

RENATO VINÍCIUS OLIVEIRA CASTRO

**MODELAGEM DO CRESCIMENTO EM NÍVEL DE ÁRVORES INDIVIDUAIS
UTILIZANDO REDES NEURAS E AUTÔMATOS CELULARES**

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

VIÇOSA
MINAS GERAIS - BRASIL
2011



**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

C355m
2011

Castro, Renato Vinícius Oliveira, 1986-
Modelagem do crescimento em nível de árvores individuais
utilizando redes neurais e autômatos celulares / Renato
Vinícius Oliveira Castro. – Viçosa, MG, 2011.
viii, 80f. : il. (algumas col.) ; 29cm.

Orientador: Carlos Pedro Boechat Soares.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 71-80

1. Eucalipto. 2. Florestas - Medição. 3. Levantamentos
florestais. 4. Eucalipto - Populações. 5. Florestas -
Administração. 6. Redes neurais (Computação). 7. Autômato
celular. I. Universidade Federal de Viçosa. II. Título.

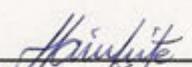
CDO adapt. CDD 634.952

RENATO VINÍCIUS OLIVEIRA CASTRO

**MODELAGEM DO CRESCIMENTO EM NÍVEL DE ÁRVORES INDIVIDUAIS
UTILIZANDO REDES NEURAIS E AUTÔMATOS CELULARES**

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

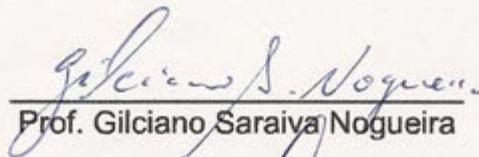
APROVADA: 18 de fevereiro de 2011.



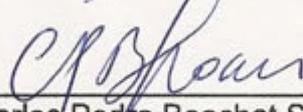
Prof. Helio Garcia Leite
(Co-orientador)



Prof. Agostinho Lopes de Souza
(Co-orientador)



Prof. Gilciano Saraiva Nogueira



Prof. Carlos Pedro Boechat Soares
(Orientador)

DEDICO

*Aos meus pais, Geraldo e Lia,
a minha esposa Ana Flávia,
a minha filha Ana Clara.
Obrigado por estarem sempre ao meu lado.*

AGRADECIMENTOS

À Deus que sempre me acompanhou, conduziu, e deu-me a sabedoria para traçar meu caminho.

À Ana Flávia e Ana Clara, grandes paixões da minha vida. Às nossas famílias, Oliveira Castro e Neves Mendes, e aos nossos amigos, pelo carinho, incentivo e apoio.

Ao professor Carlos Pedro Boechat Soares pela valiosa orientação, sempre bem direcionada, pelos permanentes incentivos e aconselhamentos e confiança depositada antes e durante o desenvolvimento do trabalho. Agradeço pela dedicação e exemplo de profissional.

Ao professor Helio Garcia Leite, pela confiança, dedicação, e apoio em todos os momentos.

Ao professor Agostinho Lopes de Souza pelas valiosas sugestões e incentivo.

Ao professor Gilciano Saraiva Nogueira pela amizade, estímulo e importantes sugestões para este trabalho.

À Universidade Federal de Viçosa (UFV) e ao Departamento de Engenharia Florestal pela oportunidade de desenvolver esta dissertação.

Aos professores e funcionários da Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM), pelos ensinamentos, convivência e companhia durante minha graduação.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro.

Agradeço a todos aqueles que, direta ou indiretamente, colaboraram na execução deste trabalho.

BIOGRAFIA

RENATO VINÍCIUS OLIVEIRA CASTRO, filho de Geraldo Martins Castro e Maria Hélia de Oliveira Martins Castro, nasceu em São Domingos do Prata, Minas Gerais, aos 07 de abril de 1986.

Residiu em João Monlevade até ingressar no curso de Engenharia Florestal na Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM), Diamantina, em julho de 2004. Obteve o título de Engenheiro Florestal em dezembro de 2008.

Em agosto de 2009 ingressou no programa de Pós-Graduação da Universidade Federal de Viçosa (UFV), onde obteve o título de Mestre em Ciência Florestal em 18 de fevereiro de 2011.

SUMÁRIO

	Página
RESUMO	vi
ABSTRACT	viii
1. INTRODUÇÃO	1
2. OBJETIVOS	5
3. REVISÃO DE LITERATURA	6
3.1. Modelos em nível de árvores individuais	6
3.1.1. Índices de competição.....	10
3.2. Redes neurais artificiais	12
3.3. Autômatos celulares.....	16
3.3.1. Autômatos celulares padrões e suas variações.....	17
3.3.2. Aplicações de autômatos celulares (AC) na área florestal	19
4. MATERIAL E MÉTODOS	21
4.1. Dados.....	21
4.2. Métodos	24
4.2.1. Comparação entre as metodologias.....	27
4.2.2. Validação.....	27
5. RESULTADOS E DISCUSSÃO	32
5.1. Índices de competição	32
5.2. Modelos de regressão.....	37
5.3. Redes neurais artificiais	47
5.4. Validação do modelo.....	58
6. CONCLUSÕES	69
7. RECOMENDAÇÕES	70
8. REFERÊNCIAS BIBLIOGRÁFICAS	71

RESUMO

CASTRO, Renato Vinícius Oliveira, M.Sc., Universidade Federal de Viçosa, fevereiro de 2011. **Modelagem do crescimento em nível de árvores individuais utilizando redes neurais e autômatos celulares.** Orientador: Carlos Pedro Boechat Soares. Co-orientadores: Helio Garcia Leite e Agostinho Lopes de Souza.

Modelar de maneira precisa o crescimento e a produção de povoamentos é importante para um melhor gerenciamento dos recursos florestais. Como o manejo tem demandado cada vez mais detalhes acerca do crescimento e dinâmica dos povoamentos, principalmente aqueles destinados à produção de madeira de alta qualidade ou a multiprodutos, modelos em nível de distribuição diamétrica e em nível de árvores individuais têm sido cada vez mais demandados. Assim sendo, este trabalho teve por objetivo modelar o crescimento e a produção de povoamentos de eucalipto, em nível de árvores individuais, utilizando regressão, redes neurais artificiais (RNA) e Autômatos Celulares (AC). Dados de parcelas permanentes foram empregados para ajuste de equações para prever o crescimento de variáveis dendrométricas (diâmetro e altura) e probabilidade de mortalidade das árvores, bem como para o treinamento das RNA para estas mesmas variáveis. As estimativas obtidas por meio de RNA foram mais precisas quando comparadas àquelas obtidas por modelos de regressão. As melhores redes, juntamente com uma arquitetura de AC, foram utilizadas para validação do modelo, empregando dados independentes daqueles utilizados no ajuste dos modelos de regressão e treinamento das RNA. Projetando-se a estrutura dessas parcelas independentes (diâmetro, altura e mortalidade das árvores) de 24 meses até 72

meses, observou-se que as RNA e a estrutura de AC forneceram estimativas precisas em nível de árvores individuais, classes de diâmetro e por unidade de área (hectares).

ABSTRACT

CASTRO, Renato Vinícius Oliveira, M.Sc., Universidade Federal de Viçosa, February, 2011. **Modeling the individual trees growth using neural networks and cellular automata.** Advisor: Carlos Pedro Boechat Soares. Co-advisors: Helio Garcia Leite and Agostinho Lopes de Souza.

Accurately model the stand growth and yield is important to improve the forest resource management. As the management has increase demanded more details about the forest stand growth and dynamics, especially those for the wood or multiproduct high quality production, diametric distribution model and individual trees model have been more demanded. Thus, this study aimed to model the eucalyptus growth and production, at the individual trees level, using regression, artificial neural networks (ANN) and Cellular Automata (CA). Data from permanent plots were used to equations adjust to predict the dendrometric variables (diameter and height) growth and the tree mortality probability, as well as for ANN training for these same variables. The estimates obtained by ANN were more accurate than those estimated by regression models. The best networks, herewith an CA architecture, were used to validate the model, using independent data of those used to adjust the regression models and ANN training. Projecting the structure of these independent plots (diameter, height and tree mortality) from 24 months to 72 months, it was observed that the ANN CA structure provided accurate estimates at the individual trees level, diameter classes and for area unit (hectares).

1. INTRODUÇÃO

A simulação da dinâmica natural da floresta baseia-se na abstração do crescimento das árvores, e deve abranger os crescimentos dimensionais, a mortalidade e outras mudanças naturais na composição e na estrutura do povoamento, como por exemplo, a sucessão de espécies em florestas naturais. Para isso é necessário dispor de dados e modelos apropriados, e a escolha do melhor modelo deve ser feita de acordo com os objetivos de manejo e o grau de detalhes desejado.

As três principais categorias de modelos de crescimento e produção florestal são: modelos em nível de povoamento; modelos de distribuição diamétrica; e modelos de árvores individuais (DAVIS e JOHNSON, 1987).

Modelos em nível de povoamento fornecem estimativas do crescimento e, ou da produção por unidade de área (CAMPOS e LEITE, 2009), sendo o volume por hectare predito ou projetado a partir de variáveis do povoamento, como idade, índice de local e área basal. O fato desses modelos não fornecerem estimativas por classe de tamanho das árvores não limita o seu emprego quando o manejo é destinado à produção de madeira para celulose e, ou energia (CAMPOS e LEITE, 2009).

Modelos de distribuição diamétrica estimam o número de árvores e a produção por hectare por classe de diâmetro (HINK e MOSER, JR., 1983), sendo a produção total obtida através do somatório da variável de interesse em todas as classes de diâmetro (CAMPOS e LEITE, 2009). É empregada uma função densidade de probabilidade (f.d.p.) para descrever a distribuição dos diâmetros na idade atual e futura em classes de amplitudes previamente

fixadas, sendo a função mais utilizada a Weibull (RENNOLLS et al., 1985; SCOLFORO e MACHADO, 1996; MIGUEL et al., 2010). A prognose da produção é realizada por modelos de regressão, utilizados na forma de sistemas de equações, as quais estimam os parâmetros da f.d.p. para idades futuras. A partir desta distribuição o número de árvores por classe de diâmetro e a produção podem ser estimadas.

A terceira categoria refere-se aos modelos em nível de árvores individuais (MAI). Esses modelos são muito variados em termo de estrutura e utilidade (DAVIS e JOHNSON, 1987). A principal vantagem do seu emprego é a possibilidade de gerar informações detalhadas sobre a dinâmica da estrutura dos povoamentos (CLUTTER et al., 1983). Cada árvore é estudada individualmente, levando-se em consideração suas características individuais, a capacidade produtiva do local e as condições de competição a que está submetida (HASENAUER, 2000).

Um MAI é constituído por um conjunto de equações e funções que estimam o crescimento em diâmetro e em altura, assim como a probabilidade de mortalidade das árvores (DAVIS e JOHNSON, 1987). Com isso, estima-se o volume das árvores sobreviventes nas idades de interesse e a produção por hectare é obtida pelo somatório desses volumes. Para a modelagem são necessários dados específicos do tamanho de cada árvore dentro do povoamento (diâmetro e altura) e, às vezes, informações sobre a distribuição espacial das árvores (CLUTTER et al., 1983; VANCLAY, 1994).

Para a projeção do crescimento em nível de árvores individuais, existe uma estrutura mais complexa, onde a todo momento devem ocorrer interações entre os indivíduos para geração dos índices de competição. Estes índices são utilizados como variáveis independentes nos sub-modelos de crescimento e mortalidade (BIGING e DOBBERTIN, 1992; MONSERUD e STERBA, 1999), sendo, a cada intervalo de prognose, recalculados.

Independente da categoria, os modelos de crescimento e produção baseiam-se no ajuste de modelos de regressão linear ou não-linear (CAMPOS e LEITE, 2009). No entanto, ferramentas de inteligência artificial, como as redes neurais artificiais (RNA) têm sido empregadas na área de mensuração florestal, em substituição aos modelos de regressão, com superioridade de precisão das estimativas (GÖRGENS, 2006; SILVA et al., 2009).

Apesar dos modelos em nível de povoamento e de distribuição diamétrica atenderem plenamente e de modo eficiente a maioria dos usuários (empresas florestais), cada vez se torna mais importante o detalhamento das informações acerca do crescimento e dinâmica dos povoamentos, principalmente para produção de madeira de alta qualidade, ou destinada a multiprodutos, o que justifica os esforços científicos sobre os modelos de árvores individuais.

Todo modelo de árvore individual requer, para o seu emprego, o desenvolvimento de algum sistema, muitas vezes específico, de modo que seja possível simular diferentes cenários de prognose.

Por volta de 1950, sistemas que consideram a interação entre indivíduos foram idealizados e serviriam para estudar fenômenos complexos. Esses sistemas são conhecidos como Autômatos Celulares (AC), e seus conceitos despertaram a atenção de pesquisadores voltados para técnicas de simulação. Atualmente, os AC são utilizados como plataforma para a modelagem de uma variedade de sistemas caracterizados por interações (onde o comportamento dos indivíduos está interligado de tal maneira que a ação de um influencia o comportamento dos outros), e possuem aplicações nas mais diferentes áreas, desde a econômica até a biológica, especialmente em sistemas que simulam a dinâmica populacional.

Os AC são sistemas dinâmicos, constituídos por um grande número de células idênticas, com conectividade local, usualmente distribuídos em uma grade regular d -dimensional. Cada célula (um tipo de elemento da memória que armazena estados das variáveis) pode possuir n estados, por exemplo, 1 ou 0, ativo ou inativo, morto ou vivo, ou outro conjunto de valores que irá depender do fenômeno a ser estudado. A evolução temporal do AC dá-se através de uma dinâmica imposta, que atua sobre cada variável da grade (SILVA, 2003). Os estados (valores) das células são alterados quando aplicadas regras de evolução.

Estudos sobre desmatamento (MÉNARD e MARCEDAU, 2007); incêndios florestais (YASSEMI et al., 2008), regeneração florestal (LANZER, 2004), e até crescimento de indivíduos (COLASANTI e HUNT, 1997) são encontrados aplicando AC.

Fazendo-se uma analogia aos modelos em nível de árvores individuais, em que o *status* competitivo de uma árvore é quantificado por índices de competição, calculados em relação às árvores vizinhas, observa-se que os AC têm grande potencial para a simulação do crescimento florestal nesse nível de abordagem e constituem uma forma simples para atualizar os efeitos competitivos que influenciam o crescimento ou mortalidade das árvores.

Em virtude das características dos AC e da potencialidade apresentada pelas redes neurais artificiais, observa-se que estes possuem grande potencial de aplicação na modelagem do crescimento, em especial na modelagem em nível de árvores individuais, necessitando, portanto, de estudos e pesquisas científicas nesta área.

2. OBJETIVOS

Diante do exposto anteriormente, esta dissertação teve por objetivos:

- Modelar o crescimento e a produção de povoamentos de eucalipto em nível de árvores individuais, utilizando modelos de regressão e redes neurais artificiais (RNA) e selecionar a metodologia que fornecesse estimativas mais precisas;
- Validar a melhor metodologia utilizando dados independentes do ajuste das equações e treinamento das RNA;
- Avaliar a eficiência do emprego de Autômatos Celulares na simulação do crescimento e da produção de povoamentos de eucalipto.

3. REVISÃO DE LITERATURA

3.1. Modelos em nível de árvores individuais

Nos modelos em nível de árvores individuais (MAI) a árvore é considerada como unidade básica para modelagem, e fornecem informações detalhadas sobre a dinâmica do crescimento do povoamento, em nível de árvore. Eles são compostos por sub-modelos, sendo os principais aqueles que estimam a mortalidade e o crescimento das variáveis dendrométricas (altura e diâmetro). Outras variáveis, como dimensões das copas, por exemplo, podem ser consideradas caso estas sejam variáveis explicativas nos demais sub-modelos. Além disso, no estudo de florestas naturais, torna-se necessário estimar também o ingresso de novas árvores (HASENAUER, 2000).

Em um MAI o crescimento dimensional pode ser estimado para uma idade futura a partir de um valor da variável na idade atual e de variáveis como o índice de competição, idade, índice de local, dentre outras. Também se pode realizar a modelagem do crescimento através do crescimento potencial, em geral avaliado a partir de árvores em crescimento livre (sem competição) ou árvores dominantes. O crescimento das árvores em concorrência é calculado por uma função modificadora do crescimento potencial, a qual serve para penalizar os efeitos da competição sobre o crescimento. Nesta função modificadora utiliza-se de índices de competição e variáveis de povoamento para reduzir o crescimento das árvores submetidas à competição (VANCLAY, 1994).

A mortalidade regular é a variável mais difícil de ser estimada nos modelos de crescimento e produção florestal (HAMILTON JR., 1986; YANG et al., 2003), sendo causada por fatores não catastróficos, tais como competição, fatores genéticos e senescência (PEET e CHRISTENSEN, 1987; CAMPOS e LEITE, 2009). Estimativas podem ser obtidas através da predição da probabilidade de mortalidade ou da sobrevivência da árvore individual (SOMERS et al., 1980). A probabilidade é normalmente modelada em função de algum índice de competição (HASENAUER et al., 2001), e variáveis dimensionais e de povoamento (BUCHMAN et al., 1983). As funções Weibull e Logística são as mais utilizadas em estudos de mortalidade (SCHNEIDER et al., 2005). O modelo proposto por West (1981) também tem sido muito eficiente para descrever esta variável.

Esforços tem sido realizados para melhorar as estimativas de mortalidade, dada a sua grande importância nos modelos em nível de árvores individuais, principalmente em povoamentos inequidistantes (GLOVER e HOOL, 1979; GADOW, 1996). Na última década, alguns trabalhos estimaram com acurácia a mortalidade de árvores por meio de redes neurais artificiais (MERKL e HASENAUER, 1998; WEINGARTNER et al. 2000; HASENAUER et al., 2001) em diferentes tipologias florestais.

A maioria dos trabalhos relacionados aos modelos em nível de árvores individuais utilizaram equações lineares e não-lineares para estimação das variáveis que compõem os seus sub-modelos (MARTIN e EK, 1984; TOMÉ e BURKHART, 1989; HYNYNEN, 1995a; MABVURIRA e MIINA, 2002; FOX et al., 2007; MONTY et al., 2008, PAULO e TOMÉ, 2009). Zeide (1993) apresenta vários modelos de regressão potenciais para modelagem das variáveis dimensionais de árvores (altura, diâmetro e volume) e discute a flexibilidade de cada uma para aplicação na modelagem de árvores individuais.

Para modelagem em nível de árvores individuais são necessários dados de parcelas permanentes, pois fornecem o histórico completo sobre o desenvolvimento do povoamento. As dimensões das árvores precisam ser medidas repetidamente ao longo do tempo com o controle rigoroso de identificação (UZOH e OLIVER, 2008).

Existem duas sub-categorias de modelos de árvores individuais, definidas como de distância dependente e de distância independente (ALIG et

al., 1984; BELLA, 1984 e AVERY e BURKHART, 1994). Nos modelos de distância dependente, são atribuídas coordenadas espaciais para cada árvore, as quais são usadas para avaliação da competição por luz, água e nutrientes entre cada árvore e as circunvizinhas, sendo mais complexos e exigentes em termos de coleta de dados (HYNYNEN, 1995b).

De acordo com Leite (1996), nos modelos de distância independente não se considera a distribuição espacial, e o índice de competição para cada árvore normalmente é obtido pela razão entre o seu diâmetro e, ou, altura e variáveis do povoamento, tais como área basal, diâmetro médio e altura média. Os vizinhos da árvore-objeto (definidos pelas árvores incluídas nas parcelas) expressam o grau de competição em que esta está submetida (SIRONEN et al., 2002).

Dever-se-ia esperar uma melhor precisão dos modelos de distância dependente em relação aos modelos de distância independente. Contudo, diversos trabalhos que compararam estas sub-categorias concluíram não haver a tendência de superioridade (LORIMER, 1983; MARTIN e EK, 1984; DANIELS et al., 1986; BIGING e DOBBERTIN; 1995).

A Figura 1 ilustra a sequência de passos que devem ser seguidos para utilizar um modelo em nível de árvores individuais (DAVIS e JOHNSON, 1987).

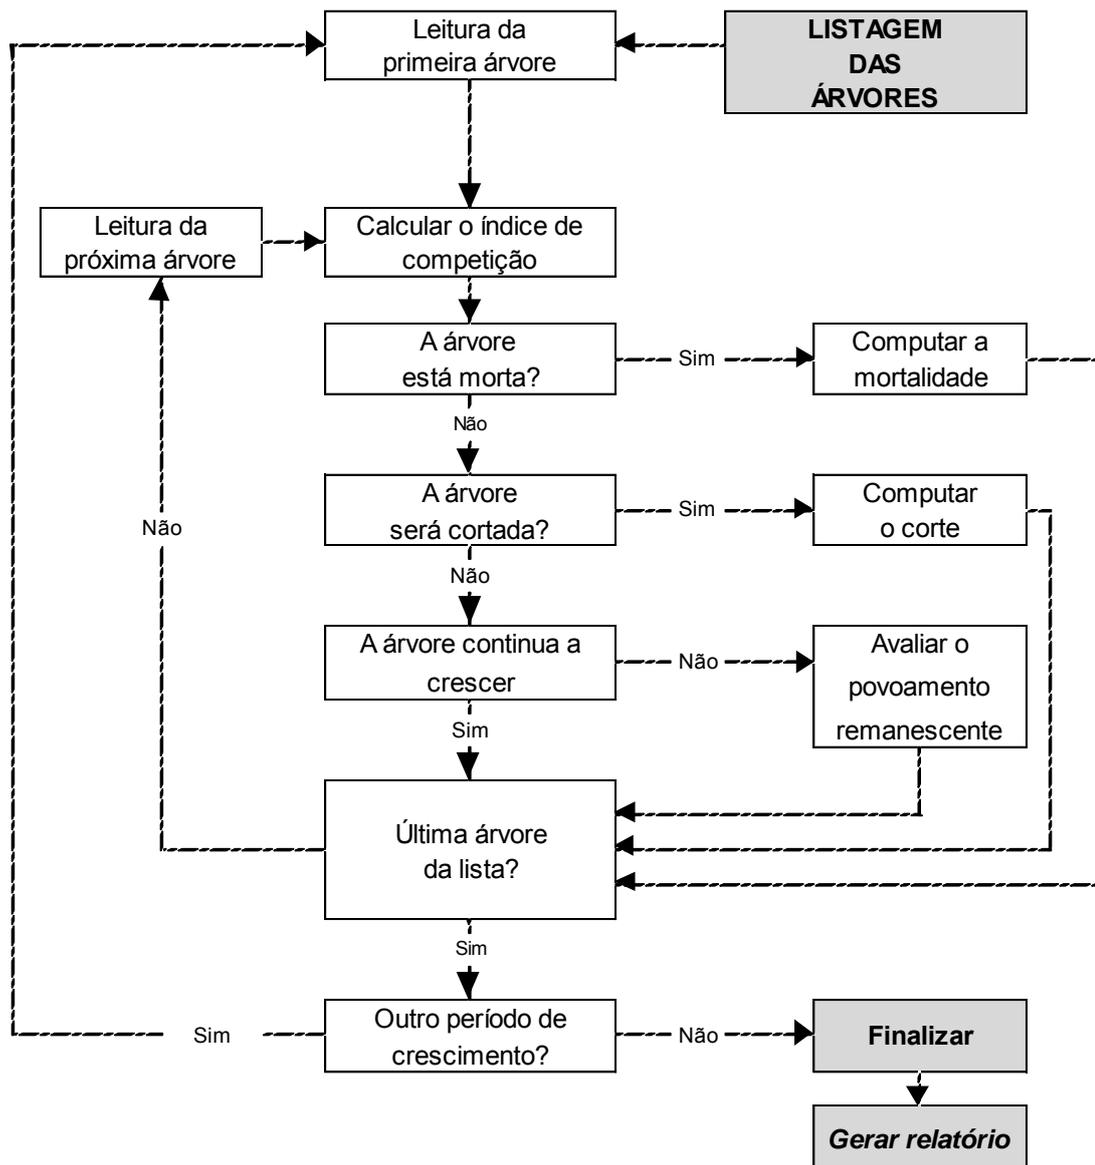


Figura 1 – Fluxograma para utilização de um modelo em nível de árvores individuais.

Fonte: Adaptado de Davis e Johnson (1987).

De acordo com a Figura 1, ao final de cada período de crescimento a soma da contribuição das árvores de forma individual pode ser então utilizada para produzir estimativas em nível de povoamento ou por classe de diâmetro.

Como exemplos, tem-se os modelos de árvores individuais apresentados na Tabela 1.

Tabela 1 – Modelos em nível de árvores individuais e os ecossistemas florestais aos quais foram aplicados e os respectivos autores

Modelo	Descrição	Autor (es)
PROGNOSIS	Independente da distância. Florestas mistas de coníferas da América do Norte.	Stage (1973); Wykoff et al. (1982)
FOREST	Dependente da distância. Crescimento e reprodução de florestas mistas da América do Norte.	Ek e Monserud (1974)
PTAEDA	Dependente da distância. Florestas de <i>Pinus taeda</i> .	Daniels e Burkhart (1975)
SILVA	Dependente da distância. Florestas puras e mistas da Europa.	Pretzsch (1992)
PROGNAUS	Independente da distância. Florestas alpinas mistas inequiâneas.	Sterba et al. (1995)
BWERT	Independente da distância. Avaliação de manejo de florestas mistas da Europa.	Nagl (1995)

Fonte: Adaptado de Davis e Johnson (1987) e Hasenauer (2000).

3.1.1. Índices de competição

A competição é definida como o efeito negativo no crescimento da árvore em virtude de outras ao seu redor, ao competirem pelos fatores de crescimento (KEDDY, 1989). O índice de competição quantifica a condição competitiva e pode ser calculado por medidas independentes ou dependentes da distância. Índices independentes da distância (*IID*) distinguem-se dos dependentes (*IDD*) por não utilizarem medidas espaciais no cálculo da competição.

Existe uma variedade de índices utilizados para diferentes tipos de povoamentos, espécies e estágios de desenvolvimento dos povoamentos (DANIELS et al., 1986; TOMÉ e BURKHART, 1989). Estudos mostraram não existir um índice de competição superior aos demais. A escolha do índice mais apropriado dependerá das informações disponíveis e da avaliação de cada índice nas estimativas dos sub-modelos. Não são verificados resultados uniformes quanto aos comportamentos dos índices em florestas de mesma formação (BIGING e DOBBETIN, 1992).

Os principais índices de competição independentes da distância (*IID*) estão descritos por Glover e Hool (1979); Stage (1973), citados por Davis e Johnson (1987) e os principais *IDD* podem ser encontrados em Prodan (1997). Entre eles, destacam-se:

3.1.1.1. Índices independentes da distância

$$IID_1 = \frac{dap_i^2}{\bar{D}^2} \quad (1)$$

$$IID_2 = \frac{Ht_i}{\bar{Ht}} \quad (2)$$

$$IID_3 = \frac{dap_i^2 Ht_i}{\bar{D}^2 \bar{Ht}} \quad (3)$$

$$IID_4 = \frac{dap_i^2}{q^2} \quad (4)$$

$$IID_5 = BAL_i \quad (5)$$

Em que: dap_i = diâmetro com casca (dap) da árvore-objeto medido a 1,30 m (cm); \bar{D} = média aritmética dos diâmetros das árvores da unidade amostral (cm); Ht_i = altura total da árvore-objeto (m); \bar{Ht} = altura média das árvores da unidade amostral (m); q = diâmetro quadrático (cm); BAL_i = somatório das áreas seccionais das árvores maiores que a árvore-objeto.

3.1.1.2. Índices dependentes da distância

$$IDD_1 = \sum_{i=1}^n \left(\frac{d_{ij} CR_i}{2} \right) \quad (6)$$

$$IDD_2 = \sum_{i=1}^{np} \left(\frac{D_i}{D_j} \frac{1}{L_{ij}} \right) \quad (7)$$

$$IDD_3 = \sum_{i=1}^{no} \left(\frac{O_{ij}}{A_j} \frac{D_i^k}{D_j} \right) \quad (8)$$

$$IDD_4 = 100 \frac{\left(\sum_{i=1}^n O_{ij} + CA_i \right)}{CA_i} \quad (9)$$

$$IDD_5 = \frac{\sum_{i=1}^n \left(O_{ij} \frac{R_j H_j}{R_i H_i} \right)}{CA_i} \quad (10)$$

Em que: d_{ij} = distância de copa sobreposta entre a árvore competidora i e a árvore j ; CR_i = raio da copa da árvore i ; n = número de árvores competidoras; D_i, D_j = diâmetro da copa da i -ésima árvore competidora e a árvore-objeto j ; L_{ij} = distância entre a árvore competidora i e a árvore-objeto j ; np = todas as árvores interceptadas por prisma com fator de área basal 10 (pés/acre) posicionado no centro da árvore-objeto; O_{ij} = área de copa sobreposta entre a árvore competidora i e a árvore-objeto j ; A_j = área de copa da árvore-objeto j ; K = fator; no = todas as árvores em que O_{ij} é positivo; CA_i = área de copa da árvore-objeto i ; R_i = raio da árvore-objeto i , crescendo em liberdade; R_j = raio da árvore competidora j , crescendo em liberdade; H_i = altura da árvore-objeto i ; H_j = altura da árvore competidora j .

3.2. Redes neurais artificiais

As redes neurais artificiais (RNA) inserem-se no campo da inteligência artificial e tratam-se de sistemas que se assemelham ao cérebro humano, com capacidade computacional adquirida por meio do aprendizado (BRAGA et al., 2003). Podem ser aplicadas em problemas de classificação de dados, análise de séries temporais, regressão e conhecimento de padrões (BARRETO, 2002).

As RNA baseiam-se no funcionamento do sistema nervoso humano, que é formado por células nervosas extremamente especializadas (neurônios). Essas células têm um papel essencial no funcionamento do corpo e do raciocínio humano. Os neurônios possuem extensões que se desenvolvem a partir do corpo celular, conhecidas como dendritos e axônios. Os dendritos são responsáveis por receberem os impulsos nervosos e conduzi-los até o corpo celular, que processa o estímulo para novamente distribuir (ou não) através de seu axônio o sinal para os dendritos de neurônios adjacentes (Figura 2).

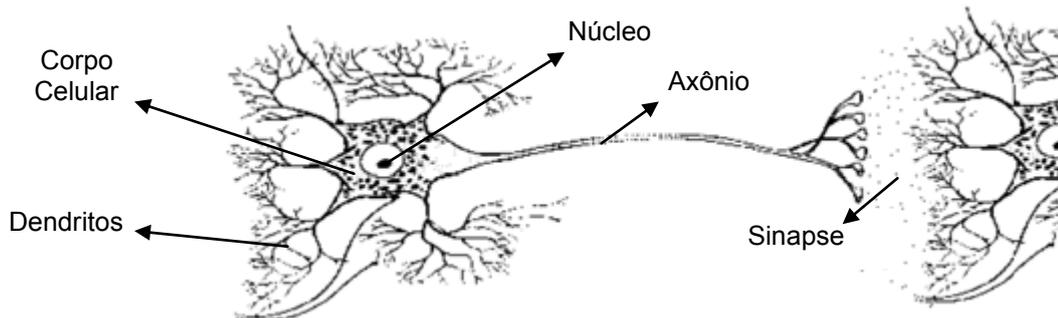


Figura 2 – Representação de neurônios biológicos.
 Fonte: Adaptado de Cavalcante (2001).

As terminações dos axônios são conectadas com os dendritos de outros neurônios através de sinapses. As conexões sinápticas têm papel fundamental na memorização da informação no cérebro humano (BARRETO, 2002).

O modelo de neurônio artificial é simples e possui m terminais de entrada que representam os dendritos, cujas ligações com o corpo celular artificial são realizadas através de elementos chamados de peso (w). Para cada uma das entradas x_i do neurônio há um peso correspondente w_i . O sinal de ativação é passado através de uma função de ativação para produzir a saída (y) do neurônio (HAYKIN, 2001) (Figura 3).

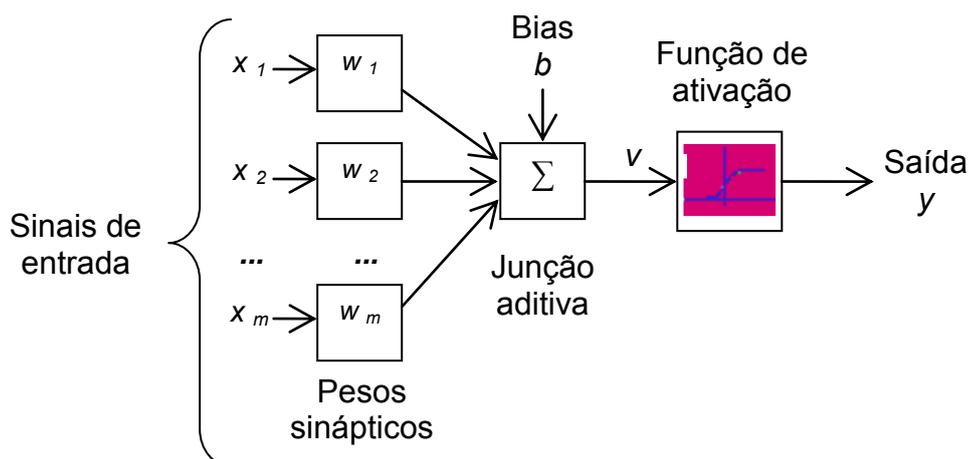


Figura 3 – Representação de neurônios artificiais.
 Fonte: Haykin (2001).

Cada neurônio artificial é uma unidade de processamento composto por uma função de ativação. A função de ativação, também chamada de função de transferência, é uma função matemática que, aplicada à combinação linear entre as variáveis de entrada e pesos que chegam a determinado neurônio, retorna um valor de saída. A função de ativação limita as entradas a uma amplitude finita, normalmente no intervalo fechado entre 0 e 1 (HAYKIN, 2001). Segundo este mesmo autor, existe diversas funções matemáticas que são utilizadas como função de ativação. Entre as mais comuns estão: função limiar (a); função linear por partes (b) e a função sigmóide (c) (Figura 4).

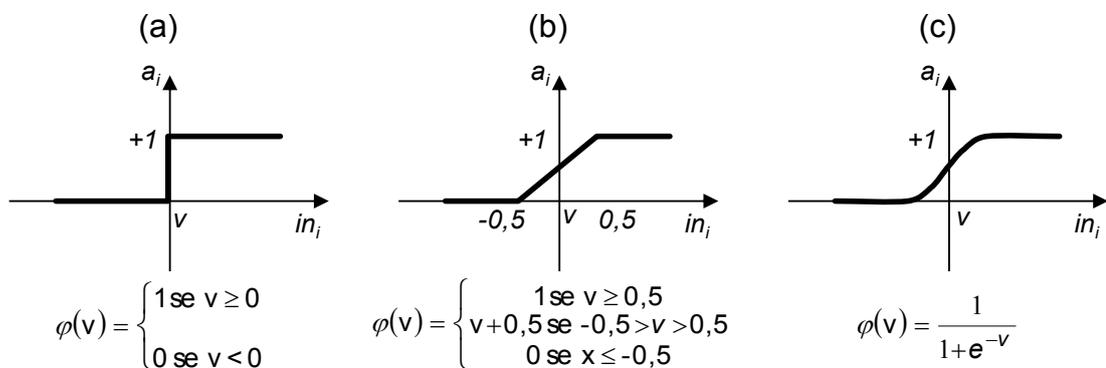


Figura 4 – Principais funções de ativação nas RNA.

As RNA mais utilizadas são as redes multicamadas do tipo *feedforward* com método de aprendizagem supervisionado. Essas redes utilizam um algoritmo de fluxo de dados em uma única direção, sem ciclos. No método de aprendizagem supervisionada, o usuário indica as variáveis de entradas e as variáveis de saídas correspondentes. A RNA é treinada utilizando um dos algoritmos de aprendizado supervisionado, sendo o mais conhecido o *back-propagation*. Este algoritmo corrige o peso entre cada conexão, de forma proporcional ao erro que esteja causando na saída da RNA. O ajuste dos pesos é feito para minimizar o erro das previsões (HAYKIN, 2001).

A arquitetura da rede é a forma como os neurônios são organizados. Usualmente as camadas são classificadas em três grupos: 1) camada de entrada: onde as variáveis são apresentadas à rede; 2) camadas intermediárias ou ocultas: onde é feita a maior parte do processamento e 3) camada de saída: onde o resultado final é concluído e apresentado (Figura 5).

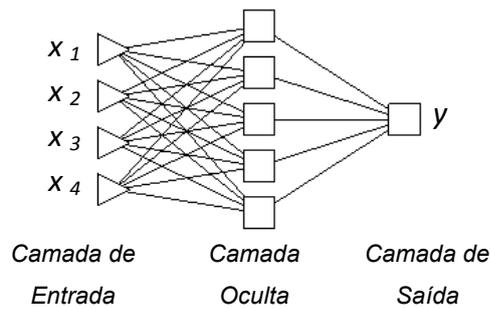


Figura 5 – Modelo genérico de arquitetura de RNA, com uma camada de entrada, uma camada oculta e uma camada de saída.

Os principais modelos de RNA utilizados para fins de previsão de variáveis contínuas são as redes MLP (*Multilayer Perceptron*) (HAYKIN, 2001). Neste tipo de rede, cada neurônio é conectado a todos os neurônios na camada subsequente, não havendo conexões entre neurônios da mesma camada. Segundo Görgens (2006), a função de ativação não-linear (geralmente a sigmoideal) aplicada a cada neurônio utiliza como argumento o produto escalar do vetor de entrada (x) e do vetor de peso (w) associado a esse nodo. Contém pelo menos uma camada oculta de processamento e alto grau de conectividade entre os neurônios, a qual é definida pelos pesos sinápticos.

Alguns autores comprovaram a eficiência desta técnica em áreas do manejo florestal, ao estudarem as RNA para estimar volumes individuais de eucalipto (GÖRGENS, 2006; SILVA et al., 2009) e de *Pinus* (DIAMANTOPOULOU, 2005), e também para estimar a produção volumétrica de eucalipto em nível de povoamento total e das variáveis diâmetro e altura em nível de árvores individuais (BINOTI, 2010). Na última década, alguns trabalhos estimaram com acurácia a mortalidade por RNA em estudos em nível de árvores individuais (MERKL e HASENAUER, 1998; WEINGARTNER et al. 2000; HASENAUER et al., 2001). Estes autores concluíram que as RNA têm grande potencial para muitas aplicações em modelagem florestal, como alternativa eficiente aos tradicionais modelos de regressão.

3.3. Autômatos celulares

Dentre as técnicas para simulação, os Autômatos Celulares (AC) merecem destaque pela sua simplicidade. Essa ferramenta é capaz de representar as interações entre os indivíduos que compõem o sistema e captar o comportamento coletivo gerado pelos indivíduos. Wolfram (1983), um dos mais renomados teóricos sobre Autômatos Celulares, os define como sendo:

“... idealizações matemáticas, no qual o espaço e o tempo são discretos, e os atributos assumem um conjunto de valores também discretos. Um Autômato Celular consiste de uma grade uniforme, com uma variável discreta em cada localidade (célula). O estado de um AC é especificado pelos valores das variáveis em cada célula e evolui em passos de tempo discretos, com o valor da variável sendo afetado pelos valores das variáveis nas células vizinhas. A vizinhança de uma célula é formada pela própria célula e demais células localizadas nas suas adjacências. As variáveis em cada célula são atualizadas simultaneamente, de acordo com um conjunto predefinido de regras de evolução.”

A grade celular é composta por N máquinas idênticas, cada uma com um padrão de conexões com outras células. Cada célula “ i ”, a um dado tempo “ t ”, possui um estado. O estado da célula i , num dado tempo t , junto com os estados das células às quais a célula i está conectada, é chamado vizinhança da célula i . A regra de evolução fornece o próximo estado da célula i . A cada passo de tempo, todas as células atualizam seus estados de acordo com a regra imposta (OLIVEIRA, 1999).

Os Autômatos Celulares foram idealizados no final dos anos 40 por John Von Neumann (VON NEUMANN, 1966). Sob o ponto de vista prático, por volta do final dos anos 60, os AC conseguiram maior divulgação através do matemático Conway, que desenvolveu o Jogo da Vida ou “*Life*” (GARDNER, 1970; DEWDNEY, 1989; DEWDNEY, 1990). O jogo da vida é um Autômato Celular com dois estados (vivo ou morto) e com vizinhança de raio 1. A evolução do AC é composta pelas seguintes regras:

- Regra 1: Uma célula que está no estado vivo (preto) permanecerá neste estado se 2 ou 3 vizinhas estiverem no estado vivo; caso contrário, ela irá para o estado morto (branco).
- Regra 2: Uma célula que está no estado morto irá para o estado vivo se exatamente 3 vizinhas estiverem no estado vivo; caso contrário, ela permanecerá em morto (Figura 6).

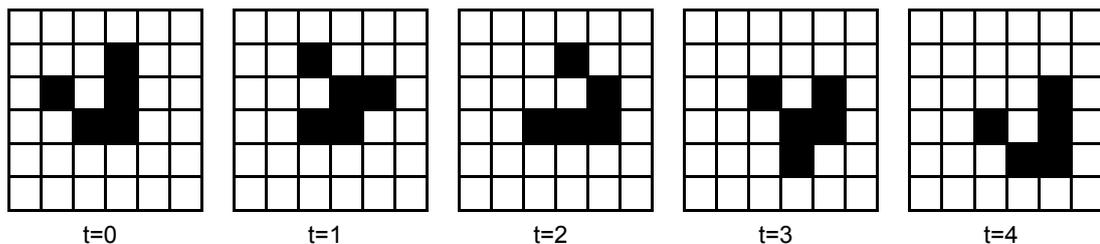


Figura 6 – Um exemplo de uma grade de Autômato Celular de 4 evoluções no *Life*.

Fonte: Xavier (2003).

Os AC possuem aplicações nas mais diversas áreas. Wolfram (1983) refere-se à cerca de 50 trabalhos que tratam de possíveis aplicações de Autômatos Celulares. A ideia básica não é tentar descrever o comportamento de um sistema apenas com modelos complexos, mas focar na simulação de sistemas onde as interações entre as células também sejam um fator importante.

3.3.1. Autômatos celulares padrões e suas variações

Os AC padrões destacam-se pela homogeneidade e conectividade local entre as células e pela regra de atualização homogênea, onde, a cada passo de tempo, todas as células atualizam seus estados simultaneamente de acordo com a regra de evolução (LANZER, 2004). Segundo Pádua (2004) os AC padrões são as versões mais simples, e suas propriedades são:

- Dimensão da grade: pode-se trabalhar com modelos de AC unidimensionais, bidimensionais, ou tridimensionais. Entretanto, a maioria dos exemplos encontrados na literatura trata-se de AC unidimensionais ou bidimensionais.

- Tamanho da vizinhança: os AC unidimensionais podem utilizar, teoricamente, qualquer raio de vizinhança. No caso de AC cujas células são arranjadas em um espaço bidimensional, as vizinhanças mais utilizadas são: a vizinhança de Von Neumann, formada por cinco células (assim conhecida pelo fato de ter sido utilizada no Autômato Celular precursor deste pesquisador) e a vizinhança de Moore, formada por nove células. No caso dos AC bidimensionais, a vizinhança de Moore também pode ser ampliada para mais células, considerando-se um raio maior em torno da célula central, podendo abranger todas as células da grade (Figura 7).

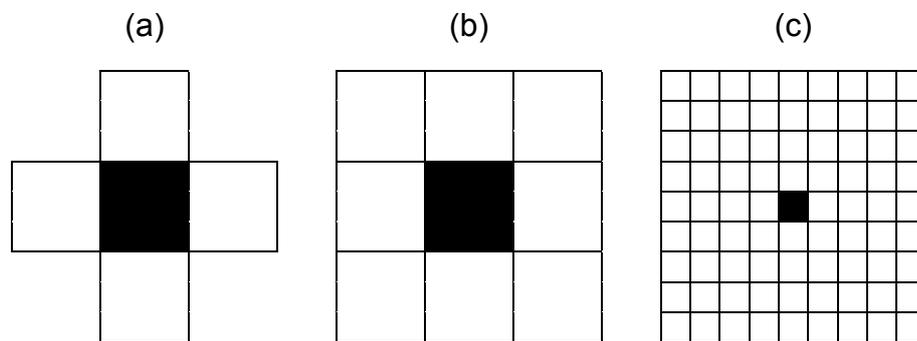


Figura 7 – Vizinhança de Von Neumann (a), Vizinhança de Moore (b) e Vizinhança de Moore estendida (c).

- Regras de evolução: um AC é caracterizado por regras de evolução de estados, que determina qual será o próximo estado de cada célula, a partir de seu estado atual. A principal é a probabilística, calculada por matrizes de transição. Progressos teóricos tais como modelos de regressão e redes neurais artificiais foram incluídas no escopo de simulações em AC.
- Regras de evolução não uniformes: diferentes células podem ser associadas a diferentes regras de evoluções.
- Vizinhança não local: as células que compõem a vizinhança podem variar a cada atualização, sendo sorteadas a cada passo de tempo.

Couclelis (1997) também sugeriu algumas modificações a serem incorporadas nos modelos de AC, os quais representam uma possibilidade técnica para se ampliar o uso destes modelos. De acordo com esse autor, o espaço não mais necessita ser regular; as vizinhanças não necessitam ser

uniformes no espaço, e as regras de evolução não necessitam ser universais (igualmente aplicáveis em cada célula). Dessa forma, as regras de evolução poderiam ser probabilísticas e/ou determinísticas, e diferentes passos de tempo poderiam ser usados. Entretanto, a maioria dos exemplos encontrados na literatura refere-se a AC binários unidimensionais ou bidimensionais, uniformes, probabilísticos e síncronos.

3.3.2. Aplicações de autômatos celulares (AC) na área florestal

Alguns trabalhos baseados em AC foram encontrados para avaliar o comportamento de incêndios florestais (ENCINAS et al., 2007a; ENCINAS et al., 2007b). Yassemi et al. (2008) desenvolveram um modelo de AC capaz de simular a propagação do fogo utilizando conhecimentos teóricos de modelagem, baseados nos princípios de propagação de ondas sob diferentes materiais combustíveis. Para validação do modelo, a simulação do AC foi comparada aos resultados reais captados por imagens de satélite durante o momento de um incêndio florestal no Canadá. Este autor concluiu que o AC foi eficiente para simular o comportamento do fogo em florestas, pois obteve um cenário realista pela simulação.

Ménard e Marcedau (2007) modelaram o desmatamento de uma floresta natural no município de Maskoutains no sul de Quebec, Canadá, sob a influência de diferentes atividades impactantes. O AC foi construído com um tamanho de célula de 100 m, baseado na vizinhança de Moore, com regularidade de tempo de 3 anos, com regras de evolução probabilísticas derivadas da comparação de dois mapas de uso da terra nos anos de 1999 e 2002. Foi simulado o comportamento do desmatamento para os anos subsequentes. Os resultados obtidos por este AC indicaram que sob os cenários avaliados, os níveis de áreas florestais naturais não seriam mantidos.

O trabalho desenvolvido por Lanzer (2004) explora as propriedades e aplicações dos AC para descrever o comportamento de regeneração de florestas naturais após a extração de madeira. As regras de evolução foram criadas a partir de conceitos de ecologia de capacidade de regeneração das florestas naturais. O AC foi validado a partir da comparação estatística dos resultados obtidos pela simulação e os resultados encontrados pela técnica da

cadeia de Markov para prognose, amplamente difundida em estudos de crescimento em florestas naturais, e não foi verificada diferença estatística entre as técnicas.

Lett et al. (1999) compararam as estimativas obtidas por um AC para simular a dinâmica de uma floresta nativa em relação a um modelo de árvore individual clássico. O AC bidimensional foi desenvolvido utilizando células quadradas e, pelas características da vegetação, cada célula continha uma ou mais espécies. O crescimento e a mortalidade, bem como o ingresso de novos indivíduos foram estimados por funções. O crescimento e a dinâmica da floresta também foram realizados por modelagem tradicional de árvores individuais. Conclui-se que as duas abordagens foram eficientes e que, apesar das diferenças conceituais (orientado pelo espaço, estimando a dinâmica de clareira nos AC; e orientado pelo indivíduo na modelagem de árvores individuais) os resultados foram semelhantes em termos de estrutura final.

4. MATERIAL E MÉTODOS

4.1. Dados

Os dados utilizados neste trabalho foram obtidos de povoamentos clonais de *Eucalyptus urophylla* x *Eucalyptus grandis* com espaçamento entre plantas de 3 x 3 m, localizados no município de Monte Dourado (PA), às margens do rio Jarí, região norte do Brasil.

A temperatura média anual da região é de 26 ° C, a umidade relativa fica entre 80 e 85 %, em quase todos os meses do ano, e a precipitação média anual é de 2250 mm, com o período chuvoso compreendido entre os meses de dezembro e julho. Os solos predominantes são os latossolos amarelos (DEMOLINARI, 2006).

Foram utilizados dados de 63 parcelas permanentes de 500 m², medidas anualmente dos 24 aos 72 meses de idade com o controle de identificação das árvores. Em cada parcela foram mensurados os diâmetros a 1,3 m de altura (*dap*) de todas as árvores, as alturas totais (*Ht*) das 15 primeiras árvores e a altura total de cinco árvores dominantes. As alturas totais das demais árvores foram estimadas por meio da seguinte equação (DEMOLINARI, 2006):

$$Ht = 36,9876 - 30,4340 \cdot \exp\left(-0,000499 \cdot (dap \cdot \ln(H_d) \cdot \ln(I))^{1,388275}\right) \quad (11)$$

$$\bar{R}^2 = 83,7\%; S_{y,x} = \pm 11,79\%.$$

Em que: dap = diâmetro com casca medido a 1,30 m de altura, em cm; H_d = média das alturas das árvores dominantes, em metros; I = idade em meses; \ln = logaritmo neperiano; \exp = exponencial.

As estimativas dos volumes com casca (V) foram obtidas por equações fornecidas pela empresa (Tabela 2).

Tabela 2 – Equações de volume com casca

Estrato	Equação
001	$\ln V = -11,145922 + 1,886699 \cdot \ln dap + 1,373333 \cdot \ln Ht$
016	$\ln V = -9,850475 + 1,7856259 \cdot \ln dap + 1,0923825 \cdot \ln Ht$
026	$\ln V = -10,162655 + 1,8427101 \cdot \ln dap + 1,1041629 \cdot \ln Ht$
041	$\ln V = -10,636733 + 1,9185875 \cdot \ln dap + 1,2004476 \cdot \ln Ht$
042	$\ln V = -10,508245 + 1,883954 \cdot \ln dap + 1,1755465 \cdot \ln Ht$
077	$\ln V = -10,382205 + 1,8935363 \cdot \ln dap + 1,1283936 \cdot \ln Ht$

Em que: V = volume individual das árvores, em m^3 ; \ln = logaritmo neperiano; dap = diâmetro com casca medido a 1,30 m de altura, em cm; Ht = alturas, em metros.

Os limites para a classificação das parcelas nas classes de produtividade foram: classe de produtividade I (Alta), parcelas com altura dominante (H_d) > 29 m na idade índice de 60 meses; classe de produtividade II (Média), parcelas com $23 < H_d \leq 29$ m; classe de produtividade III (Baixa), parcelas com $H_d \leq 23$ m. Os valores médios das variáveis do povoamento nas respectivas classes de produtividade são apresentados na Tabela 3.

Tabela 3 – Valores médios das variáveis por idade e classe de produtividade

Variável	Idade (meses)	Classe de capacidade produtiva								
		I (Alta)			II (Média)			III (Baixa)		
		Mín.	Méd.	Máx.	Mín.	Méd.	Máx.	Mín.	Méd.	Máx.
<i>dap</i> (cm)	24	4,1	12,2	18,1	4,1	10,7	17,4	4,0	8,9	16,3
	36	4,3	13,9	22,3	4,5	12,2	22,0	4,0	10,0	20,4
	48	4,8	14,9	24,7	4,8	13,3	25,1	4,3	10,8	22,7
	60	5,1	15,9	27,1	5,2	14,3	27,2	4,5	11,5	24,6
	72	5,2	16,9	29,4	5,3	15,1	28,7	4,5	12,2	24,8
\overline{dap} (cm)	24	9,8	12,2	13,2	9,2	10,7	12,0	7,1	8,9	10,0
	36	11,9	13,9	15,0	10,2	12,2	13,9	8,7	10,0	11,1
	48	13,2	14,9	16,2	11,2	13,3	15,1	9,6	10,8	12,0
	60	14,4	15,9	17,2	12,0	14,3	16,1	10,4	11,5	12,8
	72	15,6	16,9	18,0	12,5	15,1	17,1	11,0	12,2	13,5
<i>q</i> (cm)	24	10,2	12,5	13,4	9,4	10,9	12,2	7,3	9,1	10,1
	36	12,5	14,3	15,3	10,8	12,6	14,2	9,0	10,3	11,3
	48	13,9	15,4	16,5	11,9	13,7	15,4	10,0	11,2	12,3
	60	15,1	16,4	17,6	12,7	14,8	16,5	10,8	12,0	13,2
	72	16,4	17,5	18,4	13,2	15,7	17,5	11,3	12,7	13,9
<i>Ht</i> (m)	24	9,0	16,0	21,2	8,8	14,3	19,8	8,5	12,4	18,5
	36	9,8	19,7	26,8	9,6	17,6	25,7	9,1	14,8	24,7
	48	10,9	22,2	30,3	10,5	20,1	29,2	9,9	16,9	28,1
	60	11,7	24,3	32,7	11,3	22,1	31,4	10,4	18,4	30,0
	72	12,1	26,0	34,1	11,9	23,8	33,1	10,8	19,9	30,9
\overline{Ht} (m)	24	13,4	16,0	16,9	12,7	14,3	15,9	10,5	12,4	13,5
	36	17,4	19,7	20,8	15,2	17,6	19,7	13,1	14,8	15,9
	48	20,0	22,2	23,5	17,3	20,1	22,3	15,1	16,9	18,3
	60	22,5	24,3	25,6	19,1	22,1	24,3	16,9	18,4	19,8
	72	24,2	26,0	27,0	20,3	23,8	26,1	18,1	19,9	21,4
<i>B/ha</i> (m ² /ha)	24	7,8	13,7	15,9	6,4	10,1	12,7	4,7	6,9	8,2
	36	11,6	17,4	20,3	8,3	13,2	16,4	7,2	8,8	10,1
	48	12,8	19,5	23,1	10,7	15,5	19,3	8,2	10,3	12,3
	60	14,3	21,5	24,7	12,2	17,8	23,3	8,9	11,4	13,8
	72	16,1	23,3	27,2	13,2	19,9	25,7	9,5	12,2	15,9
<i>V/ha</i> (m ³ /ha)	24	47,8	93,8	111,1	44,9	65,2	84,4	23,8	41,5	55,7
	36	99,4	156,2	187,5	70,5	110,3	145,2	46,5	64,3	85,9
	48	127,2	206,1	248,2	97,6	150,9	196,0	62,1	87,9	122,9
	60	159,9	253,4	301,1	124,2	193,7	261,1	73,9	106,8	149,6
	72	193,6	297,6	353,9	143,7	235,0	324,2	84,4	124,3	185,3
<i>N/ha</i>	24	960	1103	1160	920	1073	1240	760	1069	1180
	36	940	1078	1140	900	1059	1240	760	1059	1160
	48	840	1045	1120	880	1039	1220	760	1044	1140
	60	800	1012	1120	880	1028	1180	760	1018	1140
	72	760	967	1040	860	1014	1180	760	966	1120

Em que: Mín. = valor mínimo observado; Méd. = valor médio observado; Máx. = valor máximo observado.

Para o desenvolvimento deste estudo, o conjunto de dados foi dividido aleatoriamente em dois grupos. O primeiro refere-se aos dados para a calibração das regras de evolução (ajustes das equações referentes aos modelos de regressão e treinamento de redes neurais artificiais), composto por 33 parcelas (11 em cada classe de capacidade produtiva), totalizando nas cinco medições, 8.735 casos. O segundo refere-se aos dados para a validação, composto por 30 parcelas (10 em cada classe de capacidade produtiva), as quais foram utilizadas na simulação do crescimento, totalizando 7.756 casos.

4.2. Métodos

Em virtude dos dados disponíveis (floresta equiânea e arranjo espacial único), foi avaliado o modelo de crescimento e produção em nível de árvores individuais de distância independente, considerando duas metodologias: 1) Ajuste de equações referentes aos sub-modelos de crescimento em diâmetro e altura e de probabilidade de mortalidade, por meio da técnica de regressão (linear e não-linear); 2) Emprego de redes neurais artificiais (RNA) para prever estas mesmas variáveis.

Para cada árvore, em cada medição, foram calculados os cinco índices de competição independentes da distância (*IID*) descritos em 3.1.1.1. do item revisão de literatura.

Para avaliar os índices de competição, calculou-se a correlação simples entre os cinco índices e o crescimento em diâmetro (Δd), crescimento em altura (Δh), idade (I), área basal (B/ha), e probabilidade de mortalidade ($P(M)$) e a significância estatística das correlações pelo teste t , a 95 % de probabilidade. Além disso, foram elaborados gráficos de tendência para avaliar o comportamento dos índices em função da idade e da classe de capacidade produtiva, para as árvores de maior porte (dominantes), médias e de menor porte (suprimidas).

A estratificação foi realizada agrupando-se os dados das árvores (identificadas na idade de 72 meses) em três classes de tamanho, a saber: árvores maiores ($dap > \overline{dap} + 0,5 \cdot s$), médias ($\overline{dap} - 0,5 \cdot s \leq dap \leq \overline{dap} + 0,5 \cdot s$)

e menores ($dap > \overline{dap} - 0,5 \cdot s$), para as três classes de produtividade, em que \overline{dap} é a média aritmética dos dap e s igual ao desvio padrão.

Para gerar estimativas anuais de mortalidade foram utilizadas as árvores que morreram no período avaliado, conforme Zhao et al., (2007). Foi calculada a proporção de árvores mortas por classe de diâmetro, em cada ano de medição e o cálculo da probabilidade anual de mortalidade ($P(M)$) foi realizado pela seguinte expressão (adaptado de KEISTER e TIDWELL, 1975; GLOVER e HOOL, 1979; MIRANDA et al., 1989; MACHADO et al., 2002; MAESTRI et al., 2003; ROSSI et al., 2007):

$$P(M) = \frac{n_{j1} - n_{j2}}{\sum_{i=1}^j n_{j1}} \cdot 100 \quad (12)$$

Em que: n_{j1} = número de árvores vivas na j -ésima classe de diâmetro, no início do período; n_{j2} = número de árvores vivas na j -ésima classe de diâmetro no fim do período.

4.2.1. Modelos de regressão

Para estimar o diâmetro e a altura das árvores nas idades futuras, foram ajustados os seguintes modelos de regressão:

a) Modelo de crescimento linear adaptado (TOMÉ e BURKHART, 1989; WYKOFF, 1990):

$$Y_2 = \beta_0 + \beta_1 Y_1 + \beta_2 I + \beta_3 S + \beta_4 IID_i + \varepsilon \quad (13)$$

Em que: Y_2 = diâmetro ou altura em idade futura; Y_1 = diâmetro ou altura na idade atual; $\beta_0, \beta_1, \beta_2, \beta_3, \beta_4$ = parâmetros do modelo; I, S, IID_i = idade, em meses; índice de local, em m e índices de competição, respectivamente; ε = erro aleatório.

b) Modelo de Lundviq-Korf (AMARO e TOMÉ, 1997):

$$Y_2 = \beta_0 + \beta_1 S \frac{Y_1 \frac{l_1^{\beta_2}}{l_2}}{\beta_0 + \beta_1 S} + \varepsilon \quad (14)$$

Em que: Y_2 = diâmetro ou altura em idade futura; Y_1 = diâmetro ou altura na idade atual; S = índice de local; l_1 = idade atual, em meses; l_2 = idade futura, em meses; $\beta_0, \beta_1, \beta_2$ = parâmetros do modelo; ε = erro aleatório.

Para modelar a probabilidade mortalidade foram utilizadas as funções logística e de West (1981), dadas respectivamente por:

$$P(M) = \left(1 + \exp^{(\beta_0 + \beta_1 IID_i)}\right)^{-1} + \varepsilon \quad (15)$$

$$P(M) = \beta_0 \cdot IID_i^{\beta_1} + \varepsilon \quad (16)$$

Em que: $P(M)$ = probabilidade de mortalidade de cada árvore; exp= exponencial; IID_i = índice de competição independente da distância; β_0, β_1 = parâmetros do modelo; ε = erro aleatório.

Os ajustes das equações referentes a estes modelos foram realizados com auxílio do programa *Statistica 8.0* (STATSOFT, INC, 2009). Para estimativas dos parâmetros do modelo linear foi utilizado o método de mínimos quadrados ordinários e para os modelos não-lineares foi utilizado o algoritmo *Levenberg-Marquardt*.

Cabe-se destacar que as equações referentes ao modelo 13 também foram ajustadas sem os índices de competição, para verificar o efeito desta variável nas estimativas dos diâmetros e alturas das árvores.

4.2.2. Redes neurais artificiais

Na construção e treinamento das redes neurais, utilizou-se a ferramenta *Intelligent Problem Solver*, do *Statistica 8.0* (STATSOFT, INC, 2009), sendo testadas diferentes arquiteturas de redes MLP (*Multilayer Perceptron*), ajustando os pesos para cada neurônio. Os treinamentos foram do tipo *feedforward*, pelo método supervisionado e as variáveis de entrada foram selecionadas com base na relação com a variável de saída analisada. Foram treinadas 600 redes para cada variável ($P(M)$, Ht e dap), conforme especificado na Tabela 4. A própria ferramenta selecionou, em cada arquitetura de RNA, as variáveis de entrada de importância para a previsão e as ranqueou.

Tabela 4 – Variáveis utilizadas no treinamento das RNA

Variável de saída	Variáveis de entrada	Nº de redes treinadas
<i>P(M)</i>	<i>I</i> ₁ , <i>S</i> , <i>CLA</i> , <i>IID</i> ₁	100
	<i>I</i> ₁ , <i>S</i> , <i>CLA</i> , <i>IID</i> ₂	100
	<i>I</i> ₁ , <i>S</i> , <i>CLA</i> , <i>IID</i> ₃	100
	<i>I</i> ₁ , <i>S</i> , <i>CLA</i> , <i>IID</i> ₄	100
	<i>I</i> ₁ , <i>S</i> , <i>CLA</i> , <i>IID</i> ₅	100
	<i>I</i> ₁ , <i>S</i> , <i>CLA</i>	100
Total		600
<i>Ht</i> ₂	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>Ht</i> ₁ , <i>IID</i> ₁	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>Ht</i> ₁ , <i>IID</i> ₂	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>Ht</i> ₁ , <i>IID</i> ₃	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>Ht</i> ₁ , <i>IID</i> ₄	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>Ht</i> ₁ , <i>IID</i> ₅	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>Ht</i> ₁	100
Total		600
<i>dap</i> ₂	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>dap</i> ₁ , <i>IID</i> ₁	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>dap</i> ₁ , <i>IID</i> ₂	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>dap</i> ₁ , <i>IID</i> ₃	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>dap</i> ₁ , <i>IID</i> ₄	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>dap</i> ₁ , <i>IID</i> ₅	100
	<i>I</i> ₁ , <i>I</i> ₂ , <i>S</i> , <i>dap</i> ₁	100
Total		600

Em que: *I* = idade, em meses; *Ht* = altura total (m); *dap* = diâmetro a 1,3 m (cm). Os subscritos destas variáveis (1 e 2), referem-se às medidas atuais e futuras, respectivamente; *S* = Índice de local, em m; *CLA* = classe de diâmetro (amplitude de 2 cm); *IID*_{*i*} = Índices de competição independentes da distância (*i* = 1 a 5, conforme descritos anteriormente).

4.2.1. Comparação entre as metodologias

Para selecionar a metodologia (regressão ou redes neurais) que forneceu as estimativas mais precisas de probabilidade de mortalidade (*P(M)*), altura e diâmetro das árvores, foram utilizados os seguintes critérios: a) coeficiente de correlação (r_{yy}) entre os valores observados (*y*) e estimados (\hat{y}) (STEEL e TORRIE, 1960); b) coeficiente de variação (CV (%)); c) raiz quadrada do erro médio (RQEM); d) *bias*; e) *bias*% e f) média das diferenças absolutas (MDA), (MURPHY e STERNITZKE, 1979; SIIPILEHTO, 2000 e MONTY et al., 2008), além da análise gráfica dos resíduos.

4.2.2. Validação

Para a validação da melhor metodologia (regressão ou redes neurais) utilizou-se a sequência de passos e decisões proposta por Davis e Johnson

(1987) para um modelo em nível de árvore individual. Contudo, antes foi definida uma arquitetura de Autômato Celular para a simulação, como propostos por Hegde et al. (2008).

O AC foi programado utilizando a ferramenta *Visual Basic for Applications* (VBA), sendo projetado com células simulando um formato quadrangular (3 x 3 m), dispostas em uma grade bidimensional. Cada célula correspondeu a uma árvore e a distribuição foi definida seguindo a ordem de filas e covas das parcelas. A vizinhança utilizada para raio de ação das regras foi a de Moore estendida semi-uniforme, conforme Couclelis (1997), compreendendo todas as árvores pertencentes à mesma parcela. As células vizinhas interagiram por meio de algoritmos desenvolvidos para cálculo dos índices de competição.

Cada célula possuía um código binário, utilizado para representar o estado da célula: 1 (preto), se a árvore estivesse viva; e 0 (branco) se estivesse morta (Figura 8a). Outras três variáveis foram atribuídas a cada célula, e sujeitas a mudanças a cada evolução (índice de competição, altura e *dap*). A evolução do sistema representou a dinâmica do povoamento (Figura 8b).

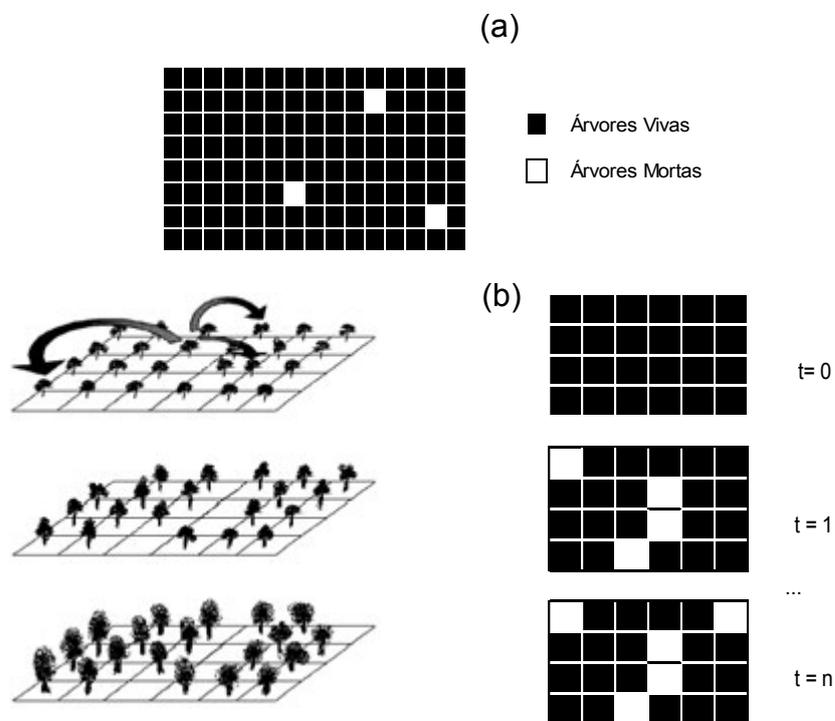


Figura 8 – Ilustração teórica do processo de evolução de uma parcela simulada pelo Autômato Celular.

Os índices de competição foram calculados para todas as células (árvores dentro da parcela) e, em seguida, foram aplicadas as seguintes regras:

- **Regra 1:** Mortalidade - onde se definiu se a árvore-objeto morreria no intervalo de projeção estipulado.
- **Regra 2:** Regra de crescimento em altura;
- **Regra 3:** Regra de crescimento em diâmetro.

Para a regra de mortalidade foi utilizado o método proposto por Pretzsch et al., (2002), em que, após estimada a probabilidade de mortalidade para cada árvore, foi também gerado um número aleatório ($P(a)$) entre zero e um, que foi comparado à probabilidade estimada. A regra de decisão para definir se a árvore morria foi: se $P(M) > P(a)$ a árvore morreria, caso contrário, a árvore permaneceria viva e suas dimensões seriam atualizadas para a idade seguinte.

A célula que, em algum momento assumisse o estado 0, permaneceria neste estado até o fim do processo, uma vez que não foi considerada a possibilidade de ingresso de uma nova árvore na sua célula. Assim suas variáveis dimensionais (diâmetro e altura), bem como o índice de competição assumiriam valores nulos.

Quando todas as árvores dentro da parcela foram submetidas às regras definidas anteriormente, computaram-se seus respectivos volumes com casca e a estrutura resultante foi projetada para idades subsequentes até a idade final de projeção.

Desta forma, definida a estrutura do Autômato Celular, as variáveis referentes à primeira medição das parcelas selecionadas para a validação (aos 24 meses) foram utilizadas para as projeções até 72 meses.

Os valores iniciais das variáveis *dap* e *Ht* foram atribuídos como estado inicial na grade do AC. Neste instante, todas as células estavam no estado vivo (1), exceto as falhas de plantio, que receberam valores 0. Partindo destas condições, o AC evoluiu no tempo (12 em 12 meses).

A estrutura do povoamento em cada idade projetada foi comparada a estrutura observada, com o objetivo de verificar se o AC foi capaz de

representar a dinâmica da floresta, e se o modelo não apresentou viés na estimação. Para isso, as estimativas das dimensões das árvores, assim como a distribuição diamétrica e o volume total por hectare foram comparados em cada classe de capacidade produtiva, nos intervalos de projeção propostos.

Para avaliar qualitativamente o nível de precisão das estimativas de mortalidade em nível de árvore individual calculou-se a porcentagem de árvores mortas classificadas corretamente, e para estimativas em nível de povoamento, foi realizada a análise gráfica das estimativas de sobrevivência.

Para verificar a igualdade das estimativas de *Ht* e *dap* das árvores individuais em relação aos valores observados foi aplicado o teste *F* (GRAYBILL, 1976).

O critério de decisão adotado para o teste *F*, segundo Chichorro et al. (2003), foi (Tabela 5):

Tabela 5 – Critério de decisão baseado na estatística *F*

Caso	Teste <i>F</i>	$R^2\%$	\bar{E} (%)	Situação
1	n.s.	≥ 90 (alto)	< 10 (baixo)	Ideal
2	n.s.	≥ 90 (alto)	≥ 10 (alto)	Aceitável
3	n.s.	< 90 (baixo)	< 10 (baixo)	Inaceitável
4	n.s.	< 90 (baixo)	≥ 10 (alto)	Inaceitável
5	*	≥ 90 (alto)	< 10 (baixo)	Aceitável
6	*	≥ 90 (alto)	≥ 10 (alto)	Inaceitável
7	*	< 90 (baixo)	< 10 (baixo)	Inaceitável
8	*	< 90 (baixo)	≥ 10 (alto)	Inaceitável

Em que: n.s. = não significativo à 5% de significância; * = significativo à 5% de significância; $R^2\%$ = coeficiente de determinação em porcentagem; \bar{E} (%) = Erro médio em porcentagem, obtido por: $\bar{E} = 100 \cdot \left\{ \sum [(Y_{ji} - Y_{ij}) / Y_{ij}] \right\} / n$.

O teste *F*, proposto por Graybill (1976), constitui uma forma analítica de realizar a análise dos resíduos, uma vez que algumas tendências observadas apenas pela análise visual dos gráficos podem ser enganosas (CHICHORRO et al., 2003).

Para verificar a dispersão e exatidão das estimativas, calcularam-se as estatísticas $r_{\hat{y}}$, CV %, RQEM, *bias*, *bias%* e MDA conforme descrito anteriormente, além de análises gráficas.

Para verificar a diferença estatística entre as distribuições diamétricas médias e por parcela estimadas e as observadas, por classe de capacidade

produtiva, em cada idade de projeção, aplicou-se o teste Qui-quadrado (χ^2) (NESBITT, 1995).

Para as estimativas em nível de povoamento, os volumes das árvores individuais foram totalizados e as estimativas por hectare das parcelas, nas idades analisadas, foram submetidas ao teste t para amostras dependentes, considerando um nível de significância de 5 %, além da análise gráfica dos valores observados e estimados.

5. RESULTADOS E DISCUSSÃO

5.1. Índices de competição

Em geral, foi observada correlação significativa ($p < 0,05$) entre os índices de competição e as variáveis de crescimento em diâmetro e altura (Δd e Δh) e probabilidade de mortalidade ($P(M)$), pelo teste t (Tabela 6). As correlações foram positivas entre os índices e as variáveis de crescimento, exceto para o índice IID_5 , cuja correlação foi negativa. Apenas o IID_3 e o IID_2 foram não significativos para o crescimento em diâmetro, na classe de capacidade produtiva alta, e para a variável mortalidade ($P(M)$) na classe baixa, respectivamente.

Nenhum índice mostrou-se superior para todas as variáveis. Para o crescimento em diâmetro (Δd) e altura (Δh), o índice IID_5 foi o que apresentou maiores correlações nas três classes de capacidades produtivas. O IID_4 foi superior para a variável $P(M)$, também para as três classes.

Tabela 6 – Matriz de correlação simples entre os índices de competição (IID_1 à IID_5), crescimento dimensional em dap (Δd) e altura (Δh), probabilidade de mortalidade ($P(M)$), idade (I) e área basal do povoamento (B/ha) para as classes de produtividade (I, II e III)

	I	IID_1	IID_2	IID_3	IID_4	IID_5	Δd	Δh	$P(M)$	B
I (Alta)										
I	1,00	-0,05	-0,07	-0,04	-0,06	0,32*	-0,34*	-0,74	-0,57*	0,89*
IID_1		1,00	0,97*	1,00*	0,99*	-0,92*	0,68*	0,44*	-0,54*	-0,06
IID_2			1,00	0,95*	0,97*	-0,92*	0,65*	0,47*	-0,57*	-0,07
IID_3				1,00	0,99*	-0,88*	0,67 ^{n.s.}	0,43*	-0,43*	-0,05
IID_4					1,00	-0,91*	0,70*	0,55*	-0,62*	-0,06
IID_5						1,00	-0,74*	-0,60*	-0,59*	-0,34*
Δd							1,00	0,82*	-0,71*	-0,36*
Δh								1,00	-0,45*	-0,68*
$P(M)$									1,00	-0,13
B/ha										1,00
II (Média)										
I	1,00	0,01	-0,01	0,02	-0,01	0,46*	-0,36*	-0,68*	-0,31*	0,79*
IID_1		1,00	0,97*	0,98*	0,98*	-0,76*	0,63*	0,41*	-0,38*	-0,02
IID_2			1,00	0,95*	0,98*	-0,76*	0,62*	0,45*	-0,38*	-0,02
IID_3				1,00	0,99*	-0,75*	0,62*	0,39*	-0,35*	-0,01
IID_4					1,00	-0,78*	0,64*	0,52*	-0,47*	-0,02
IID_5						1,00	-0,64*	-0,59*	-0,39*	-0,02
Δd							1,00	0,87*	-0,43*	-0,24*
Δh								1,00	-0,40*	-0,48*
$P(M)$									1,00	-0,22*
B/ha										1,00
III (Baixa)										
I	1,00	0,01	-0,02	0,02	-0,02	0,42*	-0,33*	-0,49*	-0,30*	0,90*
IID_1		1,00	0,98*	0,99*	0,99*	-0,84*	0,52*	0,58*	-0,30*	-0,01
IID_2			1,00	0,96*	0,98*	-0,86*	0,54*	0,57*	-0,11 ^{n.s.}	-0,01
IID_3				1,00	0,99*	-0,82*	0,55*	0,54*	-0,28*	-0,02
IID_4					1,00	-0,86*	0,62*	0,58*	-0,50*	-0,02
IID_5						1,00	-0,63*	-0,69*	-0,32*	-0,46*
Δd							1,00	0,94*	-0,53*	-0,35*
Δh								1,00	-0,46*	-0,47*
$P(M)$									1,00	-0,46*
B/ha										1,00

* significativo a 5% de significância.

^{n.s.} não significativo a 5% de significância.

A correlação simples entre estas variáveis é um critério comum para avaliar e selecionar índices de competição (DANIELS, 1976), principalmente quando se trata de modelagem linear. Porém, apenas a correlação simples não é definitiva para se avaliar o efeito entre as variáveis. Através da análise gráfica dos índices de competição, estratificados por classe de capacidade produtiva, em função da idade e do porte das árvores em que, Classe I: $\overline{dap} = 16,9$ cm e $s = 7$ cm; Classe II: $\overline{dap} = 15,1$ cm e $s = 6$ cm e Classe III: $\overline{dap} = 12,2$ cm e $s =$

6 cm, observa-se que as árvores de diferentes tamanhos apresentaram comportamentos distintos na tendência dos índices de competição (Figura 9).

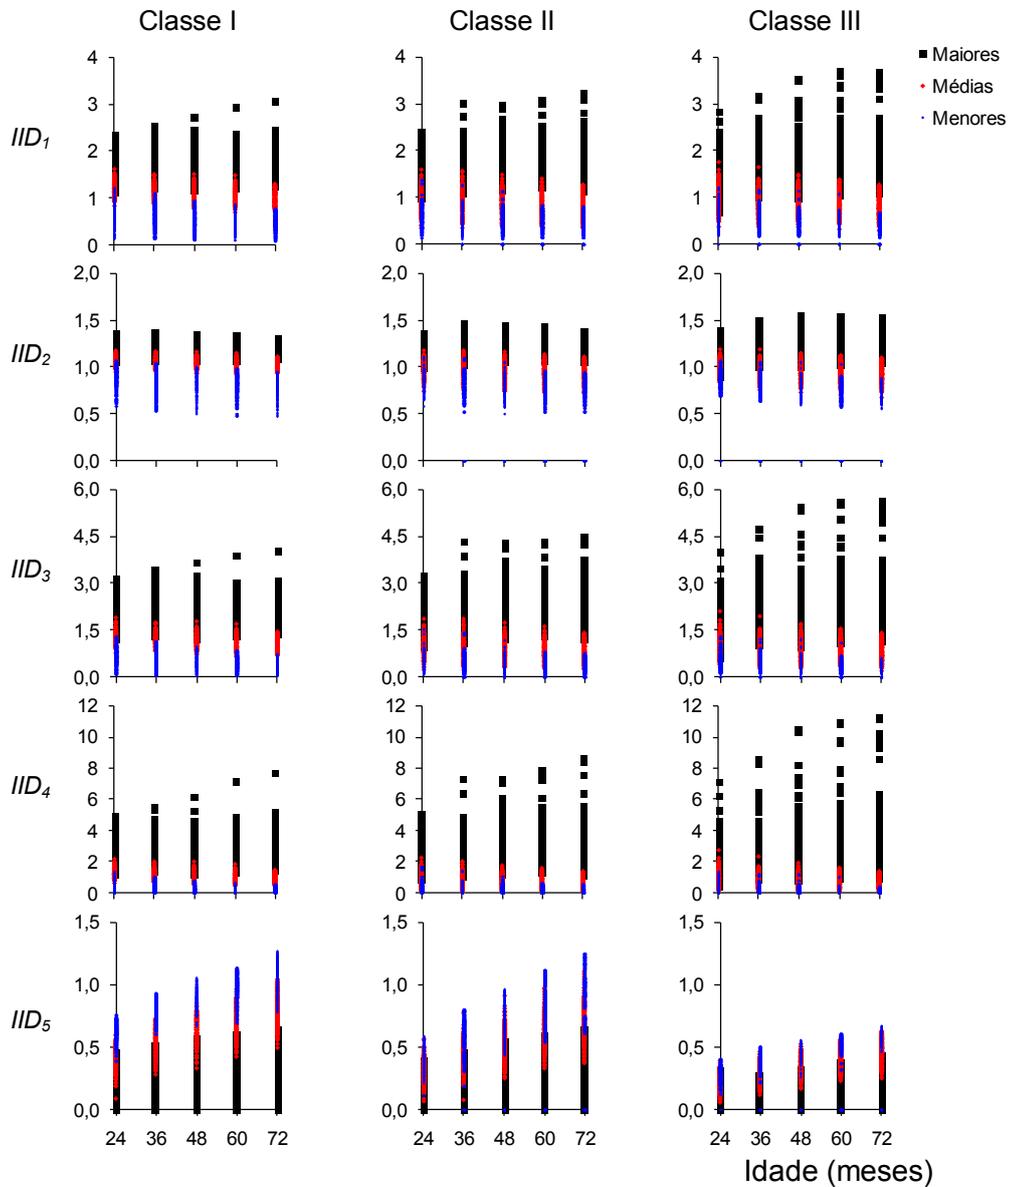


Figura 9 – Dispersão dos índices de competição em função da idade, da capacidade produtiva e da classe de tamanho das árvores.

As tendências médias dos índices de competição 1, 2, 3 e 4 (IID_1 a IID_4), na Figura 10, mostrou comportamentos semelhantes. As maiores árvores apresentaram tendência média crescente dos índices, uma vez que oferecem concorrência às árvores menores, inibindo o seu crescimento. De forma complementar, as árvores menores apresentaram tendência decrescente para os quatro primeiros índices, por serem árvores suprimidas. Além disso,

observa-se que as árvores médias apresentaram comportamentos constantes e próximos a 1.

Para o índice de competição 5 (IID_5) (Figura 10), maiores valores foram observados para as menores árvores, uma vez que este índice é o único que possuiu correlação negativa com as variáveis de crescimento. Diferentemente dos demais índices analisados, também existe uma tendência crescente em função da idade para todas as classes de tamanho (tratando-se do único índice de correlação significativa com a variável idade). Estas diferentes tendências se devem à forma de cálculo de cada índice. O IID_5 refere-se à soma das áreas seccionais das árvores maiores do que a árvore-objeto. Como as árvores continuam crescendo ao longo do tempo, o índice tende sempre a aumentar em função da idade. Os demais índices (IID_1 a IID_4) são obtidos a partir de uma razão entre variáveis (razão de tamanhos), e este comportamento crescente não é verificado para todas as classes de tamanho de árvores.

Na medida em que aumenta a idade do povoamento, a amplitude entre os índices calculados para as maiores e menores árvores tende a aumentar. Isso ocorre devido ao baixo crescimento das árvores menores e maior crescimento das maiores árvores. Verificou-se, também, que quanto pior a capacidade produtiva, maior a competição entre os indivíduos.

Tonini (2007) concluiu que a utilização de índices de competição em estimativas de crescimento dimensional, só são confiáveis para estimativas à curto prazo. Já, segundo Barclay e Layton (1990), para estimativas à longo prazo é necessário o conhecimento de mecanismos competitivos (índices) que permitam quantificar as mudanças no estoque de nutrientes, água e luz para as árvores.

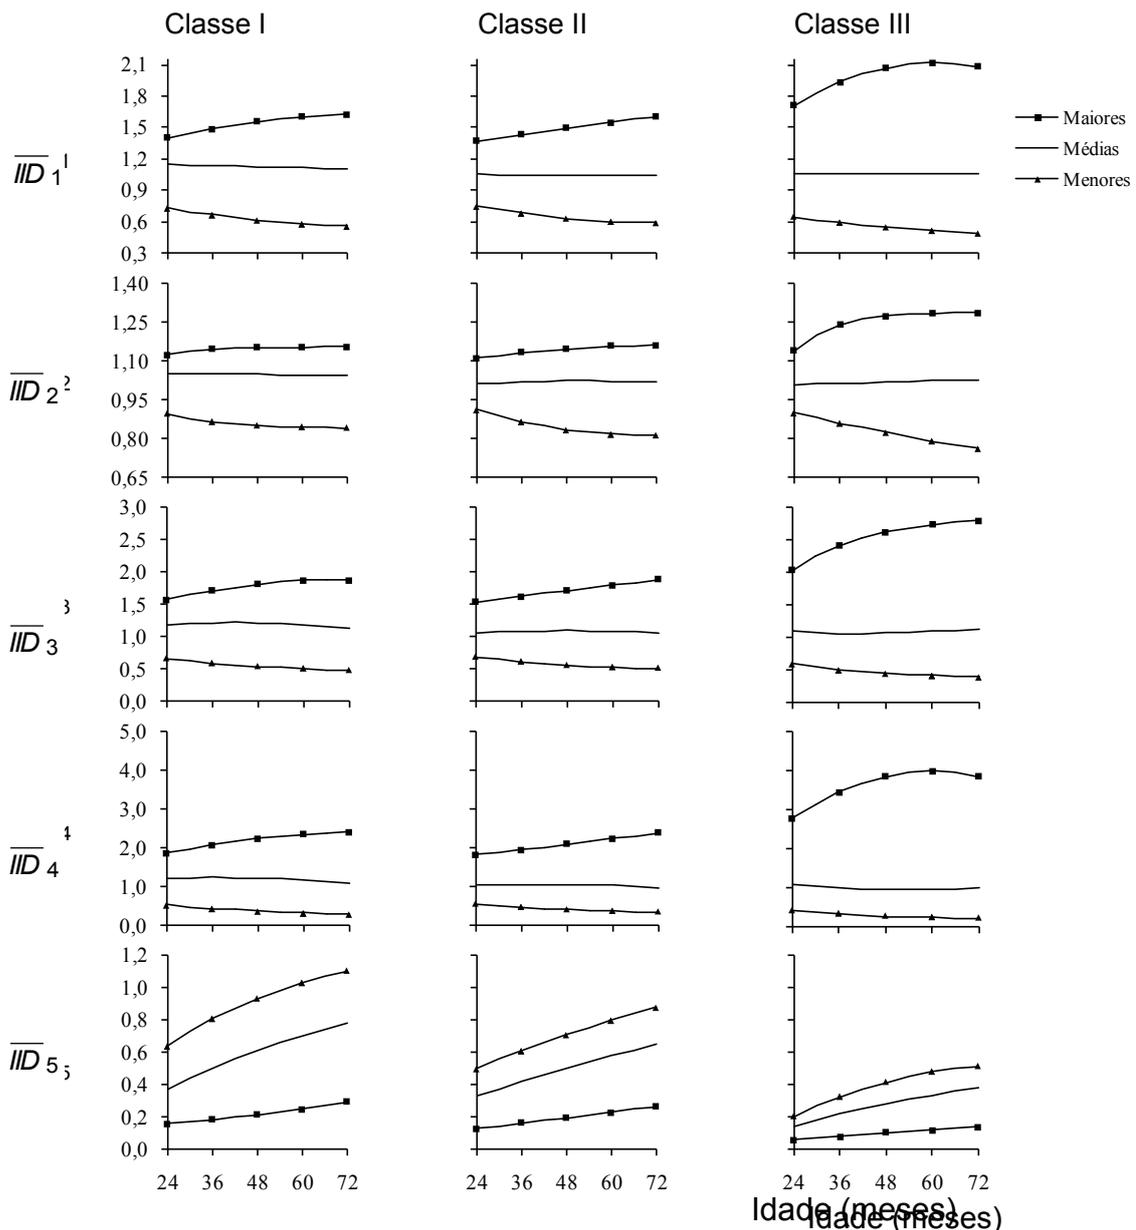


Figura 10 – Tendência média dos índices de competição em função do tempo, estratificados por classe de capacidade produtiva e classe de tamanho das árvores.

As correlações entre a probabilidade de mortalidade ($P(M)$) indicam, de forma geral, resultados significativos estatisticamente com a variável idade e os cinco índices de competição.

As probabilidades de mortalidade de árvores estão inversamente correlacionadas com a idade (-0,57; -0,31 e -0,31, respectivamente para as classes de capacidade produtiva I, II e III), indicando que há uma maior probabilidade de mortalidade em idades menores nas três classes de capacidade produtiva, assim como a tendência verificada por Waring (1987), Monserud e Sterba (1999) e Demolinari (2006).

Os índices de competição (IID_1 a IID_5) apresentaram correlações negativas com a probabilidade de mortalidade, com valores entre -0,28 e -0,62. Apenas o IID_2 apresentou resultado não significativo (-0,11) na classe de capacidade produtiva baixa (Classe III).

Biologicamente, estas tendências são esperadas, uma vez que árvores mais jovens, de menores tamanhos e localizados em áreas de menor capacidade produtiva apresentam maior probabilidade de morrer (ROSSI et al., 2007).

5.2. Modelos de regressão

Todas as estimativas dos parâmetros das equações para a variável probabilidade de mortalidade ($P(M)$) foram significativas ($p < 0,05$), exceto para o parâmetro β_0 do modelo Logística 2 (Tabela 7). Os modelos de regressão que utilizam o IID_5 não convergiram durante o ajuste e por isso não foram apresentados.

Tabela 7 – Estimativas dos parâmetros das equações para probabilidade de mortalidade ($P(M)$) e respectivas estatísticas

Modelo	Índice de Competição	Parâmetros dos modelos		$r_{y\hat{y}}$	CV % (\pm)	RQEM	bias	bias %	MDA
		$\hat{\beta}_0$	$\hat{\beta}_1$						
West 1	IID_1	0,056	-0,512	0,4243	60,9	0,0502	-0,0004	-37,8439	0,0392
West 2	IID_2	0,058	-1,525	0,3874	62,0	0,0511	-0,0003	-38,7445	0,0395
West 3	IID_3	0,057	-0,386	0,4162	61,2	0,0504	-0,0004	-38,0219	0,0392
West 4	IID_4	0,055	-0,249	0,4169	61,1	0,0504	-0,0004	-38,1096	0,0393
Logística 1	IID_1	1,630	1,505	0,4532	59,9	0,0494	0,0000	-34,1279	0,0385
Logística 2	IID_2	0,516 ^{n.s.}	2,351	0,4012	61,6	0,0508	-0,0003	-37,6137	0,0394
Logística 3	IID_3	1,798	1,396	0,4452	60,2	0,0496	0,0001	-33,8015	0,0389
Logística 4	IID_4	1,974	1,605	0,4396	60,4	0,0498	0,0004	-32,5467	0,0393

^{n.s.} = parâmetro não significativo a 5% de significância.

Na Figura 11 pode-se observar que todas as equações apresentaram tendência de subestimação da probabilidade de mortalidade.

De acordo com as estatísticas apresentadas na Tabela 7 e dos gráficos de resíduos (Figura 11), verificou-se que a equação Logística 1 apresentou desempenho um pouco superior. Vanclay (1994) concluiu que a função mais eficiente para descrever a probabilidade de mortalidade é a Logística, pois, além de gerar estimativas precisas, não exige um grande número de variáveis independentes. Hamilton Jr. (1986) cita vantagens específicas dessa função como: a função é limitada entre 0 e 1, sendo naturalmente limitada à amplitude do potencial da probabilidade de mortalidade; pode ser usada para descrever a maioria dos padrões de mortalidade que ocorrem naturalmente e; as rotinas de estimativas não-lineares podem estimar eficientemente os parâmetros dessa função, devido às facilidades computacionais.

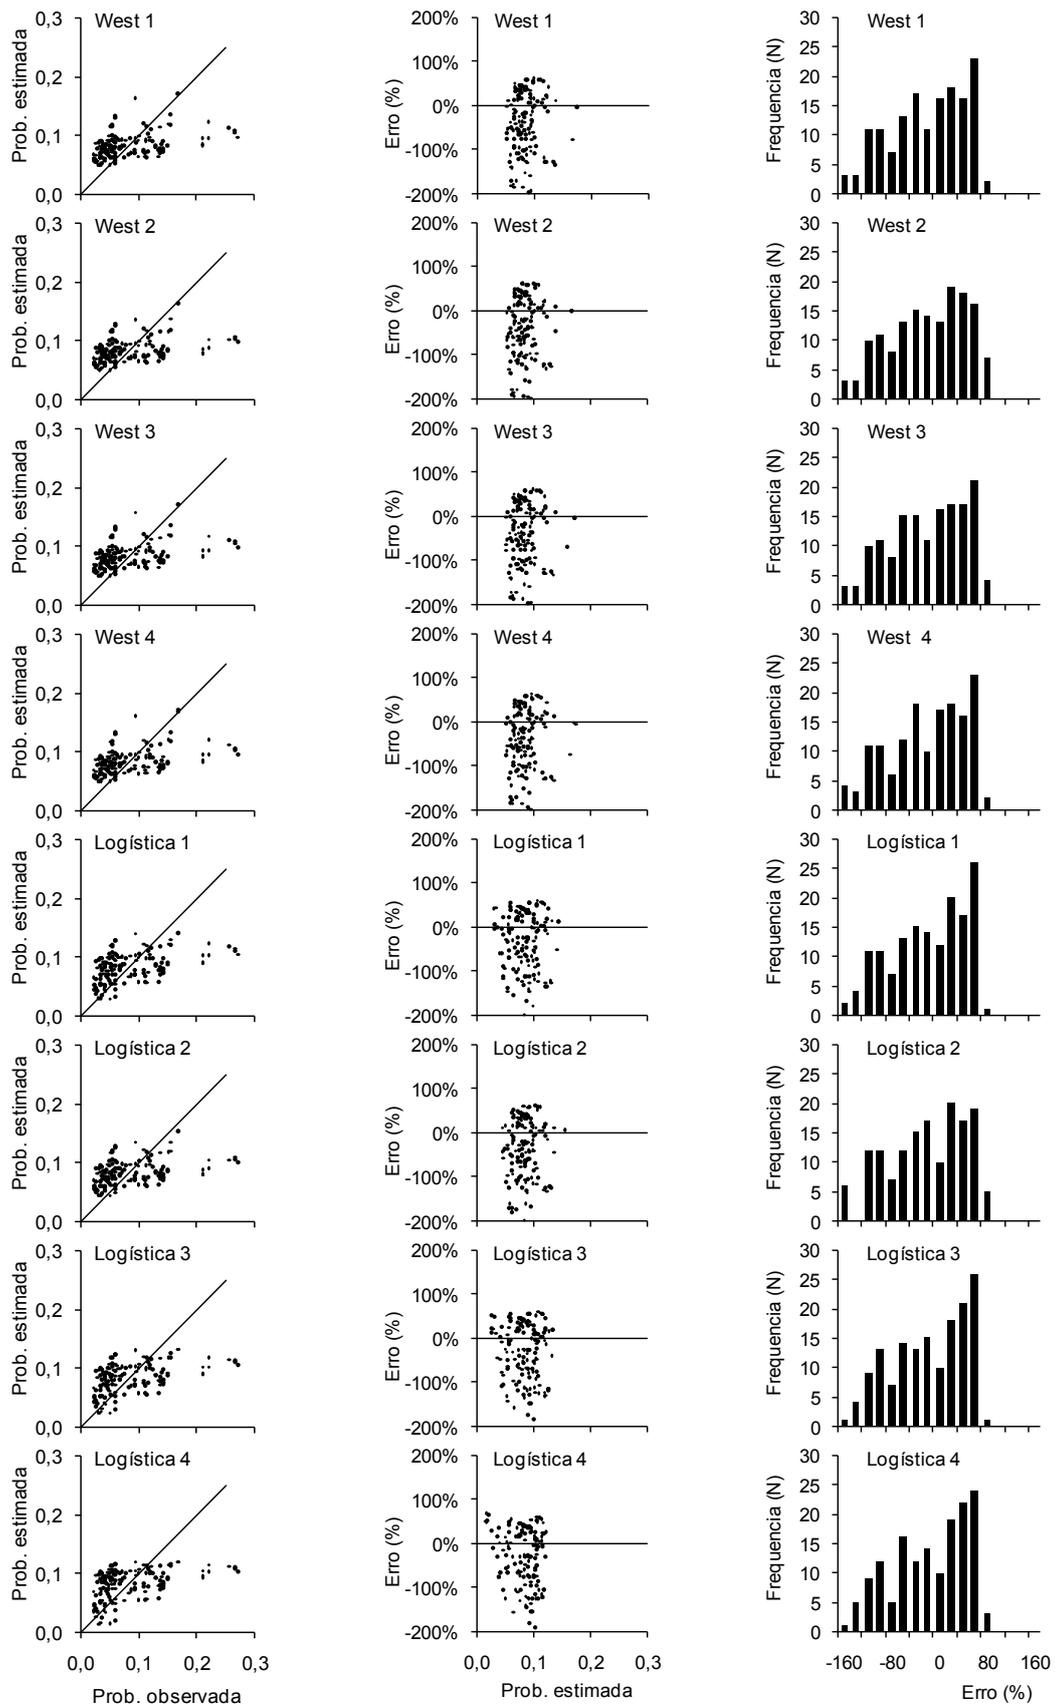


Figura 11 – Análise gráfica dos resíduos das equações para a variável probabilidade de mortalidade.

Todas as estimativas dos parâmetros das equações para a variável altura na idade futura (Ht_2) foram significativas ($p < 0,05$), exceto o parâmetro β_2 (associado à idade) na equação Linear 2 (Tabela 8).

As equações referentes aos modelos Linear 2 e Lundviq-Korf foram aquelas que apresentaram as melhores tendências de distribuição dos resíduos (Figura 12). De maneira geral, todos os modelos testados se ajustaram bem aos dados de altura, entretanto a equação referente ao modelo Linear 2 apresentou desempenho ligeiramente superior quando comparada às demais equações. As estatísticas de exatidão e precisão apresentaram melhores valores do que os encontrados por Palahí e Grau (2003) para plantios de *Pinus*.

Tabela 8 – Estimativas dos parâmetros das equações para a variável altura na idade futura (Ht_2) e respectivas estatísticas

Modelo	Índice de Competição	Parâmetros dos modelos					$r_{y\hat{y}}$	CV % (\pm)	RQEM	bias	bias %	MDA
		$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}_4$						
Linear 1	IID_1	1,0984	0,9225	-0,0294	0,0936	1,4453	0,9920	3,1	0,6354	0,0000	-0,2015	0,4910
Linear 2	IID_2	-5,2306	0,7931	-0,0015 ^{n.s.}	0,1588	6,9909	0,9930	2,9	0,5976	0,0000	-0,1420	0,4629
Linear 3	IID_3	2,1612	0,9813	-0,0420	0,0638	0,7621	0,9915	3,2	0,6547	0,0000	-0,2229	0,5070
Linear 4	IID_4	3,0899	1,0487	-0,0556	0,0297	0,2894	0,9910	3,3	0,6755	0,0000	-0,2406	0,5237
Linear 5	IID_5	2,3357	1,0346	-0,0417	0,0814	-1,7946	0,9912	3,2	0,6679	0,0000	-0,2546	0,5168
Linear 6	Nenhum	4,0028	1,1344	-0,0728	-0,0154	-	0,9903	3,4	0,7006	0,0000	-0,2445	0,5442
Lundviq-Korf	Nenhum	-0,9728	7,03E+105	0,0024	-	-	0,9927	3,0	0,6277	0,0011	0,0262	0,4770

^{n.s.} = parâmetro não significativo a 5% de significância.

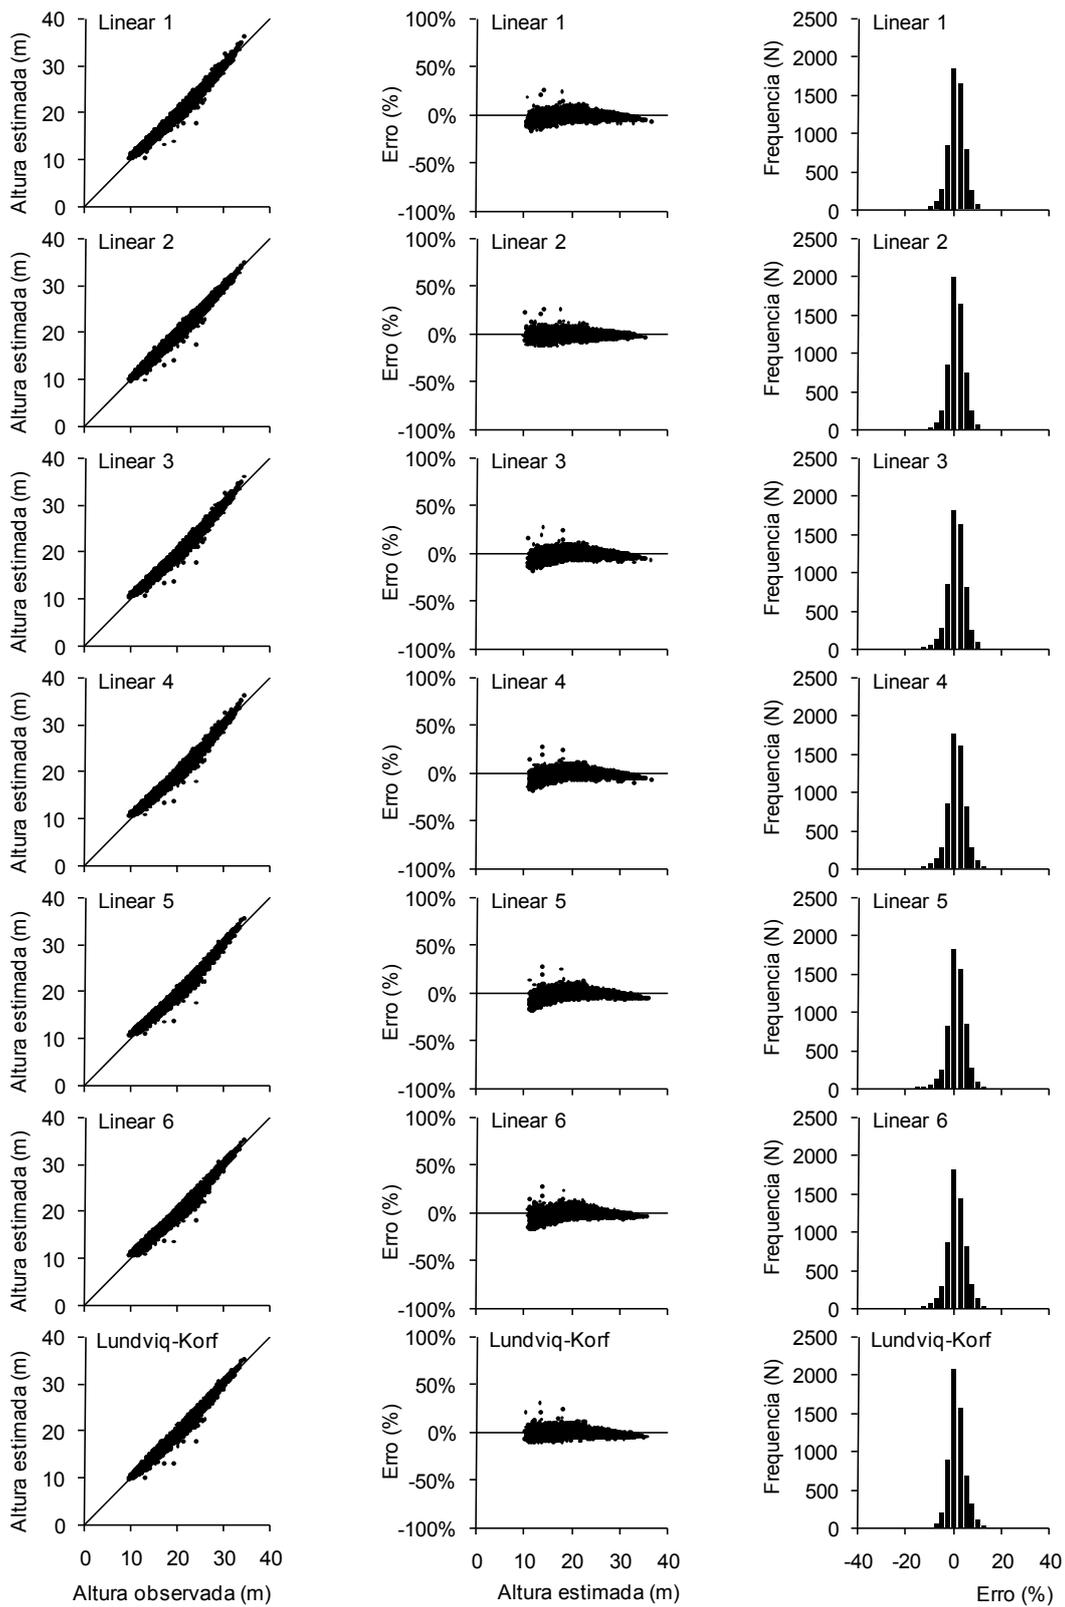


Figura 12 – Análise gráfica dos resíduos das equações para estimativa da variável altura.

Os parâmetros das equações para a estimativa da variável diâmetro foram significativas ($p < 0,05$) (Tabela 9). A exceção da equação de Lundviq-

Korf, todas as demais apresentaram distribuição dos erros não tendenciosos (Figura 13). A equação referente ao modelo Linear 5 apresentou desempenho superior.

As estatísticas de exatidão apresentaram valores superiores às encontradas por Monty et al. (2008) para plantios de *Pseudotsuga menziesii* e às encontradas por Palahí e Grau (2003) para plantios de *Pinus*, bem como valores próximos aos encontrados por Tomé e Burkhart (1989) para plantios de eucalipto em relação à estimação da variável diâmetro.

Tabela 9 – Estimativas dos parâmetros das equações para a variável diâmetro na idade futura (dap_2) e respectivas estatísticas

Modelo	Índice de Competição	Parâmetros dos modelos					$r_{y\hat{y}}$	CV % (\pm)	RQEM	bias	bias %	MDA
		$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}_4$						
Linear 1	IID_1	0,4159	1,0062	-0,0178	0,0191	0,8412	0,9922	3,9	0,5367	0,0000	-0,1547	0,4037
Linear 2	IID_2	-0,6764	1,0313	-0,0197	0,0085	2,0592	0,9919	4,0	0,5471	0,0000	-0,1119	0,4149
Linear 3	IID_3	0,8790	1,0353	-0,0208	0,0075	0,4718	0,9922	4,0	0,5387	0,0000	-0,1803	0,4051
Linear 4	IID_4	1,2466	1,0670	-0,0237	-0,0049	0,2146	0,9921	4,0	0,5404	0,0000	-0,2000	0,4057
Linear 5	IID_5	0,5065	1,0397	-0,0114	0,0462	-1,6053	0,9924	3,9	0,5291	0,0000	-0,2400	0,3964
Linear 6	Nenhum	1,7355	1,1336	-0,0294	-0,0328	-	0,9917	4,1	0,5541	0,0000	-0,1666	0,4180
Lundviq-Korf	Nenhum	-0,7593	0,6517	0,1113	-	-	0,9921	4,0	0,5441	0,0045	0,0922	0,4048

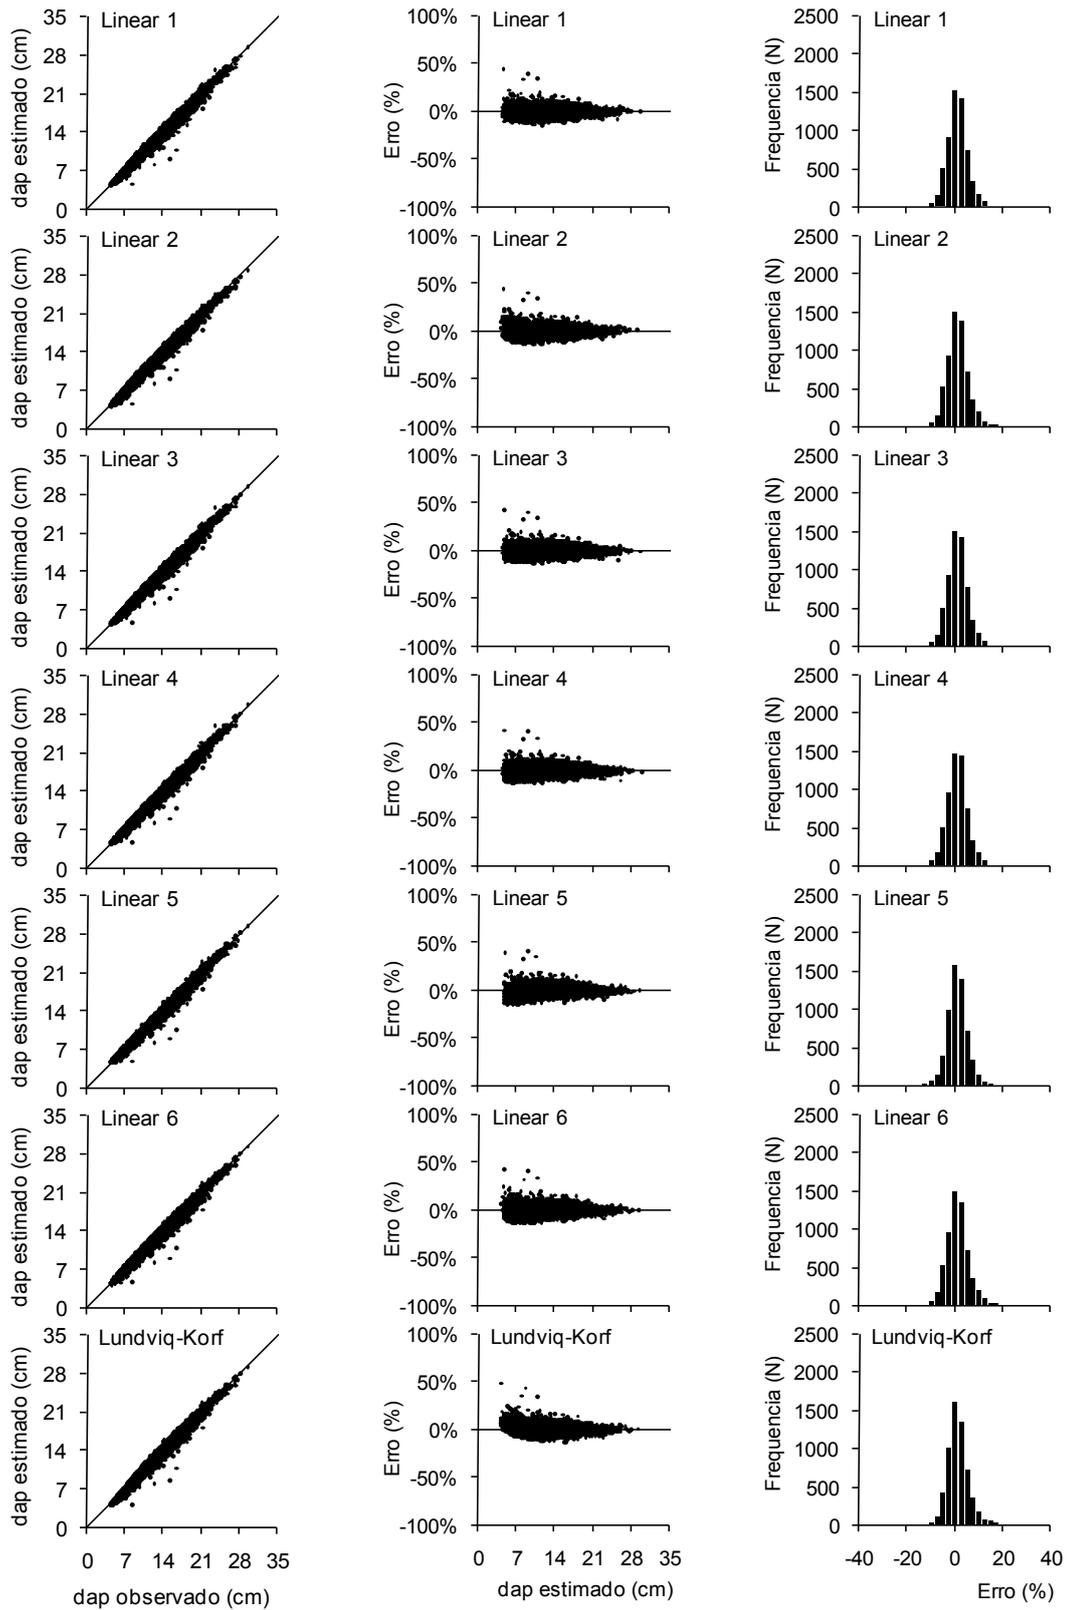


Figura 13 – Análise gráfica dos resíduos das equações para estimativa da variável *dap*.

5.3. Redes neurais artificiais

Os modelos de regressão avaliados para estimar a probabilidade de mortalidade (expressões 15 e 16) consideraram apenas o índice de competição como variável independente, o qual expressa o status competitivo de cada árvore. Glover e Hool (1979), West (1981) e Crecente-Campo et al. (2009) sugerem estimar a mortalidade sem a presença de variáveis do povoamento e da idade como variáveis independentes, por se tratar de um evento aleatório fortemente dependente apenas do *status* competitivo das árvores. Já, Guan e Gertner (1991) recomendam a combinação destas variáveis para estimar a probabilidade de mortalidade. Estes autores complementam que, para cada caso específico é necessário uma diferente estrutura.

Monserud e Sterba (1999) e Palahí e Pukkala (2003) também consideram que, além dos índices de competição, variáveis dimensionais e características de povoamento devem ser utilizados para melhorar as estimativas da variável mortalidade. Mabvurira e Miina (2002) consideraram a variável índice de local para descrever a mortalidade individual de árvores de *Eucalyptus grandis*.

Sendo assim, as RNA do tipo *Multilayer Perceptron* (MLP) foram treinadas para a probabilidade de mortalidade considerando também outras variáveis de entrada, além do índice de competição. As melhores arquiteturas foram resumidas na Tabela 10, tendo como arquitetura genérica uma camada de entrada com 4 variáveis (I_1 , S , CLA e um índice de competição IID); uma camada oculta com n neurônios; e uma camada de saída com apenas um neurônio estimando a variável probabilidade anual de mortalidade para cada árvore ($P(M)$).

Tabela 10 – Arquitetura das redes neurais artificiais ajustadas para obtenção da probabilidade de mortalidade e respectivas estatísticas

Rede	Índice de Competição	Variáveis de entrada utilizadas	Variável de saída	Número de neurônios			$r_{\hat{y}y}$	CV % (\pm)	RQEM	bias	bias %	MDA
				Camada 1	Camada 2	Camada 3						
1	IID_1	I_1, S, CLA, IID_1	$P(M)$	4	9	1	0,7440	43,1	0,0336	0,0004	-16,9064	0,0255
2	IID_2	IID_2	$P(M)$	1	3	1	0,5786	52,3	0,0411	0,0051	-15,8390	0,0305
3	IID_3	I_1, S, CLA, IID_3	$P(M)$	4	8	1	0,7988	38,6	0,0301	0,0009	-12,7304	0,0235
4	IID_4	I_1, S, CLA, IID_4	$P(M)$	4	5	1	0,7105	45,2	0,0370	0,0112	4,0104	0,0286
5	IID_5	I_1, CLA, IID_5	$P(M)$	3	4	1	0,7898	39,3	0,0306	0,0000	-16,3394	0,0244

Em que: I_1 = idade atual, em meses. S = Índice de local, em m; CLA = classe de diâmetro (amplitude de 2 cm); IID_i = Índices de competição independentes da distância (i = 1 a 5, conforme descritos anteriormente) e $P(M)$, probabilidade de mortalidade.

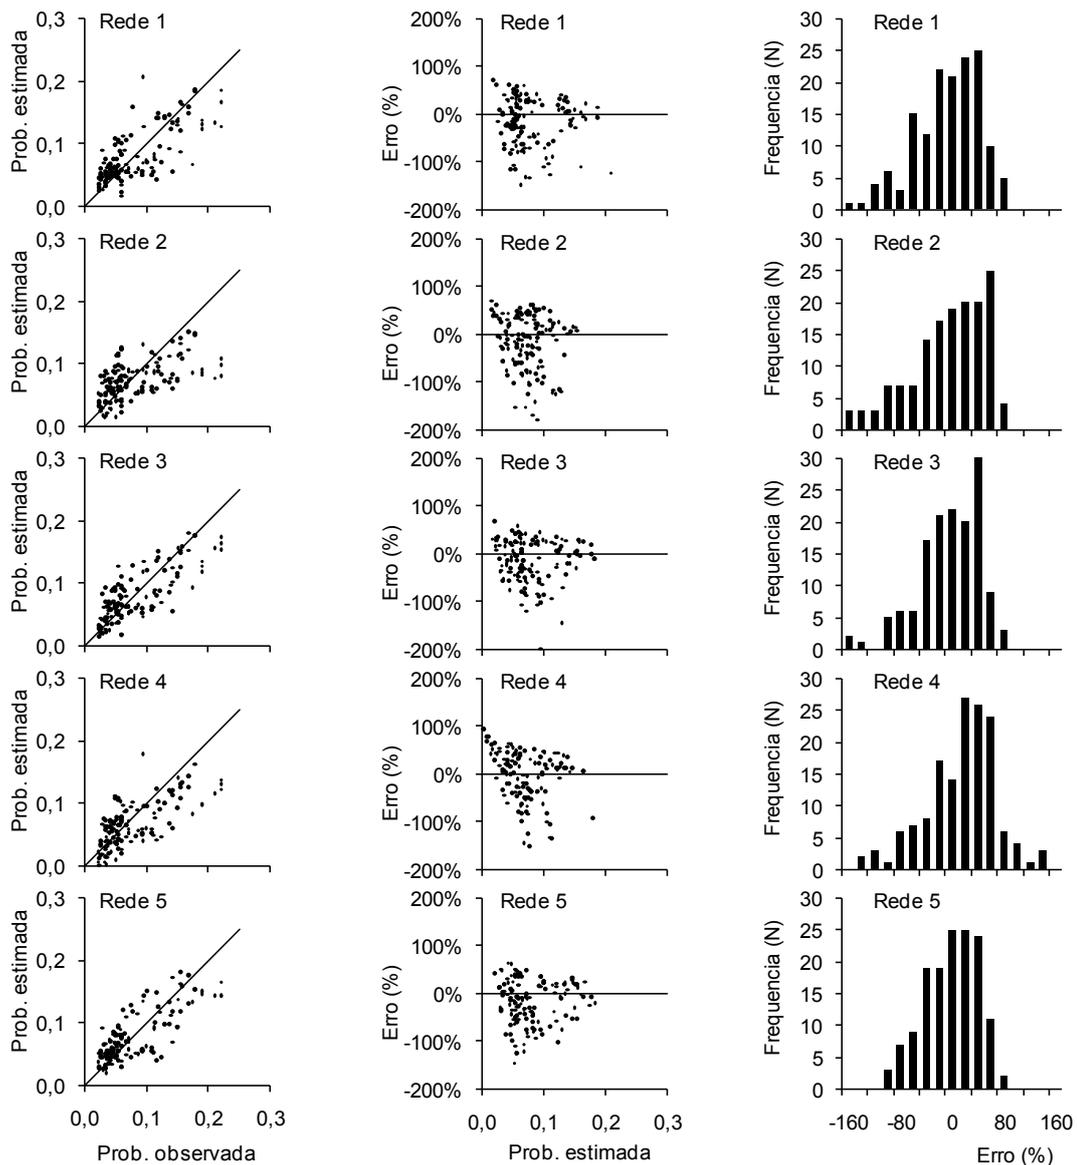


Figura 14 – Análise gráfica dos resíduos para a variável probabilidade de mortalidade, obtidas no treinamento das RNA.

De acordo com a Figura 14, a rede 2 apresentou comportamento dos resíduos semelhante aos modelos de regressão que também utilizaram apenas um índice de competição como variável dependente na estimação da probabilidade de mortalidade. As demais redes apresentaram superiores, contudo utilizaram um maior número de variáveis, sendo um ponto positivo das RNA, devido a sua flexibilidade.

Comparando as estatísticas apresentadas nas Tabelas 7 e 10 e os gráficos das Figuras 11 e 14, observou-se que as RNA foram mais precisas do que as equações para a probabilidade de mortalidade e a rede 5 resultou nas melhores estimativas. Assim como as demais, essa rede gerou estimativas

limitadas entre 0 e 1, sendo biologicamente coerentes para estimativas de mortalidade, porém foi a única que captou as variações de probabilidade nos valores extremos, ou seja, a dispersão dos resíduos foi menor.

As estimativas encontradas são aceitáveis para esta variável. Devido a dificuldade de se estimar a mortalidade das árvores, uma pequena tendência nos desvios ainda é aceitável (YANG et al., 2003; GONZÁLEZ et al., 2006).

A arquitetura da rede 5 selecionada para estimar a probabilidade de mortalidade, é

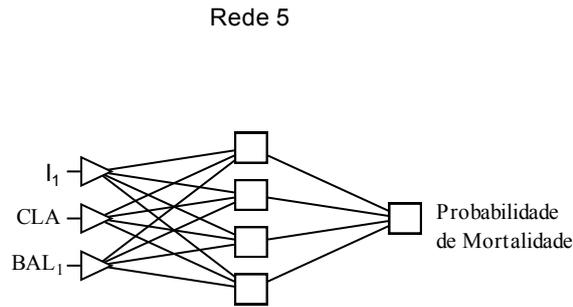


Figura 15 – Arquitetura da RNA 5 para estimativas de probabilidade de mortalidade.

O índice de competição utilizado nas estimativas de mortalidade pela RNA 5 foi o IID_5 , (obtido pelo somatório das áreas seccionais das árvores maiores que a árvore-objeto), desenvolvido por Stage (1973), citado por Davis e Johnson (1987).

Este índice foi utilizado no modelo de árvores individuais PROGNOSIS (STAGE, 1973, citado por DAVIS e JOHNSON, 1987) e no estudo de crescimento de sobreiro na Espanha (GONZÁLEZ et al., 2006). Monserud e Sterba (1999) utilizaram o IID_5 para mortalidade de espécies nativas da floresta australiana, e consideraram este índice como uma das variáveis mais importantes na avaliação da mortalidade para a quase totalidade das espécies analisadas, por ter atingido alto grau de precisão nas estimativas de mortalidade individual. Contudo, neste estudo, este índice não foi tão eficiente nos modelos de regressão testados.

As arquiteturas das redes neurais artificiais treinadas para obtenção da variável altura são resumidas na Tabela 11, tendo como arquitetura genérica uma camada de entrada com 5 variáveis (I_1 , I_2 , S , Ht_1 , e um índice de competição IID) ou 4 variáveis (I_1 , I_2 , S , Ht_1); uma camada oculta com n neurônios; e uma camada de saída com apenas um neurônio estimando a variável altura na idade futura (Ht_2).

Tabela 11 – Arquitetura das redes neurais artificiais ajustadas para obtenção da altura na idade futura (Ht_2) e respectivas estatísticas

Rede	Índice de Competição	Variáveis de entrada utilizadas	Variável de saída	Número de neurônios			$r_{\hat{y}y}$	CV % (\pm)	RQEM	bias	bias%	MDA
				Camada 1	Camada 2	Camada 3						
1	IID_1	S, Ht_1, IID_1	Ht_2	3	6	1	0,9924	3,0	0,6259	-0,0011	-0,1197	0,4370
2	IID_2	I_1, I_2, S, Ht_1, IID_2	Ht_2	5	6	1	0,9932	2,9	0,5919	-0,0089	-0,1668	0,4069
3	IID_3	I_1, I_2, S, Ht_1, IID_3	Ht_2	5	7	1	0,9944	2,6	0,5318	0,0001	-0,0695	0,4048
4	IID_4	I_1, I_2, S, Ht_1, IID_4	Ht_2	5	7	1	0,9946	2,5	0,5257	-0,0028	-0,0949	0,3979
5	IID_5	I_1, I_2, S, Ht_1, IID_5	Ht_2	5	9	1	0,9928	2,9	0,6079	0,0028	-0,1420	0,4222
6	Nenhum	I_1, S, Ht_1	Ht_2	3	7	1	0,9919	3,1	0,6429	-0,0017	-0,1374	0,4451

Em que: I = idade, em meses; Ht = altura total (m). Os subscritos destas variáveis (1 e 2), referem-se às medidas atuais e futuras, respectivamente; S = Índice de local, em m; IID_i = Índices de competição independentes da distância ($i = 1$ a 5, conforme descritos anteriormente).

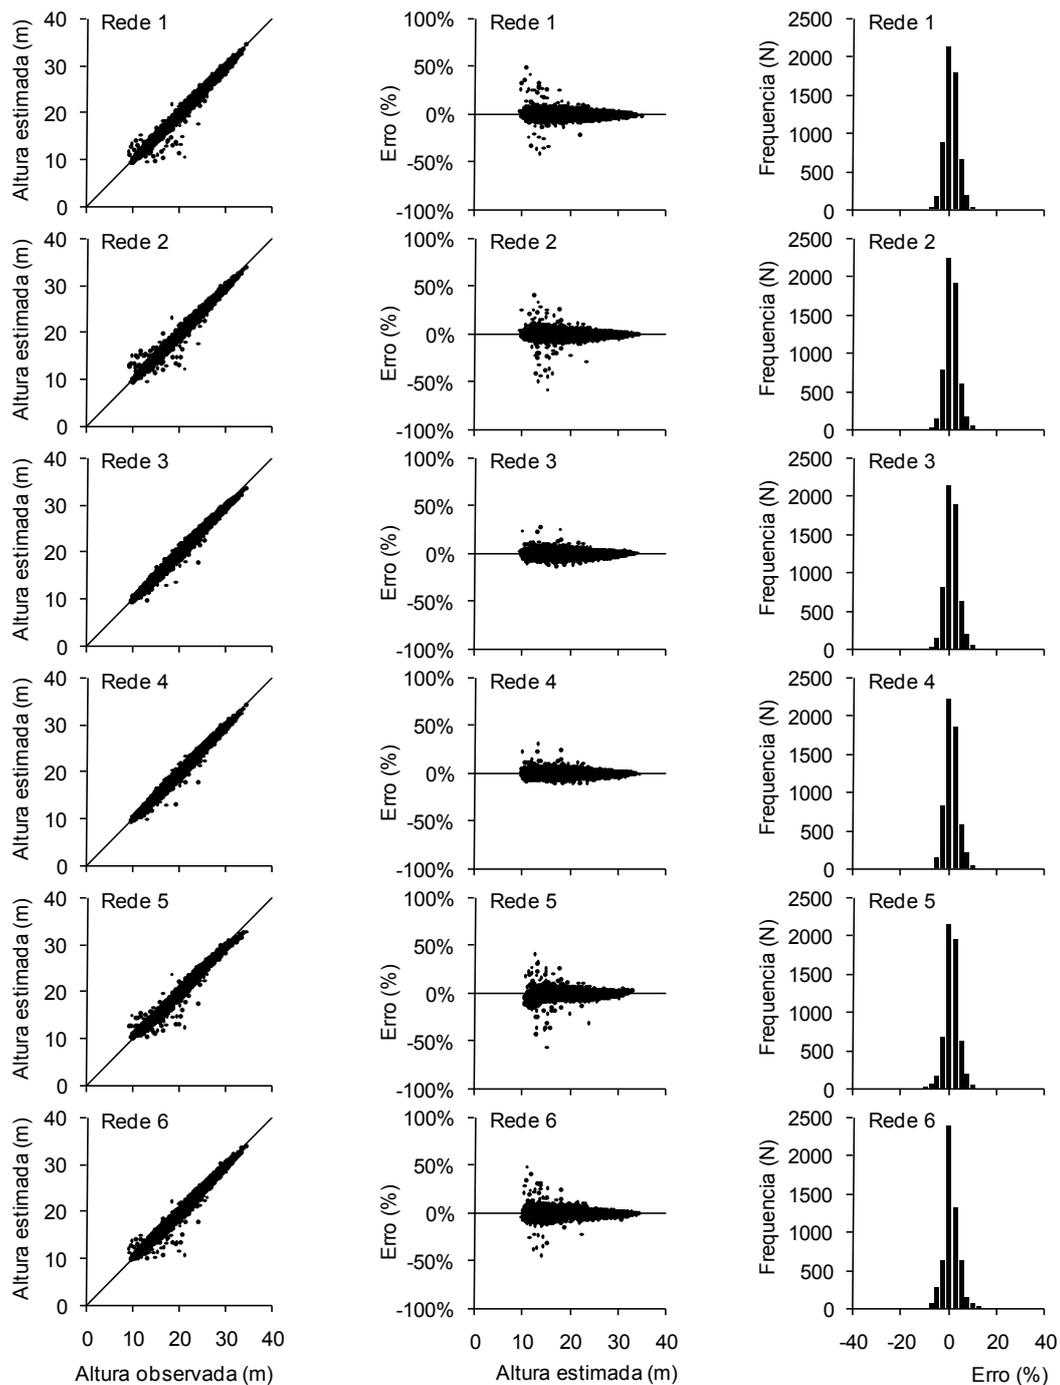


Figura 16 – Análise gráfica dos resíduos para a variável altura, obtidas no treinamento das RNA.

As estatísticas na Tabela 11 e os gráficos da Figura 16 mostram que a rede 3 foi a que apresentou as melhores estimativas para a variável altura. Comparando as estatísticas da rede 3 (Tabela 11) com a melhor equação para esta variável (Modelo Linear 2), na Tabela 8, observa-se que a RNA foi muito

superior em termos de precisão e exatidão. A arquitetura da rede 3 foi a seguinte (Figura 17):

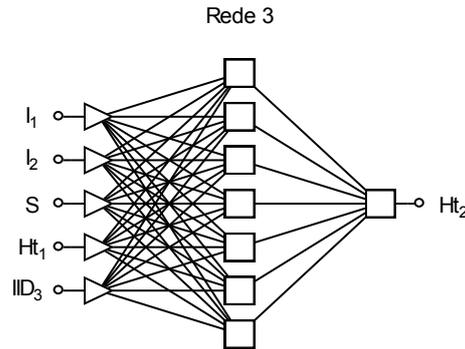


Figura 17 – Arquitetura da RNA 3 para estimativas de altura.

O índice de competição utilizado pela RNA 3 é resultante da combinação entre as variáveis diâmetro e altura (IID_3), proposto por Glover e Hool, (1979).

Apesar de ter apresentado os menores valores de correlação entre os cinco índices de competição avaliados em relação ao crescimento em altura (Tabela 6), o IID_3 apresentou uma tendência bem definida em função da idade quando estratificado por tamanho das árvores. As correlações entre este índice e a variável altura (0,43; 0,39 e 0,54, para as Classes I, II e III, respectivamente), foram próximos aos valores encontrados em outros trabalhos. Martin e Ek (1984) encontraram valores de correlação inferiores a 0,40 e Daniels (1976), inferiores a -0,45 com o incremento em altura, ambos em estudos com espécies de *Pinus*.

As RNA treinadas para a variável diâmetro em uma idade futura (dap_2) apresentaram-se precisas, haja vista as estatísticas apresentadas na Tabela 12. Além disso, observa-se, também, que a inclusão de alguns índices de competição nas redes resultou maior precisão e exatidão nas estimativas.

Os resultados das redes (Tabela 12) quando comparados com os das equações para a variável diâmetro (Tabela 9), indicam que a rede 4 foi a melhor entre todas as alternativas avaliadas.

Tabela 12 – Arquitetura das redes neurais artificiais treinadas para obtenção do diâmetro na idade futura (dap_2) e respectivas estatísticas

Rede	Índice de Competição	Variáveis de entrada utilizadas	Variável de saída	Número de neurônios			$r_{\hat{y}y}$	CV % (\pm)	RQEM	bias	bias %	MDA
				Camada 1	Camada 2	Camada 3						
1	IID_1	I_1, I_2, dap_1, IID_1	dap_2	4	5	1	0,9897	4,6	0,6181	-0,0048	-0,3141	0,4089
2	IID_2	$I_1, I_2, S, dap_1, IID_2$	dap_2	5	7	1	0,9903	4,4	0,6008	-0,0118	-0,4150	0,3986
3	IID_3	I_2, dap_1, IID_3	dap_2	3	4	1	0,9926	3,8	0,5226	0,0008	-0,3135	0,3913
4	IID_4	$I_1, I_2, S, dap_1, IID_4$	dap_2	5	5	1	0,9930	3,7	0,5076	-0,0021	-0,2532	0,3821
5	IID_5	$I_1, I_2, S, dap_1, IID_5$	dap_2	5	6	1	0,9880	4,9	0,6665	0,0013	-0,2755	0,5049
6	Nenhum	I_1, I_2, S, dap_1	dap_2	4	6	1	0,9901	4,5	0,6052	-0,0029	-0,3300	0,4014

Em que: I = idade, em meses; dap = diâmetro com casca medido a 1,30 m de altura. Os subscritos destas variáveis (1 e 2), referem-se às medidas atuais e futuras, respectivamente; S = Índice de local, em m; IID_i = Índices de competição independentes da distância ($i = 1$ a 5, conforme descritos anteriormente).

Os gráficos de resíduos da Figura 18 mostram que a rede 4 apresentou menor erro, bem como melhor tendência de distribuições das estimativas, em comparação com as demais redes, sendo portanto, a melhor.

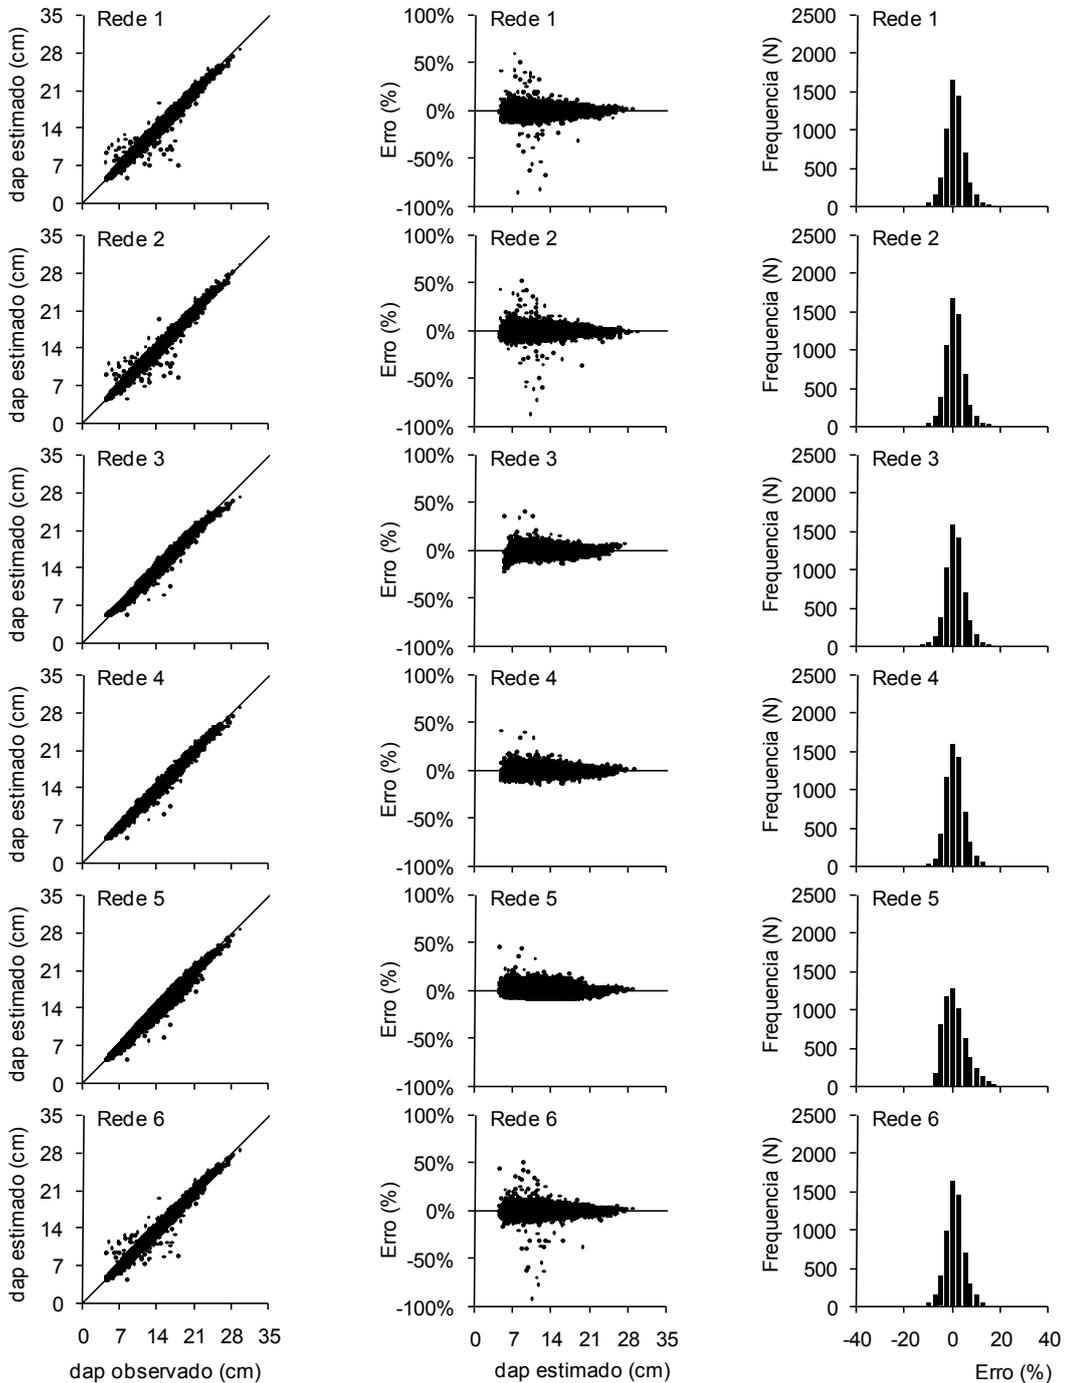


Figura 18 – Análise gráfica dos resíduos para a variável *dap*, obtidas no treinamento das RNA.

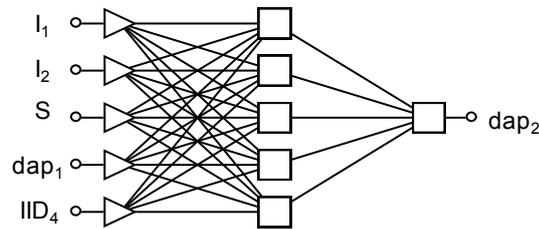


Figura 19 – Arquitetura da RNA 4 para estimativas do dap .

O índice de competição utilizado pela RNA 4 considera a razão entre o diâmetro da árvore-objeto e o diâmetro da árvore média (IID_4) (STAGE, 1973; citados por DAVIS e JOHNSON, 1987).

Este índice, assim como o IID_5 , apresentou os maiores valores de correlação entre os índices avaliados em relação ao crescimento em dap , e também uma tendência bem definida em função da idade quando estratificado por classe de tamanhos das árvores.

De acordo com as estatísticas apresentadas, pode-se observar que as RNA treinadas para os sub-modelos de crescimento em diâmetro e altura e probabilidade de mortalidade mostraram ser, de maneira geral, as mais precisas que as equações. Isto pode ser justificado uma vez que as redes não apresentaram uma estrutura definida, como é o caso dos modelos de regressão, tendo a capacidade de modelar aspectos não-lineares sem a prévia definição de uma função estatística, economizando assim tempo e esforços na escolha de modelos de regressão, além da maior facilidade em se estimar um grande número de arquiteturas pelos softwares especializados.

As RNA treinadas para estimar o crescimento dimensional (Ht e dap) utilizaram todas as variáveis de entrada disponibilizadas, enquanto a RNA utilizada para probabilidade de mortalidade excluiu a variável S , não a considerando como variável de importância durante o treinamento. O *ranking* das variáveis de entrada pode ser visualizado na Tabela 13.

As RNA apresentaram poucos neurônios na camada intermediária (4, 7 e 5, respectivamente, para as estimativas de $P(M)$, altura e dap). Segundo Pereira (1999), tal característica é preferida, visto que elas tendem a possuir

um melhor poder de generalização, sem vício para estimar apenas as variáveis que foram utilizadas no treinamento.

Tabela 13 – Descrição do tipo de rede neural artificial utilizada e o ranking de importância das variáveis de entrada para as estimativas de probabilidade de mortalidade ($P(M)$), altura (Ht) e diâmetro (dap)

Variável estimada	Entradas utilizadas	Saída	Ranking**				
			(1°)	(2°)	(3°)	(4°)	(5°)
$P(M)$ MLP (3-4-1)*	I_1, CLA, IID_5	$P(M)$	CLA	IID_5	I_1	-	-
Ht MLP (5-7-1)*	I_1, I_2, S, Ht_1, IID_3	Ht_2	I_1	I_2	Ht_1	IID_3	S
dap MLP (5-5-1)*	$I_1, I_2, S, dap_1, IID_4$	dap_2	I_1	I_2	dap_1	IID_4	S

Em que: I = idade, em meses; dap = diâmetro com casca medido a 1,30 m de altura; Ht = altura. Os subscritos destas variáveis (1 e 2), referem-se às medidas atuais e futuras, respectivamente; CLA = classe de diâmetro (amplitude de 2 cm); S = Índice de local, em m; IID_i = Índices de competição independentes da distância ($i = 1$ a 5, conforme descritos anteriormente).

* Tipo de RNA utilizada (número de neurônios de entrada – ocultos – e de saída)

** Ranking de importância das variáveis de entrada nas estimativas.

As estimativas selecionadas para as variáveis Ht e dap apresentaram coeficientes de correlação ($r_{\hat{y}y}$) entre as variáveis observadas e estimadas superiores a 0,98, indicando, segundo Garcia (2001), alto grau de associação entre estas variáveis, ou seja, alto grau de precisão das estimativas. Também foram verificados baixos valores de coeficiente de variação (CV %), raiz quadrada do erro médio (RQEM), $bias$, $bias\%$ e média das diferenças absolutas (MDA), bem como distribuição não tendenciosa dos resíduos.

Observou-se que a inclusão da variável índice de competição melhorou as estimativas de crescimento (Ht e dap), haja vista que houve significativa melhora nas estatísticas de exatidão e precisão, assim como na distribuição dos resíduos, em relação àquelas sem o índice. Este fato já era esperado, dado que o *status* competitivo influencia diretamente nas taxas de crescimento das árvores, como já descrito por Daniels (1976), Martin e Ek (1984) e Biging e Dobberting (1992). Grande parte dos trabalhos com modelos em nível de árvores individuais não consideram os índices de competição como variável explicativa nas variáveis de crescimento (ZEIDE, 1993; MENDES et al., 2006), o que pode resultar em perdas significativas de precisão das estimativas destas variáveis.

5.4. Validação do modelo

A validação do modelo de crescimento e produção em nível de árvores individuais, (baseado nas RNA), selecionado no item 5.3 foi realizada por meio do simulador, desenvolvido aplicando a teoria de Autômatos Celulares, conforme exemplificado na Figura 20. Como saída, o aplicativo reproduziu a dinâmica do povoamento, e produziu estimativas das dimensões das árvores individuais para cada passo de tempo simulado (idade). O modelo foi capaz de simular características fundamentais na dinâmica das florestas de eucalipto, tais como: mortalidade, crescimento dimensional em altura e diâmetro, em nível de árvore.

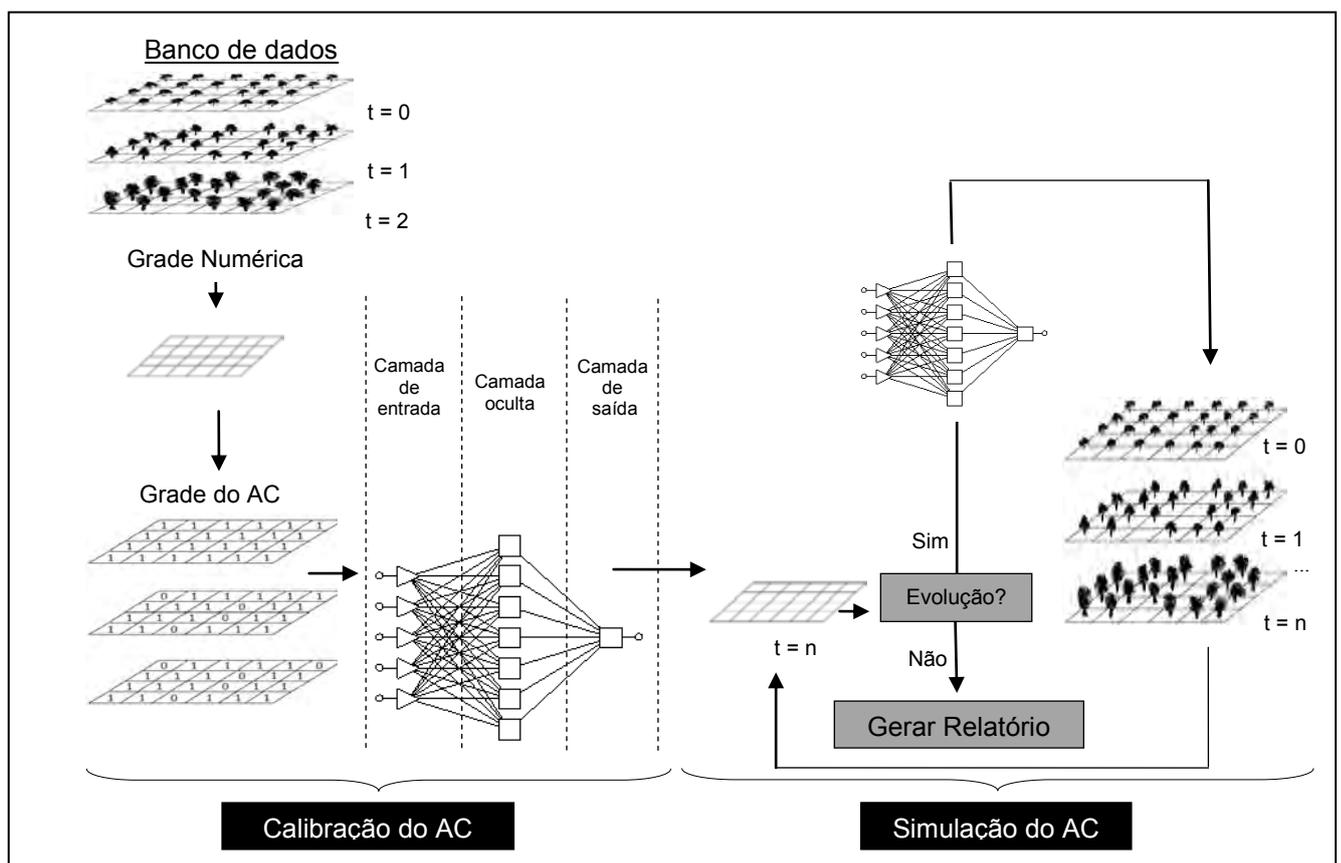


Figura 20 – Modelo de Simulação de Autômatos Celulares baseados em RNA, adaptado de Hegde et al. (2008).

Para mortalidade foram estimadas corretamente 37%; 42% e 38% das árvores nas classes de capacidade produtiva I, II e III, respectivamente na idade final de projeção. Cabe lembrar que a estimativa de mortalidade neste estudo não depende da exatidão célula a célula (precisão espacial), ou seja,

não é necessário “matar” exatamente a árvore que na realidade morreu. Isso é possível pela característica dos modelos em nível de árvores individuais de distância independente. O importante nesta simulação é que as árvores mortas possuam um tamanho igual àsquelas que realmente morreram e que ocorram no tempo correto, resultando assim, em estimativas precisas em termos de dinâmica do povoamento.

Mesmo apresentando um grau de acerto menor que 50% quanto as árvores que morreram durante o período de projeção (de 24 até 72 meses), observa-se nos gráficos da Figura 21, que foi possível estimar sem tendência o número de árvores vivas por hectare nas parcelas selecionadas para validação.

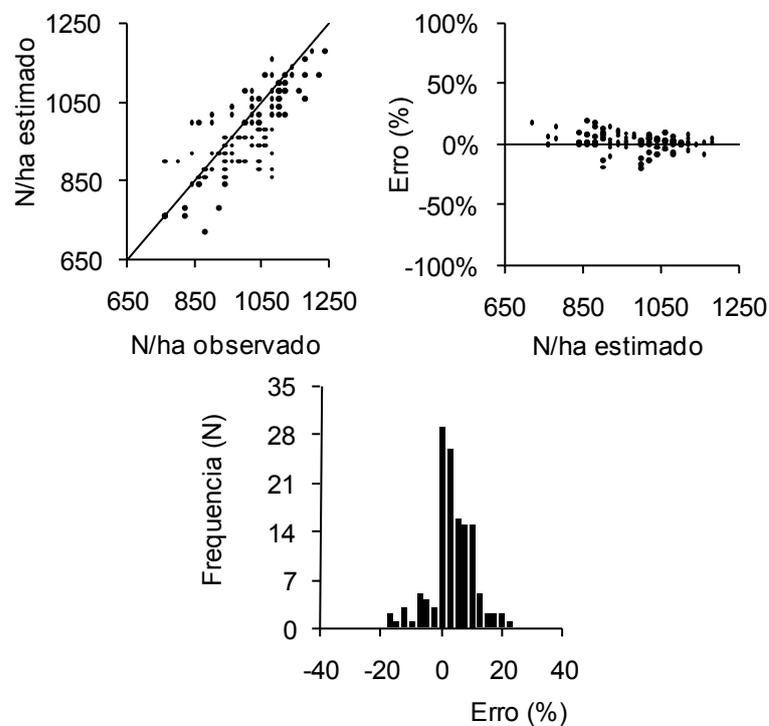


Figura 21 – Estimativas de número de árvores por hectares.

A tendência obtida na validação do modelo de árvores individuais está em conformidade com resultados descritos na literatura para estimativas de mortalidade ou sobrevivência (MONSERUD e STERBA, 1999; TAYLOR e MACLEAN, 2007).

Uma característica importante para a modelagem de mortalidade é a necessidade de um banco de dados que represente bem a população em estudo (MONSERUD e STERBA, 1999). No presente trabalho, apesar do

grande número de árvores, o número de árvores mortas não foi tão grande e mesmo assim, as estimativas obtidas para a variável de mortalidade foram satisfatórias.

Conforme Miranda et al. (1989), grande parte dos estudos de crescimento realizados ignoram a mortalidade, talvez porque é o componente do crescimento mais difícil e menos confiável de se estimar, em razão das incertezas das condições futuras do povoamento. No entanto, segundo este mesmo autor, a correta estimação da mortalidade auxilia o manejador florestal a estimar com maior precisão as produções futuras de madeira, principalmente quando a mortalidade é alta, como por exemplo, neste estudo, chegando a até 20 %.

Pela aplicação do teste F de Graybill, verificou-se que as estimativas de Ht e dap diferiram estatisticamente dos valores observados, exceto para a Classe I (Alta), na idade 48 meses. Contudo, pelo critério adotado (Tabela 5) quase todas as estimativas foram classificadas como aceitáveis. Aquelas que não se apresentaram como aceitáveis ficaram muito próximas dos valores críticos ($R^2 > 90\%$ e $\bar{E} < 10\%$) (Tabela 14). Observou-se também que valores de F aumentaram com a idade, refletindo a propagação dos erros nas estimativas.

Tabela 14 – Teste F de Graybill para os dados de validação do modelo de crescimento em nível de árvore individual, nas classes de produtividade I (Alta), II (Média) e III (Baixa), nas idades de projeção estimadas

Classe de Capacidade Produtiva	Idade (meses)	Variável									
		Ht (m)					dap (cm)				
		F	$\hat{\beta}_0$	$\hat{\beta}_1$	R^2	\bar{E} %	F	$\hat{\beta}_0$	$\hat{\beta}_1$	R^2	\bar{E} %
I (Alta)	36	5,77 *	0,34	0,98	96%	0%	4,32 *	0,17	0,98	95%	-1%
	48	2,97 n.s.	0,70	0,97	93%	0%	2,27 *	0,41	0,97	92%	0%
	60	11,01 *	0,89	0,95	91%	-1%	7,44 *	0,54	0,96	89%	-1%
	72	6,79 *	1,33	0,94	87%	0%	8,64 *	0,91	0,93	85%	-1%
II (Média)	36	12,91 *	0,60	0,97	96%	1%	25,21 *	0,54	0,97	96%	2%
	48	26,33 *	1,52	0,94	92%	1%	38,77 *	1,35	0,91	92%	2%
	60	21,72 *	2,14	0,91	88%	1%	36,28 *	1,81	0,89	88%	2%
	72	16,69 *	2,36	0,91	85%	1%	39,03 *	2,27	0,86	85%	2%
III (Baixa)	36	6,87 *	0,63	0,96	93%	0%	16,06 *	0,55	0,95	95%	1%
	48	14,15 *	0,77	0,97	90%	1%	35,52 *	0,98	0,94	91%	3%
	60	32,75 *	1,75	0,93	85%	3%	48,23 *	1,58	0,90	86%	4%
	72	23,17 *	2,05	0,92	81%	2%	39,50 *	1,87	0,89	83%	4%

* significativo a 5% de significância.

n.s. não significativo a 5% de significância.

Os valores de coeficiente de variação (CV %), raiz quadrada do erro médio (RQEM), *bias*, *bias%* e média das diferenças absolutas (MDA), aumentaram à medida que se aumentaram as idades projetadas, enquanto o coeficiente de correlação ($r_{\hat{y}y}$) diminuiu (Tabela 15). Tal tendência é esperada, visto que as projeções para uma determinada idade futura já consideram o erro da projeção anterior que é, então, acumulado.

As Figuras 22 e 23 auxiliaram na verificação da exatidão das estimativas do modelo e de Autômato Celular, mostrando a concentração das estimativas em torno da linha de 45°, tanto para a variável altura, quanto para o diâmetro.

Tabela 15 – Estatísticas considerando os valores de altura (*Ht*) e diâmetro (*dap*) estimados pelo simulador e observados, em cada idade (em meses) e classe de capacidade produtiva

Classe de Capacidade Produtiva	Idade (meses)	Variável											
		<i>Ht</i> (m)						<i>dap</i> (cm)					
		$r_{y\hat{y}}$	CV % (\pm)	RQEM	<i>bias</i>	<i>bias</i> %	MDA	$r_{y\hat{y}}$	CV % (\pm)	RQEM	<i>bias</i>	<i>bias</i> %	MDA
I (Alta)	36	0,9794	3,5	0,7069	-0,0804	-0,4889	0,4555	0,9760	5,5	0,7665	-0,0811	-0,8561	0,5158
	48	0,9645	4,6	1,0398	0,0268	0,0026	0,7409	0,9611	7,1	1,0654	-0,0164	-0,4432	0,7519
	60	0,9531	5,1	1,2716	-0,2233	-1,0667	0,9302	0,9451	8,5	1,3793	-0,1843	-1,6418	0,9614
	72	0,9341	5,9	1,5404	-0,1527	-0,7844	1,1586	0,9246	10,3	1,7482	-0,2109	-1,8897	1,2482
II (Média)	36	0,9813	3,4	0,6209	0,0898	0,4941	0,4528	0,9809	4,8	0,6238	0,1470	1,2461	0,4606
	48	0,9573	5,1	1,0908	0,2194	1,0167	0,8476	0,9616	7,0	0,9710	0,1350	1,1742	0,7537
	60	0,9383	6,3	1,4371	0,1696	0,6351	1,1540	0,9402	9,0	1,3454	0,1367	0,9643	1,0671
	72	0,9205	7,1	1,7473	0,1485	0,3685	1,4248	0,9217	10,7	1,6854	0,1622	0,9654	1,3509
III (Baixa)	36	0,9664	4,1	0,6354	0,0245	0,1006	0,4855	0,9750	5,4	0,5645	0,0611	0,5587	0,4164
	48	0,9469	5,7	1,0310	0,2162	1,0151	0,8110	0,9530	7,7	0,9237	0,2654	2,1634	0,7345
	60	0,9208	7,0	1,4403	0,4415	2,0173	1,1376	0,9288	9,6	1,2663	0,4142	3,1381	1,0115
	72	0,9027	7,8	1,6839	0,4195	1,6418	1,3273	0,9086	11,0	1,5074	0,4265	2,8055	1,2005

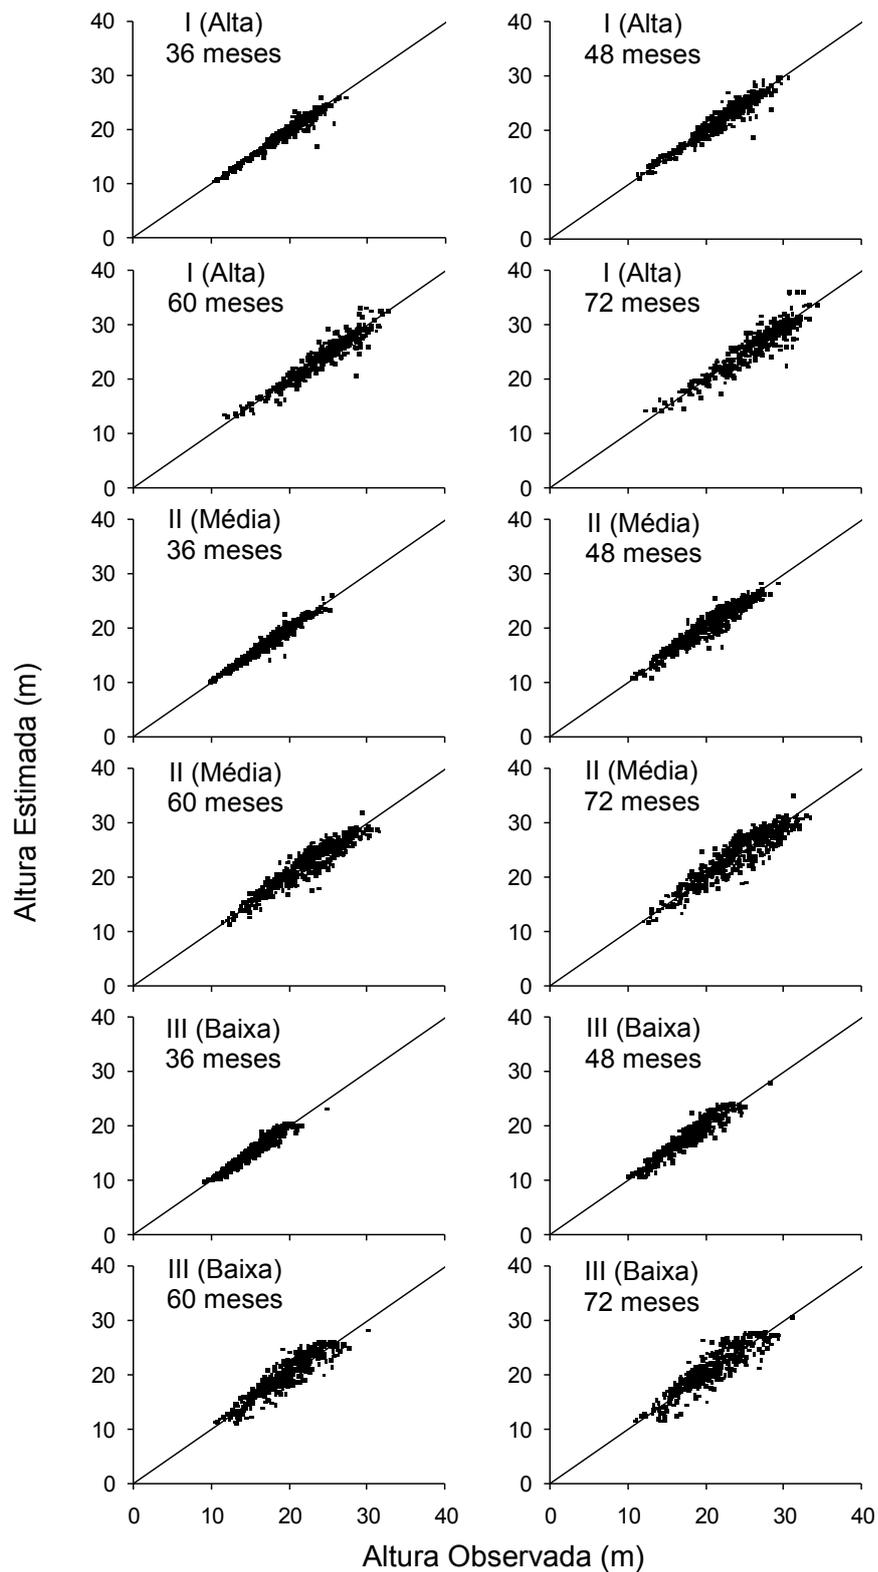


Figura 22 – Estimativas de altura obtidas pelo simulador de Autômatos Celulares para as classes de capacidade produtiva I (Alta), II (Média) e III (Baixa), em relação aos valores observados.

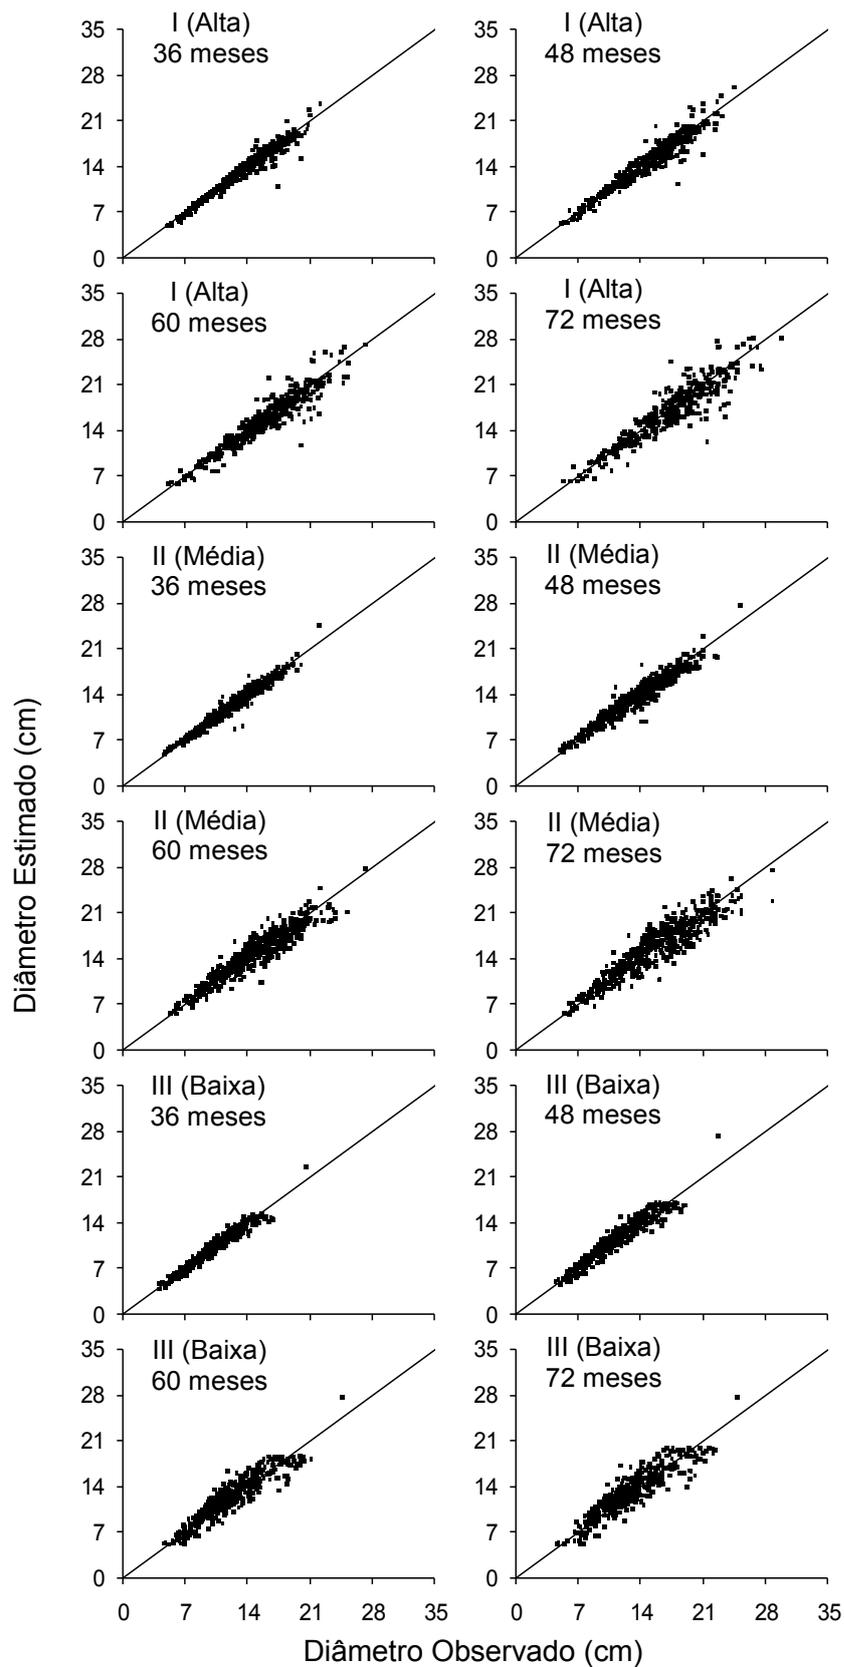


Figura 23 – Estimativas de diâmetro obtidas pelo simulador de Autômatos Celulares para as classes de capacidade produtiva I (Alta), II (Média) e III (Baixa), em relação aos valores observados.

As distribuições do número por hectare de árvores por classe diamétrica, obtidas através das projeções do modelo de árvores individuais, apresentaram tendência à normalidade, com deslocamento para a direita à medida que o povoamento atinge maiores idades, assim como a tendência da distribuição observada (Figura 24), conforme descrito por Leite et al. (2005).

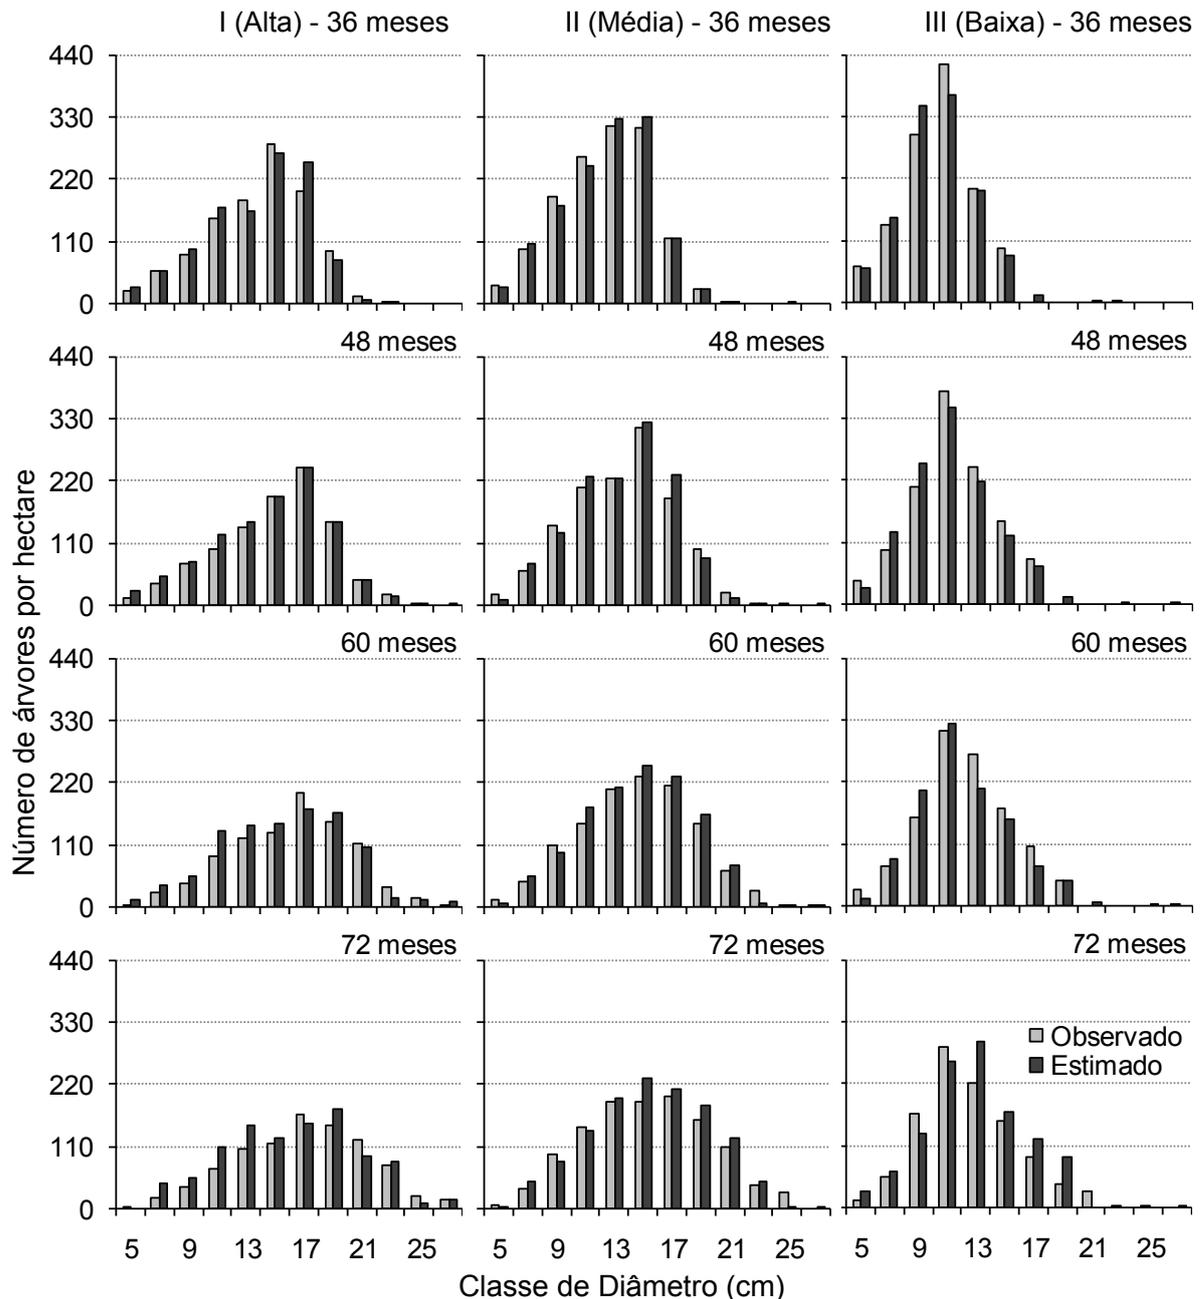


Figura 24 – Número de árvores por hectare, observados e estimados, para cada idade de projeção, nas classes de capacidade produtiva I (Alta), II (Média) e III (Baixa).

O teste Qui-quadrado foi não significativo para todas as classes de capacidade produtiva e em todas as idades analisadas, ou seja, as distribuições estimadas médias foram estatisticamente iguais às observadas (Tabela 16).

Tabela 16 - Estatística Qui-quadrado (χ^2) entre distribuições diamétricas médias estimadas e observadas

Idade (meses)	Classe de Capacidade Produtiva											
	I (Alta)			II (Média)			III (Baixa)					
	χ^2	<i>n</i>	$\chi^2_{0,05}$	χ^2	<i>n</i>	$\chi^2_{0,05}$	χ^2	<i>n</i>	$\chi^2_{0,05}$			
36	1,53	10	16,92	n.s.	0,28	9	0,94	n.s.	0,97	6	11,07	n.s.
48	1,44	11	18,31	n.s.	1,37	10	1,45	n.s.	0,92	7	12,59	n.s.
60	4,57	12	19,68	n.s.	1,63	11	3,22	n.s.	0,92	8	14,07	n.s.
72	5,21	11	18,31	n.s.	2,12	11	6,54	n.s.	0,80	8	14,07	n.s.

n.s. = não significativo a 5% de significância.

Considerando as distribuições diamétricas das parcelas individualmente, em cada classe de produtividade e nas diferentes idades, observa-se que o número de árvores por classe não diferiram estatisticamente, pelo teste χ^2 para quase a totalidade das parcelas (Tabela 17).

Tabela 17 – Porcentagem do número de parcelas com distribuições diamétricas estimadas iguais às observadas pelo teste Qui-quadrado (χ^2)*

Idade (meses)	Classe de Capacidade Produtiva					
	I (Alta)		II (Média)		III (Baixa)	
	= (%)	≠ (%)	= (%)	≠ (%)	= (%)	≠ (%)
36	100	0	100	0	100	0
48	90	10	90	10	100	0
60	90	10	90	10	90	10
72	80	20	80	20	80	20
Média Geral	90	10	90	10	93	7

* nível de significância de 5%.

A tendência encontrada está dentro dos padrões obtidos em trabalhos de modelagem da distribuição diamétrica para plantios de eucaliptos (NOGUEIRA et al., 2005; ARAUJO JÚNIOR et al., 2010; BINOTI et al., 2010).

As estimativas de volume por hectare, por parcela, projetadas até a idade de 72 meses não diferiram significativamente dos valores reais, em todas as classes de capacidade produtiva e idades, pelo teste *t* para amostras dependentes (Tabela 18).

Tabela 18 - Teste *t* para amostras dependentes entre as estimativas de volume por hectare e valores observados por parcela

Variável	Idade (meses)	Classe de Capacidade Produtiva					
		I (Alta)		II (Média)		III (Baixa)	
		<i>t</i>	<i>t</i> _{0,05}	<i>t</i>	<i>t</i> _{0,05}	<i>t</i>	<i>t</i> _{0,05}
Volume (m ³ /ha)	36		-0,50 n.s.		0,20 n.s.		-0,33 n.s.
	48	2,26	-0,67 n.s.	2,26	0,11 n.s.	2,26	0,16 n.s.
	60	(n=10)	-1,70 n.s.	(n=10)	-0,04 n.s.	(n=10)	0,43 n.s.
	72		-1,74 n.s.		-0,19 n.s.		0,32 n.s.

n.s. = não significativo a 5% de significância.

As estimativas médias dos estoques volumétricos na idade final ficaram próximas às observadas (Figura 25). As diferenças percentuais entre os estoques estimados e aqueles observados na idade de 72 meses foram de -7, 0 e 6 %, respectivamente para as classes I, II e III. Além disso, em idades menores, as estimativas foram mais precisas, indicando que o modelo baseado em redes neurais fornece estimativas precisas em qualquer idade.

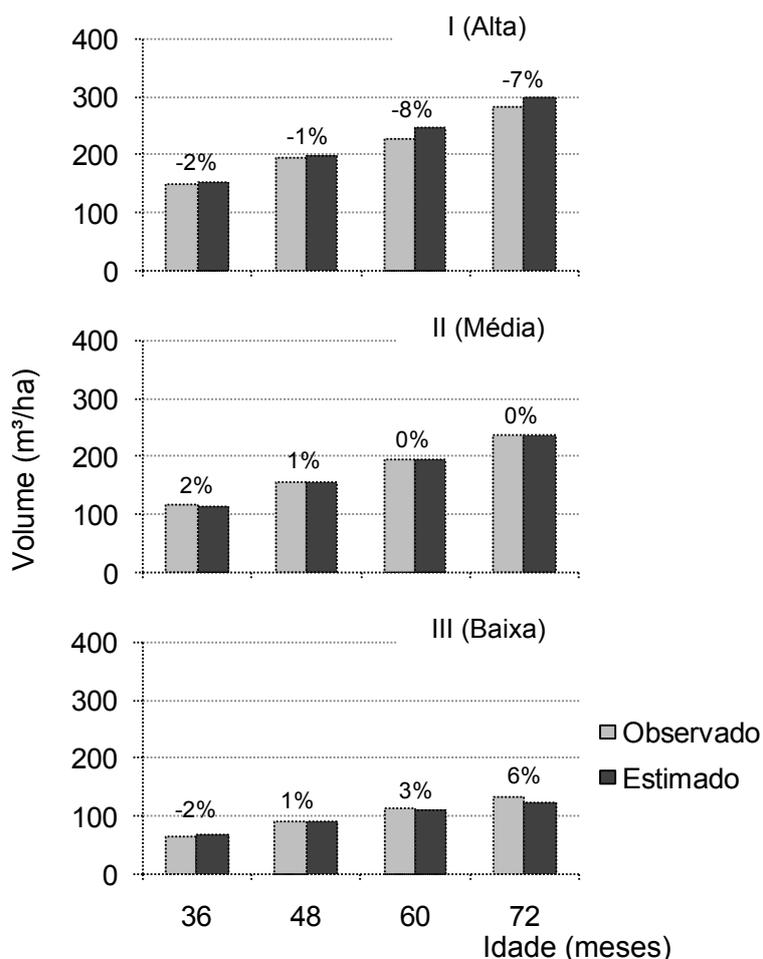


Figura 25 – Estimativas da produção volumétrica em nível de povoamento para as classes de capacidade produtiva I (Alta), II (Média) e III (Baixa), após as projeções pelo modelo de árvores individuais no AC.

Pelos resultados apresentados, pôde-se observar que o modelo de árvores individuais baseado em RNA foi adequado para estimar crescimento e produção no povoamento de eucalipto estudado. O simulador traduziu a dinâmica do povoamento, com estimativas precisas em todos os graus de detalhamento, ou seja, foi possível obter estimativas confiáveis em nível de povoamento total, distribuição diamétrica e árvores individuais, sendo útil para qualquer propósito de manejo florestal.

6. CONCLUSÕES

Nesse estudo pôde-se concluir que:

- As redes neurais artificiais estimaram com precisão o crescimento em diâmetro, em altura e a probabilidade de mortalidade, apresentando superioridade nas estimativas em relação aos modelos de regressão;
- O modelo de simulação de Autômatos Celulares foi capaz de descrever a dinâmica da floresta;
- Os resultados gerados pelas simulações podem subsidiar o planejamento de produção de madeira em todos os níveis de detalhamento desejados;
- O simulador desenvolvido neste estudo simplifica o uso dos modelos de crescimento e produção em nível de árvores individuais;
- Tanto a forma de se estimar os sub-modelos de crescimento e de mortalidade, quanto o aplicativo desenvolvido facilitaram a tarefa de simulação, mostrando que esta tecnologia é acessível e muito eficaz.

7. RECOMENDAÇÕES

Devido à eficiência da metodologia utilizada para estudo de modelagem de árvores individuais em povoamentos de eucalipto, recomenda-se:

- Simular desbastes, verificando se os índices de competição são capazes de captar o efeito deste tratamento;
- Aplicar o sistema proposto no estudo de crescimento e produção de florestas nativas;
- Integrar, no mesmo aplicativo de Autômato Celular, os algoritmos de redes neurais artificiais.

8. REFERÊNCIAS BIBLIOGRÁFICAS

ALIG, R. J.; PARKS, P. J.; FARRAR JR. R. M.; VASIEVIECH, J. M. **Regional timber yield and cost information for the South: Modelings techniques**. Washington: USDA, 1984. 28 p.

AMARO, A.; TOMÉ, M. **Empirical and Process – Bases Models for Forest Tree and Stand Growth Simulation**. Lisboa: Salamandra, 1997, 591 p.

ARAÚJO JÚNIOR, C. A.; NOGUEIRA, G. S.; OLIVEIRA, M. L. R.; MIRANDA, R. O. V.; CASTRO, R. V. O.; PELLI, E. Projeção da distribuição diamétrica de povoamentos de eucalipto em diferentes amplitudes de classe. **Pesquisa Agropecuária Brasileira**. v. 45, n.11, p.1275-1281, 2010.

AVERY, T. E.; BURKHART, H. E. **Forest measurements**. 4. ed., New York: McGraw-Hill Book Co, 1994. 408 p.

BARCLAY, H. J.; LAYTON, C. R. Growth and mortality in managed Douglas fir: Relation to a competition index. **Forest Ecology and Management**. v. 36, n. 1, p. 187-204, 1990.

BARRETO, J. M. **Introdução às redes neurais artificiais**. Florianópolis: UFSC, 2002.

BELLA, I. Growth, Yield, and ENFOR. **Forestry Report**, v. 29, n. 24, p. 1-8, 1984.

BIGING, G. S.; DOBBERTIN, M. Evaluation of competition indices in individual tree growth models. **Forest Science**. v. 41, n. 2, p. 360–377, 1995.

BIGING, G. S.; DOBBERTIN, M. A comparison of distance-dependent competition measures for height and basal area growth of individual conifer tree. **Forest Science**. v. 38, n. 3, p. 695-720. 1992.

BINOTI, D. H. B.; LEITE, H. G.; NOGUEIRA, G. S.; SILVA, M. L. M; GARCIA, S. L. R.; CRUZ, J. P. Uso da função Weibull de três parâmetros em um modelo de distribuição diamétrica para plantios de eucalipto submetidos a desbaste. **Revista Árvore**, v. 34, n. 1, p. 147-156, 2010.

BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54 p. Dissertação (Mestrado) - Universidade Federal de Viçosa, Viçosa.

BRAGA, A. P.; CARVALHO, A. C. P. L. F; LUDEMIR, T. B. Redes Neurais Artificiais. In: REZENDE, S. O. **Sistemas Inteligentes: Fundamentos e Aplicações**. Barueri: Manole, 2003. p. 141-168.

BUCHMAN, R. G.; PEDERSON, S. P.; WALTERS, N. R. A tree survival model with application to species of the Great Lakes region. **Canadian Journal of Forest Research**, v. 13, n. 4, p. 601-608, 1983.

CAMPOS, J. C. C; LEITE, H. G. **Mensuração Florestal: Perguntas e respostas**. Viçosa: UFV, 3. ed., 2009, 548 p.

CAVALCANTE, C. C. **Predição neural e estimação de função densidade de probabilidade aplicada à equalização cega**. 2001. 172 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Ceará.

CHICHORRO, J. F; RESENDE, J. L. P; LEITE, H. G. Equações de volume e de *taper* para quantificar multiprodutos da madeira em Floresta Atlântica. **Revista Árvore**, v.27, n.6, p. 799 - 809, 2003

CLUTTER, J. L.; FORTSON, J. C.; PIENAAR, L. V.; BRISTER, G. H.; BAILEY, R. L. **Timber management: A quantitative approach**. New York: John Wiley & Sons, 1983, 333 p.

COLASANTI, R. L.; HUNT, R. Resource dynamics and plant growth: a self-assembling model for individuals, populations and communities. **Functional Ecology**, v. 11, n. 2, p. 133-145, 1997.

COUCLELIS, H. From cellular automata to urban models: new principles for model development and implementation. **Environment and Planning**, v. 24, n. 2, p. 165-174, 1997.

CRECENTE-CAMPO, F.; MARSHALL, P.; SOALLEIRO, R. R. Modeling noncatastrophic individual tree mortality for *Pinus radiata* plantations in northwestern Spain. **Forest Ecology and Management**, Amsterdam, v. 257, n. 4, p. 1542-1550, 2009.

DANIELS, R. F.; BURKHART, H. E.; CLASON, T. R. A comparison of competition measures for predicting growth of loblolly pine trees. **Canadian Journal Forest Research**, v. 16, n. 6, p. 1230-1237, 1986.

DANIELS, R.F. Simple competition indices and their correlation with annual loblolly pine tree growth. **Forest Science**, v. 22, n. 4, p. 454-456, 1976.

DAVIS, L. S.; JOHNSON, K. N. **Forest management**. New York: McGraw-Hill, 3. ed., 1987. 790 p.

DEMOLINARI, R. A. **Crescimento de povoamentos de eucalipto não-desbastados**. 2006. 72 p. Dissertação (Mestrado) - Universidade de Viçosa - Viçosa.

DEWDNEY, A. K. A Cellular Universe of Debris, Droplets, Defects and Demons. **Scientific American**, v. 261, n. 2, p. 102-105, 1989.

DEWDNEY, A. K. The cellular automata programs that create wireworld, rugworld and other diversions. **Scientific American**, v. 262, n. 1, p. 146-149, 1990.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and Electronics in Agriculture**, v. 48, n. 3, p. 235-244, 2005.

ENCINAS, A. H.; ENCINAS, L. H.; WHITE, S. H.; REY, A. M. D.; SÁNCHEZ, G. R. Simulation of forest fire fronts using cellular automata. **Advances in Engineering Software**. v. 38, n. 6, p. 372-378, 2007b.

ENCINAS, L. H.; WHITE, S. H.; REY, A. M, D.; SÁNCHEZ, G. R. Modelling forest fire spread using hexagonal cellular automata. **Applied Mathematical Modelling**. v. 31, n. 6, p. 1213-1227, 2007a.

FOX, J. C.; BI, H.; ADES, P. K. Spatial dependence and individual-tree growth models I. Characterising spatial dependence. **Forest Ecology and Management**, v. 245, n. 1, p. 10-19, 2007.

GADOW, K. V. Modelling growth in managed forests - realism and limits of lumping. **The Science of the Total Environmental**, v. 183, n. 1-2, p. 167-177, 1996.

GARCIA, S. M. **Florestamentos compensatórios para retenção de água em microbacias**. Santa Maria, 2001. 161 p. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Santa Maria, 2001.

GARDNER, M. The fantastic combinations of John Conway's new solitaire game of "Life", **Scientific American**, v. 223, n. 4, p. 120-123, 1970.

GLOVER, G. R.; HOOL, J. N. A basal area ratio predictor of loblolly pine plantation mortality. **Forest Science**, v. 25, n. 2, p. 275-282, 1979.

GONZÁLEZ, M. S.; RÍO, M.; CAÑELLAS, I.; MONTERO. Distance independent tree diameter growth model for cork oak stands. **Forest ecology and Management**, v. 255, n. 1, p. 262-270, 2006.

GÖRGENS, E. **Estimação do volume de árvores utilizando redes neurais artificiais**. 2006. 84 p. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, 2006.

GRAYBILL, F. A. **Theory and application of linear model**. s.l.: Belmont Duxbury, 1976. 704 p.

GUAN, B. T.; GERTNER, G. Using a parallel distributed processing system to model individual tree mortality. **Forest Science**, v. 37, n. 3, p. 871-885, 1991.

HAMILTON JR., D. A. A logistic model of mortality in thinned and unthinned mixed conifer stands of Northern Idaho. **Forest Science**, v. 32, n. 4, p. 989-1000, 1986.

HASENAUER, H. Princípios para a modelagem de ecossistemas florestais. **Ciência e Ambiente**, v. 20, n. 1, p. 53-69, 2000.

HASENAUER, H.; MERKL, D.; WEINGARTNER, M. Estimating tree mortality of Norway spruce stands with neural networks. **Advances in Environmental Research**. v. 5, n. 4, p. 405-414, 2001.

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

HEGDE, N. P.; MURALIKRISHNA, I. V.; CHALAPATIRAO, K. V. Settlement growth prediction using neural network and cellular automata. **Journal of**

Theoretical and Applied Information Technology, v. 4 ,n. 5, p. 419-428, 2008.

HINK, D. M.; MOSER, JR. J. W. A generalized framework for predicting forest yield and stand structure using diameter distributions. **Forest Science**, v. 29, n. 1, p. 85-95, 1983.

HYNYNEN, J. **Modelling tree growth for managed stands**. The Finnish Forest Research Institute, Research Papers 576, 1995b, 59 p.

HYNYNEN, J. Predicting the growth response to thinning for Scots pine stands using individual-tree growth models. **Silva Fennica**, v. 29, n. 3, p. 225–246, 1995a.

KEDDY, P. A. **Competition**. New York: Chapman & Hall. 1989, 202p.

KEISTER, T. D.; TIDWELL, G. R. Competition ratio dynamics for improved mortality estimates in simulated growth of forests stands. **Forest Science**, v. 21, n. 1, p. 46-51, 1975.

LANZER, A. T. S. **Um modelo de simulação de autômatos celulares para avaliação das condições de biodiversidade e resiliência na exploração de florestas naturais**. 2004. 252 p. Tese (Doutorado) – Universidade Federal de Santa Catarina, Florianópolis.

LEITE, H. G. **II Curso de Modelagem do crescimento e da produção**. Viçosa, 1996. 121 p. Apostila – Universidade Federal de Viçosa.

LEITE, H. G., NOGUEIRA, G. S., CAMPOS, J. C. C., SOUZA, A. L., CARVALHO, A. Avaliação de um modelo de distribuição diamétrica ajustado para povoamentos de *Eucalyptus* sp. submetidos a desbaste. **Revista Árvore**, v. 29, n. 2, p. 271-280, 2005.

LETT, C.; SILBER, C.; BARRET, N. Comparison of a cellular automata network and an individual-based model for the simulation of forest dynamics. **Ecological Modelling**. v. 121, n.1, p. 277 – 293, 1999.

LORIMER, C. G. Test of age-independent competition index for individual trees in natural hardwood stands. **Forest Ecology and Management**, v. 6, n. 4, p. 343-360, 1983.

MABVURIRA, D.; MIINA, J. Individual-tree growth and mortality models for *Eucalyptus grandis* (Hill) Maiden plantations in Zimbabwe. **Forest Ecology and Management**, v. 161, n. 1, p. 231-245, 2002.

MACHADO, S. A.; TONON, A. E.; FILHO, A. F.; OLIVEIRA, E. B. Comportamento da mortalidade natural em bracatingais nativos em diferentes densidades iniciais e classes de sítio. **Ciência Florestal**. v. 12, n. 2, p. 41- 50, 2002.

MAESTRI, R.; SANQUETTA, C.R.; ARCE, J.C. Modelagem do crescimento de povoamentos de *Eucalyptus grandis* através de processos de difusão. **Revista Floresta**, Curitiba, v. 33, n. 2, p. 169-182, 2003.

MARTIN, G. L.; EK, A. R. A comparison of competition measures and growth models for predicting plantation red pine diameter and height growth. **Forest Science**, v. 30, n. 3, p. 731-743, 1984.

MÉNARD, A.; MARCEDAU, D. J. Simulating the impact of forest management scenarios in an agricultural landscape of southern Quebec, Canada, using a geographic cellular automata. **Landscape and Urban Planning**, v. 79, n. 3, p. 253-265, 2007.

MENDES, B. R.; CALEGARIO, N.; VOLPATO, C. E. S.; MELO, A. A. Desenvolvimento de modelos de crescimento de árvores individuais fundamentado em equações diferenciais. **Revista Cerne**, v. 12, n. 3, p. 254-263, 2006.

MERKL, D.; HASENAUER, H. Using neural networks to predict individual tree mortality. In Proceedings of the Int'l Conference on Engineering Applications of Neural Networks, **Proceedings...** Gibraltar, UK. June, 10-12, 1998.

MIGUEL, E. P., MACHADO, S. A., FILHO, A. F., ARCE, J. E. Using the Weibull function for prognosis of yield by diameter class in *Eucalyptus urophylla* stands. **Revista Cerne**, v. 16, n. 1, p. 94-104, 2010.

MIRANDA, R.C. de.; CAMPOS, J.C.C.; PAULA NETO, F de.; OLIVEIRA, L.M. de. Predição da mortalidade regular para eucalipto. **Revista Árvore**, v. 13, n. 2, p. 152-173, 1989.

MONSERUD, R. A.; STERBA, H. Modeling individual tree mortality for Australian forest species. **Forest ecology and Management**. v. 113, n. 2, p. 109-123, 1999.

MONTY A.; LEJEUNE, P.; RONDEUX, J. Individual distance-independent girth increment model for Douglas-fir in southern Belgium. **Ecological Modelling**. v. 212, n. 3, p. 472-479, 2008.

MURPHY, P. A.; STERNITZKE, H. S. **Growth and yield estimation for loblolly pine in the West Gulf**. New Orleans: US Department of Agriculture, 1979. 8p. (Research paper, SO-154).

NESBITT, J. E. **Qui-Quadrado**. São Paulo: Harbra, 1995. 33 p.

NOGUEIRA, G. S.; LEITE, G. L.; CAMPOS, J. C. C.; CARVALHO, A. F.; SOUZA, A. L. Modelo de distribuição diamétrica para povoamentos de *Eucalyptus* sp. submetidos a desbaste **Revista Árvore**, v. 29, n. 4, p. 579-589, 2005.

OLIVEIRA, G. M. B. **Dinâmica e evolução de autômatos celulares unidimensionais**. 1999. 149 p. Tese (Doutorado em Ciência) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

PÁDUA, F. L. C. **Autômatos celulares: teoria e aplicações**. Belo Horizonte, UFMG, 2004. 19 p. (Seminário de Pós Graduação).

PALAHÍ, M.; GRAU, J. M. Preliminary site index model and individual-tree growth and mortality models for Black pine (*Pinus nigra* Arn.) in Catalonia (Spain). **Investigaciones Agrarias: Sistemas y Recursos Forestales**. v. 12, n. 1, p. 137-148, 2003.

PALAHÍ, M.; PUKKALA, T. Optimising the management of Scots pine (*Pinus sylvestris* L.) stands in Spain based on individual-tree models. **Annals of Forest Science**. v. 60, n. 2, p. 105-114, 2003.

PAULO, J. A.; TOMÉ, M. An Individual Tree Growth Model for Juvenile Cork Oak Stands in Southern Portugal. **Silva Lusitana**, v. 17, n. 1, p. 27-38, 2009.

PEET, R. K.; CHRISTENSEN, N. L. Competition and tree death. **BioScience**, v. 37, n. 8, p. 586-595, 1987.

PEREIRA, B. B. **Introduction to Neural Networks in Statistics**, Center of Multivariate Analysis, Technical Report, Penn. State University, 1999.

PRETZSCH, H.; BIBER, P.; DURSKÝ, J. The single tree-based stand simulator SILVA: construction, application and evaluation. **Forest Ecology and Management**. v. 162, n. 1, p. 3-21, 2002.

PRODAN, M.; PETERS, R.; COX, F.; REAL, P. **Mensura florestal**. IICA/BMZ/GTZ. 1997, 561 p.

RENNOLLS, K.; GEARY, D. N.; ROLLINSON, T. J. D. Characterizing diameter distributions by the use of the Weibull distribution. **Forestry**, v. 58, n. 1, p. 57-66, 1985.

ROSSI, L. M. B.; KOEHLER, H. S.; SANQUETTA, C. R.; ARCE, J. E. Modelagem da mortalidade em florestas naturais. **Revista Floresta**, v. 37, n. 2, p. 275-291, 2007.

SCHNEIDER, P. R.; OLIVEIRA, F. F.; SILVA, L. H. S.; LÚCIO, A. D.; GUIMARÃES, C. A. F.; SCHNEIDER P. S. Análise da mortalidade de *Acacia mearnsii* De Wild. **Ciência Florestal**, v. 15, n. 2, p. 137-143, 2005.

SCOLFORO, J. R. S., MACHADO, A. M. Um sistema de crescimento e produção com simulador de desbaste. **Scientia Forestalis**, n. 50, p. 51-64, 1996.

SIIPILEHTO, J. A comparison of two parameter prediction methods for stand structure in Finland. **Silva Fennica**, n. 34, v. 4, p. 331–349, 2000.

SILVA, H. S. **Um modelo de autômatos celulares para a diferenciação celular**. 2003. 46 p. Dissertação (Mestrado) - Universidade Federal de Viçosa, Viçosa.

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

SIRONEN, S.; KANGAS, A.; MALTAMO, A.; KANGAS, J. Estimating individual tree growth with the k-Nearest Neighbour and k-Most Similar Neighbour methods. **Silva Fennica**. v. 35, n. 4, p. 453-467, 2002.

SOMERS, G. L.; ODERWARLD, R. G.; HARMS, W. R.; LANGDON, O. G. Predicting mortality with a weibull distribution. **Forest Science**, v. 26, n. 2, p. 291-300, 1980.

STATSOFT, Inc. **STATISTICA (data analysis software system), version 8**. 2009.

STEEL, R. G. D.; TORRIE, J. H. **Principles and procedures of statistics**. New York: McGraw – Hill, 1960. 481 p.

TAYLOR, S. L.; MACLEAN, D. A. Spatiotemporal patterns of mortality in declining balsam fir and spruce stands. **Forest Ecology and Management**. v. 253, n. 1, p. 188-201, 2007.

TOMÉ, M.; BURKHART, H. E. Distance-dependent competition measures for predicting growth of individual tree. **Forest Science**, v. 35, n. 3, p. 816-831, 1989.

TONINI, H. Índices de competição e o seu uso na modelagem do crescimento das árvores. Boa Vista: **Embrapa Roraima**, 2007. 30 p.

UZOH, F. C. C.; OLIVER, W. W. Individual tree diameter increment model for managed even-aged stands of ponderosa pine throughout the western United States using a multilevel linear mixed effects model. **Forest Ecology and Management**, v. 256, n. 1, p. 438-445, 2008.

VANCLAY, J. K. **Modeling Forest growth and yield: applications to mixed tropical Forest**. Wallingford: CAB International, 1994. 312 p.

VON NEUMANN, J., **Theory of Self - Reproducing Automata**, ed. A., W. Burks, University of Illinois Press, Illinois, 1966.

WARING, R. H. Characteristics of trees predisposed to die. **BioScience**, Washington, v. 37, n. 8, p. 569-574, 1987.

WEINGARTNER, M.; MERKL, D.; HASENAUER, H. Improving tree mortality predictions of Norway Spruce stands with neural networks. In Proceedings of the Symposium on Integration in Environmental Information Systems, **Proceedings...** Zell am See, Austria, 2000.

WEST, P. W. Simulation of diameter growth and mortality in regrowth eucalypt forest of southern Tasmania. **Forest Science**, v. 27, n. 3, p. 603-616, 1981.

WOLFRAM, S. Statistical mechanics of cellular automata. **Review of modern physics**, v. 55, n. 1, p. 601-644, 1983.

WYKOFF, W. R. A basal area increment model for individual conifers in the northern rocky mountains. **Forest Science**, v. 36, n. 4, p. 1077-1104, 1990.

XAVIER, A. **Explorando Sistemas Complexos no Ensino Fundamental**. 2003. 162 p. Dissertação (Mestrado em Educação) – Faculdade de Educação, UFMG, Belo Horizonte.

YANG, Y.; TITUS, S. J.; HUANG, S. Modeling individual tree mortality for white spruce in Alberta. **Ecological Modeling**, v. 163, n. 3, p. 209-222, 2003.

YASSEMI, S.; DRAGIĆEVIĆ, S.; SCHMIDT, M. Design and implementation of an integrated GIS - based cellular automata model to characterize forest fire behaviour. **Ecological Modelling**, v. 210, n. 1-2, p. 71-84, 2008.

ZEIDE, B. Analysis of growth equations. **Forest Science**, v. 39, n. 4, p. 594-616, 1993.

ZHAO, D.; BORDERS, B.; WANG, M.; KANE, M. Modeling mortality of second rotation loblolly pine plantations in the Piedmont/Upper coastal plain and lower coastal plain of the southern United States. **Forest Ecology and Management**, Amsterdam, v. 255, n. 1, p. 132 – 143, 2007.