

PROGNOSE DA DISTRIBUIÇÃO DIAMÉTRICA NA AMAZÔNIA UTILIZANDO REDES NEURAS ARTIFICIAIS E AUTÔMATOS CELULARES

Leonardo Pequeno Reis^{1*}, Agostinho Lopes de Souza², Pamella Caroline Marques dos Reis Reis², Lucas Mazzei³, Daniel Henrique Breda Binoti², Helio Garcia Leite²

^{1*}Instituto de Desenvolvimento Sustentável Mamirauá, Grupo de Pesquisa em Ecologia Florestal, Tefé, AM, Brasil - leonardopequenoreis@gmail.com

²Universidade Federal de Viçosa, Departamento de Engenharia Florestal, Viçosa, MG, Brasil - alsouza@ufv.br; pamellaca@gmail.com; lucas.mazzei@embrapa.br; danielhbbinoti@gmail.com; hgleite@ufv.br

³Embrapa Amazônia Oriental, Belém, PA, Brasil - lucas.mazzei@embrapa.br

Recebido para publicação: 24/05/2017 - Aceito para publicação: 27/02/2018

Resumo

A análise da distribuição diamétrica é imprescindível para o manejo florestal, pois subsidia a avaliação dos estoques remanescentes e de colheita de madeira. Este trabalho teve como objetivo projetar a distribuição diamétrica utilizando redes neurais artificiais (RNA) e autômatos celulares (AC). Em 1979, foi realizada colheita seletiva com intensidade de 72,5 m³ 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 podem ser utilizadas para projetar a distribuição diamétrica ao longo do ciclo de corte.

Palavras-Chave: Inteligência artificial, manejo florestal, modelagem.

Abstract

Prognosis of the diameter distribution in the Amazon by using artificial neural networks and cellular automata. The analysis of the diameter distribution is indispensable for forest management since it subsidizes the assessment of the remaining stocks and of wood harvest. This work aimed to project the diameter distribution by using artificial neural networks (ANN) and cellular automata (CA). In 1979, selective harvest was performed with an intensity of 72.5 m³ ha⁻¹ in an area of 64 ha in the Floresta Nacional do Tapajós (state of Pará, Brazil). In the distribution projection, ANNs were used as a rule for CA evolution, considering the probability of projection's trees and their closest neighbors. The projection from all the analyzed periods showed no statistical difference at 5% of significance in relation to the observed one, which demonstrates that the projection followed the tendency of the distribution's dynamics. ANN and CA are efficient and can be used to design the diameter distribution during the cutting cycle.

Keywords: Artificial intelligence, forest management, modeling.

INTRODUÇÃO

A expansão agropecuária e as mudanças climáticas são importantes agentes de perturbação na bacia amazônica. As interações entre desmatamento, incêndios e seca potencialmente levam a perdas de armazenamento de carbono, 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. Na Amazônia, foi responsável por desmatar 11.000 km² em 2007, diminuindo para 5.900 km² em 2013 (SWANN *et al.*, 2015). Em menor proporção, está a exploração seletiva ilegal de madeira. Ela não realiza a conversão do solo, mas funciona como inicialização de desflorestamento 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 madeira, dentro de um sistema de manejo florestal adequado, mantém substancialmente a biodiversidade (85-100%), o carbono (76%) e estoques de madeira após a colheita. Revelaram também que os rendimentos aumentam com a utilização da 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. Para a determinação da intensidade e do 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, o que dificulta a modelagem principalmente para grandes períodos de tempo (pelo menos, 30 anos).

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 simular empiricamente 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. São fundamentados 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 (VASCONCELOS *et al.*, 2009; SOUZA *et al.*, 2014). Entretanto, essa técnica não considera as mudanças de mortalidade ao longo do tempo e a passagem de árvores entre as classes e fica restrita ao período considerado na construção da matriz. Uma alternativa na prognose da estrutura diamétrica é o uso de Redes Neurais Artificiais (RNA) e autômatos celulares (AC), ferramentas de inteligência artificial que podem ser aplicadas 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 interligados por um grande número de interconexões, propensas a armazenar conhecimento experimental e torná-lo disponível para o uso (SILVA *et al.*, 2010). Isso torna a RNA uma ferramenta adequada para a prognose de florestas manejadas por 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 compõem a rede; habilidades de generalização, capacidade de aplicar o conhecimento aprendido no treinamento em dados desconhecidos; adaptabilidade, adaptação de 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 (SILVA *et al.*, 2010).

A aplicação de RNA na área florestal tem ganhado alta relevância por apresentar resultados de sucesso, como por exemplo: classificação de estágios sucessionais na Amazônia (KUPLICH, 2009); otimização de índice de competição (RICHARDS *et al.*, 2008); estimação do volume de árvores (BINOTI *et al.*, 2014); modelagem da distribuição diamétrica (DIAMANTOPOULOU *et al.*, 2015); modelagem do crescimento em diâmetro, mortalidade e sobrevivência de árvores na Amazônia (REIS *et al.*, 2016; REIS *et al.*, 2018).

Já os AC são sistemas de interações locais, discretos no tempo e no espaço e compostos por células, em que o estado de cada célula é resultado de seu estado atual, de sua regra de transição para outras células e de sua interação com células vizinhas (ILACHINSKI, 2001). O AC foi utilizado 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) e na prognose da distribuição diamétrica em povoamento equiâneo (BINOTI *et al.*, 2013).

Como áreas significativas de florestas nativas na Amazônia são suprimidas para usos alternativos do solo, apoiar técnicas que viabilizam o manejo florestal, que mantém a floresta em pé, é de fundamental importância na tomada de decisões sustentáveis. Tem-se como hipótese que a prognose da distribuição diamétrica poderá ser estimada com maior precisão utilizando redes neurais artificiais e autômatos celulares. Portanto, o trabalho objetiva empregar autômatos celulares como regra de evolução em redes neurais artificiais para projetar a distribuição dos diâmetros em floresta colhida, podendo servir como tomada de decisão para o manejo florestal sustentável na Amazônia brasileira.

MATERIAL E MÉTODOS

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. Pertence ao bioma Amazônia e sua tipologia é Floresta Ombrófila Densa de terra firme (COSTA FILHO *et al.*, 1980). O clima da região é o 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) mencionaram a exploração de quatro espécies de alto valor comercial na década de 1940: pau-rosa (*Aniba roseodora* Ducke), maçaranduba (*Manilkara huberi* (Ducke) A. Chev.), freijó (*Cordia goeldiana* Huber) e cedro (*Cedrela odorata* L.).

Em 1975, foi realizado um inventário a 100% de intensidade das espécies madeireiras com DAP ≥ 15 cm em 64 ha da área de estudo. Em 1979, foi realizada a exploração de 64 espécies madeireiras, as quais acumularam, em média, um volume colhido de $72,5 \text{ m}^3 \text{ ha}^{-1}$ (COSTA FILHO *et al.*, 1980). Em 1981, foram instaladas 36 parcelas permanentes (50 m x 50 m) aleatoriamente. Nessas parcelas, todas as árvores com DAP ≥ 5 cm foram identificadas botanicamente *in loco*, e o material botânico foi depositado no Herbário IAN da Embrapa Amazônia Oriental. Foram realizadas remediações nas parcelas permanentes em 1982, 1983, 1985, 1987, 1992, 1997, 2007, 2010 e 2012.

Autômato celular e Redes Neurais Artificiais

Para um modelo unidimensional de AC, o valor i da célula no tempo t , denominado $c_i(t)$, 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 unidimensionais com raio 2 ($r = 2$). Assim, cada célula possui 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 ao estado da célula. Nas classes de diâmetro das bordas, por exemplo, foram considerados os valores de probabilidade das classes vizinhas das quatro classes posteriores (12,5, 17,5, 22,5 e 27,5 cm) para a classe de 7,5 cm, foram consideradas as classes 7,5, 17,5, 22,5 e 27,5 cm para a classe de 12,5 cm e foram consideradas as classes 7,5, 12,5, 22,5 e 27,5 cm para a classe de 17,5 cm, e assim sucessivamente.

Para a construção da regra de evolução do AC, foram treinadas 300 redes neurais artificiais, utilizando 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 da RNA, utilizando 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 teste do modelo. Os dados de teste não fizeram parte do treinamento das RNA. O treinamento toma como base a regra delta generalizada, também conhecida como algoritmo *backpropagation*, aplicada nas redes alimentadas para frente de camadas múltiplas, denominadas *Perceptron* multicamadas (*multilayer Perceptron* – MLP).

O algoritmo *backpropagation* é realizado mediante aplicações sucessivas de duas fases bem específicas. De acordo com Silva *et al.* (2010), a primeira fase a ser aplicada é denominada de “propagação adiante” (*forward*), na qual os sinais $\{x_1, x_2, \dots, x_n\}$ de uma amostra do conjunto de treinamento são inseridos nas entradas de rede e são propagados camada a camada até a produção das respectivas saídas. A aplicação dessa fase visa obter as respostas da rede, considerando apenas valores atuais de pesos sinápticos e limiares de seus neurônios, os quais permanecem inalterados durante cada execução. Logo em seguida, as respostas produzidas pelas saídas da rede são comparadas com as respectivas respostas desejadas que estiverem disponíveis. Os respectivos desvios (erros) entre as respostas desejadas e aquelas produzidas pelos neurônios de saída são então calculados, os quais serão subsequentemente utilizados para ajustar os pesos e limiares de todos os seus neurônios. Em função desses valores de erros, é aplicada a segunda fase do método *backpropagation*, denominado “propagação reversa” (*backward*). As alterações (ajustes) dos pesos sinápticos e limiares de todos os neurônios da rede são executados no decorrer dessa fase (SILVA *et al.*, 2010).

Em resumo, as aplicações sucessivas das fases *forward* e *backward* fazem com que os pesos sinápticos e limiares dos neurônios se ajustem automaticamente em cada iteração, o que implica na gradativa diminuição da soma dos erros produzidos pelas respostas da rede frente àquelas desejadas (SILVA *et al.*, 2010).

No treinamento, foi utilizada a ferramenta *Intelligent Problem Solver* (IPS) do software Statistica 12 para a análise das funções de ativação (Tabela 1) da camada intermediária (Identidade, Logística, Tangente hiperbólica e exponencial) e de saída (Logística e Exponencial). Os pesos iniciais das redes foram gerados aleatoriamente. O critério de parada do algoritmo ocorre quando o erro quadrático médio começa a aumentar. Nesse caso, o

treinamento é interrompido. O treinamento da rede continua até 10.000 ciclos, desde que o erro esteja em decréscimo.

Tabela 1 Funções de ativação usada no treinamento das redes neurais artificiais.

Table 1 Activation functions used in the training of artificial neural networks.

Função	Equação	Descrição	Intervalo
Identidade	α	Com essa função, o nível de ativação é transmitido diretamente como a saída dos neurônios.	$(-\infty, +\infty)$
Logística	$\frac{1}{1 + e^{-\alpha}}$	Essa é uma curva em forma de S (sigmóide)	$(0, 1)$
Tangente hiperbólica	$\frac{e^{\alpha} - e^{-\alpha}}{e^{\alpha} + e^{-\alpha}}$	É uma função simétrica em forma de S (sigmóide).	$(-1, +1)$
Exponencial	$e^{-\alpha}$	Função exponencial negativa.	$(0, +\infty)$

α : é a entrada líquida de um neurônio, para MLP – é a soma ponderada das entradas dos neurônios.

No treinamento, foi utilizada somente uma camada escondida. O intervalo do número de neurônios nessa camada foi definido pelo método de Fletcher-Gloss de acordo com o número de variáveis de entrada e saída, calculado pela equação (2).

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

em que: n = número de entradas da rede; n_1 = quantidade de neurônios na camada escondida; n_2 = 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 a estatística de correlação entre os valores estimados e reais ($r_{Y\hat{Y}}$) e a raiz quadrada do erro quadrático (RQEQM) médio no treinamento e teste.

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

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

em que: \hat{Y} = valores estimados pelas redes; Y = valores observados nas parcelas permanentes; S^2 = variância; Cov. = covariância.

A RQEQM utilizada para comparar as redes indica que, quanto menor a estimativa, mais confiável é o treinamento ou generalização. A RQEQM é calculada pela equação (4).

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

em que: \hat{Y} = valores estimados pelas redes; 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. O primeiro ano de medição foi 1981 e o último, 2012. A significância estatística, entre as distribuições diamétricas projetadas e observadas, foi verificada pelo teste de aderência Kolmogorov-Smirnov (K-S), a 5% de significância, pela equação (5).

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

em que: $F_o(x)$ = frequência acumulada observada; $F_e(x)$ = frequência acumulada projetada; 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).

RESULTADOS

No treinamento e teste de 300 redes, foram escolhidas as cinco melhores, que apresentaram coeficiente de correlação acima de 99% e o erro abaixo de 17% (Tabela 2). 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 2. Resultados estatísticos do treinamento e teste de Redes Neurais Artificiais (RNA) utilizadas como regra de evolução em Autômatos Celulares (AC).

Table 2. Statistical results of the training and test of Artificial Neural Networks (ANNs) used as evolution rule in Cellular Automata (CA).

RNA	Arquitetura	Treinamento		Teste		Função 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

$r_{Y\hat{Y}}$: coeficiente de correlação; RQEQM: raiz quadrada do erro quadrático médio; MLP: perceptron multicamadas.

Número de variáveis de entrada – número de neurônios da camada intermediária – número de neurônios na camada de saída.

Para exemplificar a transição utilizando RNA e AC, foi escolhida aleatoriamente uma parcela (parcela permanente 10) dos dados da validação (Tabela 3). A classe 32,5 cm no ano $t = 0$ (1981), por exemplo, apresentava probabilidade de ocorrência de árvores de 0,01; as classes vizinhas tinham probabilidade de 0,04, 0,03, 0,02 e 0,02 para 22,5, 27,5, 37,5 e 42,5 cm, respectivamente. Aplicando a regra de transição para $t = 1$ (1982), a probabilidade foi de 0,01.

Tabela 3. Comparação da probabilidade de ocorrência de árvores da distribuição diamétrica observada versus a projetada usando Redes Neurais Artificiais (RNA) e Automatos Celulares (AC) em uma parcela de floresta colhida seletivamente no leste da Amazônia.

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

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	$\geq 62,5$
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	0,00	0,01
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 4), utilizando as parcelas escolhidas aleatoriamente para a validação das RNA, não diferiram a 5% de significância da distribuição diamétrica observada ao longo de 30 anos (1982, 1983, 1985, 1987, 1992 1997, 2007 e 2012).

Tabela 4. Projeção da probabilidade de ocorrência de árvores da distribuição diamétrica usando Redes Neurais Artificiais (RNA) e Autômatos Celulares (AC) em uma floresta colhida seletivamente no leste da Amazônia.
Table 4. 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 Amazônia.

CC	1982		1983		1985		1987		1992		1997		2007		2012	
	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est
7,5	0,616	0,601	0,615	0,603	0,592	0,574	0,579	0,554	0,541	0,526	0,519	0,510	0,521	0,517	0,535	0,519
12,5	0,160	0,168	0,170	0,175	0,176	0,185	0,177	0,188	0,187	0,188	0,193	0,183	0,187	0,171	0,183	0,161
17,5	0,086	0,100	0,080	0,108	0,092	0,119	0,093	0,126	0,096	0,128	0,099	0,126	0,099	0,116	0,091	0,110
22,5	0,051	0,057	0,051	0,057	0,056	0,058	0,061	0,060	0,068	0,064	0,063	0,067	0,058	0,061	0,057	0,065
27,5	0,025	0,028	0,024	0,028	0,023	0,030	0,029	0,033	0,039	0,042	0,048	0,048	0,045	0,040	0,042	0,046
32,5	0,021	0,021	0,019	0,019	0,019	0,018	0,018	0,019	0,025	0,024	0,024	0,029	0,029	0,026	0,031	0,030
37,5	0,015	0,014	0,015	0,012	0,017	0,012	0,015	0,012	0,010	0,015	0,016	0,018	0,018	0,018	0,017	0,020
42,5	0,012	0,011	0,010	0,009	0,011	0,008	0,014	0,009	0,013	0,010	0,013	0,012	0,013	0,013	0,016	0,015
47,5	0,006	0,006	0,006	0,006	0,007	0,006	0,005	0,007	0,011	0,008	0,011	0,010	0,010	0,011	0,008	0,012
52,5	0,004	0,004	0,004	0,005	0,002	0,005	0,003	0,006	0,004	0,008	0,007	0,009	0,008	0,010	0,005	0,011
57,5	0,001	0,003	0,001	0,004	0,003	0,005	0,002	0,006	0,002	0,008	0,002	0,009	0,006	0,010	0,007	0,011
62,5	0,004	0,006	0,004	0,005	0,004	0,006	0,005	0,006	0,004	0,008	0,008	0,010	0,006	0,010	0,008	0,011
Dcal.-KS	0,019		0,028		0,028		0,025		0,027		0,029		0,020		0,038	
Dtab. KS	0,041		0,039		0,039		0,039		0,041		0,042		0,041		0,040	

Obs.: Observado; Est.: Estimado.

Exemplificando os resultados em duas parcelas da validação (Figura 1), pode ser verificado 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.

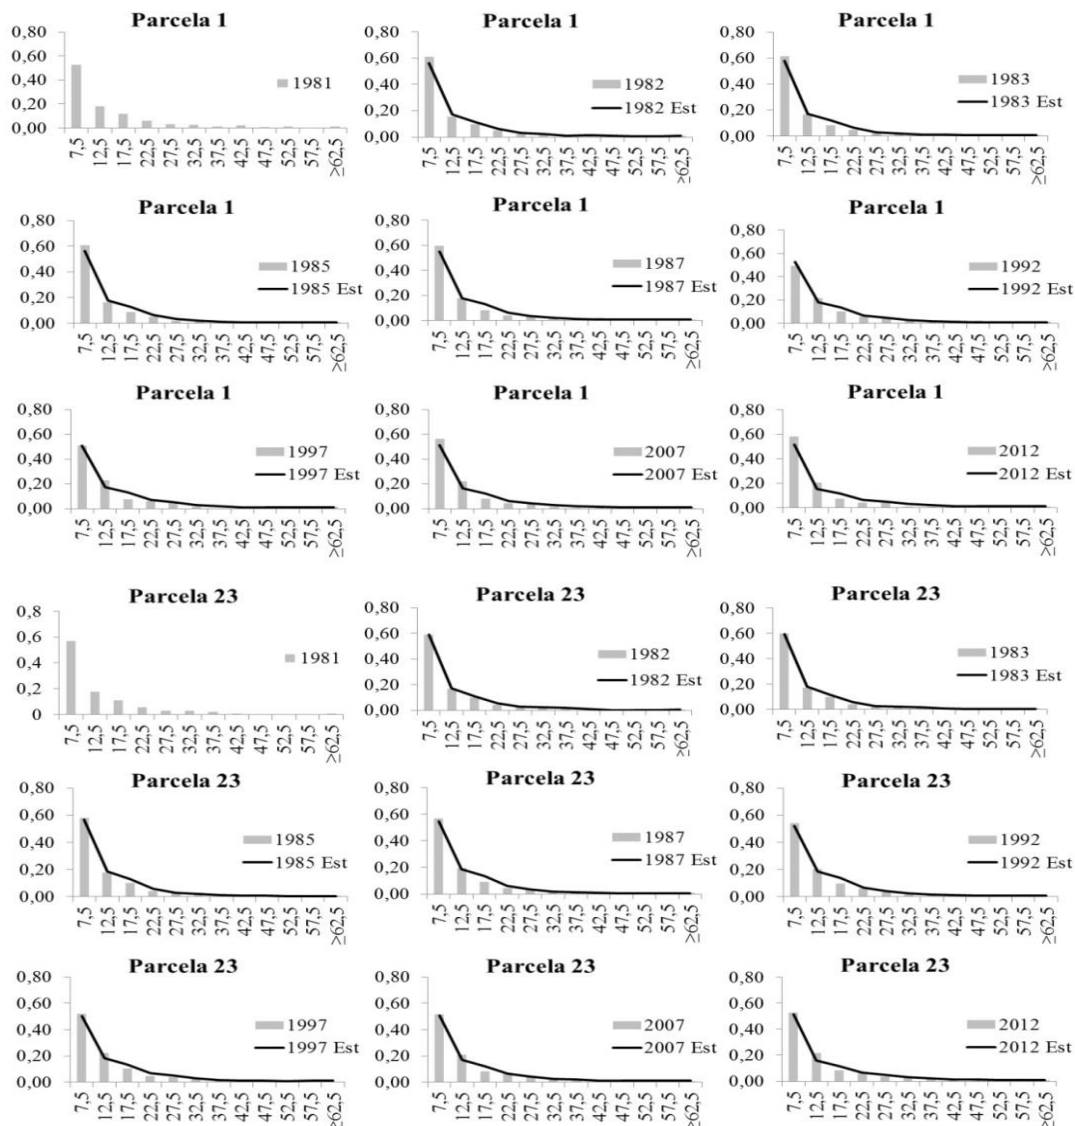


Figura 1. Projeção da probabilidade de árvores na distribuição diamétrica utilizando Redes Neurais Artificiais (RNA) e Autômatos Celulares (AC) em uma floresta colhida seletivamente no leste da Amazônia. Eixo x: centro de classe de diâmetro (cm); Eixo y: probabilidade de árvores.

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

DISCUSSÃO

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

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, o que sustenta a forma exponencial negativa (RUBIN *et al.*, 2006). Isso indica que a densidade das menores árvores sustenta a população das maiores.

A complexidade de projetar a distribuição diamétrica depois da colheita seletiva ocorre por causa da intensidade de corte maior nas classes de 60 a 80 cm (REIS *et al.*, 2010). Isso afeta a dinâmica da floresta por abrir clareiras artificiais, alterando o crescimento das espécies e, conseqüentemente, mudando a probabilidade de

passagem de árvores entre as classes. 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 4).

Alguns trabalhos que projetaram a distribuição diamétrica com base na cadeia probabilística de Markov na Floresta Amazônica e Mata Atlântica descreveram que as estruturas diamétricas observadas e projetadas não diferiram entre si. Elas utilizaram pequenos períodos de tempo (até 15 anos), servindo, conseqüentemente, para o planejamento no curto prazo (VASCONCELOS *et al.*, 2009; SOUZA *et al.*, 2014). Isso difere muito de projetar um ciclo de corte completo de 30 anos, porém foi possível com o uso de RNA e AC. Osazuwa-Peters *et al.* (2015) destacaram, em estudo com monitoramento de 45 anos em floresta tropical, a importância de entender a dinâmica a longo prazo após o corte seletivo. Modelos que representam a dinâmica por um período longo servem como ferramenta para o planejamento da conservação de ecossistemas.

Apesar de não incluir diretamente a mortalidade e o recrutamento no modelo, como recomendado para modelagem de florestas nativas (VANCLAY, 1994; ROSSI *et al.*, 2007a; ROSSI *et al.*, 2007b), o uso da RNA e AC apresentou estimativas precisas na projeção. Esse resultado pode ser atribuído à relação da classe (célula) alvo com as células vizinhas e ao 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 (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. Esta diminuiria a insegurança quanto à recuperação do estoque após a colheita florestal e serviria como base para o manejador, no que se refere à aplicação de tratamentos silviculturais em diferentes parcelas, ou unidades de trabalho, já que a projeção pode ser realizada em pequenas unidades.

CONCLUSÕES

- A projeção da distribuição diamétrica após a colheita pode ser realizada com eficiência, utilizando redes neurais artificiais e autômatos celulares ao longo do ciclo de corte na Amazônia, por não apresentar diferença significativa entre a distribuição diamétrica observada e a estimada no período analisado, mantendo a forma da distribuição diamétrica observada ao longo do tempo. Com isso, a técnica pode subsidiar decisões silviculturais adequadas, como ciclo e intensidade de corte, levando em consideração a distribuição diamétrica inicial da área de manejo.
- Em futuros trabalhos, poderão ser testados cenários de corte com diferentes intensidades utilizando RNA e AC para projetar a distribuição diamétrica ao longo do ciclo de corte proposto.

AGRADECIMENTOS

A 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

AZEVEDO, C. P.; SANQUETTA, C. R.; SILVA, J. N. M.; MACHADO, S. A.; SOUZA, C. R.; OLIVEIRA, 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, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G.; SILVA, A. A. L.; ALBULQUERQUE, A. C. Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais. **Cerne**, Lavras, v. 19, n. 4, p. 677-685, 2013.

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, n. 2, p. 283-288, 2014.

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

DAVIDSON, E. A.; ARAÚJO, A. C.; ARTAXO, P.; BALCH, J. K.; BROWN, I. F.; BUSTAMANTE, M. M. C.; COE, M. T.; DEFRIES, R. S.; KELLER, M.; LONGO, M.; MUNGER, J. W.; SCHROEDER, W.; SOARES-FILHO, B. S.; SOUZA, C. M.; WOFSEY, S. C. The Amazon basin in transition. **Nature**, Londres, v. 481, p. 321-328, 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**, Amsterdam, v. 133, p. 33-45, 2015.

ILACHINSKI, A. **Cellular automata: a discrete universe**. River Edge: World Scientific; 2001, 840 p.

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.

MATHEY, A.; KRUMHOLTZ, E.; DRAGICEVIC, S.; VERTINSKY, I. An object-oriented cellular automata model for forest planning problems. **Ecological modeling**, Amsterdam, v. 212, n. 3-4, p. 359-371, 2008

OSAZUWA-PETERS, O. L.; JIMÉNEZ, I.; OBERLE, B.; CHAPMAN, C. A.; ZANNE, A. Z. 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**, Amsterdam, v. 357, p. 10-21, 2015.

PUTZ, F. E.; ZUIDEMA, P. A.; SYNNOTT, T.; PEÑA-CLAROS, M.; PINARD, M. A.; SHEIL, D.; VANCLAY, J. K.; SIST, P.; GOURLET-FLEURY, S.; GRISCOM, B.; PALMER, J.; SUSTAINING, R. Z. Conservation values in selectively logged tropical forests: the attained and the attainable. **Conservation Letters**, Medford, v. 5, n. 4, p. 296-303, 2012.

REIS, L. P.; DE SOUZA, A. L.; DOS REIS, P. C. M.; MAZZEI, L.; SOARES, C. P. B.; TORRES, C. M. M. E.; DA SILVA, L. F.; RUSCHEL, A. R.; RÊGO, L. J. S.; LEITE, H. G. Estimation of mortality and survival of individual trees after harvesting wood using artificial neural networks in the amazon rain forest. **Ecological Engineering**, Amsterdam, v. 112, p. 140-147, 2018.

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. Prognosis on the diameter of individual trees on the eastern region of the amazon using artificial neural networks. **Forest Ecology and Management**, v. 382, p. 161-167, 2016.

REIS, L. P.; RUSCHEL, A. R.; COELHO, A. A.; LUZ, A. S.; 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.

REIS, L. P.; RUSCHEL, A. R.; SILVA, J. N. M.; REIS, P. C. M.; CARVALHO, J. O. P.; SOARES, M. H. M. Dinâmica da distribuição diamétrica de algumas espécies de Sapotaceae após exploração florestal na Amazônia Oriental. **Revista de Ciências Agrárias**, Belém, v. 57, n. 3, p. 234-243, 2014.

RICHARDS, M.; MCDONALD, A. J. S.; AITKENHEAD, M. J. Optimisation of competition indices using simulated annealing and artificial neural networks. **Ecological modelling**, Amsterdam, v. 214, n. 2-4, p. 375-284, 2008.

ROSSI, L. M. B.; KOEHLER, H. S.; SANQUETTA, C. R.; ARCE, J. E. Modelagem de Mortalidade em Florestas Naturais. **Floresta**, v. 37, n. 2, p. 275-291, 2007a.

ROSSI, L. M. B.; KOEHLER, H. S.; ARCE, J. E.; SANQUETTA, C. R. Modelagem de Recrutamento em Florestas. **Floresta**, Curitiba, v. 37, n. 3, p. 453-467, 2007b.

RUBIN, B. D.; MANION, P. D.; FABER-LANGENDOEN, D. Diameter distributions and structural sustainability in forests. **Forest Ecology and Management**, Amsterdam, v. 222, n. 1-3, p. 427-438, 2006.

SCANLON, T.; CAYLOR, K.; LEVIN, S.; RODRIGUEZ-ITURBE, I. Positive feedbacks promote power-law clustering of Kalahari vegetation. **Nature**, Londres, v. 449, p. 209-212, 2007.

SILVA, I. N.; SPATTI, D. H.; FLAUZIN, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010, 399 p.

SOARES-FILHO, B. S.; NEPSTAD, D.; CURRAN, L.; VOLL, E.; CERQUEIRA, G.; GARCIA, R. A.; RAMOS, C. A.; MCDONALD, A.; LEFEBVRE, P.; SCHLESINGER, P. Modeling conservation in the Amazon basin. **Nature**, Londres, v. 440, p. 520-523, 2006.

SOUZA, C. R.; AZEVEDO, C. P.; ROSSI, L. M. B.; SANTOS, J.; HIGUCHI, N. Projection of diametric distribution and carbon stock of a managed forest in Manaus/AM. **Floresta**, Curitiba, v. 44, n. 3, p. 525-534, 2014.

SWANN, A. L. S.; LONGO, M.; KNOX, R. G.; LEE, E.; MOORCROFT, P. R. Future deforestation in the Amazon and consequences for South American climate. **Agricultural and Forest Meteorology**, Amsterdam, v. 214–215: p. 12-24, 2015.

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

VASCONCELOS, S. S.; HIGUCHI, N.; DOLIVEIRA, M. V. N. Projeção da distribuição diamétrica de uma floresta explorada seletivamente na Amazônia Ocidental. **Acta Amazonica**, Manaus, v. 31, n. 1, p. 71-80, 2009.