos os treinamentos.

A tendenciosidade apresentada na estimativa do recrutamento ocorreu devido ao seu processo altamente estocástico nas subparcelas, representado um excesso de contagem de zeros, sem recrutamento, que dificulta a modelagem (ZHANG *et al.*, 2012), além da elevada biodiversidade da área dando grande variabilidade de estratégias de recrutamento, como por exemplo, a existência de espécies que se regeneram por meio de banco de sementes ou banco de plântulas, que pode prejudicar a modelagem (RIVETT *et al.*, 2016). Também períodos diferentes entre medições interferem na modelagem (VANCLAY, 1994), o período mais curto foi de um ano e o mais longo de 10 anos (Figura 4A).

Os recrutamentos podem não ser observados em períodos curtos nas subparcelas menos dinâmicas, ou ter poucos indivíduos recrutados, esse fato pode ser a causa da superestimação no período de 1982 a 1983, quando a floresta apresentou aumento no crescimento e recrutamento por causa da abertura de dossel devido a colheita florestal. Mas, após a colheita de impacto reduzido, o recrutamento não é afetado de forma significativa, ao longo do tempo

(RIVETT *et al.*, 2016), isso pode ser observado nas melhores estimativas nos outros períodos a partir de 1987, apesar do elevado recrutamento de 1997 a 2007, em que um dos fatores foi um longo intervalo entre medições.

Embora o efeito do intervalo entre as medições acarrete interferência nas taxas de recrutamento, quando ocorreu um declínio nas taxas com o aumento do intervalo (ROSSI *et al.*, 2007), a RNA 1 acompanhou a tendência de desaceleração da taxa de recrutamento após a colheita florestal (Figura 4B). Isso pode ser devido à inclusão das variáveis de tempo (período entre medições e período após o corte), que explicam essa variação de recrutamento, sendo as mais correlacionadas com o recrutamento (Tabela 2).

Apesar de o recrutamento ser altamente estocástico ao longo do tempo, por possuir diferentes mosaicos de regeneração (Floresta Madura, Floresta em construção e clareiras), que podem influenciar as estimativas, sendo esse mosaico representado como variável de entrada categórica na tentativa de captar essa dinâmica após colheita, e as medições das parcelas terem períodos variados, a RNA 1, seguiu a tendência do recrutamento ao longo do tempo (Figura 4 A e B). Portanto, é uma ferramenta de predição de recrutamento altamente adequada a florestas tropicais. A menor diferença em comparação de árvores recrutadas observadas e estimadas foi no período de 1997 a 2007 com 0,01%, e a maior foi no período de 1985 a 1987 de 17,6% (Figura 4 A e B). Isso devido à desaceleração da taxa de recrutamento após a colheita.

Como a estimativa de recrutamento por meio das RNA não utilizaram grupos de espécies separadamente, a alocação do recrutamento pode ser determinada em grupos de espécies pela probabilidade média de recrutamento (VANCLAY, 1994; NASCIMENTO *et al.*, 2013), servindo como base para o manejo florestal.

5. Conclusões

O recrutamento de árvores após a colheita florestal pode ser estimado com eficiência empregando redes neurais artificiais, utilizando variáveis de entrada da estrutura horizontal, dinâmica florestal e situação do sítio quanto a maturidade de formação florestal, da subparcela alvo e de sua vizinhança.

Agradecimentos

À Capes pela concessão de bolsas ao autor e a Embrapa Amazônia Oriental pela concessão de dados de monitoramento de parcelas permanentes e ao apoio financeiro do projeto Segundo Ciclo de Corte: EMBRAPA - 03.12.00.030.00.00 e CNPq 483831/2011-5.

Referências bibliográficas

AZEVEDO, P. C. SANQUETTA, C. R.; SILVA, J. N. M.; MACHADO, S. A.; SOUZA, C. R.; OLIBEIRA, M. M. Simulação de estratégias de manejo florestal na Amazônia com o uso do modelo SYMFOR. **Acta Amazonica**, Manaus, v. 38, n. 1, p. 51-70, 2008.

BINOTI, M. L. M. S.; 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**, Viçosa, v. 33, p. 1133-1139, 2009.

BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R.; SILVA, A. A. L. Redes neurais artificiais para estimação do volume de árvores. **Revista Árvore**, Viçosa, v. 38, p. 283-288, 2014.

BINOTI, M. L. M. S.; LEITE, H. G.; BINOTI, D. H. B.; GLERIANI, J. M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, Lavras, v. 21, p. 97-105, 2015.

CARVALHO, J.O.P. **Inventário diagnóstico da regeneração natural da vegetação em área da Floresta Nacional do Tapajós**. Belém: Embrapa Amazônia Oriental, 1980. p. 23. (Embrapa CPATU. Boletim de pesquisa, 2).

CASTRO, R. V. O.; SOARES, C. P. B.; LEITE, H. G.; SOUZA, A. L.; MARTINS, F. B.; NOGUEIRA, G. S.; ROMARCO, M. L. O. Artificial neural networks effectiveness to estimate mortality in a Semi-deciduous Seasonal Forest. **Australian Journal of Basic and Applied Sciences**, Amman, v. 9, p. 435-444, 2015.

COSTA FILHO, P.P.; COSTA, H.B.; AGUIAR, O.R.; **Exploração mecanizada da floresta tropical, úmida sem babaçu**. Belém: Embrapa Amazônia Oriental, 1980. p. 29. (Embrapa-CPATU. Circular técnico 9).

DIAMANTOPOULOU, M. J. Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests. **Sustainable Computing: Informatics and Systems**, Arlington, v. 2, 190-197, 2012.

- DIAMANTOPOULOU, M. J.; OZÇELIK, R.; CRECENTE-CAMPO, F.; ELER, U. Estimation of Weibull function parameters for modelling tree diameter distribution using least squares and artificial neural networks methods. **Biosystems Engineering**, Bedford, v. 133, p. 33–45, 2015.
- HAYKIN, S. **Redes neurais: princípios e práticas**. Porto Alegre: Bookman, 2001. 900 p.
- KLOPCIC, M.; POLJANEC, A.; BONCINA, A. Modelling natural recruitment of European beech (*Fagus sylvatica* L.). **Forest Ecology and Management**, Amsterdam, n. 284, p. 142–151, 2012.
- KUPLICH, T. M. Classifying regenerating forest stages in Amazônia using remotely sensed images and a neural network. **Forest Ecology and Management**, Amsterdam, v. 234, n. 1–3, p. 1–9, 2006.
- 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**, Enschede, V. 11, n. 4, p. 265–272, 2009.
- NASCIMENTO, R. G. M. MACHADO, S. A.; FIGUEREDO FILHO, A.; HIGUCHI, N. Modelagem da sobrevivência, mortalidade e recrutamento de uma floresta na Amazônia Central. **Scientia Forestalis**, Piracicaba, v. 41, n. 99, p. 319-330, 2013.
- REIS, L. P.; CARVALHO, J.O.P.; REIS, P.C.M.; GOMES, J.M.; RUSCHEL, A. R.; SILVA, M.G. Crescimento de mudas de *Parkia gigantocarpa* Ducke, em um sistema de enriquecimento em clareiras após a colheita de madeira. **Ciências Florestas**, Santa Maria, v. 24, p. 431, 2014.
- REIS, L. P.; RUSCHEL, A. R.; COELHO, A. A.; LUZ, A. S. da; MARTINS-DA-SILVA, R. C. V. Avaliação do potencial madeireiro na Floresta Nacional do Tapajós após 28 anos da exploração florestal. **Pesquisa Florestal Brasileira**, Colombo, v. 30, n. 64, p. 265-281, 2010.
- RICHARDS, M.; MCDONALD, A.J.S.; AITKENHEAD, M. J. Optimisation of competition indices using simulated annealing and artificial neural networks. **Ecological modelling**, Towson, v. 2024, p. 375-284, 2008.

RIVETT, S. L.; BICKNELL, J. E.; DAVIES, Z. G. Effect of reduced-impact logging on seedling recruitment in a neotropical forest. **Forest Ecology and Management**, Amsterdam, n. 367, P 71–79, 2016.

ROSSI, L. M. B.; KOEHLER, H.S.; ARCE, J. E.; SANQUETTA, C.R. Modelagem de Recrutamento em Florestas. **Floresta**, Curitiba, v. 37, p. 453-467, 2007.

SILVA, I. N.; SPATTI, D. H.; FLAUZIN, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 396 p.

SILVA, J. N. M.; LOPES, J. C. A.; OLIVEIRA, L. C. de; SILVA, S. M. A.; CARVALHO, J. O. P. de; COSTA, D. H. M.; MELO, M. S.; TAVARES, M. J. M. **Diretrizes para Instalação e Medição de Parcelas Permanentes em Florestas Naturais da Amazônia Brasileira**. Belém: Embrapa / ITTO, 2005. 68 p.

VANCLAY, J. K. **Modelling forest growth and yield: applications to mixed tropical forests**. Oxford: CAB International, 1994. 312 p.

ZHANG, X.; LEI, Y.; CAI, D.; LIU, F. Predicting tree recruitment with negative binomial mixture models. **Forest Ecology and Management**, Amsterdam, n. 270, p. 209–215, 2012.

ARTIGO II

PROGNOSE DO DIÂMETRO DE ÁRVORES INDIVIDUAIS NO LESTE DA AMAZÔNIA UTILIZANDO REDES NEURAS ARTIFICIAIS¹

Resumo

A prognose da estrutura da floresta ao longo do ciclo de corte utilizando modelos de árvores individuais é uma das alternativas para administrar o manejo das florestas tropicais objetivando sua sustentabilidade. Atualmente no manejo florestal na Amazônia não se usam modelos de crescimento e produção para prognosticar o estoque futuro levando a insegurança em relação a sua sustentabilidade ambiental e econômica. Portanto, para diminuir as incertezas em relação a sustentabilidade do manejo florestal este trabalho foi desenvolvido com o objetivo de modelar o crescimento das árvores individuais em uma floresta manejada na Amazônia utilizando redes neurais artificiais (RNA) servindo como subsídio ao manejador na obtenção do estoque futuro após a colheita florestal. Em 1979 foi realizada a colheita seletiva, com intensidade de 72,5 m³ ha⁻¹ em uma área de 64 ha na Floresta Nacional do Tapajós – PA. Em 1981 foram instaladas aleatoriamente e inventariadas, 36 parcelas permanentes (50 x 50 m). Nove medições sucessivas foram realizadas em 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 e 2012. Na modelagem do diâmetro futuro foi realizado o treinamento e teste de RNA, incluindo diferentes índices de competição semi-independentes da distância (*ICSID*). Todas as RNA, com *ICSID* e sem, apresentaram correlação acima de 99%, RQEQM menor que 11% e EF acima de 0,98. Com base na prognose do crescimento das árvores conclui-se que a RNA pode ser usada com eficiência para auxiliar no manejo de florestas tropicais e com isso obter a intensidade de corte e o ciclo de corte mais adequado por espécie, garantido a sustentabilidade econômica e ambiental do manejo florestal.

Palavras-chave: Manejo Florestal, Modelagem, Inteligência artificial.

¹ **Artigo publicado:** Reis, L. P., de Souza, A. L., Mazzei, L., dos Reis, P. C. M., Leite, H. G., Soares, C. P. B., Torres, C. M. M. E., da Silva, L. F., Ruschel, A. R., 2016. Prognosis on the diameter of individual trees on the eastern region of the amazon using artificial neural networks. **For. Ecol. Manage.** v. 382, p. 161–167. doi:10.1016/j.foreco.2016.10.022

PROGNOSIS ON THE DIAMETER OF INDIVIDUAL TREES ON THE EASTERN REGION OF THE AMAZON USING ARTIFICIAL NEURAL NETWORKS

Abstract

The prognosis of forest structure along the cutting cycle, using models of individual trees, is one of the alternatives to manage tropical forests aiming at sustainability. Currently, in forest management practiced in the Amazon Region, growth and production models are not used to predict the future stock of the forest. Thus, the sustainable economic and environmental aspects of this activity remain uncertain. The aim of this present work was to model the growth of individual trees in a forest managed in the Amazon Region, by using artificial neural networks (ANN) to serve as subsidy to the wielder in obtaining future stock after logging, thus reducing uncertainty on forest management sustainability. Selective harvest was carried out in 1979 with an intensity of $72.5 \text{ m}^3 \text{ ha}^{-1}$ in a 64 ha area in the Tapajós National Forest - PA. In 1981, 36 permanent plots (50 x 50 m) were installed at random and inventoried. There were nine successive measurements in 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010, and 2012. In the modeling of the future diameter, training and testing of ANN were carried out, including different semi-independent competition indexes (*DSICI*). All ANN, with and without *DSICI*, presented correlation above 99%, RMSE below 11%, and EF above 0.98. Based on the prognosis of tree growth, we were able to conclude that ANN can be effectively used to assist in the management of tropical forests and, thus, allow for the most suitable cutting intensity and cutting cycle per species, ensuring environmental and economic sustainability of forest management.

Keywords: Forest Management, Modeling, Artificial Intelligence

1. Introdução

Em 2011, foram destinados 403 milhões de hectares de floresta tropical no mundo para a produção de madeira (Putz et al., 2012). Publicações revelaram que a exploração seletiva de madeiras, realizada de conformidade com os princípios do manejo florestal sustentável, mantém substancialmente a biodiversidade (85-100%), os estoques de carbono (76%) (Putz et al., 2012) e volume de madeira (88%) considerando a intensidade aplicada atualmente na Amazônia (Reis et al., 2010), após a colheita, e que os rendimentos aumentam se for utilizada a exploração de impacto reduzido e tratamentos silviculturais.

O manejo de florestais tropicais é a atividade produtiva que garante a legalidade e sustentabilidade da produção de madeiras ao longo do tempo, tanto do ponto de vista ambiental

(Reis et al., 2015, 2010) como econômica (Santana et al., 2012). Apesar disso, a modelagem do crescimento e produção é negligenciada nos planos de manejo florestais no Brasil. A modelagem, principalmente de árvores individuais, é uma das ferramentas que pode balizar o planejamento ao longo prazo, subsidiando tecnicamente a decisão sobre a intensidade de corte e ciclo de corte mais adequado à sustentabilidade da floresta (Huth e Ditzer, 2001; Phillips et al., 2004; Valle et al., 2007).

Nos modelos de árvores individuais, a árvore é a unidade de modelagem usada para simular crescimento, ingresso e mortalidade, considerando algum nível de competição (índice de competição). Desta forma, eles aproximam-se mais da complexidade do ecossistema de florestas nativas tropicais, bem como permitem simular diferentes intervenções de colheita florestal. Contudo, foram desenvolvidos poucos modelos para florestas tropicais amazônicas, destacando-se o CAFOGROM, um modelo cohort; e o SYMFOR, um modelo de árvore individual (Alder e Silva, 2000; Azevedo et al., 2008; Phillips et al., 2004).

Além do tradicional método de ajuste dos modelos em nível de árvore individual, baseado em regressão linear e não linear, alternativamente pode ser utilizada a inteligência artificial, por meio das Redes Neurais Artificiais (RNA) (Diamantopoulou, 2005). As RNA são modelos computacionais inspirados no sistema nervoso dos seres vivos. Uma RNA forma um conjunto de unidades de processamento paralelo, caracterizadas por neurônios artificiais que são interligados por um grande número de interconexões (Silva et al., 2010).

Alguns estudos demonstraram o sucesso da aplicação da RNA em modelagem de árvores individuais como, por exemplo, para estimar o crescimento e mortalidade em florestas inequidistantes (Ashraf et al., 2015; Castro et al., 2015; Richards et al., 2008) e em florestas equidistantes (Castro et al., 2013a, 2013b). Contudo, nenhum estudo utilizou redes neurais artificiais (RNA) em modelagem de árvore individual em florestas inequidistantes manejadas.

Diante desta lacuna, este trabalho foi desenvolvido com objetivo de modelar a projeção do diâmetro futuro de árvores individuais em uma floresta manejada na Amazônia utilizando redes neurais artificiais, para subsidiar decisões técnicas sobre o manejo florestal.

2. Material e Métodos

2.1. Área de estudo

A área de estudo está localizada na Floresta Nacional do Tapajós, à altura do Km 67 (55° 00' W, 2° 45' S) da Rodovia BR-163, Cuiabá-Santarém. Insere-se no bioma Amazônia e a tipologia é Floresta Ombrófila Densa de terra firme. O clima da região é tropical úmido com temperatura média anual acima de 26 °C e é classificado como Ami pelo sistema de Köppen.

A umidade relativa média é de 86% e a precipitação média anual de 1.900 a 2.200 mm. Apresenta topografia plana a ondulada, com ocorrência de solo tipo Latossolo Amarelo Distrófico (Alvares et al., 2013; Costa Filho et al., 1980).

Na Floresta Nacional do Tapajós, especificamente na área de estudo, Costa Filho et al. (1980) relataram a colheita seletiva, realizada na década de 1940, de quatro espécies de alto valor comercial: pau-rosa (*Aniba roseodora* Ducke), maçaranduba (*Manilkara huberi* (Ducke) A. Chev.), freijó (*Cordia goeldiana* Huber) e cedro (*Cedrela odorata* L.).

No ano de 1979, em 64 ha da área de estudo foi realizada colheita intensiva de 64 espécies madeireiras, com um volume médio de extração de 72,5 m³ ha⁻¹ (Reis et al., 2010).

As espécies que se destacaram em volume colhido à época, foram: *Hymenaea courbaril* L., *Carapa guianensis* Aubl., *Manilkara huberi*, *Lecythis lurida* (Miers) S. A. Mori., *Bertholletia excelsa* Humb. & Bonpl., *Astronium lecointei* Ducke, *Goupia glabra* Aubl., *Virola michelii* Heckel, *Erismia uncinatum* Warm. e *Terminalia amazonia* (J. F. Gmel) Exell, que juntas representaram 47,4% do volume total extraído (Reis et al., 2010). A colheita foi executada sob dois tratamentos: corte de todas as árvores com $dap \geq 45$ cm, em 39 ha; e corte das árvores com $dap \geq 55$ cm, em 25 ha (Costa Filho et al., 1980). Entretanto, os tratamentos foram considerados conjuntamente, formando apenas uma comunidade, visto a alta similaridade constatada nas comparações realizadas (Reis et al., 2010).

Em 1981, foram instaladas, aleatoriamente, 36 parcelas permanentes de 50 m x 50 m cada uma, onde todas as árvores com $dap \geq 5$ cm foram identificadas botanicamente *in loco*. Remedições dessas parcelas permanentes ocorreram em 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 e 2012.

2.2. Variáveis e dados usados no treinamento e teste das redes neurais

As parcelas permanentes foram divididas em dois grupos: um grupo composto por 29 parcelas para o treinamento das RNA e outro com sete parcelas, para a generalização das RNA treinadas (validação), perfazendo um total de 80% de dados para o treinamento e 20% para a generalização. As parcelas usadas na generalização (validação) não fizeram parte do treinamento. Isso foi para avaliar o modelo com dados independentes aos do treinamento das RNA.

Para modelar a projeção do diâmetro futuro das árvores individuais, as variáveis de entrada foram: dap , diâmetro mensurado à altura de 1,30 m de altura (mm) em relação ao solo, classe de floresta (CF), classe de identificação de Fuste (CIF), índice de competição (IC), grupos de crescimento (GE), intensidade de infestação por *Cipó* ($CP0$: variável não observada;

CP1: nenhum cipó na árvore; CP2: cipós presentes, porém sem causar danos; e CP3: cipós presentes, restringindo o crescimento); e iluminação de copa (*ILO*: variável não observada; IL1: copa emergente ou completamente exposta à luz; IL2: copa parcialmente iluminada, ou seja, parcialmente coberta por copas de árvores vizinhas; e IL3: copa completamente coberta por copas de árvores vizinhas). A variável de saída foi o incremento periódico anual (mm ano^{-1}) que depois foi utilizado para calcular o diâmetro futuro (DAP_2).

As classes de floresta (*CF*) foram definidas pela metodologia proposta por Silva et al. (2005):

1. Floresta madura: a subparcela apresenta pelo menos uma árvore com diâmetro igual ou maior que 40 cm.
2. Floresta em construção: a subparcela apresenta pelo menos uma árvore com diâmetro igual ou maior que 10 cm e menor que 40 cm.
3. Clareira: há uma abertura no dossel de pelo menos 50% da área da subparcela e poucas ou nenhuma árvore com diâmetro maior que 10 cm presentes na subparcela. Quando existirem, as copas se projetam para fora do limite da subparcela.

As classes de identificação de fuste (*CIF*) foram definidas pela metodologia proposta por Silva et al. (2005):

1. Árvore viva em pé, completa.
2. Árvore viva em pé, sem copa, fuste > 4,0 m.
3. Árvore viva em pé, sem copa, fuste < 4,0 m.
4. Árvore viva caída.
11. Árvore escorada por causa natural.
13. Árvore inclinada por causa natural.
15. Árvore arqueada por causa natural

Os índices de competição testados neste estudo foram os semi-independentes da distância (*ICSID*), dentro os quais:

$$ICSID_1 = \frac{\bar{d}^2}{D_t^2}$$

Adaptado (Glover e Hool, 1979) (1)

$$ICSID_2 = Bal_i$$

(Stage, 1973)

(2)

$$ICSID_3 = Z_1 \sum_{i=1}^{n_1} \frac{D_i}{\bar{D}_t} + Z_2 \sum_{j=1}^{n_2} \frac{D_j}{\bar{D}_t} \quad \text{Adaptado de Phillips et al. (2004) (3)}$$

Em que, D_t é o diâmetro da árvore-objeto; \bar{d}^2 é a média aritmética dos diâmetros na subparcela da árvore-objeto; Bal_i é a somatória das áreas seccionais das árvores vizinhas maiores que a área seccional da árvore-objeto, na subparcela; Z_1 e Z_2 são os coeficientes de importância relativa para a competição das zonas 1 e 2, respectivamente, D_i e D_j são as árvores “*over-topping*” nas duas zonas. n_1 e n_2 são o número total de árvores “*over-topping*” nas três zonas. As árvores “*over-topping*” são as que apresentam o diâmetro maior que a árvore-objeto nas subparcelas nas duas zonas.

A zona 1 é um quadrado de 10 x 10 m contendo t árvores (Figura 1). A zona 2 definida como relativa a zona 1. São atribuídos pesos aleatórios que refletem a competição em cada zona, sendo $Z_1 = 9$ e $Z_2 = 4$ (Phillips et al., 2004).




Figura 1. Zonas de competição considerando uma árvore na subparcela. Adaptado de Phillips et al. (2004).

Figure 1. Competition zones considering a tree on the sub-plot. Adapted from Phillips et al. (2004).

Foi realizada análise de agrupamento (*clustering*) por distância euclidiana e método de Ward para classificar as espécies em grupos de crescimento utilizando o incremento periódico

anual em diâmetro (IPA_{dap}), em mm ano^{-1} , das famílias botânicas nos diferentes períodos (1981 a 1982, 1982 a 1983, 1983 a 1985, 1985 a 1987, 1987 a 1992, 1992 a 1997, 1997 a 2007 e 2007 a 2012), formando quatro grupos de crescimento (Tabela 1).

Tabela 1. Grupos de crescimento formados a partir do Incremento Periódico Anual em dap (IPA_{dap}) das famílias botânicas após colheita florestal.

Table 1. Growth groups created from the Annual Periodical Increment on dbh (API_{dbh}) of the botanical families after the forestry harvesting.

Grupos	Famílias	IPA_{dap} (mm ano^{-1})
1	A identificar, Chrysobalanaceae, Connaraceae, Lamiaceae, Lecythidaceae, Myrtaceae, Ochnaceae, Opiliaceae, Quinaceae, Rubiaceae, Rutaceae, Sapindaceae, Siparunaceae e Violaceae.	1,355
2	Achariaceae, Annonaceae, Apocynaceae, Aquifoliaceae, Boraginaceae, Burseraceae, Caryocaraceae, Celastraceae, Clusiaceae, Dichapetalaceae, Ebenaceae, Elaeocarpaceae, Euphorbiaceae, Hippocrateaceae, Lacisternaceae, Lauraceae, Leguminosae-papilionoideae, Malvaceae, Melastomataceae, Moraceae, Myristicaceae, Nyctaginaceae, Olacaceae, Polygonaceae, Salicaceae, Sapotaceae, Solanaceae e Ulmaceae.	2,731
3	Anacardiaceae, Combretaceae, Goupiaceae, Humiriaceae, Leguminosae-caesalpinioideae, Malpighiaceae, Meliaceae e Simaroubaceae.	3,856
4	Araliaceae, Bignoniaceae, Bixaceae, Caricaceae, Leguminosae-mimosoideae, Rosaceae, Urticaceae e Vochysiaceae.	7,771

2.3. Treinamento e avaliação das RNA

O treinamento das RNA consistiu na aplicação de um conjunto de passos ordenados com intuito de ajustar os pesos e os limiares de seus neurônios. Assim, tal processo de ajuste, também conhecido como algoritmo de aprendizagem, visou sintonizar a rede para que as suas respostas estejam próximas dos valores de saída (Silva et al., 2010).

No processo de modelagem, foram treinadas 1200 RNA, 300 para cada índice de competição avaliado ($ICSID_1$, $ICSID_2$, e $ICSID_3$) e 300 RNA sem a variável de índice de competição para tornar as RNA mais simples no processo de modelagem (Tabela 2).

Tabela 2. Variáveis utilizadas no treinamento das redes neurais artificiais (RNA) em uma floresta após colheita florestal no leste da Amazônia.

Table 2. Variables used to train the artificial neural networks (ANN) on a forest after forestry harvesting on the Eastern region of the Amazon

Índice de competição	Variáveis de Entrada	Número de treinamentos	Saída
<i>ICSID₁</i>	<i>dap₁, CF, GC, CIF, Cipó, IL, ICSID₁</i>	300	<i>IPA_{dap}</i>
<i>ICSID₂</i>	<i>dap₁, CF, GC, CIF, Cipó, IL, ICSID₂</i>	300	<i>IPA_{dap}</i>
<i>ICSID₃</i>	<i>dap₁, CF, GC, CIF, Cipó, IL, ICSID₃</i>	300	<i>IPA_{dap}</i>
<i>Sem ICSID</i>	<i>dap₁, CF, GC, CIF, Cipó, IL</i>	300	<i>IPA_{dap}</i>
Total Geral		1200	

Variáveis de entrada contínua: *ICSID*: Índice de competição semi-independente da distância; *dap₁*: Diâmetro atual mensurado a 1,30 m do solo (mm); Variáveis de entrada categórica: *CF*: classe de floresta; *GE*: grupo de crescimento; *CIF*: Classe de Identificação de Fuste; *Cipó*: Intensidade de infestação por Cipó e *IL*: Iluminação de Copa. Saída contínua: *IPA_{dap}*: Incremento Periódico Anual, em mm ano⁻¹.

No treinamento da rede foi utilizada a arquitetura *feedforward* de camadas múltiplas, o Perceptron multicamadas (MLP) e a ferramenta *Intelligent Problem Solver* (IPS) do software Statistica 13 (StaSoft Inc, 2016) para a escolha das funções de ativação (Identidade, Logística, Tangente hiperbólica e exponencial) da camada intermediária e de saída. No treinamento foi utilizado somente uma camada oculta e o intervalo do número de neurônios nessa camada foi definido pelo método de Fletcher-Gloss (Silva et al., 2010). O intervalo do número de neurônios foi fixado de acordo com o número de variáveis de entrada e saída, dado pela seguinte expressão:

$$(2 \cdot \sqrt{n} + n_2) \leq n_1 \leq (2 \cdot n + 1) \quad (4)$$

em que n é o número de entradas da rede, n_1 é a quantidade de neurônios na camada escondida e n_2 é a quantidade de neurônios na camada de saída.

O máximo definido por este método evita memorização dos dados de entrada (*overfitting*) ou extrair informação insuficientemente no treinamento (*underfitting*).

Para cada treinamento foram retidas cinco redes. Dessas, escolheu-se uma por treinamento considerando a correlação entre os valores estimados e observados. Na escolha e comparação das RNA a serem usadas na prognose dos diâmetros futuros foram avaliadas, no treinamento e na generalização, a estatística de correlação ($r_{Y\hat{Y}}$) entre os valores estimados e reais, a raiz quadrada do erro quadrático médio (RQEQM) e cálculo da eficiência do modelo (EF); os valores de EF podem variar de -1 (sem ajuste) a +1 (ajuste perfeito) (Hung et al., 2016; Loague e Green, 1991), dados por:

$$r_{Y\hat{Y}} = \frac{Cov(Y, \hat{Y})}{\sqrt{S^2(Y)S^2(\hat{Y})}} \quad (5)$$

$$RQEQM = 100 \cdot \bar{Y}^{-1} \sqrt{n^{-1} \sum_{i=1}^n (Y_i - \hat{Y})^2} \quad (6)$$

$$EF = \frac{\sum_{i=1}^n (Y - \bar{Y})^2 - \sum_{i=1}^n (\hat{Y} - Y)^2}{\sum_{i=1}^n (Y - \bar{Y})^2} \quad (7)$$

em que \hat{Y} : valores estimados pelas RNA; Y: valores observados nas parcelas permanentes, S^2 : variância, Cov.: covariância e n o número de observações.

Também foi realizada a análise gráfica da dispersão dos erros relativos percentuais (Erro %) em relação aos valores observados, obtidos por:

$$Erro \% = \frac{(\hat{Y} - Y)}{Y} \cdot 100 \quad (8)$$

3. Resultados

Todas as variáveis contínuas de entrada que foram usadas na prognose se correlacionaram ($p < 0,05$) com o incremento periódico anual (IPA_{dap}) das árvores (Tabela 3). As variáveis com maior correlação, foram $ICSID_3$ e IPA_{dap} . Os índices de competição ($ICSID$) foram correlacionados negativamente com o IPA_{dap} , indicando que quanto maior a competição, menor será o crescimento das árvores. Em relação ao dap_l quanto maior o porte da árvore maior será o crescimento.

Tabela 3. Correlação linear entre as variáveis de entrada e saída, usadas no treinamento e teste das RNA.; IPA_{dap} : Incremento Periódico Anual, em mm ano^{-1} ; $ICSID$: índice de competição semi-independente da distância; dap_1 : diâmetro no início do período de tempo t da árvore-objeto (mm).

Table 3. Linear correlation between the input and output variables, used for the training and test of ANN. API_{dbh} : Annual Periodical Increment on dbh, in mm year^{-1} ; $DSICI$: distance semi-independent competition index; dbh_1 : diameter at the beginning of time period t of the studied tree (mm).

Variáveis	IPA_{dap}	dap_1	$ICSID_1$	$ICSID_2$	$ICSID_3$
IPA_{dap}	1.0000	-	-	-	-
DAP_1	0,1497*	1.0000	-	-	-
$ICSID_1$	-0,1473*	-0,4871*	1.0000*	-	-
$ICSID_2$	-0,1449*	-0,2459*	0,5580*	1.0000*	-
$ICSID_3$	-0,2093*	-0,6816*	0,7681*	0,3967*	1.0000*

* Significativo a 5%.

As RNA utilizadas no treinamento e teste apresentaram correlação entre os dados observados e estimados acima de 99% e o RQEQM de todas as RNA ficou abaixo de 11% (Tabela 4). A RNA com o menor RQEQM no treinamento foi a que utilizou o $ICSID_3$ e no teste foi a que não usou variável de competição. No entanto, cabe destacar que a diferença entre essas redes foi menor que 1% no teste.

Em todas as RNA a eficiência do modelo (EF) foi acima de 0,98 (Tabela 4), tanto no teste como no treinamento, sendo o ideal em termos de eficiência o mais próximo de 1. No treinamento a RNA que apresentou maior eficiência foi a que utilizou o $ICSID_3$ e no teste foi a $ICSID_2$. Mas a diferença entre as RNA foi também inferior a 1% no treinamento e no teste.

Tabela 4. Medidas de precisão do treinamento e teste das redes neurais artificiais (RNA) na estimativa do diâmetro final (dap_2) de árvores individuais. $ICSID$: Índice de competição semi-independente da distância; $r_{Y\hat{Y}}$: Coeficiente de correlação; RQEQM: raiz quadrada do erro quadrático médio (%); EF: Eficiência do modelo; MLP: Perceptron multicamadas.

Table 4. Training and test accuracy measurements of artificial neural networks (ANNs) on the final diameter estimation (dbh_2) of individual trees. $DSICI$: distance semi-

independent competition index; $r_{Y\hat{Y}}$: correlation coefficient; RMSE: root mean square error (%); EF: model efficiency; MLP: multi-layer Perceptron.

RNA	Ind ex	Arquitetura MLP	Treinamento			Teste			Funções de Ativação	
			RQEQM (%)	$r_{Y\hat{Y}}$	EF	RQEQM (%)	$r_{Y\hat{Y}}$	EF	Camada Intermediária	Camada de Saída
<i>ICSID</i> ₁	5	24-38-1	10,0021	0,99 22	0,98 97	10,0506	0,99 16	0,98 31	Exponencial	Exponencial
<i>ICSID</i> ₂	1	24-39-1	10,0587	0,99 21	0,98 41	10,1181	0,99 15	0,98 28	Exponencial	Logística
<i>ICSID</i> ₃	3	24-12-1	9,9754	0,99 23	0,98 98	10,0672	0,99 16	0,98 30	Tangente hiperbólica	Exponencial
Sem <i>ICSID</i>	5	23-22-1	10,1439	0,99 20	0,98 94	10,0014	0,99 17	0,98 32	Exponencial	Logística

As redes neurais artificiais treinadas podem ser obtidas através do contato com o autor pelo email: leonardoqueenoreis@gmail.com

As redes treinadas apresentaram padrões semelhantes de distribuição dos erros, com os maiores erros nos menores diâmetros (Figura 2). Apesar da presença de alguns dados discrepantes, representados pelos pontos mais distantes da linha de tendência, todas as RNA seguiram a tendência dos dados observados.

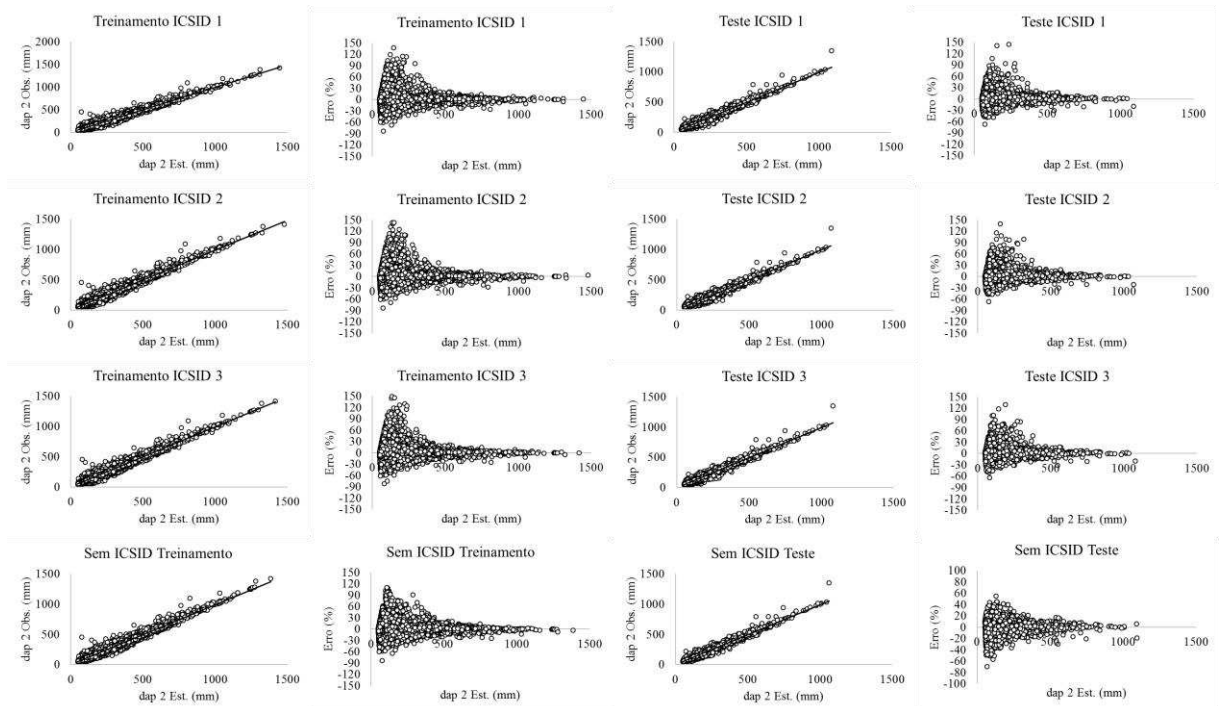


Figura 2. Distribuição das estimativas do diâmetro final (dap_2) em relação aos valores observados e dos resíduos no processo de treinamento e teste das redes neurais artificiais (RNA).

Figure 2. Distribution of the final diameter estimations (dbh_2) in relation to the observed values and the residues on the training and test process of artificial neural networks (ANNs).

Utilizando-se de todas as RNA, observou-se que a área basal estimada, calculada com os diâmetros futuros estimados por meio do IPA_{dap} , seguiu a tendência da área basal observada no total da área, ao longo do tempo após a colheita florestal (Figura 3).

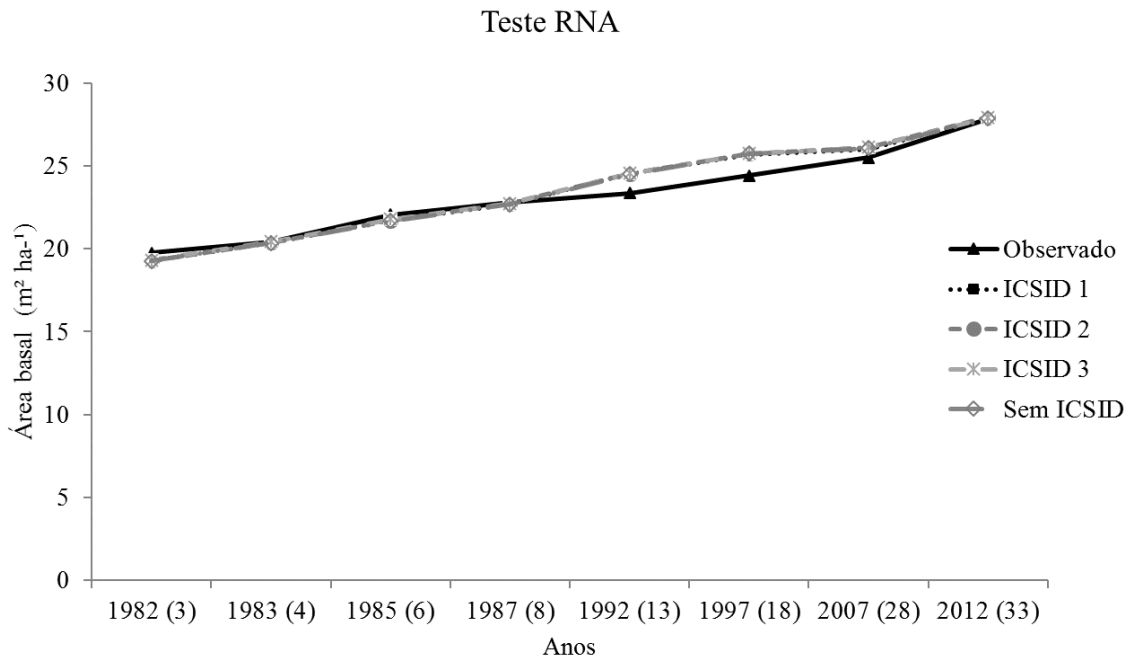


Figura 3. Áreas basais observadas e estimadas ao longo do tempo após a colheita de madeiras. Valores em parênteses representam os anos após a colheita florestal.

Figure 3. Observed and estimated basal areas throughout time after the harvesting of wood. Values within parentheses represent the years after the forestry harvest.

4. Discussão

Os $ICSID$ apresentaram correlação negativa em relação ao IPA_{dap} (Tabela 3), isso ocorre por causa de que quanto mais competidores com os diâmetros e as áreas seccionais maiores do que da árvore-objeto, limitam o desenvolvimento das árvores. Resultado já esperado, com o crescimento do índice de competição menor seria a taxa de crescimento (Richards et al., 2008).

A variável $ICSID_3$, com correlação altamente significativa com o IPA_{dap} (Tabela 3) e o menor RQEQM no treinamento, considerando o treinamento, foi a variável contínua mais importante para estimar a taxa de crescimento.

A RNA usando *ICSID*₃ representa mais realisticamente a competição, isso por considerar a competição tanto dentro da parcela da árvore-objeto como também das parcelas vizinhas, sendo que o crescimento em diâmetro é explicado em grande parte pela vizinhança (von Oheimb et al., 2011); utiliza as árvores competidoras maiores que a árvore-objeto, por causa da relação existente entre o *dap* e a competição principalmente por luz (Laurans et al., 2014); e apresenta pesos que ponderam a diminuição da competição com o afastamento da árvore-objeto, representando a diminuição da competição conforme a distância entre as árvores aumenta (Valle et al., 2007). Índices de competição que apresentam pelo menos uma relação de distância são melhores para descrever o crescimento do que os totalmente não dependentes de distância (Wang et al., 2015).

Apesar disso, todas os modelos apresentaram estimativas estatísticas próximas (Tabela 4) de correlação, RQEQM e EF, sendo que no teste a RNA que não utilizou *ICSID* obteve o menor RQEQM. Todas as RNA seguiram a tendência dos dados observados (Figura 2 e 3), isso demonstrou a elevada capacidade das RNA de modelar a complexa dinâmica da floresta após a colheita florestal, mesmo sem a inclusão da variável competição.

A precisão das estimativas também foi devido à inclusão das variáveis categóricas, que em diversos estudos apresentaram influência significativa em relação ao crescimento, como por exemplo, iluminação de copa (Gustafsson et al., 2016), infestação de Cipó (Campanello et al., 2007; Reis et al., 2015); a classe de floresta, representadas pelos diferentes tamanhos de clareira (Stan e Daniels, 2014) e os grupos de crescimento (Azevedo et al., 2008; Valle et al., 2007), corroborando o uso dessas variáveis na modelagem de florestas inequidâneas.

Os maiores erros associados aos menores diâmetros em todas as RNA (Figura 2) decorrem da grande heterogeneidade de taxas de crescimento das menores árvores, por serem as que sofrem mais o efeito da competição.

Com elevada frequência, observa-se indivíduos com o mesmo diâmetro, mas com taxas de crescimento muito diferentes (Rozendaal et al., 2015), não só pela competição, mas também decorrente da sucessão da floresta, representados pelos diferentes mosaicos de regeneração, que afetam o estabelecimento e desenvolvimento das menores árvores (Farrion et al., 2016; Reis et al., 2014).

Realizando a estimativa ao longo do tempo após a colheita florestal, todas as RNA, apresentaram em 1997, 18 anos após a colheita, superestimava da área basal observada em até 5,4%. Isso se deve pela forte desaceleração da taxa de crescimento a partir de 1987, com a menor taxa no ano de 1997 (Figura 4) e uma elevação do crescimento após esse ano. A diminuição do crescimento em 1997 pode ter sido pela elevada seca provocada pelo fenômeno

do El Niño e posterior crescimento causado pela abertura de dossel devido à mortalidade das árvores (Gloor et al., 2009; Phillips et al., 2010; Slik, 2004; Williamson et al., 2000)




Figura 4. Incremento periódico anual (IPA_{dap} mm ano⁻¹) observadas e estimadas ao longo do tempo após a colheita de madeiras. Valores em parênteses representam os anos após a colheita florestal.

Figure 4. Observed and estimated Annual Periodical Increment (API_{dbh} mm year⁻¹) throughout time after the harvesting of wood. Values within parentheses represent the years after the forestry harvest.

O forte crescimento após a colheita e desaceleração, ocorridos no início, foi ocasionado pela abertura do dossel florestal, que elevou o crescimento das árvores, e depois com o contínuo fechamento do dossel, promoveu diminuição da taxa de crescimento (Reis et al., 2015).

As RNA na prognose do incremento periódico anual em diâmetro, apresentaram crescimento relativamente constante, com desaceleração do crescimento mais tardio a partir do ano de 1992, 13 anos após a colheita. Com isso, houve uma subestimação logo após a colheita e uma superestimação no final do período analisado (Figura 4). Apesar disso, a prognose seguiu a tendência dos dados observados, conseguindo prognosticar o crescimento mais elevado no início e uma desaceleração contínua até o final do período.

5. Conclusões

Todas as RNA testadas podem ser utilizadas na prognose do crescimento individual de árvores em florestais tropicais após a colheita, por apresentar RQEQM abaixo de 11%,

correlação acima de 99% e eficiência do modelo acima de 0,97. Com destaque para a RNA que não utilizou índice de competição como variável de entrada, sendo a RNA mais simples e a que apresentou o menor RQEQM no teste.

A prognose utilizando RNA seguiu a tendência dos dados observados em relação à área basal ao longo do tempo (33 anos), mas ocorreu subestimação da taxa de crescimento logo após a colheita e uma superestimação no final do período avaliado, causado por fatores aleatórios que não foram inseridas como variáveis independentes no modelo.

O manejo florestal sustentável praticado atualmente na Amazônia não utiliza modelos de crescimento e produção para prognosticar o estoque futuro causando insegurança ambiental e econômica para essa atividade. Com a estimativa do crescimento de árvores individuais por meio das RNA, pode-se calcular volume, área basal e distribuição diamétrica futura por espécie, podendo definir a intensidade e ciclo de corte mais adequado, que não provoque superexploração de espécies, garantindo a sustentabilidade econômica e ambiental do manejo florestal.

Agradecimentos

À Capes pela concessão de bolsas ao autor e a Embrapa Amazônia Oriental pela concessão de dados de monitoramento de parcelas permanentes e ao apoio financeiro do projeto Segundo Ciclo de Corte: EMBRAPA - 03.12.00.030.00.00 e CNPq 483831/2011-5.

Referências bibliográficas

- Alder, D., Silva, J.N.M., 2000. An empirical cohort model for management of Terra Firme forests in the Brazilian Amazon. *For. Ecol. Manage.* 130, 141–157.
- Alvares, C.A., Stape, J.L., Sentelhas, P.C., De Moraes Gonçalves, J.L., Sparovek, G., 2013. Köppen's climate classification map for Brazil. *Meteorol. Zeitschrift* 22, 711–728. doi:10.1127/0941-2948/2013/0507
- Ashraf, M.I., Meng, F.-R., Bourque, C.P. -a., MacLean, D. a., 2015. A Novel Modelling Approach for Predicting Forest Growth and Yield under Climate Change. *PLoS One* 10, e0132066. doi:10.1371/journal.pone.0132066
- Azevedo, C.P. De, Sanquetta, C.R., Silva, J.N.M., Machado, S.A., Souza, C.R., Oliveira, M.M. De, 2008. Simulação de estratégias de manejo florestal na Amazônia com o uso do modelo SYMFOR. *Acta Amaz.* 38, 51–70. doi:10.1590/S0044-59672008000100007

- Campanello, P.I., Garibaldi, J.F., Gatti, M.G., Goldstein, G., 2007. Lianas in a subtropical Atlantic Forest: Host preference and tree growth. *For. Ecol. Manage.* 242, 250–259. doi:10.1016/j.foreco.2007.01.040
- Castro, R.V.O., Boechat, C.P.S., Leite, H.G., Souza, A.L. de, Nogueira, G.S., Martins, F.B., 2013a. Individual Growth Model for Eucalyptus Stands in Brazil Using Artificial Neural Network. *ISRN For.* 2013, 1–12. doi:10.1155/2013/196832
- Castro, R.V.O., Soares, C.P.B., Leite, H.G., Souza, A.L., Martins, F.B., Nogueira, G.S., Romarco. M. L. O., 2015. Artificial Neural Networks Effectiveness to Estimate Mortality in a Semi-Deciduous Seasonal Forest. *Aust. J. Basic Appl. Sci.* 9, 435–444.
- Castro, R.V.O., Soares, C.P.B., Martins, F.B., Leite, H.G., 2013b. Crescimento e produção de plantios comerciais de eucalipto estimados por duas categorias de modelos. *Pesqui. Agropecu. Bras.* 48, 287–295. doi:10.1590/S0100-204X2013000300007
- Costa Filho, P., Costa, H., Aguiar, O., 1980. Exploração mecanizada da floresta tropical úmida sem babaçu. *Embrapa-CPATU. Circ. técnico* 9, 29.
- Diamantopoulou, M.J., 2005. Artificial neural networks as an alternative tool in pine bark volume estimation. *Comput. Electron. Agric.* 48, 235–244. doi:10.1016/j.compag.2005.04.002
- Farrior, C.E., Bohlman, S. a, Hubbell, S., Pacala, S.W., 2016. Dominance of the suppressed: Power-law size structure in tropical forests. *Science* (80-.). 351, 155–157. doi:10.1126/science.aad0592
- Gloor, M., Phillips, O.L., Lloyd, J.J., Lewis, S.L., Malhi, Y., Baker, T.R., Lopez-Gonzalez, G., Peacock, J., Almeida, S., de Oliveira, A.C.A., Alvarez, E., Amaral, I., Arroyo, L., Aymard, G., Banki, O., Blanc, L., Bonal, D., Brando, P., Chao, K.J., Chave, J., Dávila, N., Erwin, T., Silva, J., Di Fiore, A., Feldpausch, T.R., Freitas, A., Herrera, R., Higuchi, N., Honorio, E., Jimenez, E., Killeen, T., Laurance, W., Mendoza, C., Monteagudo, A., Andrade, A., Neill, D., Nepstad, D., Vargas, P.N., Peñuela, M.C., Cruz, A.P., Prieto, A., Pitman, N., Quesada, C., Salomão, R., Silveira, M., Schwarz, M., Stropp, J., Ramirez, F., Ramirez, H., Rudas, A., ter Steege, H., Silva, N., Torres, A., Terborgh, J., Viquez,

- R., van der Heijden, G., 2009. Does the disturbance hypothesis explain the biomass increase in basin-wide Amazon forest plot data? *Glob. Chang. Biol.* 15, 2418–2430. doi:10.1111/j.1365-2486.2009.01891.x
- Glover, G.R., Hool, J.N., 1979. A Basal Area Ratio Predictor of Loblolly Pine Plantation Mortality. *For. Sci.* 25, 275–282.
- Gustafsson, M., Gustafsson, L., Alloysius, D., Falck, J., Yap, S., Karlsson, A., Ilstedt, U., 2016. Life history traits predict the response to increased light among 33 tropical rainforest tree species. *For. Ecol. Manage.* 362, 20–28. doi:10.1016/j.foreco.2015.11.017
- Hung, T.T., Almeida, A.C., Eyles, A., Mohammed, C., 2016. Predicting productivity of Acacia hybrid plantations for a range of climates and soils in Vietnam. *For. Ecol. Manage.* 367, 97–111. doi:10.1016/j.foreco.2016.02.030
- Huth, A., Ditzer, T., 2001. Long-term impacts of logging in a tropical rain forest - A simulation study. *For. Ecol. Manage.* 142, 33–51. doi:10.1016/S0378-1127(00)00338-8
- Laurans, M., Hérault, B., Vieilledent, G., Vincent, G., 2014. Vertical stratification reduces competition for light in dense tropical forests. *For. Ecol. Manage.* 329, 79–88. doi:10.1016/j.foreco.2014.05.059
- Loague, K., Green, R.E., 1991. Statistical and graphical methods for evaluating solute transport models: Overview and application. *J. Contam. Hydrol.* 7, 51–73. doi:10.1016/0169-7722(91)90038-3
- Phillips, O.L., van der Heijden, G., Lewis, S.L., Lopez-Gonzalez, G., Arag?o, L.E.O.C., Lloyd, J., Malhi, Y., Monteagudo, A., Almeida, S., D?vila, E.A., Amaral, I., Andelman, S., Andrade, A., Arroyo, L., Aymard, G., Baker, T.R., Blanc, L., Bonal, D., de Oliveira, ?tila Cristina Alves, Chao, K.J., Cardozo, N.D., da Costa, L., Feldpausch, T.R., Fisher, J.B., Fyllas, N.M., Freitas, M.A., Galbraith, D., Gloor, E., Higuchi, N., Honorio, E., Jim?nez, E., Keeling, H., Killeen, T.J., Lovett, J.C., Meir, P., Mendoza, C., Morel, A., Vargas, P.N., Pati?o, S., Peh, K.S.H., Cruz, A.P., Prieto, A., Quesada, C.A., Ram?rez, F., Ram?rez, H., Rudas, A., Salam?o, R., Schwarz, M., Silva, J., Silveira, M., Ferry Slik, J.W., Sonk?, B., Thomas, A.S., Stropp, J., Taplin, J.R.D., V?squez, R., Vilanova, E., 2010. Drought-mortality relationships for tropical forests. *New Phytol.* 187, 631–646.

doi:10.1111/j.1469-8137.2010.03359.x

- Phillips, P.D., De Azevedo, C.P., Degen, B., Thompson, I.S., Silva, J.N.M., Van Gardingen, P.R., 2004. An individual-based spatially explicit simulation model for strategic forest management planning in the eastern Amazon. *Ecol. Modell.* 173, 335–354. doi:10.1016/j.ecolmodel.2003.09.023
- Putz, F.E., Zuidema, P.A., Synnott, T., Pena-Claros, M., Pinard, M.A., Sheil, D., Vanclay, J.K., Sist, P., Gourlet-Fleury, S., Griscom, B., Palmer, J., Zagt, R., 2012. Sustaining conservation values in selectively logged tropical forests: The attained and the attainable. *Conserv. Lett.* 5, 296–303. doi:10.1111/j.1755-263X.2012.00242.x
- Reis, L.P., de Carvalho, J.O.P., dos Reis, P.C.M., Gomes, J.M., Ruschel, A.R., da Silva, M.G., 2014. Crescimento de mudas de *Parkia gigantocarpa* ducke, em um sistema de enriquecimento em clareiras após a colheita de madeira. *Cienc. Florest.* 24, 431–436. doi:10.5902/19805098
- Reis, L.P., dos Reis, P.C.M., Ruschel, A.R., Silva, J.N.M., de Carvalho, J.O.P., de Souza, A.L., Soares, M.H.M., Miyahara, R.K.N., 2015. Forest dynamics in the eastern Amazon with special reference to sapotaceae species. *Floresta* 45, 567–576. doi:10.5380/ufv.v45i3.35947
- Reis, L.P., Ruschel, A.R., Coelho, A.A., Luz, A.S. Da, Martins-da-Silva, R.C.V., 2010. Avaliação do potencial madeireiro na Floresta Nacional do Tapajós após 28 anos da exploração florestal. *Pesqui. Florest. Bras.* 30, 265–281. doi:10.4336/2010.pfb.30.64.265
- Richards, M., McDonald, A.J.S., Aitkenhead, M.J., 2008. Optimisation of competition indices using simulated annealing and artificial neural networks. *Ecol. Modell.* 214, 375–384. doi:10.1016/j.ecolmodel.2008.03.008
- Rozendaal, D.M. a., During, H.J., Sterck, F.J., Asscheman, D., Wiegerraad, J., Zuidema, P. a., 2015. Long-term growth patterns of juvenile trees from a Bolivian tropical moist forest: shifting investments in diameter growth and height growth. *J. Trop. Ecol.* 1–11. doi:10.1017/S0266467415000401
- Santana, A.C. De, Santos, M.A.S. Dos, Santana, Á.L. De, Yared, J.A.G., 2012. O valor econômico da extração manejada de madeira no baixo Amazonas, estado do Pará. *Rev. Árvore* 36, 527–536. doi:10.1590/S0100-67622012000300015

- Silva, I.N., Spatti, D.H., Flauzino, R.A., 2010. Redes neurais artificiais: para engenharia e ciências aplicadas. ARTLIBER, São Paulo.
- Slik, J.W.F., 2004. El Nino droughts and their effects on tree species composition and diversity in tropical rain forests. *Oecologia* 141, 114–120. doi:10.1007/s00442-004-1635-y
- Stage, A., 1973. Prognosis model for stand development, USDA for Serv. Res. Pap. INT-137. Washington, DC. doi:10.5962/bhl.title.69018
- Stan, A.B., Daniels, L.D., 2014. Growth releases across a natural canopy gap-forest gradient in old-growth forests. *For. Ecol. Manage.* 313, 98–103. doi:10.1016/j.foreco.2013.11.004
- StatSoft Inc, 2016. StatSoft [WWW Document]. *Stat. Data Anal. Softw. Syst.* 13. URL <http://www.statsoft.com/>
- Valle, D., Phillips, P., Vidal, E., Schulze, M., Grogan, J., Sales, M., van Gardingen, P., 2007. Adaptation of a spatially explicit individual tree-based growth and yield model and long-term comparison between reduced-impact and conventional logging in eastern Amazonia, Brazil. *For. Ecol. Manage.* 243, 187–198. doi:10.1016/j.foreco.2007.02.023
- von Oheimb, G., Lang, A.C., Bruelheide, H., Forrester, D.I., Wäsche, I., Yu, M., Härdtle, W., 2011. Individual-tree radial growth in a subtropical broad-leaved forest: The role of local neighbourhood competition. *For. Ecol. Manage.* 261, 499–507. doi:10.1016/j.foreco.2010.10.035
- Wang, Y., Yang, H., Li, Y.L., Qiu, S., 2015. Tree competition index based on the structural equation model. *J. Beijing For. Univ.* 37, 28–37. doi:10.13332/j.1000-1522.20140075
- Williamson, G.B., Laurance, W.F., Oliveira, A.A., Delam??nica, P., Gascon, C., Lovejoy, T.E., Pohl, L., 2000. Amazonian tree mortality during the 1997 El Nino drought. *Conserv. Biol.* 14, 1538–1542. doi:10.1046/j.1523-1739.2000.99298.x

ARTIGO III

REDES NEURAIIS ARTIFICIAIS PARA ESTIMAR A MORTALIDADE E SOBREVIVÊNCIA DE ÁRVORES INDIVIDUAIS APÓS A COLHEITA DE MADEIRA NA AMAZÔNIA

Resumo

A modelagem de árvores individuais em florestas tropicais na Amazônia permite, com segurança, a utilização dos recursos escassos de forma sustentável. Infelizmente, na Amazônia brasileira, modelos de crescimento e produção ainda não são utilizados para estimar o estoque futuro da floresta. Com isso, planos de manejo florestal não apresentam subsídios técnico-científicos que garantam a produção de madeira de forma sustentável ao longo do ciclo de corte. Este estudo teve por objetivo estimar a sobrevivência e a mortalidade de árvores individuais em floresta colhida seletivamente, utilizando Redes Neurais Artificiais (RNA), para subsidiar decisões silviculturais no manejo florestal na Amazônia Brasileira. Em 1979 foi realizada a colheita seletiva, com intensidade de $72,5 \text{ m}^3 \text{ ha}^{-1}$ em uma área de 64 ha na Floresta Nacional do Tapajós – PA. Em 1981 foram instaladas aleatoriamente e inventariadas, 36 parcelas permanentes (50 m x 50 m). Nove medições sucessivas foram realizadas em 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 e 2012. A modelagem, classificação, da sobrevivência e mortalidade foi realizado o treinamento e teste de RNA, incluindo diferentes índices de competição semi-independentes da distância (*ICSID*) como variáveis independentes. A eficiência global da classificação da sobrevivência e mortalidade foi acima de 89% no treinamento e acima de 90% no teste, para todas as RNA. A taxa de acerto da classificação da sobrevivência foi acima de 99% no teste e no treinamento para todas as RNA, mas a classificação da mortalidade apresentou baixa precisão, com taxas de acerto abaixo de 6%. O coeficiente Kappa geral ficou abaixo de 8% em todas as RNA (classificação “pobre”), mas todas as RNA ficaram acima de 55% na classificação da sobrevivência (classificação “boa”). O estudo permitiu concluir que a RNA estima com maior precisão a sobrevivência individual de árvores, do que a mortalidade, por ser este um evento mais raro que a sobrevivência.

Palavras-chave: Manejo Florestal, Modelagem, Inteligência artificial.

ARTIFICIAL NEURAL NETWORKS TO ESTIMATE THE MORTALITY AND SURVIVAL OF INDIVIDUAL TREES AFTER HARVESTING WOOD IN THE AMAZON RAIN FOREST

Abstract

Modeling individual trees in tropical rain forests in the Amazon allows for the safe use of scarce resources in a sustainable way. Unfortunately, in the Brazilian Amazon rain forest growth and production models are not yet used to estimate future forest stock. Thus, forest management plans do not present technical-scientific support that guarantees the production of wood in a sustainable way throughout the cutting cycle. Therefore, this work aims to estimate the survival and mortality of individual trees in a selectively harvested forest using Artificial Neural Networks (ANN) to support silvicultural decisions in forest management in the Amazon rain forest. In 1979, a selective harvest was carried out, with 72.5 m³ ha⁻¹ in an area of 64 ha in Floresta Nacional do Tapajós (Tapajós National Forest) in the state of Pará, Brazil. In 1981, 36 (50 m x 50 m) permanent plots were installed at random and inventoried. Nine successive measurements were carried out in 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010, and 2012. In the modeling, classification, survival, and mortality, training and ANN testing were performed, including different semi-distance-independent competition indices (ICSID). The overall efficiency of the classification was above 89% in training and above 90% in the test for all ANNs. Survival classification hit rate was above 99% in the test and training for all ANNs but the mortality score was low, with hit rates below 6%. The overall Kappa coefficient was below 8% for all ANNs (ranked “poor”) but all ANNs were above 55% in the survival classification (ranked “good”). ANN estimates the individual survival of trees more accurately but this does not occur with mortality, which is a rarer event than survival.

Keywords: Forest management, Modeling, Artificial intelligence.

1. Introdução

Estudos sobre dinâmica de florestas tropicais são importantes para a compreensão da evolução do ecossistema florestal após distúrbios antrópicos, como ocorre no manejo florestal para produção de madeira. Estes estudos subsidiam a modelagem de crescimento e produção, e a prognose da estrutura da floresta ao longo do ciclo de corte. Principalmente, utilizando modelos de árvores individuais que é uma das alternativas para administrar o manejo das florestas tropicais objetivando sua sustentabilidade (Reis et al., 2016).

Os modelos de árvores individuais, estimam a sobrevivência e a mortalidade por árvore individual. Esses componentes da dinâmica florestal são necessários para a correta prognose do número de árvores, área basal, distribuição de diâmetros e produção.

Uma das problemáticas de modelar a mortalidade é que diversos fatores, aleatórios, podem causar a morte de árvores. Por exemplo, a mortalidade regular é causada por envelhecimento, supressão e competição, e eventos que ocorrem com menos frequência, como exemplo, incidência normal de pragas e doenças, e fenômenos meteorológicos (secas, tempestades, etc.); e a mortalidade irregular, pode ser causada por incêndios de grades dimensões, surtos de pragas e doenças, e condições meteorológicas adversas, mais severas (Vanclay, 1994). Também ocorre a mortalidade por danos causados pela colheita florestal, que pode danificar raízes e casca criando pontos de entrada para pragas e doenças; e perturbação do dossel que pode trazer desvantagem para algumas espécies de árvores (Vanclay, 1994).

A mortalidade de árvores pode ser feita empregando regressão (Phillips et al., 2004, 2003; Valle et al., 2007), ou métodos de inteligência artificial, principalmente, Redes Neurais Artificiais (Diamantopoulou, 2005; Reis et al., 2016). Diferentes estudos que modelaram a mortalidade e sobrevivência de árvores individuais utilizando RNA obtiveram um melhor ajuste do que técnicas estatísticas tradicionais (Guan e Gertner, 1991a, 1991b; King et al., 2000) e demonstram que é possível prognosticar a sobrevivência e a mortalidade individual de árvores por meio de RNA. Porém, foi encontrado somente um estudo sobre a modelagem da mortalidade de árvores em floresta tropical (Castro et al., 2015), mesmo assim não foi em um período longo e não foi em uma floresta colhida, que possui uma dinâmica bem diferenciada de áreas não colhidas (Reis et al., 2015).

Já a prognose do crescimento em diâmetro individual de árvores, após a colheita em floresta tropical na Amazônia, foi estimada com precisão utilizando RNA (Reis et al., 2016), assim como em outros tipos de florestas inequidistantes (Ashraf et al., 2015; Richards et al., 2008).

No que se refere a classificação, por exemplo, se a árvore está morta ou viva, a RNA apresenta uma função discriminante mais complexa do que as técnicas tradicionais de classificação, a função discriminante final é altamente flexível, não-linear, e apresenta uma melhor separação (King et al., 2000).

Observando a problemática de prognosticar a sobrevivência e a mortalidade de árvores individuais em florestas tropicais, o objetivo do trabalho foi prognosticar a sobrevivência e a mortalidade individual de árvores utilizando redes neurais artificiais após colheita em uma floresta na Amazônia para subsidiar decisões silviculturais no manejo florestal.

2. Material e métodos

2.1. Área de estudo

A área de estudo está localizada na Floresta Nacional do Tapajós, à altura do Km 67 (55° 00' W, 2° 45' S) da Rodovia BR-163, Cuiabá-Santarém. Insere-se no bioma Amazônia e a tipologia é Floresta Ombrófila Densa de terra firme. O clima da região é tropical úmido com temperatura média anual acima de 26 °C e é classificado como Ami pelo sistema de Köppen. A umidade relativa média é de 86% e a precipitação média anual de 1.900 a 2.200 mm. Apresenta topografia plana a ondulada, com ocorrência de solo tipo Latossolo Amarelo Distrófico (Alvares et al., 2013; Costa Filho et al., 1980; Reis et al., 2016).

Na Floresta Nacional do Tapajós, especificamente na área de estudo, Costa Filho et al. (1980) relataram a colheita seletiva, realizada na década de 1940, de quatro espécies de alto valor comercial: pau-rosa (*Aniba roseodora* Ducke), maçaranduba (*Manilkara huberi* (Ducke) A. Chev.), freijó (*Cordia goeldiana* Huber) e cedro (*Cedrela odorata* L.).

No ano de 1979, em 64 ha da área de estudo foi realizada colheita intensiva de 64 espécies madeireiras, com um volume médio de extração de 72,5 m³ ha⁻¹ (Reis et al., 2010).

As espécies que se destacaram em volume colhido à época, foram: *Hymenaea courbaril* L., *Carapa guianensis* Aubl., *Manilkara huberi*, *Lecythis lurida* (Miers) S. A. Mori., *Bertholletia excelsa* Humb. & Bonpl., *Astronium lecointei* Ducke, *Goupia glabra* Aubl., *Virola michelii* Heckel, *Erismia uncinatum* Warm. e *Terminalia amazonia* (J. F. Gmel) Exell, que juntas representaram 47,4% do volume total extraído (Reis et al., 2010). A colheita foi executada sob dois tratamentos: corte de todas as árvores com *dap* ≥ 45 cm, em 39 ha; e corte das árvores com *dap* ≥ 55 cm, em 25 ha (Costa Filho et al., 1980). Entretanto, os tratamentos foram considerados conjuntamente, formando apenas uma comunidade, visto a alta similaridade constatada nas comparações realizadas (Reis et al., 2010).

Em 1981, foram instaladas, aleatoriamente, 36 parcelas permanentes de 50 m x 50 m, contendo 25 subparcelas de 10 m x 10 m, em que todas as árvores com *dap* ≥ 5 cm foram identificadas botanicamente *in loco*. Remedições dessas parcelas permanentes ocorreram em 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 e 2012.

2.2. Variáveis e dados usados no treinamento e teste das redes neurais

As parcelas permanentes foram divididas em dois grupos: um grupo composto por 29 parcelas para o treinamento das RNA e outro com sete parcelas, para a generalização das RNA treinadas (validação), perfazendo um total de 80% de dados para o treinamento e 20% para a generalização. As parcelas usadas na generalização (validação) não fizeram parte do

treinamento. Isso foi para avaliar o modelo com dados independentes aos do treinamento das RNA.

Na modelagem da mortalidade e sobrevivência das árvores individuais, as variáveis de entrada foram: diâmetro mensurado à altura de 1,30 m de altura (*dap*) em relação ao solo, classe de floresta (*CF*), classe de identificação de Fuste (*CIF*), índice de competição (*IC*), grupos de crescimento (*GE*), intensidade de infestação por *Cipó* (CP0: variável não observada; CP1: nenhum cipó na árvore; CP2: cipós presentes, porém sem causar danos; e CP3: cipós presentes, restringindo o crescimento); e iluminação de copa (*IL0*: variável não observada; IL1: copa emergente ou completamente exposta à luz; IL2: copa parcialmente iluminada, ou seja, parcialmente coberta por copas de árvores vizinhas; IL3: copa completamente coberta por copas de árvores vizinhas) (Reis et al., 2016); Danos a árvore (D0: variável não observada; D1: árvore sem danos; D2: danos leves por causa natural; D3: danos leves causados pela colheita; D4: danos causados por corte de cipó; D5: danos severos por causa natural; D6: danos severos pela colheita; D10: danos recuperados) e podridão na árvore (P0: variável não observada; P1: sem podridão e P2: podridão presente). A variável de saída categórica (Classificação) foi a árvore Morta ou Sobrevivente.

As classes de floresta (*CF*) foram definidas pela metodologia proposta por Silva et al. (2005):

4. Floresta madura: a subparcela apresenta pelo menos uma árvore com diâmetro igual ou maior que 40 cm.
5. Floresta em construção: a subparcela apresenta pelo menos uma árvore com diâmetro igual ou maior que 10 cm e menor que 40 cm.
6. Clareira: há uma abertura no dossel de pelo menos 50% da área da subparcela e poucas ou nenhuma árvore com diâmetro maior que 10 cm presentes na subparcela. Quando existirem, as copas se projetam para fora do limite da subparcela.

As classes de identificação de fuste (*CIF*) foram definidas pela metodologia proposta por Silva et al. (2005):

5. Árvore viva em pé, completa.
6. Árvore viva em pé, sem copa, fuste > 4,0 m.
7. Árvore viva em pé, sem copa, fuste < 4,0 m.
8. Árvore viva caída.
9. Árvore escorada por causa natural.
10. Árvore inclinada por causa natural.
11. Árvore arqueada por causa natural.

Os índices de competição testados neste estudo foram os semi-independentes da distância (*ICSID*), dentro os quais:

$$ICSID_1 = \frac{\bar{d}^2}{D_t^2} \quad \text{Adaptado (Glover e Hool, 1979) (1)}$$

$$ICSID_2 = Bal_i \quad \text{(Stage, 1973) (2)}$$

$$ICSID_3 = Z_1 \sum_{i=1}^{n1} \frac{D_i}{D_t} + Z_2 \sum_{j=1}^{n2} \frac{D_j}{D_t} \quad \text{Adaptado de Phillips et al. (2004) (3)}$$

Em que, D_t é o diâmetro da árvore-objeto; \bar{d}^2 é a média aritmética dos diâmetros na subparcela da árvore-objeto; Bal_i é a somatória das áreas seccionais das árvores vizinhas maiores que a área seccional da árvore-objeto, na subparcela; Z_1 e Z_2 são os coeficientes de importância relativa para a competição das zonas 1 e 2, respectivamente, D_i e D_j são as árvores “*over-topping*” nas duas zonas. n_1 e n_2 são o número total de árvores “*over-topping*” nas três zonas. As árvores “*over-topping*” são as que apresentam o diâmetro maior que a árvore-objeto nas subparcelas nas duas zonas.

A zona 1 é um quadrado de 10 x 10 m contendo t árvores (Figura 1). A zona 2 é definida como relativa a zona 1. São atribuídos pesos aleatórios que refletem a competição em cada zona, sendo $Z_1=9$ e $Z_2=4$ (Phillips et al., 2004).




Figura 1. Zonas de competição considerando uma árvore na subparcela. Adaptado de Phillips et al. (2004).

Figure 1. Competition zones considering a tree on the sub-plot. Adapted from Phillips et al. (2004).

Foi realizada análise de agrupamento (*clustering*) por distância euclidiana e método de Ward para classificar as espécies em grupos de crescimento utilizando o incremento periódico anual em diâmetro (IPA_{dap}), em mm ano^{-1} (Reis et al., 2016), das famílias botânicas nos diferentes períodos (1981 a 1982, 1982 a 1983, 1983 a 1985, 1985 a 1987, 1987 a 1992, 1992 a 1997, 1997 a 2007 e 2007 a 2012), em que foram formados quatro grupos de crescimento (Tabela 1).

Tabela 1. Grupos de crescimento formados a partir do Incremento Periódico Anual em dap (IPA_{dap}) das famílias botânicas após colheita florestal.

Table 1. Growth groups created from the Annual Periodical Increment on dbh (API_{dbh}) of the botanical families after the forestry harvesting.

Grupos	Famílias	IPA_{dap} (mm ano^{-1})
1	A identificar, Chrysobalanaceae, Connaraceae, Lamiaceae, Lecythidaceae, Myrtaceae, Ochnaceae, Opiliaceae, Quiinaceae, Rubiaceae, Rutaceae, Sapindaceae, Siparunaceae e Violaceae.	1,355
2	Achariaceae, Annonaceae, Apocynaceae, Aquifoliaceae, Boraginaceae, Burseraceae, Caryocaraceae, Celastraceae, Clusiaceae, Dichapetalaceae, Ebenaceae, Elaeocarpaceae, Euphorbiaceae, Hippocrateaceae, Lacistemaceae, Lauraceae, Leguminosae-papilionoideae, Malvaceae, Melastomataceae, Moraceae, Myristicaceae, Nyctaginaceae, Olacaceae, Polygonaceae, Salicaceae, Sapotaceae, Solanaceae e Ulmaceae.	2,731
3	Anacardiaceae, Combretaceae, Goupiaceae, Humiriaceae, Leguminosae-caesalpinioideae, Malpighiaceae, Meliaceae e Simaroubaceae.	3,856
4	Araliaceae, Bignoniaceae, Bixaceae, Caricaceae, Leguminosae-mimosoideae, Rosaceae, Urticaceae e Vochysiaceae.	7,771

2.3. Treinamento e avaliação das RNA

O treinamento das RNA consistiu na aplicação de um conjunto de passos ordenados com intuito de ajustar os pesos e os limiares de seus neurônios. Assim, tal processo de ajuste, também conhecido como algoritmo de aprendizagem, visou sintonizar a rede para que as suas respostas estejam próximas dos valores de saída (Silva et al., 2010).

No processo de modelagem, foram treinadas 1200 RNA, 300 para cada índice de competição avaliado ($ICSID_1$, $ICSID_2$ e $ICSID_3$) e 300 RNA sem a variável de índice de competição para tonar as RNA mais simples no processo de modelagem (Tabela 2).

Tabela 2. Variáveis utilizadas no treinamento das redes neurais artificiais (RNA) em uma floresta após colheita florestal no leste da Amazônia.

Table 2. Variables used to train the artificial neural networks (ANN) on a forest after forestry harvesting on the Eastern region of the Amazon

Índice de competição	Variáveis de Entrada	Número de treinamentos	Saída Categórica
$ICSID_1$	dap_1 , CF , GC , CIF , $Cipó$, IL , $ICSID_1$, D , P	300	M e S
$ICSID_2$	dap_1 , CF , GC , CIF , $Cipó$, IL , $ICSID_2$, D , P	300	M e S
$ICSID_3$	dap_1 , CF , GC , CIF , $Cipó$, IL , $ICSID_3$, D , P	300	M e S
<i>Sem $ICSID$</i>	dap_1 , CF , GC , CIF , $Cipó$, IL , D , P	300	M e S
Total Geral		1200	

Variáveis de entrada contínua: $ICSID$: Índice de competição semi-independente da distância; dap_1 : Diâmetro atual mensurado a 1,30 m do solo (mm); Variáveis de entrada categórica: CF : classe de floresta; GE : grupo de crescimento; CIF : Classe de Identificação de Fuste; $Cipó$: Intensidade de infestação por Cipó; IL : Iluminação de Copa; D : Dano e P : Podridão. Saída categórica: Árvore Morta (M) ou Sobrevivente (S).

No treinamento das redes foi utilizada a arquitetura *feedforward* de múltiplas camadas, o Perceptron multicamadas (MLP) e a ferramenta *Intelligent Problem Solver* (IPS) do software Statistica 13 (StaSoft Inc, 2016), sendo testadas, as funções de ativação Identidade, Logística, Tangente hiperbólica e exponencial nas camadas intermediária e de saída. O número de neurônios na camada oculta foi definido pelo método de Fletcher-Gloss (Silva et al., 2010). O intervalo do número de neurônios foi fixado de acordo com o número de variáveis de entrada e saída, e dado pela seguinte expressão:

$$(2 \cdot \sqrt{n} + n_2) \leq n_1 \leq (2 \cdot n + 1) \quad (4)$$

em que n é o número de entradas da rede, n_1 é a quantidade de neurônios na camada escondida e n_2 é a quantidade de neurônios na camada de saída.

O máximo definido por este método evita memorização dos dados de entrada (*overfitting*) ou extrair informação insuficiente no treinamento (*underfitting*).

Para observar se existe alguma correlação linear simples entre as variáveis contínuas de entrada e a saída da RNA, foi realizado a análise estatística de correlação linear simples a 5% de significância, usando a média das parcelas permanentes. Com amostra de n pares de valores X_i, Y_i ($i = 1, 2, \dots, n$), pode-se obter a correlação (r_{yx}), a partir da seguinte expressão:

$$r_{yx} = \frac{Cov(Y, X)}{\sqrt{S^2(X)S^2(Y)}} \quad (5)$$

A avaliação da classificação foi realizada por meio da geração da matriz de erro (2 x 2), sendo possível o cálculo do erro de omissão (EO), erro de comissão (EC), taxa de acerto, Índice de exatidão global e coeficiente Kappa total (Cohen, 1960) e condicional (por classe). A estatística Kappa é comumente utilizada na avaliação da precisão da classificação (King et al., 2000; Moisen e Frescino, 2002):

$$k = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})} \quad (6)$$

$$k_{cond} = \frac{N x_{ii} - (x_{i+} \cdot x_{+i})}{N x_i - (x_{i+} \cdot x_{+i})} \quad (7)$$

em que:

k = coeficiente Kappa; k_{cond} = coeficiente Kappa condicional por classe; r = número de linhas na matriz; x_{ii} = número de observações na linha(i) e coluna(i), valores da diagonal da matriz; x_{i+} = total marginal da linha (i); x_{+i} = total marginal da coluna (i); e N = número total de observações.

O coeficiente Kappa pode ser avaliado pela escala seguinte de qualidade de classificação (Landis e Koch, 1977): $k \leq 0,20$ (pobre), 0,21-0,40 (razoável), 0,41-0,60 (moderado), 0,61-0,80 (bom) e 0,81-1,00 (muito bom).

Foi avaliado a distribuição diamétrica das árvores sobreviventes nos diferentes anos com o teste de aderência Qui-quadrado (χ^2) a 5% de significância.

3. Resultados

As médias das variáveis independentes contínuas de entrada utilizadas nas RNA não se correlacionaram linearmente ($p > 0,05$) com a média da taxa de sobrevivência e mortalidade após a colheita florestal (Tabela 3). Nenhum índice de competição testado apresentou, relação com os percentuais de mortalidade e sobrevivência.

Tabela 3. Correlação linear entre as variáveis de entrada e saída, usadas no treinamento e teste das RNA. S (%): Média da taxa de sobrevivência; M (%): Média da taxa de mortalidade; *ICSID*: índice de competição semi-independente da distância; *dap_t*: diâmetro no início do período de tempo *t* da árvore-objeto (mm).

Table 3. Linear correlation between input and output variables used in ANN training and test. S (%): Average survival rate; M (%): Average mortality rate; *ICSID*: semi-distance-independent competition index; *dap_t*: diameter at the beginning of *t* time period of the object tree (mm).

Variáveis	S (%)	M (%)	<i>ICSID</i> ₁	<i>ICSID</i> ₂	<i>ICSID</i> ₃	<i>dap_t</i>
S (%)	1,0000	-	-	-	-	-
M (%)	-1,0000*	1,0000	-	-	-	-
<i>ICSID</i> ₁	-0,0379	0,0379	1,0000	-	-	-
<i>ICSID</i> ₂	0,1635	-0,1635	0,6550*	1,0000	-	-
<i>ICSID</i> ₃	0,0926	-0,0926	-0,4508*	0,1923	1,0000	-
<i>dap_t</i>	0,2930	-0,2930	0,8089*	0,4764*	-0,6004*	1,0000

* $p < 0,05$.

A eficiência global da classificação foi acima de 89% no treinamento e acima de 90% no teste, para todas as RNA (Tabela 4). A taxa de acerto da classificação do número de árvores sobreviventes foi acima de 99% no teste e no treinamento para todas as RNA, o que foi considerado uma boa classificação da sobrevivência. Porém, a classificação do número de árvores mortas apresentou baixa precisão, com taxas de acerto abaixo de 6%, no teste e no treinamento das RNA. Apesar disso, a precisão do teste foi melhor que a do treinamento, isso caracteriza uma eficiente na generalização na RNA para dados independentes.

A RNA que usou o *ICSID*₃ foi a que apresentou a maior taxa de acerto na mortalidade, já a RNA que não utilizou um índice de competição apresentou a menor taxa de acerto, abaixo de

5% na mortalidade. Essa RNA apresentou valores muito próximos na taxa de acerto da classificação da sobrevivência, ficando com 99,72% de acerto na classificação e na eficiência global com 90,05%, próximo da eficiência das RNA que utilizaram o *ICSID*₁ e *ICSID*₃.

Tabela 4. Medidas de precisão do treinamento e teste das redes neurais artificiais (RNA) na classificação da sobrevivência e mortalidade de árvores individuais. *ICSID*: índice de competição semi-independente da distância; MLP: multi-layer Perceptron. TA: Taxa de acerto (%); IEG: índice de eficiência global (%).

Table 4. Training precision measures and Artificial Neural Network (ANN) test in the classification of survival and mortality of individual trees. *ICSID*: semi-distance-independent competition index; MLP: multilayer perceptron. HR: Hit rate (%); OEE: Overall equipment effectiveness (%).

RNA	Index	Arquitetura MLP	Treinamento			Teste			Funções de ativação	
			TA (%)	TA (%)	IEG (%)	TA (%)	TA (%)	IEG (%)	Camada intermediária	Camada de saída
			S	M		S	M			
<i>ICSID</i> ₁	2	35-44-2	99,71	3,92	89,38	99,69	5,22	90,05	Logística	Exponencial
<i>ICSID</i> ₂	1	35-16-2	99,71	4,03	89,39	99,73	5,02	90,07	Tangente hiperbólica	Tangente hiperbólica
<i>ICSID</i> ₃	3	35-66-2	99,73	4,09	89,42	99,68	5,29	90,05	Tangente hiperbólica	Exponencial
Sem <i>ICSID</i>	5	34-59-2	99,73	3,77	89,38	99,72	4,89	90,05	Logística	Tangente hiperbólica

As redes neurais artificiais treinadas podem ser obtidas através do contato com o autor pelo email: leonardoqueenoreis@gmail.com

Todas as RNA apresentaram um erro de omissão (EO) acima de 94% no treinamento e teste na classificação da mortalidade, em contraponto, o EO da classificação da sobrevivência ficou bem abaixo com 0,4%, esse erro representa que as árvores são omitidas de sua correta classe e assinalados a uma outra classe (Tabela 5). O erro de comissão (EC) para todas as RNA no treinamento e teste ficaram abaixo de 38% e 65%, respectivamente, para a sobrevivência e mortalidade, esse erro representa as árvores erroneamente incluídas em uma dada classe quando elas deveriam ser assinaladas à outra classe.

Tabela 5. Erros e precisão do treinamento e teste das redes neurais artificiais (RNA) na classificação da sobrevivência e mortalidade de árvores individuais. EO: Erro de omissão (%); EC: Erro de comissão (%); Coeficiente Kappa geral e condicionado (%); *ICSID*: índice de competição semi-independente da distância.

Table 5. Errors and precision of training and Artificial Neural Networks (ANN) in the classification of survival and mortality of individual trees. EO: Error of omission (%); EC: Error of commission (%); General and conditioned Kappa coefficient (%); *ICSID*: semi-distance-independent competition index.

ANN	Treinamento						Teste							
	EO (%)		EC (%)		K. Cond. (%)		K. Geral	EO (%)		EC (%)		C. Kappa Cond. (%)		K. Geral (%)
	S	M	S	M	S	M		S	M	S	M	S	M	
<i>ICSID</i> ₁	0,29	96,08	10,43	37,76	57,67	3,26	6,17	0,31	94,78	9,75	34,17	62,0	4,45	8,30
<i>ICSID</i> ₂	0,29	95,97	10,42	37,36	58,13	3,36	6,36	0,27	94,98	9,77	32,14	64,2	4,30	8,06
<i>ICSID</i> ₃	0,27	95,91	10,41	35,42	60,30	3,43	6,49	0,32	94,71	9,75	34,96	61,1	4,50	8,37
Sem <i>ICSID</i>	0,27	96,23	10,44	37,16	58,34	3,14	5,96	0,28	95,11	9,78	33,33	62,9	4,17	7,83

O coeficiente Kappa geral ficou abaixo de 8% em todas as RNA (Tabela 5), tanto no treinamento como no teste. De acordo com escala de qualidade de classificação do coeficiente Kappa (Landis e Koch, 1977), a classificação de todas as RNA foi considerada “pobre” ($k \leq 0,20$). A rede que apresentou o maior coeficiente Kappa foi a que utilizou o *ICSID*₃ e a menor foi a que não utilizou índice de competição.

Em relação ao coeficiente Kappa calculado por classe (condicionado) todas as RNA ficaram acima de 55% para a sobrevivência (Tabela 5). Destaque-se para as RNA que utilizaram os índices de competição *ICSID*₂ e *ICSID*₃ que obtiveram coeficientes Kappa, respectivamente, de 64,2 e 61,1% nos dados de teste, sendo que essas classificações foram consideradas, de acordo com a escala de qualidade de classificação do coeficiente Kappa, como “bom” (0,61-0,80).

A classificação da mortalidade em todas as redes apresentou um coeficiente Kappa abaixo de 5% (Tabela 5), tanto no teste como no treinamento. A RNA que apresentou o maior coeficiente Kappa foi a que utilizou o *ICSID*₃, no treinamento (3,43%) e no teste (4,50%), de acordo com escala de qualidade de classificação do coeficiente Kappa, a classificação dessa rede também foi considerada “pobre” ($k \leq 0,20$).

A distribuição de diâmetro exponencial dos dados estimados e observados das árvores sobreviventes apresentaram forma de J-invertido (Figura 2). A distribuição estimada não foi diferente ($p > 0,05$) da observada (Tabela 6) nos anos de 1982, 1983, 1985, 1987 e 2012 nos dados de teste em todas as RNA. A distribuição diamétrica estimada dos anos de 1992, 1997 e 2007 foi diferente ($p < 0,05$) da observada (Tabela 6), nesses anos ocorreu uma superestimação

da sobrevivência no menor centro de classe de diâmetro (7,5 cm), em todas as redes, nos dados de teste (Figura 2).

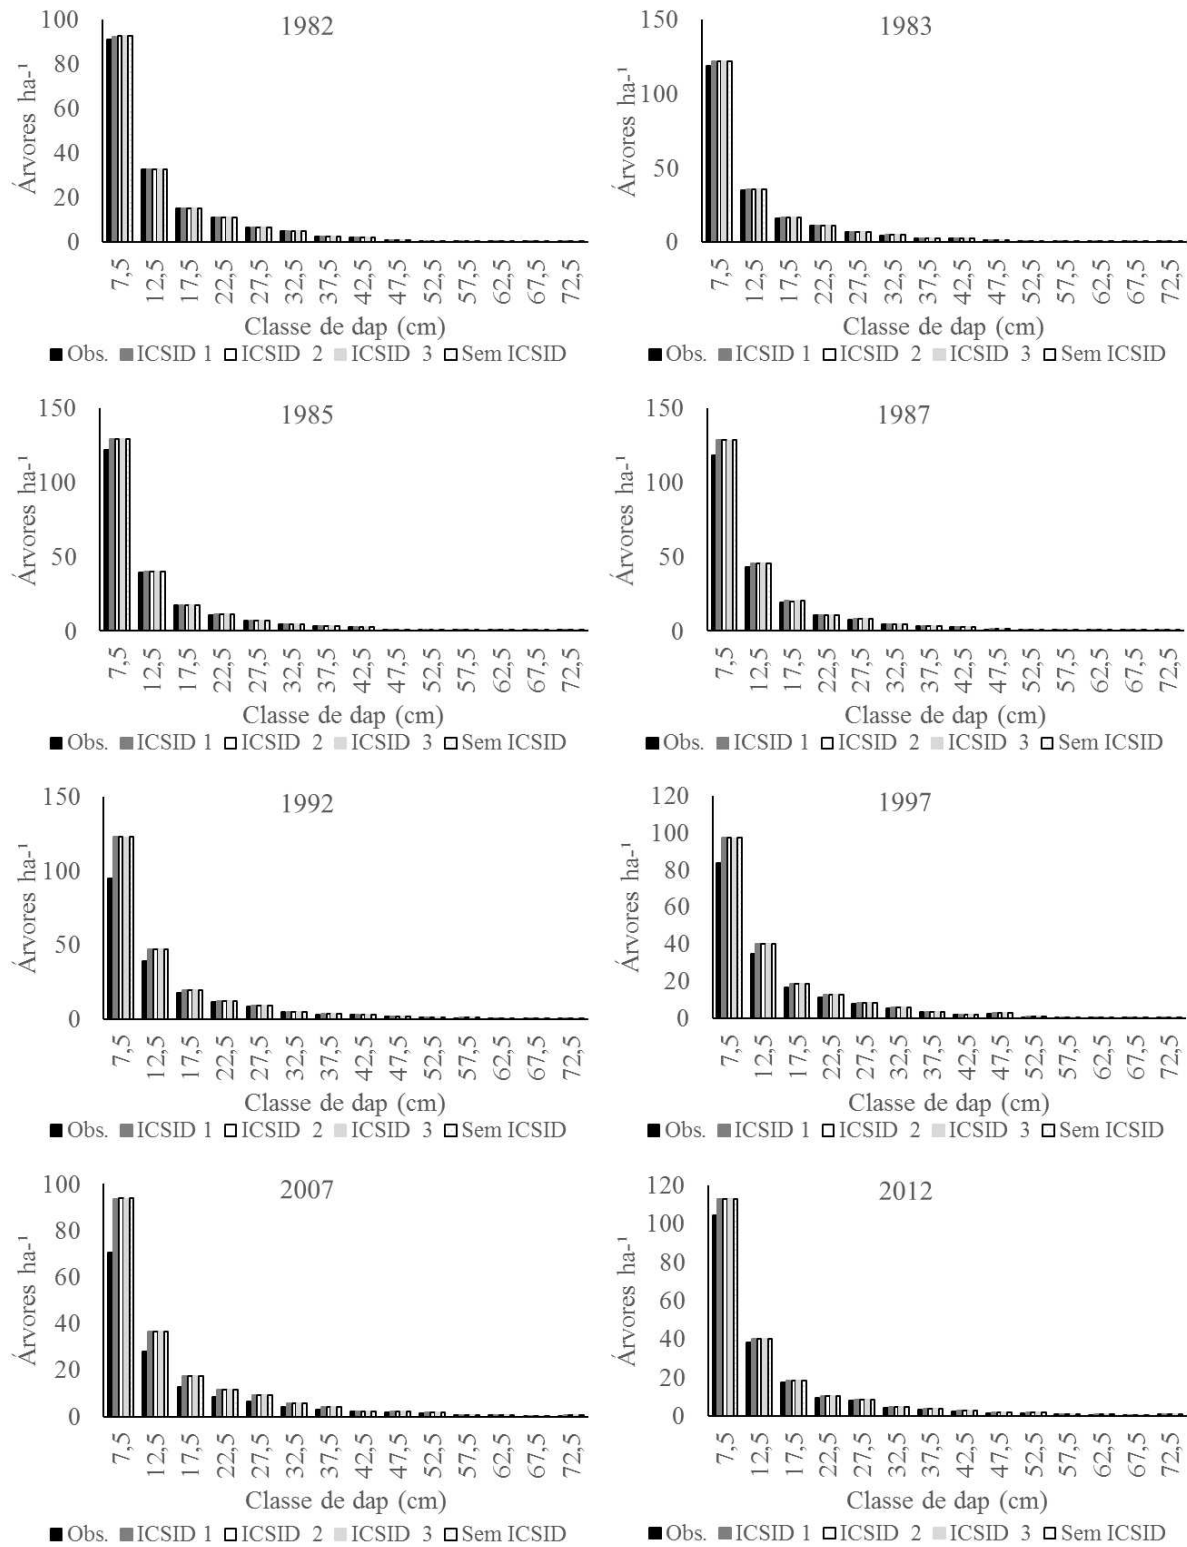


Figura 2. Distribuição diamétrica observada e estimada pelas RNA das árvores sobreviventes nos anos após a colheita florestal. *ICSID*: índice de competição semi-independente da distância.

Figure 2. Observed and estimated diametric distribution by ANN of surviving trees in the years after forest harvest. *ICSID*: semi-distance-independent competition index.

Tabela 6. Teste Qui-quadrado (χ^2) de aderência entre a distribuição diamétrica observada e estimada nos anos após a colheita florestal. *ICSID*: índice de competição semi-independente da distância.

Table 6. Chi-square test (χ^2) of adherence between the diameter distribution observed and estimated in the years after the forest harvest. *ICSID*: semi-distance-independent competition index.

Anos	<i>ICSID</i> ₁		<i>ICSID</i> ₂		<i>ICSID</i> ₃		Sem <i>ICSID</i>	
	Qui-quadrado (χ^2)	p-valor	Qui-quadrado (χ^2)	p-valor	Qui-quadrado (χ^2)	p-valor	Qui-quadrado (χ^2)	p-valor
1982	0,270	0,9999	0,254	0,9999	0,327	0,9999	0,324	0,9999
1983	1,076	0,9998	1,076	0,9998	1,025	0,9998	1,092	0,9998
1985	4,361	0,9296	4,361	0,9296	4,138	0,9409	4,397	0,9277
1987	9,006	0,5315	9,074	0,5251	8,713	0,5595	9,155	0,5595
1992	75,234	< 0,0001	75,961	< 0,0001	75,147	< 0,0001	75,961	< 0,0001
1997	27,799	0,0019	28,318	0,0016	27,287	0,0023	29,265	0,0011
2007	102,869	< 0,0001	104,172	< 0,0001	102,869	< 0,0001	104,576	< 0,0001
2012	9,595	0,4767	9,695	0,4676	9,835	0,4551	10,219	0,4215

Graus de liberdade: 10.

4. Discussão

A inexistência de correlação linear ($p > 0,05$) entre as médias das variáveis contínuas de entrada com os percentuais de sobrevivência e mortalidade, pode indicar que tais médias não representaram a complexa e estocástica relação da dinâmica dessas taxas, mas pode existir correlação não linear entre as variáveis (Tabela 3). A média do diâmetro das árvores (Vanclay, 1994) e os índices de competição por parcela não se correlacionaram linearmente com a mortalidade ($p > 0,05$), mas são preditores muito utilizados em modelagem de árvores individuais (Phillips et al., 2004).

A eficiência global elevada indica que a qualidade da classificação foi eficiente, porém, essa eficiência considera somente a diagonal principal da matriz de erros, não contemplam os erros de omissão e contingência para cada uma das classes (Tabela 4 e 5). Isso pode ser observado pela elevada taxa de acerto para a sobrevivência acima de 99% e na mortalidade não ter ultrapassado 6%.

Como o coeficiente Kappa utiliza toda a matriz de erros, e não somente a diagonal principal dessa matriz, ele representa melhor a qualidade da classificação (Tabela 5). A classificação geral da mortalidade e sobrevivência não foi precisa, ficando classificada como “pobre”, isso é devido, principalmente, a classificação da mortalidade, com o coeficiente Kappa também classificado como “pobre”.

O problema da modelagem da mortalidade em florestas tropicais está na estocasticidade desse componente, que a torna de difícil prognose. Isso ocorre devido ao longo ciclo de vida das árvores, tornando a mortalidade um evento raro (King et al., 2000) e sua descrição requer um levantamento regular de um grande número de árvores (Wernsdörfer et al., 2008) e uma série de dados ecológicos que influenciam na mortalidade regular são de difícil obtenção e não são mensurados em parcelas permanentes, como por exemplo, variáveis do microclima das parcelas.

Por outro lado, a sobrevivência, por não ser um evento tão raro e com um maior número de ocorrência apresentou a classificação considerada “bom” pelo coeficiente Kappa em todas as redes testadas (Tabela 5).

A rede que utilizou o *ICSID*₃ apresentou o maior acerto na mortalidade e sobrevivência e os maiores coeficientes Kappa (Tabela 4 e 5). Esse índice representa melhor a competição. Isto por considerar a competição tanto dentro da parcela da árvore-objeto como também das parcelas vizinhas (Figura 1), por utilizar as árvores competidoras maiores que a árvore-objeto e apresentar pesos que ponderam a diminuição da competição com o afastamento da árvore-objeto.

A floresta estudada apresentou a distribuição dos diâmetros exponencial ao longo de 31 anos, na forma de J-invertido, típica de florestas tropicais, tendência que foi acompanhada por todas as RNA (Figura 2). Essa tendência é comum em florestas sem intensas perturbações, com maior número de indivíduos nas menores classes de diâmetros, que sustenta essa forma de exponencial negativa (Rubin et al., 2006). Isso indica que a densidade das menores árvores sustenta a população das maiores árvores (Rubin et al., 2006).

A não aderência da distribuição diamétrica estimada com a observada nos anos de 1992, 1997 e 2007 (Tabela 6), ocorreu por causa da superestimação da primeira classe de diâmetro, em todas as redes testadas, chegando a uma diferença na classe de 7,5 cm de 29,7, 15,8 e 32,8%, em 1992, 1997 e 2007 respectivamente, em comparação com a modelagem *ICSID*₃. Isso ocorreu por que as árvores com menores diâmetros são as que sofrem mais o efeito da competição (Farrior et al., 2016; Reis et al., 2016). Houve uma diminuição natural na sobrevivência nesses

anos nessa classe (7,5 cm) e uma recuperação no final do período (2012) o que foi acompanhado pelas RNA (Figura 2).

A taxa de sobrevivência foi acompanhada por todas as RNA ao longo do tempo após a colheita florestal (Figura 3). Com a superestimação no número de árvores sobreviventes nos anos de 1992, 1997 e 2007, e como houve aumento da sobrevivência no último período, todas as RNA apresentaram a mesma tendência após 33 anos da colheita florestal. Mas analisando a taxa anual de sobrevivência, todos os modelos testados seguiram a tendência dos dados observados, primeiro com o aumento da sobrevivência após a exploração e segundo com a diminuição contínua da sobrevivência, isso só foi possível por causa da elevada taxa de acerto das redes neurais na classificação da sobrevivência.




Figure 3. Sobrevivência (árvores ha⁻¹) e taxa de sobrevivência anual (árvore ha⁻¹ ano⁻¹) observadas e estimadas ao longo do tempo após a colheita de madeiras. Valores em parênteses representam os anos após a colheita florestal.

Figure 3. Survival (trees ha⁻¹) and annual survival rate (tree ha⁻¹ year⁻¹) observed and estimated over time after harvesting wood. Values in parentheses represent the years after the forest harvest.

A elevação da sobrevivência no início do período após a colheita florestal foi devido a abertura do dossel que aumentou o crescimento das árvores e a diminuiu a taxa de sobrevivência ao longo do tempo foi causada pelo fechamento contínuo do dossel (Reis et al., 2016, 2015).

Apesar das variáveis contínuas de entrada das redes não apresentarem correlação com os percentuais de sobrevivência e mortalidade, a sua taxa de acerto foi devido as variáveis categóricas, como demonstrado por Reis et al. (2016) que apresentaram influência significativa

em relação ao crescimento, como por exemplo, iluminação de copa (Gustafsson et al., 2016), infestação de Cipó (Campanello et al., 2007; Reis et al., 2015); a classe de floresta, representadas pelos diferentes tamanhos de clareira (Stan e Daniels, 2014), grupos de crescimento (Azevedo et al., 2008; Valle et al., 2007) e danos e podridão que podem ser causados ou não decorrentes de atividades de colheita que também contribuem para a mortalidade em povoamentos florestais (Vanclay, 1994), corroborando o uso dessas variáveis na modelagem de florestas inequiâneas.

5. Conclusões

Redes neurais artificiais são eficientes para prognosticar a sobrevivência de árvores individuais após a colheita florestal, com taxas de acerto acima de 99% e coeficiente Kappa superior a 55%, sendo indicado o uso das RNA para prognosticar a taxa de sobrevivência anual e a distribuição de diâmetros ao final do ciclo de corte, servindo assim em florestas colhidas na Amazônia.

Agradecimentos

À Capes pela concessão de bolsas ao autor e a Embrapa Amazônia Oriental pela concessão de dados de monitoramento de parcelas permanentes e ao apoio financeiro do projeto Segundo Ciclo de Corte: EMBRAPA - 03.12.00.030.00.00 e CNPq 483831/2011-5.

Referências bibliográficas

- Alvares, C.A., Stape, J.L., Sentelhas, P.C., De Moraes Gonçalves, J.L., Sparovek, G., 2013. Koppen's climate classification map for Brazil. *Meteorol. Zeitschrift* 22, 711–728. doi:10.1127/0941-2948/2013/0507
- Ashraf, M.I., Meng, F.-R., Bourque, C.P. -a., MacLean, D. a., 2015. A Novel Modelling Approach for Predicting Forest Growth and Yield under Climate Change. *PLoS One* 10, e0132066. doi:10.1371/journal.pone.0132066
- Azevedo, C.P. De, Sanquetta, C.R., Silva, J.N.M., Machado, S.A., Souza, C.R., Oliveira, M.M. De, 2008. Simulação de estratégias de manejo florestal na Amazônia com o uso do modelo SYMFOR. *Acta Amaz.* 38, 51–70. doi:10.1590/S0044-59672008000100007
- Campanello, P.I., Garibaldi, J.F., Gatti, M.G., Goldstein, G., 2007. Lianas in a subtropical

- Atlantic Forest: Host preference and tree growth. *For. Ecol. Manage.* 242, 250–259. doi:10.1016/j.foreco.2007.01.040
- Castro, R.V.O., Soares, C.P.B., Leite, H.G., Souza, A.L., Martins, F.B., Nogueira, G.S., Romarco, M. L. O., 2015. Artificial Neural Networks Effectiveness to Estimate Mortality in a Semi-Deciduous Seasonal Forest. *Aust. J. Basic Appl. Sci.* 9, 435–444.
- Cohen, J., 1960. A coefficient of agreement for nominal scales. *Educ. Psychol. Meas.* 20, 37–46. doi:10.1177/001316446002000104
- Costa Filho, P., Costa, H., Aguiar, O., 1980. Exploração mecanizada da floresta tropical úmida sem babaçu. Embrapa-CPATU. *Circ. técnico* 9, 29.
- Diamantopoulou, M.J., 2005. Artificial neural networks as an alternative tool in pine bark volume estimation. *Comput. Electron. Agric.* 48, 235–244. doi:10.1016/j.compag.2005.04.002
- Farrior, C.E., Bohlman, S. a, Hubbell, S., Pacala, S.W., 2016. Dominance of the suppressed: Power-law size structure in tropical forests. *Science* (80-.). 351, 155–157. doi:10.1126/science.aad0592
- Glover, G.R., Hool, J.N., 1979. A Basal Area Ratio Predictor of Loblolly Pine Plantation Mortality. *For. Sci.* 25, 275–282.
- Guan, B.T., Gertner, G., 1991a. Modeling red pine tree survival with an artificial neural network. *For. Sci.* 37, 1429–1440.
- Guan, B.T., Gertner, G., 1991b. Using a parallel distributed processing system to model individual tree mortality. *For. Sci.* 32, 871–885.
- Gustafsson, M., Gustafsson, L., Alloysius, D., Falck, J., Yap, S., Karlsson, A., Ilstedt, U., 2016. Life history traits predict the response to increased light among 33 tropical rainforest tree species. *For. Ecol. Manage.* 362, 20–28. doi:10.1016/j.foreco.2015.11.017
- King, S.L., Bennett, K.P., List, S., 2000. Modeling noncatastrophic individual tree mortality using logistic regression , neural networks , and support vector methods. *Comput. Electron. Agric.* 27, 401–406.

- Landis, J.R., Koch, G.G., 1977. The Measurement of Observer Agreement for Categorical Data. *Biometrics* 33, 159–174. doi:10.2307/2529310
- Moisen, G.G., Frescino, T.S., 2002. Comparing five modelling techniques for predicting forest characteristics. *Ecol. Modell.* 157, 209–225. doi:10.1016/S0304-3800(02)00197-7
- Phillips, P.D., Brash, T.E., Yasman, I., Subagyo, P., van Gardingen, P.R., 2003. An individual-based spatially explicit tree growth model for forests in East Kalimantan (Indonesian Borneo). *Ecol. Modell.* 159, 1–26. doi:10.1016/S0304-3800(02)00126-6
- Phillips, P.D., De Azevedo, C.P., Degen, B., Thompson, I.S., Silva, J.N.M., Van Gardingen, P.R., 2004. An individual-based spatially explicit simulation model for strategic forest management planning in the eastern Amazon. *Ecol. Modell.* 173, 335–354. doi:10.1016/j.ecolmodel.2003.09.023
- Reis, L.P., de Souza, A.L., Mazzei, L., dos Reis, P.C.M., Leite, H.G., Soares, C.P.B., Torres, C.M.M.E., da Silva, L.F., Ruschel, A.R., 2016. Prognosis on the diameter of individual trees on the eastern region of the amazon using artificial neural networks. *For. Ecol. Manage.* 382, 161–167. doi:10.1016/j.foreco.2016.10.022
- Reis, L.P., dos Reis, P.C.M., Ruschel, A.R., Silva, J.N.M., de Carvalho, J.O.P., de Souza, A.L., Soares, M.H.M., Miyahara, R.K.N., 2015. Forest dynamics in the eastern Amazon with special reference to sapotaceae species. *Floresta* 45, 567–576. doi:10.5380/ufv.v45i3.35947
- Reis, L.P., Ruschel, A.R., Coelho, A.A., Luz, A.S. Da, Martins-da-Silva, R.C.V., 2010. Avaliação do potencial madeireiro na Floresta Nacional do Tapajós após 28 anos da exploração florestal. *Pesqui. Florest. Bras.* 30, 265–281. doi:10.4336/2010.pfb.30.64.265
- Richards, M., McDonald, A.J.S., Aitkenhead, M.J., 2008. Optimisation of competition indices using simulated annealing and artificial neural networks. *Ecol. Modell.* 214, 375–384. doi:10.1016/j.ecolmodel.2008.03.008
- Rubin, B.D., Manion, P.D., Faber-Langendoen, D., 2006. Diameter distributions and structural sustainability in forests. *For. Ecol. Manage.* doi:10.1016/j.foreco.2005.10.049
- Silva, I.N., Spatti, D.H., Flauzino, R.A., 2010. *Redes Neurais Artificiais: Para Engenharia e Ciências Aplicadas*. ARTLIBER, São Paulo.

- Stage, A., 1973. Prognosis model for stand development, USDA for Serv. Res. Pap. INT-137. Washington, DC. doi:10.5962/bhl.title.69018
- Stan, A.B., Daniels, L.D., 2014. Growth releases across a natural canopy gap-forest gradient in old-growth forests. *For. Ecol. Manage.* 313, 98–103. doi:10.1016/j.foreco.2013.11.004
- StaSoft Inc, 2016. StatSoft [WWW Document]. *Stat. Data Anal. Softw. Syst.* 13. URL <http://www.statsoft.com/>
- Valle, D., Phillips, P., Vidal, E., Schulze, M., Grogan, J., Sales, M., van Gardingen, P., 2007. Adaptation of a spatially explicit individual tree-based growth and yield model and long-term comparison between reduced-impact and conventional logging in eastern Amazonia, Brazil. *For. Ecol. Manage.* 243, 187–198. doi:10.1016/j.foreco.2007.02.023
- Vanclay, J.K., 1994. Modelling forest growth and yield: applications to mixed tropical forests. *Model. For. growth yield Appl. to Mix. Trop. For.* 312pp.
- Wernsdörfer, H., Rossi, V., Cornu, G., Oddou-Muratorio, S., Gourlet-Fleury, S., 2008. Impact of uncertainty in tree mortality on the predictions of a tropical forest dynamics model. *Ecol. Modell.* 218, 290–306. doi:10.1016/j.ecolmodel.2008.07.017

ARTIGO IV

PROGNOSE DA DISTRIBUIÇÃO DE DIÂMETROS NO LESTE DA AMAZÔNIA UTILIZANDO REDES NEURAS ARTIFICIAIS

Resumo

A análise da distribuição de diâmetros é imprescindível no manejo florestal por subsidiar a avaliação dos estoques remanescentes e de colheita de madeira. Este trabalho teve por objetivo projetar a distribuição diamétrica utilizando redes neurais artificiais (RNA) e autômatos celulares (AC). Em 1979 foi realizada a colheita seletiva, com intensidade de $72,5 \text{ m}^3 \text{ ha}^{-1}$ em uma área de 64 ha na Floresta Nacional do Tapajós – PA. Na projeção da distribuição, foram empregadas RNA como regra de evolução de AC, considerando a probabilidade de árvores da projeção e suas vizinhas mais próximas. A projeção em todos os períodos analisados não apresentou diferença estatística a 5% de significância em relação à observada, demonstrando que a projeção seguiu a tendência da dinâmica da distribuição. As RNA e AC são eficientes e devem ser utilizadas para projetar a distribuição diamétrica ao longo do ciclo de corte.

Palavras-Chave: Inteligência artificial, Manejo Florestal, Modelagem.

PROGNOSIS OF DISTRIBUTION OF DIAMETERS IN THE EAST OF AMAZONIA USING ARTIFICIAL NEURAL NETWORKS

Abstract

The analysis of the distribution of diameters is indispensable in forest management for subsidizing the evaluation of the remaining stocks and of wood harvest. This work aimed to design the diametric distribution using artificial neural networks (ANNs) and cellular automata (CA). In 1979 the selective harvest was performed with an intensity of $72.5 \text{ m}^3 \text{ ha}^{-1}$ in an area of 64 ha in the Tapajós National Forest - PA. In the projection of the distribution, ANNs were used as a rule of CA evolution, considering the probability of trees of the projection and their closest neighbors. The projection in all the analyzed periods showed no statistical difference at 5% of significance in relation to the observed, demonstrating that the projection followed the tendency of the dynamics of distribution. ANNs and CA are efficient and should be used to design the diametric distribution during the cutting cycle.

Keywords: Artificial intelligence, Forest management, Modeling.

1. Introdução

A expansão agropecuária e as mudanças climáticas se tornaram importantes agentes de perturbação na bacia amazônica. As interações entre o desmatamento, incêndios e à seca potencialmente levam a perdas de armazenamento de carbono e mudanças nos padrões de precipitação regionais e vazão dos rios (Davidson et al., 2012). A conversão de terras para a agropecuária é a principal força destrutiva das florestas tropicais no mundo e na Amazônia foi responsável por desmatar 11.000 km², somente em 2007, diminuindo para 5.900 km², em 2013 (Swann et al., 2015), e em menor proporção está a exploração seletiva ilegal de madeira, que não realiza a conversão da terra, mas funciona como inicialização de desflorestamento (Asner et al., 2005), se não forem aplicadas técnicas adequadas de manejo aliada à falta de comando e controle do Estado.

Em 2011, foram destinados 403 milhões de hectares de floresta tropical no mundo para a produção de madeira (Putz et al., 2012). Mais de 100 publicações revelaram que a exploração seletiva de madeiras dentro de um sistema de manejo florestal adequado mantém substancialmente a biodiversidade (85-100%), carbono (76%) (Putz et al., 2012) e estoques de madeira (88%), após a colheita (Reis e al., 2010), e que os rendimentos aumentam se for utilizada a exploração de impacto reduzido e tratamentos silviculturais (Putz et al., 2012).

A sustentabilidade do manejo florestal não é comprometida se a intensidade de corte não ultrapassar a capacidade de recuperação do estoque remanescente, em um determinado tempo planejado. Na determinação da intensidade e ciclo de corte, os modelos de crescimento e produção são fundamentais, posto que projetam o estoque remanescente e estimam o estoque futuro, utilizando informações de crescimento, ingresso e mortalidade. A problemática na construção de modelos em florestas tropicais está nos padrões essencialmente estocásticos da dinâmica florestal que dificulta a modelagem (Fox et al., 2001), principalmente para grandes períodos de tempo, pelo menos 30 anos (Brasil, 2006).

A modelagem de crescimento e produção florestal abrange desde modelos estatísticos simples de povoamento, pela relação do diâmetro ou altura média com a idade do povoamento, até modelos que utilizam as distâncias entre árvores, índices de sítio e área basal do povoamento para empiricamente simular a competição entre árvores por água, luz e nutrientes (Vanclay, 1994).

Os modelos de distribuição diamétrica estimam a densidade (árvores ha⁻¹) por classe de diâmetro nas idades presentes e futuras. Fundamentam-se em funções de densidade de probabilidade (fdp), como a função Weibull e matrizes de probabilidade (transição). A matriz de transição é a técnica mais empregada em florestas inequiâneas na Amazônia para prognose

da estrutura diamétrica (Teixeira et al., 2007; Vasconcelos et al., 2009). Entretanto, essa técnica não considera as mudanças da mortalidade ao longo do tempo e a passagem de árvores entre as classes, e fica restrita ao período considerado na construção da matriz (Spathelf & Durlo, 2001).

Uma alternativa na prognose da estrutura diamétrica é o uso da inteligência artificial como as Redes Neurais Artificiais (RNA) e autômatos celulares (AC) na área florestal. As RNA são modelos computacionais inspirados no sistema nervoso dos seres vivos. Formam um conjunto de unidades de processamento paralelo, caracterizadas por neurônios artificiais que são interligados por um grande número de interconexões, que tem a propensão para armazenar conhecimento experimental e torná-lo disponível para o uso (Haykin, 2001; Silva et al., 2010).

Isso torna a RNA uma ferramenta adequada para a prognose de florestas manejadas pelas suas propriedades e capacidades inerentes como: não-linearidade, característica importante para a análise da dinâmica florestal, por ser inerentemente não-linear; capacidade de aprendizagem, entendimento de relacionamento entre as diversas variáveis que compõe a rede; habilidades de generalização, capacidade de aplicar o conhecimento aprendido no treinamento em dados desconhecidos; adaptabilidade, adapta seus pesos sinápticos a modificações do meio ambiente; e organização de dados, organização interna visando possibilitar o agrupamento de padrões que apresentam particularidades em comum (Haykin, 2001; Silva et al., 2010).

A aplicação de RNA na área florestal tem ganhado alta relevância por apresentar resultados de sucesso, como por exemplo: modelagem da distribuição diamétrica (Leduc et al., 2001; Diamantopoulou et al., 2015), otimização de índice de competição (Richards et al., 2008), estimar o volume de árvores (Binoti et al., 2014), predição de incêndios florestais na Amazônia (Maeda et al., 2009), classificação de estágios sucessionais na Amazônia (Kuplich, 2009), estimar a altura de árvores (Diamantopoulou, 2012), modelagem da mortalidade de árvore individual em floresta inequiânea (Castro et al., 2015) e prognose da produção de povoamento equiâneo (Binoti et al., 2015).

Já AC são sistemas de interações locais, discretos no tempo e no espaço, compostos de células, sendo o estado de cada célula é resultado de seu estado atual, da sua regra de transição para outras células e da sua interação com células vizinhas (Ilachinski, 2001). A AC foi utilizada na prognose de taxa de desflorestamento na Amazônia (Soares-Filho et al., 2006), análise de interações locais com a estrutura da comunidade florestal (Scanlon et al., 2007), planejamento florestal (Mathey et al., 2008), estratégia de política de conservação (Mondal & Southworth, 2010) e na prognose da distribuição diamétrica em povoamento equiâneo (Binoti et al., 2012; Binoti et al., 2013).

Como áreas significativas de florestas nativas na Amazônia vêm sendo suprimidas para usos alternativos da terra, apoiar técnicas que viabilizam o manejo florestal, que mantém a floresta em pé, são de fundamental importância na tomada de decisões sustentáveis. Portanto, o objetivo foi empregar autômatos celulares com regra de evolução em redes neurais artificiais para projetar a distribuição diamétrica em floresta colhida, servindo como tomada de decisão em manejo florestal sustentável na Amazônia brasileira.

2. Material e métodos

2.1. Área de estudo

A área de estudo está localizada na Floresta Nacional do Tapajós, à altura do Km 67 (55° 00' W, 2° 45' S) da Rodovia BR-163, Cuiabá-Santarém. Insere-se no bioma Amazônia e a tipologia é Floresta Ombrófila Densa de terra firme (Costa Filho et al., 1980).

O clima da região é tropical úmido com temperatura média anual de 25 °C, classificado como Ami pelo sistema de Köppen. A umidade relativa média é de 86% e a precipitação média anual é de 2.100 mm. Apresenta topografia plana a ondulada, com ocorrência de solo tipo Latossolo Amarelo Distrófico (Costa Filho et al., 1980).

Na Floresta Nacional do Tapajós e particularmente na área de estudo, Costa Filho et al. (1980) mencionam a exploração de quatro espécies de alto valor comercial: pau-rosa (*Aniba roseodora* Ducke), maçaranduba (*Manilkara huberi* (Ducke) A. Chev.), freijó (*Cordia goeldiana* Huber) e cedro (*Cedrela odorata* L.) na década de 1940.

Em 64 ha da área de estudo, em 1975, foi realizado um inventário a 100% de intensidade das espécies madeireiras com DAP ≥ 15 cm e, posteriormente, em 1979, realizada exploração de 64 espécies madeireiras, as quais acumularam em média um volume colhido de 72,5 m³ ha⁻¹ (Costa Filho et al., 1980).

Em 1981 foram instaladas, aleatoriamente, 36 parcelas permanentes (50 m x 50 m). Nessas parcelas, todas as árvores com DAP ≥ 5 cm foram identificadas botanicamente *in loco* e material botânico depositado no Herbário IAN da Embrapa Amazônia Oriental. Realizaram-se remedições nas parcelas permanentes em 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 e 2012.

2.2. Autômato celular e Redes Neurais Artificiais

Para um modelo unidimensional de AC, o valor i da célula no tempo t , denominado por $c_i(t)$, evolui de acordo com a regra F que é função do $c_i(t)$ e das outras células que se encontram

dentro da extensão r (para ambas as direções) de $c_i(t)$ (Ilachinski, 2001; Binoti et al., 2013), conforme a equação (1).

$$C_i(t) = F(C_{i-r}(t-1), \dots, C_{i+r}(T+1)) \quad (1)$$

Os autômatos celulares utilizados foram os unidimensionais com raio 2 ($r=2$), com isso cada célula possui 4 vizinhos, dois vizinhos à esquerda e dois vizinhos à direita, além da própria célula que será atualizada. Cada célula corresponde a uma classe diamétrica de amplitude de 5 cm, árvores com diâmetro igual ou superior a 62,5 cm foram agrupadas na última classe diamétrica. A probabilidade de ocorrência de árvores em cada classe corresponde o estado da célula.

Na construção da regra de evolução do AC foram treinadas 300 redes neurais artificiais, utilizando seis variáveis de entrada: estado atual da célula; estado das células contidas na extensão da sua vizinhança; e o período de tempo entre as medições, em anos. A variável de saída foi o estado futuro da célula. A projeção da densidade (árvores ha^{-1}) foi realizada por meio de RNA, sendo as variáveis de entrada: densidade atual, densidade futura e período entre as medições, em anos.

Os dados foram separados em dados de treinamento e de teste, 80% e 20%, respectivamente, perfazendo 29 parcelas para treinamento e sete parcelas para o teste do modelo. Os dados de teste/validação não fizeram parte do treinamento/calibração das RNA.

No treinamento foi utilizada a arquitetura *feedforward* de camadas múltiplas, o Perceptron multicamadas (MLP). Para o treinamento foi utilizada a ferramenta *Intelligent Problem Solver* (IPS) do software Statistica 13 (StaSoft Inc, 2016) para a escolha das funções de ativação (Identidade, Logística, Tangente hiperbólica e exponencial) da camada intermediária e de saída. No treinamento foi utilizado somente uma camada oculta e o intervalo do número de neurônios nessa camada foi definido pelo método de Fletcher-Gloss, definindo um intervalo do número de neurônios, de acordo com o número de variáveis de entrada e saída, calculado pela equação (2).

$$2 \cdot \sqrt{n} + n_2 \leq n_1 \leq 2 \cdot n + 1 \quad (2)$$

Sendo n o número de entradas da rede, n_1 é a quantidade de neurônios na camada escondida e n_2 é a quantidade de neurônios na camada de saída.

No treinamento foram retidas cinco redes, escolhidas pela correlação entre os valores estimados e reais. Para a escolha e comparação das RNA a serem usadas na prognose foram avaliadas, no treinamento e generalização, a estatística de correlação entre os valores estimados e reais ($r_{Y\hat{Y}}$) e a raiz quadrada do erro quadrático médio (RQEQM).

A correlação indica a intensidade da relação entre os valores estimados e observados e quanto mais próxima de 1, maior a correlação entre as variáveis. Para calcular a correlação utilizou-se a equação (3).

$$r_{Y\hat{Y}} = \frac{Cov(Y, \hat{Y})}{\sqrt{S^2(Y)S^2(\hat{Y})}} \quad (3)$$

Sendo, \hat{Y} = valores estimados pelas RNA; Y= valores observados nas parcelas permanentes; S^2 = variância; e Cov. = covariância.

A raiz quadrada do erro quadrático médio (RQEQM) utilizada para comparar as RNA, indica que quanto menor a estimativa mais confiável é o treinamento ou generalização, sendo calculada pela equação (4).

$$RQEQM = 100. \bar{Y}^{-1} \sqrt{n^{-1} \sum_{i=1}^n (Y_i - \hat{Y})^2} \quad (4)$$

Sendo, \hat{Y} : valores estimados pelas RNA; Y: valores observados nas parcelas permanentes; n: número de observações.

Depois da escolha da melhor rede foi realizada a projeção da distribuição diamétrica, utilizando os dados das parcelas de validação do modelo, começando pelo primeiro ano de medição (1981) até o último ano de mediação (2012). A significância estatística entre as distribuições diamétricas projetadas e observadas foi avaliada pelo teste de aderência Kolmogorov-Smirnov (K-S), a 5% de significância, dada pela equação (5).

$$D_{cal} = Max|F_o(x) - F_e(x)| \quad (5)$$

Sendo, $F_o(x)$ = frequência acumulada observada; $F_e(x)$ = frequência acumulada projetada; e n= número de observações.

O valor de D_{tab} para 5% de significância foi obtido pela equação (6).

$$D_{tab} = \frac{1,35}{\sqrt{n}} \quad (6)$$

Em que, D_{tab} = valor crítico a 5% de significância.

N = número de observações.

Se $D_{calc} < D_{tab}$: aceita-se H_0 (distribuição observada é igual à projetada).

Se $D_{calc} \geq D_{tab}$: rejeita-se H_0 (distribuição observada não é igual à projetada).

3. Resultados e Discussão

No treinamento e teste de 300 RNA foram escolhidas as cinco melhores redes, que apresentaram coeficiente de correlação acima de 99% e o erro abaixo de 17% (Tabela 1). Esse resultado demonstrou que o ajustamento foi realizado com precisão e corrobora com os resultados obtidos por Binoti et al. (2013) para florestas equiâneas.

Tabela 1. Resultados estatísticos do treinamento e teste de Redes Neurais Artificiais (RNA) utilizadas como regra de evolução em Autômatos Celulares (AC). $r_{Y\hat{Y}}$: Coeficiente de correlação; RQEQM: raiz quadrada do erro quadrático médio.

Table 1. Statistical results of the training and test of Artificial Neural Networks (ANN) used as evolution rule in Cellular Automata (CA). $r_{Y\hat{Y}}$: correlation coefficient; RMSE: root mean square error.

RNA	Arquitetura	Treinamento		Teste		Funções de ativação	
		$r_{Y\hat{Y}}$	RQEQM (%)	$r_{Y\hat{Y}}$	RQEQM (%)		
1	MLP 6-10-1	0,9963	15,4582	0,9976	12,9526	Logística	Exponencial
2	MLP 6-9-1	0,9964	15,3063	0,9975	13,2112	Logística	Logística
3	MLP 6-11-1	0,9963	15,4641	0,9975	13,2261	Tangencial	Logística
4	MLP 6-9-1	0,9960	16,1205	0,9976	13,0323	Logística	Exponencial
5	MLP 6-9-1	0,9963	15,5412	0,9975	13,2189	Tangencial	Exponencial

As redes neurais artificiais treinadas podem ser obtidas através do contato com o autor pelo email: leonardopequenoreis@gmail.com

A RNA 1 obteve o melhor ajuste, por apresentar RQEQM do teste mais baixo, demonstrando maior capacidade de generalização, conforme recomenda Silva et al. (2010). Essa RNA não apresentou excessiva memorização dos dados (*overfitting*), e, portanto, foi escolhida para projetar a distribuição diamétrica no tempo a partir dos dados da primeira medição.

Para exemplificar a transição, utilizando RNA e AC, foi escolhida aleatoriamente uma parcela (pp 10) dos dados da validação (Tabela 2). Tomando como exemplo a classe 32,5cm, no ano $t = 0$ (1981), que apresentava a probabilidade de ocorrer árvores de 0,01, com as vizinhas com probabilidade de 0,04, 0,03, 0,02 e 0,02, respectivamente, as classes 22,5, 27,5, 37,5 e 42,5 cm. Aplicando a regra de transição para $t = 1$, ano de 1982, a probabilidade foi de 0,01.

Tabela 2. Projeção da probabilidade de ocorrência de árvores da distribuição diamétrica usando Redes Neurais Artificiais e Autômatos Celulares (AC) em uma parcela de floresta colhida seletivamente no leste da Amazônia.

Table 2. Projection of the probability of occurrence of the diametric distribution trees using Artificial Neural Networks and Cellular Automata (CA) in a selectively harvested portion of forest in eastern Amazonia.

		Centro de classe (cm)											
Tempo	Ano	7,5	12,5	17,5	22,5	27,5	32,5	37,5	42,5	47,5	52,5	57,5	≥62,5
Probabilidade Observada													
0	1981	0,65	0,13	0,06	0,04	0,03	0,01	0,02	0,02	0,02	0,01	0,00	0,01
1	1982	0,69	0,13	0,05	0,04	0,03	0,01	0,02	0,01	0,02	0,01	0,00	0,01
2	1983	0,70	0,13	0,05	0,03	0,03	0,01	0,01	0,01	0,02	0,01	0,01	0,01
3	1985	0,67	0,15	0,05	0,03	0,03	0,01	0,01	0,00	0,02	0,00	0,01	0,01
4	1987	0,66	0,15	0,06	0,03	0,03	0,02	0,01	0,01	0,01	0,01	0,01	0,00
5	1992	0,60	0,17	0,08	0,05	0,01	0,03	0,01	0,01	0,01	0,01	0,00	0,01
6	1997	0,58	0,16	0,08	0,07	0,02	0,03	0,02	0,02	0,01	0,00	0,01	0,01
7	2007	0,55	0,17	0,11	0,05	0,04	0,01	0,02	0,02	0,01	0,01	0,01	0,02
8	2012	0,57	0,14	0,11	0,05	0,03	0,02	0,01	0,03	0,01	0,01	0,01	0,02
Probabilidade Projetada													
1	1982	0,66	0,14	0,06	0,04	0,03	0,01	0,01	0,01	0,01	0,01	0,01	0,01
2	1983	0,66	0,16	0,07	0,04	0,03	0,01	0,01	0,01	0,01	0,01	0,01	0,01
3	1985	0,62	0,17	0,07	0,04	0,03	0,01	0,01	0,01	0,01	0,01	0,01	0,01
4	1987	0,59	0,18	0,08	0,04	0,03	0,01	0,01	0,01	0,01	0,01	0,01	0,01
5	1992	0,56	0,18	0,09	0,05	0,03	0,02	0,01	0,01	0,01	0,01	0,01	0,01
6	1997	0,55	0,18	0,09	0,06	0,04	0,02	0,01	0,01	0,01	0,01	0,01	0,01
7	2007	0,56	0,17	0,09	0,05	0,03	0,02	0,02	0,01	0,01	0,01	0,01	0,01
8	2012	0,55	0,17	0,09	0,06	0,04	0,02	0,02	0,01	0,01	0,01	0,01	0,01

A distribuição diamétrica projetada ao longo do tempo (Tabela 3), utilizando as parcelas escolhidas aleatoriamente para a validação das RNA, não diferiram significativamente a 5% de probabilidade da distribuição diamétrica observada ao longo de 30 anos (1982, 1983, 1985, 1987, 1992 1997, 2007 e 2012).

Tabela 3. Projeção da probabilidade de ocorrência de árvores da distribuição diamétrica usando Redes Neurais Artificiais e Autômatos Celulares (AC) em uma floresta colhida seletivamente no leste da Amazônia.

Table 3. Projection of the probability of occurrence of the diametric distribution trees using Artificial Neural Networks and Cellular Automata (CA) in a selectively harvested forest in eastern Amazon.

CC	1982		1983		1985		1987		1992		1997		2007		2012	
	Ob	Est	Ob	Est	Ob	Est	Ob	Est	Ob	Est	Ob	Est	Ob	Est	Ob	Est
7,5	0,6	0,6	0,6	0,6	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5
12,5	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1
17,5	0,0	0,1	0,0	0,1	0,0	0,1	0,0	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,0	0,1
22,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
27,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
32,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
37,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
42,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
47,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
52,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
57,5	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
≥62,	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Dcal.	0,019		0,028		0,028		0,025		0,027		0,029		0,020		0,038	
Dtab.	0,041		0,039		0,039		0,039		0,041		0,042		0,041		0,040	

Exemplificando o resultado em duas parcelas da validação (Figura 1) pode-se verificar que a projeção usando RNA e AC segue a tendência em todo o ciclo de corte dos valores observados, sem apresentar desvios da forma de exponencial negativa da floresta.

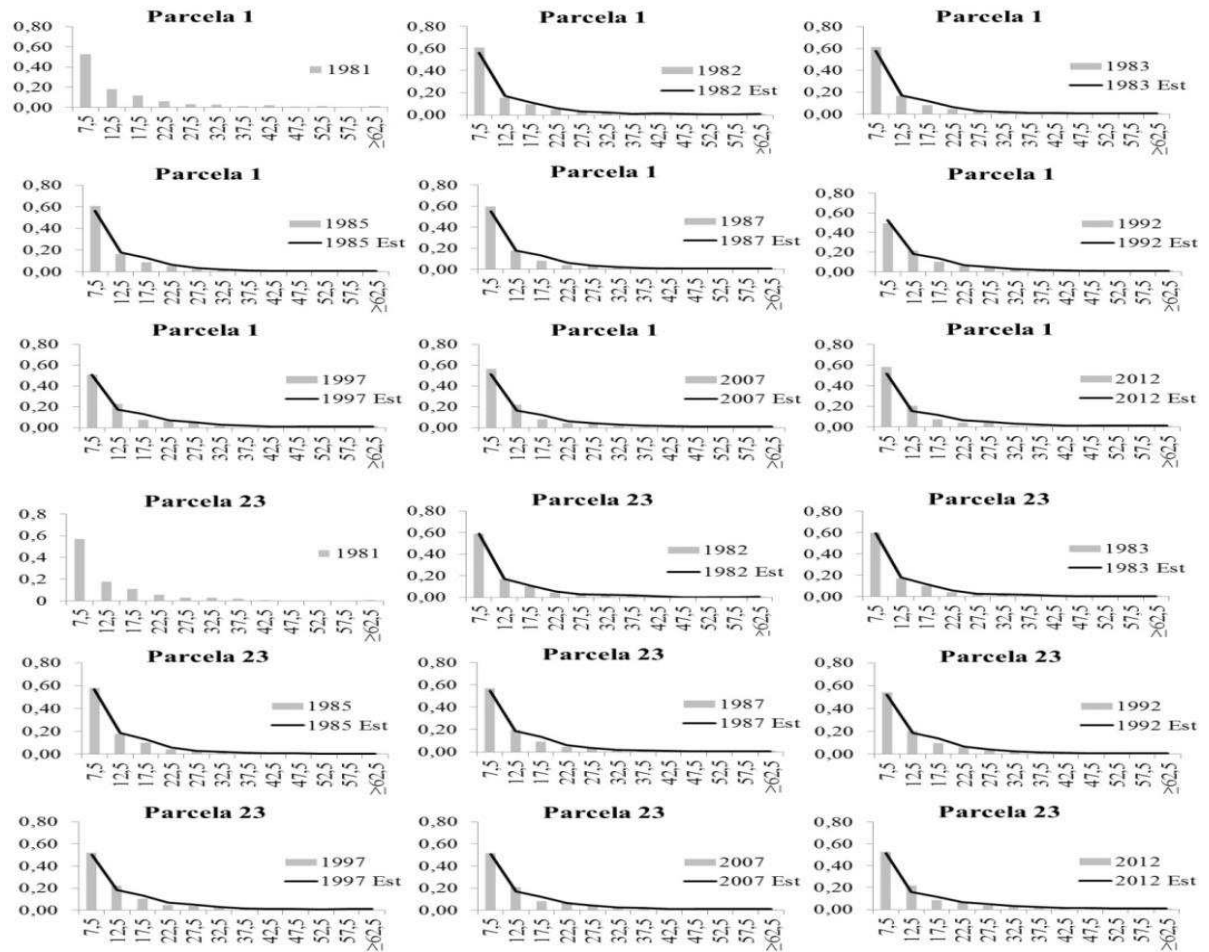


Figura 1. Projeção da probabilidade de árvores na distribuição diamétrica utilizando Redes Neurais Artificiais e Autômatos Celulares (AC) em uma floresta colhida seletivamente no leste da Amazônia. Eixo x: Centro de classe de diâmetro (cm); Eixo y: Probabilidade de árvores.

Figure 1. Projection of the probability of trees in the diametric distribution using Artificial Neural Networks and Cellular Automata (CA) in a selectively harvested forest in eastern Amazonia. X-axis: diameter class Center (cm); Y-axis: Probability of trees.

A floresta estudada apresentou distribuição diamétrica ao longo de 31 anos na forma de J-invertido, típica de florestas tropicais. Essa tendência é comum em florestas sem intensas perturbações, com maior número de indivíduos nas menores classes de diâmetros, que sustenta essa forma de exponencial negativa (Rubin et al., 2006). Isso indica que a densidade das menores árvores sustenta a população das maiores árvores (Rubin et al., 2006).

A complexidade de projetar a distribuição diamétrica depois de colheita seletiva ocorre por causa da intensidade de corte maior nas classes de 60 a 80 cm (Reis et al., 2014), o que afeta a dinâmica da floresta, por abrir clareiras artificiais, alterando o crescimento das espécies

(Carvalho et al., 2004) e, conseqüentemente, mudando a probabilidade de passagem de árvores entre as classes e a mortalidade. Apesar da alteração que ocorre ao longo do tempo na estrutura, a projeção da distribuição diamétrica, por aplicação de RNA e AC, seguiu a tendência da complexa dinâmica florestal após a colheita seletiva de madeiras sem apresentar desvios na forma da distribuição (Tabela 3).

Alguns trabalhos que projetaram a distribuição diamétrica baseados em cadeia probabilística de Markov na Floresta Amazônica e Mata Atlântica, também descreveram que as estruturas diamétricas observadas e projetadas não diferiram entre si, mas usando pequenos períodos de tempo, até 15 anos, conseqüentemente servindo para o planejamento no curto prazo (Teixeira et al., 2007; Vasconcelos et al., 2009; Souza et al., 2014; Dalla Lana, 2015), o que difere muito de projetar um ciclo de corte completo de 30 anos, como o apresentado pela utilização da RNA e AC. Osazuwa-Peters et al. (2015) destacaram em estudo de 45 anos em floresta tropical, a importância de entender a dinâmica a longo prazo após o corte seletivo. Portanto, modelos que representam a dinâmica por um período longo servem como a melhor ferramenta para o planejamento da conservação de ecossistemas.

Apesar de não incluir diretamente no modelo a mortalidade e o recrutamento, como recomendado na modelagem de florestas inequidâneas (Vanclay, 1994; Rossi et al., 2007a; Rossi et al., 2007b), o uso da RNA e AC apresentou estimativas precisas na projeção. Isso pode ser atribuído à relação da classe (célula) alvo com as células vizinhas e o período de tempo decorrido. Rubin et al. (2006) e Reis et al. (2014) ressaltaram que a distribuição diamétrica possibilita inferir sobre ingresso, mortalidade e histórico de desenvolvimento das espécies arbóreas, bem como avaliar a intensidade de perturbações que ocorreram na comunidade florestal, isso demonstra que essas relações foram captadas pela RNA.

Como a floresta estudada chegou ao ciclo de corte praticado na Amazônia, usando corte seletivo, de 20 a 40 anos (Phillips et al., 2004; Azevedo et al., 2008), a técnica de projeção pode ser usada como um importante instrumento no manejo de florestas nativas como guia para determinar ciclos de corte e intensidades de corte na Amazônia em florestas de terra firme.

Os resultados demonstraram que a técnica proposta pode ser adotada no planejamento de longo prazo, ideal para o manejo florestal sustentável, que ocorre em períodos maiores que outras atividades econômicas, diminuindo a insegurança quanto à recuperação do estoque após a colheita florestal, servindo como base para o manejador quanto a aplicação de tratamentos silviculturais em diferentes parcelas, ou unidades de trabalho, já que a projeção pode ser realizada em pequenas unidades.

4. Conclusões

A projeção da distribuição de diâmetros após a colheita de madeiras pode ser realizada com exatidão, utilizando redes neurais artificiais e autômatos celulares, ao longo do ciclo de corte, na Amazônia.

Agradecimentos

À Capes pela concessão de bolsas ao autor e a Embrapa Amazônia Oriental pela concessão de dados de monitoramento de parcelas permanentes e ao apoio financeiro do projeto Segundo Ciclo de Corte: EMBRAPA - 03.12.00.030.00.00 e CNPq 483831/2011-5.

Referências bibliográficas

Asner GP, Knapp D, Broadbent EN, Oliveira PJC; Keller M, Silva JNM. Selective logging in the Brazilian Amazon. *Science* 2005; 310 (5747): 480-482.

Azevedo CP, Sanquetta CR, Silva JNM, Machado SA, Souza CR, Oliveira MM. Simulação de estratégias de manejo florestal na Amazônia com o uso do modelo SYMFOR. *Acta Amazonica* 2008; 38 (1): 51-70.

Binoti DHB, Binoti MLMS, Leite HG, Silva AAL, Albuquerque AC. Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais. *Cerne* 2013; 19 (4): 677-685.

Binoti DHB, Binoti MLMS, Leite HG, Silva A, Santos ACA. Modelagem da distribuição diamétrica em povoamentos de eucalipto submetidos a desbaste utilizando autômatos celulares. *Revista Árvore* 2012; 36 (5): 931-940.

Binoti MLMS, Binoti DHB, Leite HG, Garcia SLR, Ferreira MZ, Rode R, Silva AAL. Redes neurais artificiais para estimação do volume de árvores. *Revista Árvore* 2014; 38 (2): 283-288.

Binoti MLMS, Leite HG, Binoti DHB, Gleriani JM. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. *Cerne* 2015; 21 (1): 97-105.

BRASIL. *IN 05/2006 como a resolução CONAMA N 406 do MMA*. 2006.

Carvalho JOP, Silva JNM, Lopes JCA. Growth rate of a terra firme rain forest in Brazilian Amazonia over an eight-year period in response to logging. *Acta Amazonica* 2004; 34 (2): 209-217.

Castro RVO, Soares CPB, Leite HG, Souza AL, Martins FB, Nogueira GS, Romarco MLO. Artificial neural networks effectiveness to estimate mortality in a Semi-deciduous Seasonal Forest. *Australian Journal of Basic and Applied Sciences* 2015; 9 (5) 435-444.

Costa Filho PP, Costa HB, Aguiar OR. *Exploração mecanizada da floresta tropical, úmida sem babaçu*. Belém: Embrapa Amazônia Oriental, 1980. (Embrapa-CPATU. Circular técnico 9).

Dalla Lana M, Netto Péllico S, Corte APD, Sanquetta CR, Ebling AA. Prognose da Estrutura Diamétrica em Floresta Ombrófila Mista. *Floram* 2015; 22 (1): 71-78

Davidson EA, Araújo AC, Artaxo P, Balch JK, Brown IF, Bustamante MMC, Coe MT, Defries RS, Keller M, Longo M, Munger JW, Schroeder W, Soares-Filho BS, Souza CM, Wofsy, S. C. The Amazon basin in transition. *Nature* 2012; 481: 321-328.

Diamantopoulou MJ. Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests. *Sustainable Computing: Informatics and Systems* 2012; 2 (4): 190-197.

Diamantopoulou MJ, Ozcelik R, Crecente-Campo F, Eler U. Estimation of Weibull function parameters for modelling tree diameter distribution using least squares and artificial neural networks methods. *Biosystems Engineering* 2015; 133: 33-45.

Fox JC, Ades PW, Bi H. Stochastic structure and individual-tree growth models. *Forest Ecology and Management* 2001; 154 (1-2): 261-276.

Haykin S. *Redes neurais: princípios e práticas*. Porto Alegre: Bookman; 2001.

Ilachinski A. *Cellular automata: a discrete universe*. River Edge: World Scientific; 2001.

Kuplich TM. Classifying regenerating forest stages in Amazônia using remotely sensed images and a neural network. *Forest Ecology and Management* 2006; 234 (1-3): 1-9.

Leduc DJ, Matney TG, Belli KL, Baldwin VC. Predicting diameter distributions of longleaf pine plantations: a comparison between artificial neural networks and other accepted methodologies. *USDA Forest Service, Southern Research Station, Research Paper, SRS-25*, 2001.

Maeda EE, Formaggio AR, Shimabukuro YE, Arcoverde GFB, Hansen MC. Predicting forest fire in the Brazilian Amazon using MODIS imagery and artificial neural networks. *International Journal of Applied Earth Observation and Geoinformation* 2009; 11 (4): 265–272.

Mathey A, Krcmar E, Dragicevic S, Vertinsky I. An object-oriented cellular automata model for forest planning problems. *Ecological modeling* 2008; 212 (3-4): 359-371.

Mondal P, Southworth J. Evaluation of conservation interventions using a cellular automata-Markov model. *Forest Ecology and Management* 2010; 260 (10): 1716-1725.

Osazuwa-Peters OL, Jiménez I, Oberle B, Chapman CA, Zanne AZ. Selective logging: Do rates of forest turnover in stems, species composition and functional traits decrease with time since disturbance?– A 45 year perspective. *Forest Ecology and Management* 2015; 357: 10–21.

Phillips, P.D.; Azevedo C.P., Degen, B., Thompson, I.S., Silva, J.N.M., Van Gardingen P.R. An individual-based spatially explicit simulation model for strategic forest management planning in the eastern Amazon. *Ecological Modelling* 2004; 173 (4): 335-354.

Putz FE, Zuidema PA, Synnott T, Peña-Claros M, Pinard MA, Sheil D, Vanclay JK, Sist P, Gourlet-Fleury S, Griscom B, Palmer J, Sustaining RZ. Conservation values in selectively logged tropical forests: the attained and the attainable. *Conservation Letters* 2012; 5 (4): 296–303.

Reis LP, Ruschel AR, Coelho AA, Luz AS, Martins-Da-Silva RCV. Avaliação do potencial madeireiro na Floresta Nacional do Tapajós após 28 anos da exploração florestal. *Pesquisa Florestal Brasileira* 2010; 30 (64): 265-281.

Reis LP, Ruschel AR, Silva JNM, Reis PCM, Carvalho JOP, Soares MHM. Dinâmica da distribuição diamétrica de algumas espécies de Sapotaceae após exploração florestal na Amazônia Oriental. *Revista de Ciências Agrárias* 2014; 57 (3): 234-243.

- Richards M, McDonald AJS, Aitkenhead MJ. Optimisation of competition indices using simulated annealing and artificial neural networks. *Ecological modelling* 2008; 214 (2-4) 375-284.
- Rossi, L. M. B.; Koehler, H. S.; Sanquetta, C.R.; Arce, J.E. Modelagem de Mortalidade em Florestas Naturais. *Floresta* 2007; 37 (2): 275-291a.
- Rossi LMB, Koehler HS, Arce JE, Sanquetta CR. Modelagem de Recrutamento em Florestas. *Floresta*. *Floresta* 2007; 37 (3): 453-467b.
- Rubin BD, Manion PD, Faber-Langendoen D. Diameter distributions and structural sustainability in forests. *Forest Ecology and Management* 2006; 222 (1-3): 427–438.
- Scanlon T, Caylor K, Levin S, Rodriguez-Iturbe I. Positive feedbacks promote power-law clustering of Kalahari vegetation. *Nature* 2007; 449: 209–212.
- Silva IN, Spatti DH, Flauzin RA. *Redes neurais artificiais: para engenharia e ciências aplicadas*. São Paulo: Artliber; 2010.
- Soares-Filho BS, Nepstad D, Curran L, Voll E, Cerqueira G, Garcia RA, Ramos CA, McDonald A, Lefebvre P, Schlesinger P. Modeling conservation in the Amazon basin. *Nature* 2006; 440: 520-523.
- Souza CR, Azevedo CP, Rossi LMB, Santos J, Higuchi N. Projection of diametric distribution and carbon stock of a managed forest in Manaus/AM. *Floresta* 2014; 44 (3): 525-534.
- Spathelf P, Durlo MA. Transition matrix for modeling the dynamics of a subtropical seminatural forest in southern Brazil. *Forest Ecology and Management* 2001; 151 (1-3): 139-149.
- StaSoft Inc, 2016. StatSoft [WWW Document]. Stat. Data Anal. Softw. Syst. 13. URL <http://www.statsoft.com/>
- Swann ALS, Longo M, Knox RG, Lee E, Moorcroft PR. Future deforestation in the Amazon and consequences for South American climate. *Agricultural and Forest Meteorology* 2015; 214–215: 12–24.

Teixeira LM, Chambers JQ, Silva AR, Lima AJN, Carneiro VMC, Santos J, Higuchi N. Projeção da dinâmica da floresta natural de terra firme, região de Manaus-AM, com o uso da Cadeia de Transição Probabilística de Markov. *Acta Amazonica* 2007; 37 (3): 377-384.

Vanclay JK. *Modelling forest growth and yield: applications to mixed tropical forests*. Oxford: CAB International; 1994.

Vasconcelos SS, Higuchi N, Doliveira MVN. Projeção da distribuição diamétrica de uma floresta explorada seletivamente na Amazônia Ocidental. *Acta Amazonica* 2009; 31 (1): 71-80.

CONCLUSÃO GERAL

A modelagem utilizando redes neurais artificiais para prognosticar o recrutamento, o crescimento, a sobrevivência e a distribuição diamétrica de floresta tropical colhida seletivamente seguiu a tendência dos dados observados, com elevada precisão no recrutamento, no crescimento individual de árvores, na sobrevivência e na distribuição diamétrica, e pode ser utilizada para subsidiar as decisões silviculturais no manejo florestal sustentável na Amazônia.