

**DANIEL DE PAULA SILVEIRA**

**ESTIMAÇÃO DO VOLUME DE MADEIRA EMPILHADA UTILIZANDO  
IMAGENS DIGITAIS E REDES NEURAIS**

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

**VIÇOSA**  
**MINAS GERAIS – BRASIL**  
**2014**

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

T

S587e  
2014 Silveira, Daniel de Paula, 1989-  
Estimação do volume de madeira empilhada utilizando  
imagens digitais e redes neurais / Daniel de Paula Silveira. –  
Viçosa, MG, 2014.  
ix, 55f. : il. (algumas color.) ; 29 cm.

Inclui apêndice.

Orientador: Márcio Lopes da Silva.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Eucalipto - Madeira. 2. Madeira - Fator empilhamento.  
3. Empilhamento - Volume sólido. 4. Processamento imagens -  
Técnicas digitais. 5. NeuroDIC (Programa de computador). 6. .  
I. Universidade Federal de Viçosa. Departamento de Engenharia  
Florestal. Programa de Pós-graduação em Ciência Florestal.  
II. Título.

CDD 22. ed. 634.9285

**DANIEL DE PAULA SILVEIRA**

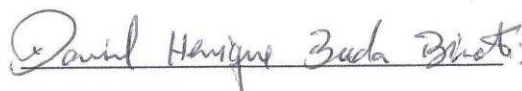
**ESTIMAÇÃO DO VOLUME DE MADEIRA EMPILHADA UTILIZANDO  
IMAGENS DIGITAIS E REDES NEURAIS**

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: 20 de outubro de 2014



Helio Garcia Leite



Daniel Henrique Breda Binoti



Márcio Lopes da Silva

(Orientador)

**Dedico...**

...a Deus...

...aos meus pais, Vicente e Eliane...

...a minha irmã, Letícia

...a minha namorada, Mireli...

## **AGRADECIMENTOS**

Primeiramente a Deus, por mais essa oportunidade concedida.

Aos meus pais, Vicente e Eliane, por proporcionar minha formação moral e espiritual, que são a base para alcançar meus objetivos.

À minha irmã Letícia, por todas as alegrias compartilhadas.

À minha namorada Mireli, pelos sorrisos, motivação, carinho e paciência em todas as etapas desse trabalho.

À minha Tia Eunice, pelas orações e carinho.

Aos professores Márcio, Helio e Binoti, pela amizade e valiosas contribuições nesse trabalho.

Ao departamento de Engenharia Florestal da Universidade Federal de Viçosa e ao CNPq pela oportunidade concedida.

À toda família Silveira e amigos.

## **BIOGRAFIA**

Daniel de Paula Silveira, filho de Vicente de Paula Silveira e Eliane de Paula Silva e Silveira nasceu no dia 08 de janeiro 1989 na cidade de Vazante, no estado de Minas Gerais, Brasil.

Em 2007 ingressou na Universidade Federal de Viçosa no curso de Engenharia Florestal. Durante o período de estudos teve a oportunidade de ser bolsista do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) duas vezes, desenvolvendo trabalhos na área de Manejo e Mensuração Florestal.

Em 2011 estudou na University of Minnesota – EUA e trabalhou com pesquisas científicas relacionadas à adubação nitrogenada na mesma instituição.

Em 2012 concluiu o curso de graduação agraciado com a Medalha Artur Bernardes pelo desempenho acadêmico. No mesmo ano ingressou no programa de pós-graduação da Universidade Federal de Viçosa.

## SUMÁRIO

RESUMO .....	vi
ABSTRACT .....	viii
CAPÍTULO 1 .....	1
1. INTRODUÇÃO .....	1
2. OBJETIVO .....	3
3. MATERIAL E MÉTODOS.....	4
4. RESULTADOS.....	9
5. DISCUSSÃO .....	27
6. CONCLUSÕES .....	29
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	30
CAPÍTULO 2.....	32
1. INTRODUÇÃO .....	32
2. OBJETIVO .....	35
3. MATERIAL E MÉTODOS.....	36
4. RESULTADOS.....	42
5. DISCUSSÃO .....	46
6. CONCLUSÕES .....	50
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	51
APÊNDICE.....	53

## RESUMO

SILVEIRA, Daniel de Paula, M.Sc., Universidade Federal de Viçosa, outubro de 2014. **Estimação do volume de madeira empilhada utilizando imagens digitais e redes neurais.** Orientador: Márcio Lopes da Silva.

Neste estudo é apresentado um sistema computadorizado para estimação do fator de empilhamento utilizando redes neurais artificiais –NeuroDIC. O sistema foi utilizado em um estudo de caso de quantificação do volume de madeira empilhada sobre caminhões. O NeuroDIC foi desenvolvido utilizando a linguagem de programação Java. Como ambiente de desenvolvimento foram utilizados o IDE (Integrated Development Environment) Netbeans 7.1 e a JDK 7.3 (Java Development Kit). É uma ferramenta gratuita, que pode ser utilizada em qualquer sistema operacional. A madeira utilizada no estudo foi proveniente de um talhão pertencente a uma empresa de reflorestamento do centro-oeste paulista, plantado com um híbrido de *Eucalyptus grandis* x *Eucalyptus urophylla*, com idade de 8,5 anos, espaçamento de 3,0 X 3,0 m e empilhada sobre caminhões. Cada pilha carregada sobre os caminhões foi fotografada transversalmente ao comprimento das toras, a uma distância aproximada de 2,5 m. Em cada uma foram tiradas seis fotos, sendo uma da porção superior esquerda (SE), superior central (SC), superior direita (SD), inferior esquerda (IE), inferior direita (ID) e uma central (CE). O volume cúbico de cada pilha foi determinado pela cubagem de cada tora pela fórmula de Huber.



O volume em estéreo foi calculado pela medição das dimensões da pilha no caminhão. Ao todo foram treinadas 420 redes e escolhidas 42 dentre elas, sendo uma para cada imagem. As redes foram aplicadas e cada imagem classificada foi comparada a imagem original visualmente, analisando a qualidade da classificação após aplicação das redes neurais. Foram obtidos 42 fatores de empilhamento no total. Foi calculada a média entre eles resultando em um fator de empilhamento médio. A diferença média entre o volume cúbico calculado no campo e pelo processamento digital de imagens utilizando RNA foi de 1,9%. Comparado ao processo convencional de cubagem de toda a carga para estimação do fator de empilhamento, houve redução de aproximadamente 90% dos custos da atividade ao adotar o processamento digital de imagens utilizando redes neurais artificiais.

## ABSTRACT

SILVEIRA, Daniel de Paula, M.Sc., Universidade Federal de Viçosa, october, 2014. **Estimation of the volume wooden stacked using digital images and neural networks**. Adviser: Márcio Lopes da Silva.

In this study is presented the computerized system to estimate the piling factor using artificial neural networks - NeuroDIC and use it to estimate the volume of wood piled on trucks using digital images. NeuroDIC was developed using the Java programming language. As a development environment IDE (Integrated Development Environment) Netbeans 7.1 and JDK 7.3 (Java Development Kit) was used. The software is a free tool that can be used on any operating system. The wood used in the study came from a field belonging to a reforestation company Midwestern São Paulo planted with a hybrid of *Eucalyptus grandis* x *Eucalyptus urophylla*, aged 8.5 years, planting space of 3.0 X 3.0 meters, piled on trucks. Each stack loaded on the trucks was photographed across the length of the logs, a distance of approximately 2.5 meters. In each pile, six photographs were taken, one from the upper left (SE) , upper center (SC), upper right (SD), lower left (IE), lower right (ID) and a center (CE). The cubic volume of each pile was estimated by cubing each log by the method of Huber. The stereo volume was calculated by measuring the

dimensions of the pile in the truck. Altogether 420 networks were trained and chosen 42 among them, one for each image. The networks have been applied and each classified image was visually compared to the original image, analyzing the quality of the classification after application of neural networks. 42 piling factors were obtained in total. The average between them was calculated resulting in medium piling factor. The average difference between the calculated cubic volume in the field and by digital image processing using RNA was 1.9%. Compared to the conventional process of measuring the entire load to determine the piling factor, there was a reduction of approximately 90% of activity costs to adopt the digital image processing using artificial neural networks.

## **CAPÍTULO 1**

### **SITEMA COMPUTACIONAL DE CLASSIFICAÇÃO DIGITAL DE IMAGENS UTILIZANDO REDES NEURAIAS ARTIFICIAIS**

#### **1. INTRODUÇÃO**

A estimacão do volume cúbico de madeira transportado em caminhões ainda é um grande desafio para os profissionais que lidam com comercialização desse produto. Isso porque os vários métodos utilizados para quantificar o volume cúbico de cargas, quando não são extremamente caros, são imprecisos.

Tentando contornar essa dificuldade no setor florestal, alguns autores propuseram alternativas de utilizando imagens digitais buscando solucionar o problema de forma rápida e menos custosa possível. (BERTOLA, 2002; SILVA, 2003). Mesmo assim, ainda são necessários avanços na busca de resultados mais precisos e que exijam menos recursos e mão de obra.

Uma forma prática de estimar o volume sólido de madeira empilhada é a partir da mensuração das dimensões da pilha, que permite a obtenção do volume em metro estéreo (st). Este volume (st) pode ser convertido em volume sólido de madeira ( $m^3$ ) através de um fator de correção denominado de fator de empilhamento ( $Fe$ ) (MACHADO e FIGUEIREDO FILHO, 2003 ).

Uma técnica que vem sendo utilizada no setor florestal e tem apresentado ótimos resultados, sobretudo na área de mensuração florestal, são as Redes Neurais Artificiais (RNA). Uma RNA é um modelo computacional biologicamente inspirado, constituído por elementos de processamento simples (neurônios artificiais) dispostos em camadas e conectados entre si, sendo estas conexões, geralmente, associadas a coeficientes denominados de pesos. O ajuste destes pesos é realizado por um processo chamado treinamento ou aprendizado, sendo responsável pela extração das características dos dados e armazenamento de conhecimento das redes. A aplicação de uma rede consiste no processo de generalização, ou seja, utilização de uma rede treinada em dar resposta para dados inéditos (BRAGA et al., 2007; BINOTI, et al., 2014).

A quantificação de volume cúbico de madeira empilhada pode ser feita empregando RNA com a classificação digital de imagens. O objetivo do processo de classificação de uma imagem é categorizar todos os pixels em classes, ou temas. Essa categorização permite a construção de imagens temáticas e a visualização da distribuição espacial e proporção das classes na imagem.

## **2. OBJETIVO**

O objetivo desse estudo foi apresentar o sistema computadorizado para estimação do fator de empilhamento utilizando redes neurais artificiais – NeuroDIC (<http://neuroforest.ucoz.com>), para auxiliar os gestores florestais, acadêmicos e extensionistas nas tomadas de decisões relacionadas a classificação de padrões. São apresentados os princípios básicos do sistema, destacando suas características, seu principal uso e possíveis aplicações do software no setor florestal.

### 3. MATERIAL E MÉTODOS

#### *Características do software*

O NeuroDIC foi desenvolvido utilizando a linguagem de programação Java. Como ambiente de desenvolvimento foram utilizados o IDE (Integrated Development Environment) Netbeans 7.1 e a JDK 7.3 (Java Development Kit). O sistema utiliza a biblioteca Encog 3 para treinamento e geração das RNA (HEATON, 2011). O software é gratuito e pode ser utilizado em qualquer sistema operacional. A seguir são apresentados conceitos importantes para melhor entendimento e uso do Neurodic.

#### *Definição de imagem*

Uma imagem é composta por um conjunto de pontos, denominados *Pixels* (Picture Elements) ou *Dots*. Estes *pixels* estão dispostos na tela do computador formando uma matriz de pontos que é denominada *Mapa de Bits*. Este mapa de bits é um reticulado onde cada elemento da matriz possui uma informação referente a cor associada aquele ponto específico. Uma determinada imagem possuirá também uma resolução associada a ela, que é o número de elementos que esta imagem possui na

horizontal e na vertical. Cada elemento da imagem possuirá uma localização, que é definida pela suas coordenadas. (MUSCI, 2014)

A radiação emitida pelo sol é refletida pelos objetos terrestres e representada nas imagens digitais por valores numéricos ou números digitais (ND) em função desta reflexão (brilho). Quanto maior a reflexão, maior o valor registrado. Para imagens de 8 bits, os números digitais compreendem valores entre 0 e 255. Um pixel com ND igual a 241 representa uma reflectância ou emitância muito alta (tonalidade clara), enquanto que um ND igual a 12 representa reflectância ou emitância muito baixa (tonalidade escura). Um computador é capaz de analisar estes números e extrair informações.

Uma imagem colorida é formada por três números, correspondente as cores: vermelho, verde e azul. Ou seja, uma imagem colorida é formada por diferentes intensidades de vermelho, verde e azul de acordo com o brilho (valor numérico) de cada pixel (Figura 1).

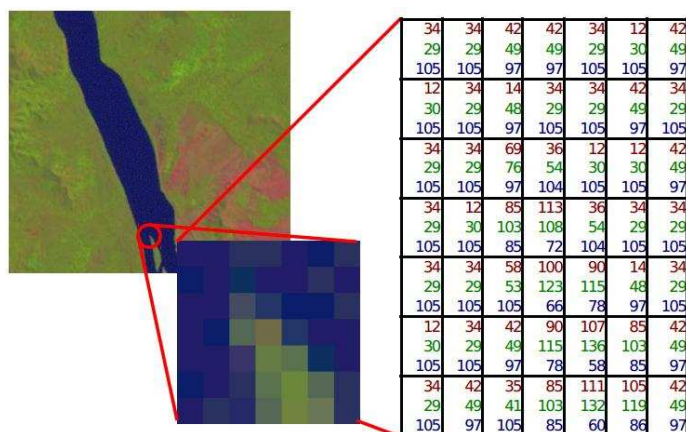


Figura 1 – Estrutura de uma imagem digital colorida

### *Etapas do processamento de imagens*

Um sistema de processamento de imagens é constituído de diversas etapas. Podemos citar como principais, dentre outras: formação e aquisição da imagem, pré-processamento, segmentação e extração de atributos, como ilustra a Figura 1.



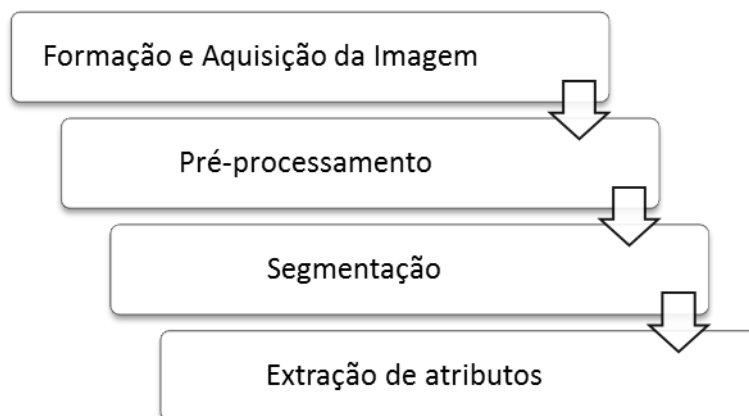


Figura 1 – Etapas de um sistema de processamento digital de imagens.

### *Formação e aquisição da imagem*

Aquisição de uma imagem é o processo de conversão de uma cena real tridimensional em uma imagem digital.

O dispositivo de aquisição de imagens mais utilizado atualmente é a câmera CCD (Charged Coupled Device). Ela consiste de uma matriz de células semicondutoras fotossensíveis, que atuam como capacitores, armazenando carga elétrica proporcional à energia luminosa incidente. O sinal elétrico produzido é condicionado por circuitos eletrônicos especializados, produzindo à saída um Sinal Composto de Vídeo (SCV) analógico e monocromático. (MARQUES FILHO e VIEIRA NETO, 1999).

Para a aquisição de imagens coloridas utilizando CCD é necessário um conjunto de prismas e filtros de cor encarregados de decompor a imagem colorida em suas componentes Vermelho, Verde e Azul, cada qual capturada por um CCD independente. Os sinais elétricos correspondentes a cada componente são combinados posteriormente conforme o padrão de cor utilizado (NTSC (National Television Standards Committee) ou PAL (Phase Alternating Line), por exemplo). (MARQUES FILHO e VIEIRA NETO, 1999).




Figura 2 – Visão esquemática de uma câmera CCD

(Fonte: MARQUES FILHO e VIEIRA NETO, 1999)

### *Pré-processamento*

As técnicas de pré-processamento têm a função de melhorar a qualidade da imagem. Estas técnicas envolvem duas categorias principais: métodos que operam no domínio espacial e métodos que operam no domínio da frequência. Técnicas de processamento no domínio espacial baseiam-se em filtros que manipulam o plano da imagem, enquanto que as técnicas de processamento no domínio da frequência se baseiam em filtros que agem sobre o espectro da imagem. (ESQUEF; ALBUQUERQUE; ALBUQUERQUE, 2003)

O uso de filtros em imagens consiste na aplicação de técnicas de transformação (operadores – máscaras) com o objetivo de corrigir, suavizar ou realçar determinadas características de uma imagem dentro de uma aplicação específica. (THOMÉ, 2013)

O histograma da imagem digital é uma ferramenta bastante útil na etapa de pré-processamento, fornece uma visão estatística sobre a distribuição dos pixels, sobre o contraste da imagem e os níveis de iluminação. Além disso, o histograma é bastante utilizado na etapa de segmentação, principalmente em técnicas que se utilizam da similaridade entre os pixels. O histograma é

utilizado com frequência como sendo uma distribuição estatística dos pixels na imagem. (ESQUEF; ALBUQUERQUE; ALBUQUERQUE, 2003).

### *Segmentação*

Segmentar uma imagem significa, de modo simplificado, separar a imagem como um todo nas partes que a constituem e que se diferenciam entre si. É usual denominar “objetos” da imagem os grupos de pixels de interesse, ou que fornecem alguma informação para o processamento digital da imagem (PDI). Da mesma forma, a denominação “fundo” da imagem é utilizada para o grupo de pixels que podem ser desprezados ou que não têm utilidade no PDI. Essas denominações “objeto” e “fundo” possuem uma conotação bastante subjetiva, podendo se referir a grupos de pixels que formam determinadas regiões na imagem sem que representem um objeto, de modo literal, presente na imagem processada.

A segmentação é considerada, dentre todas as etapas do processamento de imagens, a etapa mais crítica do tratamento da informação. É na etapa de segmentação que são definidas as regiões de interesse para processamento e análises posteriores. Como consequência deste fato, quaisquer erros ou distorções presentes nesta etapa se refletem nas demais etapas, de forma a produzir ao final do processo resultados não desejados que podem contribuir de forma negativa para a eficiência de todo o processamento. (ESQUEF; ALBUQUERQUE; ALBUQUERQUE, 2003).

### *Extração de atributos*

A etapa final de um sistema de processamento de imagens é aquela em que se extraem as informações úteis da imagem processada, como por exemplo a área de cada classe na imagem.

## 4. RESULTADOS

### *O software*

O sistema computacional denominado *NeuroDIC 2.0* foi desenvolvido em ambiente Java, para ser o mais amigável possível ao usuário, permitindo a importação de imagens digitais nos formatos mais usuais, aplicação de diversos filtros de imagens, treinamento, validação e aplicação de redes neurais de forma rápida e simples. Sua estrutura de uso está apresentada na Figura 3 e sua tela inicial, na Figura 4.

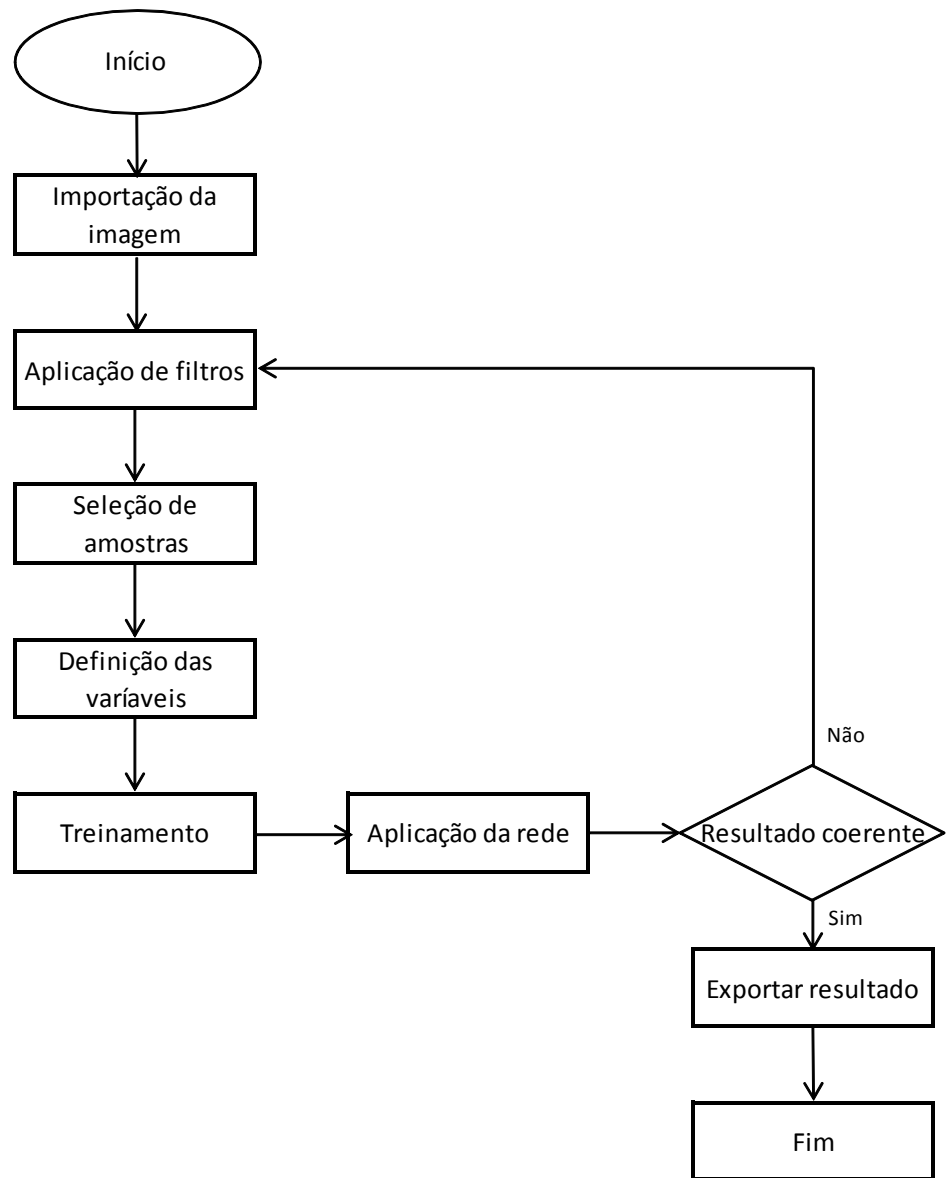


Figura 3 – Esquema geral de utilização do software *NeuroDIC 2.0*

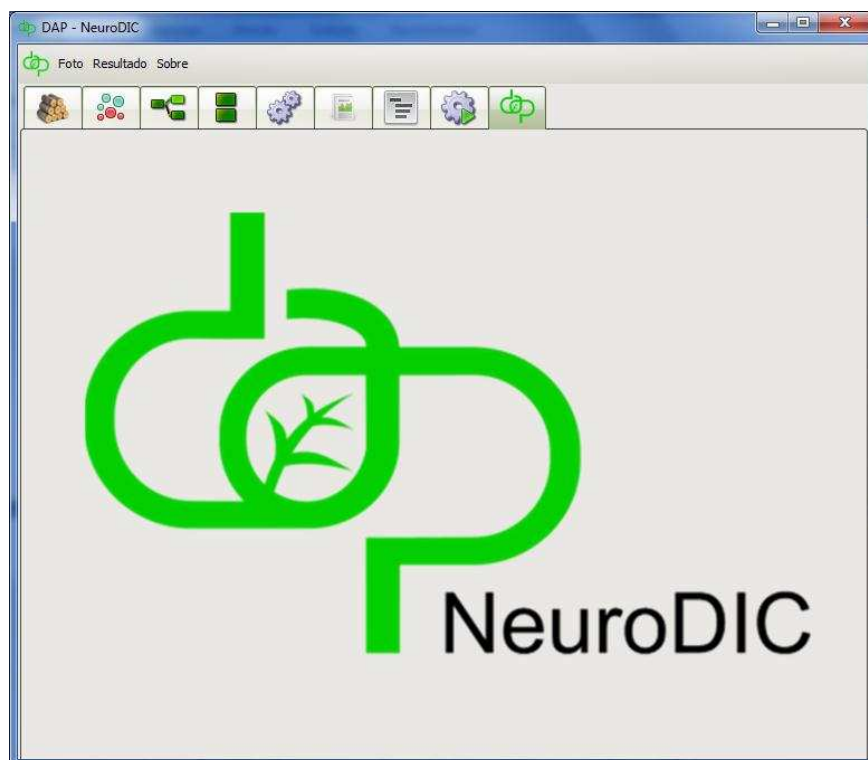


Figura 4 – Tela inicial do *NeuroDIC 2.0*

Na primeira aba do sistema é feita a importação da imagem, aplicação dos diversos filtros disponibilizados nessa versão e seleção das amostras para treinamento (Figura 5).

O sistema permite a seleção de inúmeras classes de feições, que podem ser definidas pelo usuário na primeira aba do sistema. Além do número de classes, a cor atribuída a cada classe também pode ser editada conforme necessidade do usuário.

Nessa versão atual do programa, foram incluídos na etapa de pré-processamento os seguintes filtros de imagem: Contrast, Curves, Gain, Invert, Solarize, Threshold, BlackWhite e GrayLevels.

A seguir é apresentada uma descrição sucinta de cada filtro de imagem.

- Contrast: Filtro básico para alterar o brilho e contraste da imagem original
- Curves: Aplica uma curva de transferência em cada canal da imagem
- Gain: Semelhante ao Contrast, mas permite maiores variações.

- Invert: Inverte todos os pixels da imagem, convertendo a imagem em um negativo.
- Solarize: semelhante ao Invert, entretanto a função de transformação tem formato em “V”.
- Threshold: Transforma a imagem colorida em uma imagem preto branco. Pixels com valor maior e menor do que o parâmetro definido são transformados em branco e preto, respectivamente.
- BlackWhite: Transforma a imagem em preto e branco simples.
- GrayLevels: Imagem é transformada para escala de cinzas.

Na Figura 6 são apresentados exemplos da imagem após transformação pelos filtros. Cabe ressaltar que são apenas exemplos, uma vez que os filtros Contrast, Curves, Gain e Threshold necessitam de parâmetros para aplicação e dependendo dos valores definidos os resultados são diferentes.




Figura 5 – Primeira aba do sistema NeuroDIC com imagem de exemplo importada.




Figura 6 - Exemplos de resultados alcançados após aplicação dos diferentes filtros de imagens disponibilizados no sistema. Imagem central é a imagem original.

Na mesma aba de aplicação dos filtros é possível fazer a seleção das amostras de cada classe definida pelo usuário para compor o grupo de treinamento da Rede Neural Artificial. No caso de exemplo, foram definidas duas classes para a pilha de toras, sendo uma “Madeira” e a outra “Vazio”.

Na Figura 7 é apresentado o processo de coleta de pontos amostrais das classes definidas. Os pontos de cor branca e preta indicam pontos de amostragem para as classes “Vazio” e “Madeira”, respectivamente.



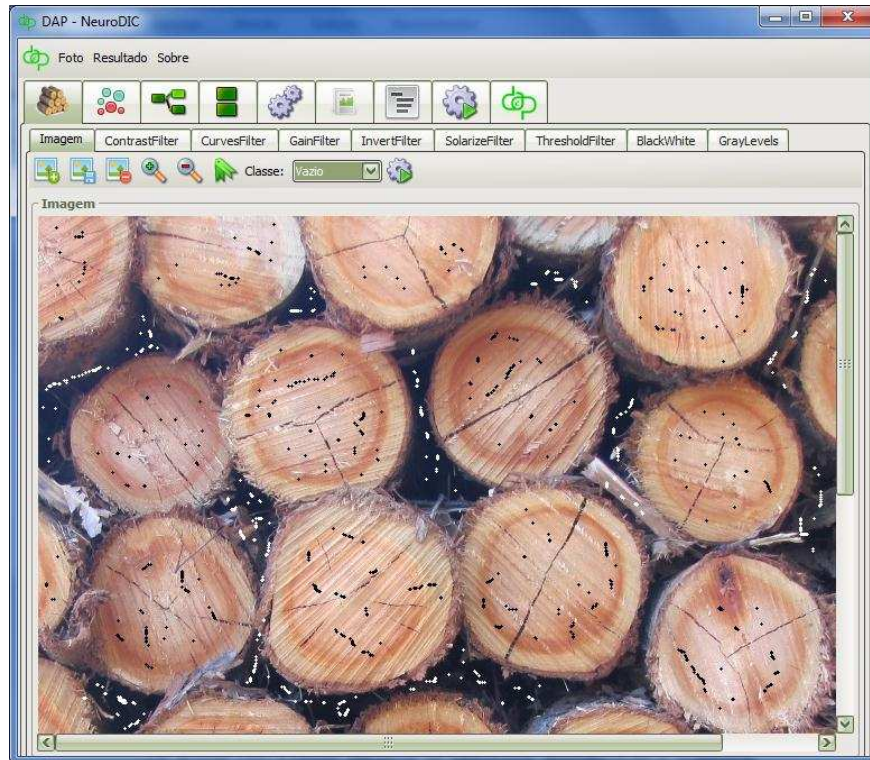


Figura 7 – Pontos amostrais coletados para as classes de feições “Vazio” e “Madeira” (brancos e pretos, respectivamente).

A coleta das amostras é feita utilizando o mouse e para cada clique do botão esquerdo uma amostra é selecionada. Ao coletar amostras na imagem original, o software faz coletas em todas as imagens modificadas pelos filtros. Para permitir maior flexibilidade na coleta, é possível selecionar amostras diretamente nas imagens modificadas. Para isso basta apenas selecionar a aba do filtro correspondente e selecionar amostras.

Ao selecionar uma amostra, o software capta a posição cartesiana bem como os valores Vermelho, Verde e Azul do pixel selecionado em cada imagem (original e modificadas). Na aba seguinte (Figura 8) é possível visualizar todas as amostras coletadas e os respectivos atributos coletados nas imagens.

Valor X	Valor Y	Valor Red	Valor Green	Valor Blue	Classe No...	Classe Val...	Valor Red ...	Valor Gre...	Valor Bl
264	139	226	183	166	Madeira	1	255	201	171
263	140	228	186	170	Madeira	1	255	207	178
263	142	213	174	157	Madeira	1	255	185	155
261	142	211	174	158	Madeira	1	252	185	156
257	143	224	187	169	Madeira	1	255	209	176
255	145	218	185	168	Madeira	1	255	205	174
249	145	228	191	175	Madeira	1	255	216	187
246	145	207	169	156	Madeira	1	245	176	153
241	145	229	199	188	Madeira	1	255	230	210
237	147	231	199	188	Madeira	1	255	230	210
233	147	255	223	216	Madeira	1	255	255	255
230	148	208	175	166	Madeira	1	246	187	171
229	148	222	184	175	Madeira	1	255	203	187
226	151	253	217	205	Madeira	1	255	255	241
223	151	243	203	193	Madeira	1	255	237	219
430	129	196	149	131	Madeira	1	225	140	108
424	132	202	157	136	Madeira	1	236	155	117
424	133	207	162	139	Madeira	1	245	164	122
423	134	208	166	144	Madeira	1	246	171	131
421	135	207	166	146	Madeira	1	245	171	135
421	137	205	167	146	Madeira	1	241	173	135
420	138	205	167	148	Madeira	1	241	173	138
419	140	208	169	152	Madeira	1	246	176	146
418	140	205	163	147	Madeira	1	241	165	137
418	143	199	157	141	Madeira	1	230	155	126
417	144	195	154	136	Madeira	1	223	149	117
409	151	211	170	148	Madeira	1	252	178	138

Figura 8 – Amostras coletadas nas imagens após seleção dos pontos pertencentes a cada feição.

A etapa seguinte consiste na determinação das variáveis de treinamento (Figura 9). Para treinamento da rede, são necessárias variáveis de entrada e pelo menos uma variável de saída. Fazendo uma analogia com a regressão, variáveis de entrada podem ser entendidas como as variáveis independentes do modelo de regressão, ou seja, aquelas utilizadas para descrever o comportamento da variável dependente. Por sua vez, a variável de saída é a variável dependente, aquela que se busca estimar através de relações funcionais entre outras variáveis. Na escolha das variáveis de entrada, o programa permite a escolha de dois tipos de variáveis de entrada:

- a) Variáveis contínuas: são as características que podem ser medidas em uma escala quantitativa, ou seja, apresentam valores numéricos.
- b) Variáveis categóricas: são as características que não possuem valores quantitativos, mas, ao contrário, são definidas por várias categorias, ou seja, representam uma classificação dos indivíduos.

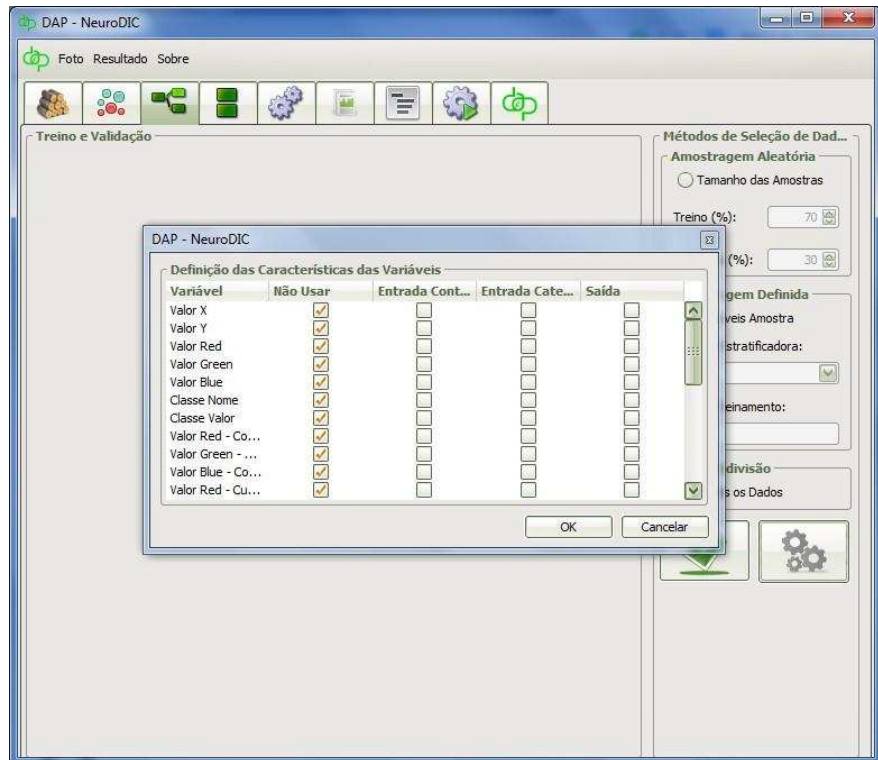


Figura 9 – Tela de seleção de amostras para treinamento da Rede Neural Artificial.

Após seleção das amostras de treinamento, é necessário normalizar os dados (Figura 10). Essa etapa é necessária, pois as funções de ativação dos neurônios artificiais geram saídas no intervalo de 0 a 1 ou -1 a 1. A normalização transforma os valores de uma variável de forma que o maior valor seja 1 e o menor seja 0 ou -1, e os demais são transformados dentro do intervalo. Existem várias formas de normalização, porém a mais comum e implantada no sistema foi a normalização linear:

$$v' = \frac{(v - \min)(LS - LI)}{(\max - \min)} + LI$$

em que:

$v'$  = valor normalizado;

$v$  = valor real, antes da normalização;

$\min$  = menor valor da variável a ser normalizada;

$\max$  = maior valor da variável a ser normalizada;

$LS$  = limite superior do intervalo de normalização;

LI = limite inferior do intervalo de normalização

O sistema automaticamente já faz a normalização das variáveis e apresenta informações da amostra na tela de normalização, conforme Figura 10.

Valores Observados - Variáveis Contínuas			
Variáveis	Valor Red	Valor Green	Valor Blue
Valor Máximo	255,0	231,0	229,0
Valor Mínimo	20,0	24,0	34,0

Limites Normalização - Variáveis Contínuas			
Variáveis	Valor Red	Valor Green	Valor Blue
Valor Máximo	1	1	1
Valor Mínimo	0	0	0

Descrição de Variáveis Categóricas			
Variáveis			
Número de...			

Valores Variável de Saída			
Variável - ...	Classe Val...	Saída - Li...	
Valor Máximo	2,0	1	
Valor Mínimo	1,0	0	

Figura 10 – Tela de normalização das variáveis escolhidas para treinamento

A etapa seguinte consiste na configuração da RNA e do treinamento, onde são definidos os neurônios da camada oculta, funções de ativação por camada, algoritmo de treinamento e parâmetros, critério de parada, dentre outros (Figura 11). Não foi objetivo desse trabalho caracterizar cada configuração de rede e treinamento disponível no software.

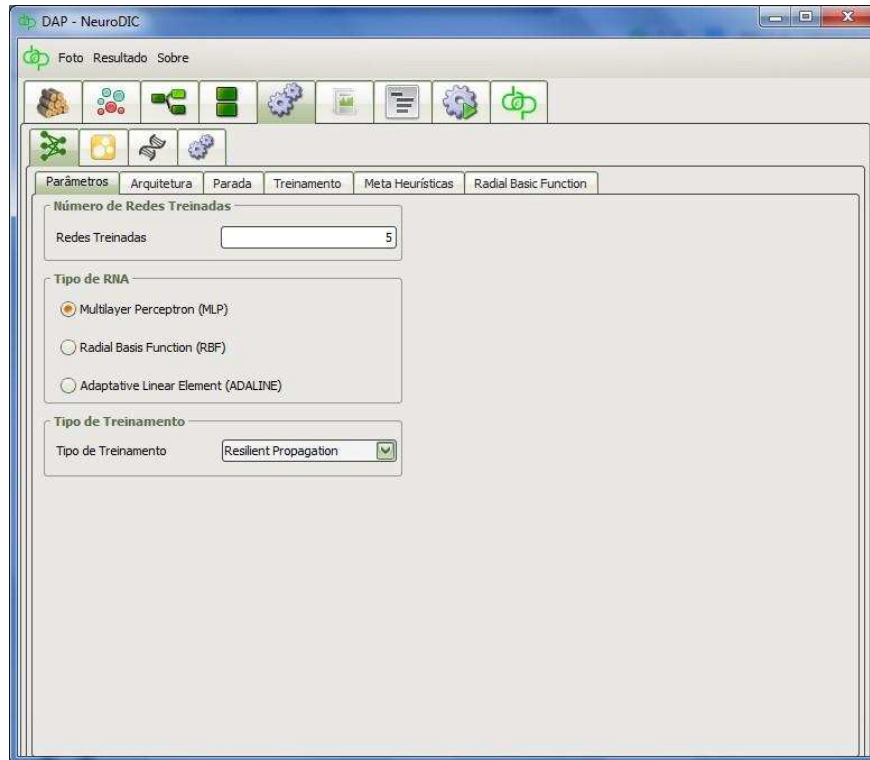


Figura 11 – Tela para configuração da RNA e do treinamento

Estando configurado, o software pode então iniciar o treinamento da RNA. É possível acompanhar a evolução do treinamento na tela do programa (Figura 12), onde são apresentados os valores do Erro Quadrático Médio (EQM), calculado da seguinte forma:

$$EQM = \frac{1}{n} \sum_{i=1}^n (Y'_i - Y_i)^2$$

em que:

EQM = erro quadrado médio;

n = total de registros escolhidos para treinamento;

$Y'_i$  = valor estimado na i-ésima amostra

$Y_i$  = valor observado na i-ésima amostra




Figura 12 – Tela evidenciando cálculo do EQM em cada geração

Após o treinamento, as estimativas dos valores de saída, bem como gráficos de resíduo para cada rede treinada podem ser avaliados na aba seguinte (Figura 13).

DAP - NeuroDIC

Foto Resultado Sobre

Estimativas Estatísticas Gráficos

Resultados

Valor X	Valor Y	Valor Red	Valor Green	Valor Blue	Classe No...	Classe Val...	Valor Red ...	Valor Gre...	Valor I
264	139	226	183	166	Madeira	1	255	201	171
263	140	228	186	170	Madeira	1	255	207	178
263	142	213	174	157	Madeira	1	255	185	155
261	142	211	174	158	Madeira	1	252	185	156
257	143	224	187	169	Madeira	1	255	209	176
255	145	218	185	168	Madeira	1	255	205	174
249	145	228	191	175	Madeira	1	255	216	187
246	145	207	169	156	Madeira	1	245	176	153
241	145	229	199	188	Madeira	1	255	230	210
237	147	231	199	188	Madeira	1	255	230	210
233	147	255	223	216	Madeira	1	255	255	255
230	148	208	175	166	Madeira	1	246	187	171
229	148	222	184	175	Madeira	1	255	203	187
226	151	253	217	205	Madeira	1	255	255	241
223	151	243	203	193	Madeira	1	255	237	219
430	129	196	149	131	Madeira	1	225	140	108
424	132	202	157	136	Madeira	1	236	155	117
424	133	207	162	139	Madeira	1	245	164	122
423	134	208	166	144	Madeira	1	246	171	131
421	135	207	166	146	Madeira	1	245	171	135
421	137	205	167	146	Madeira	1	241	173	135
420	138	205	167	148	Madeira	1	241	173	138
419	140	208	169	152	Madeira	1	246	176	146
418	140	205	163	147	Madeira	1	241	165	137
418	143	199	157	141	Madeira	1	230	155	126

Linha Selecionada: 0 Total de Registros: 899

Figura 13 – Tela para avaliação dos resultados do treinamento

O software permite salvar a RNA treinada ou simplesmente aplicá-la na imagem importada. Para aplicar a RNA é necessário codificar a imagem em uma matriz que contenha todas as informações dos pixels e seus valores digitais. Além das informações dos pixels da imagem original, são também codificadas as informações das imagens transformadas pelos filtros. A rede treinada utiliza essa matriz de dados para estimar a classe de cada pixel da imagem e classificá-la nas classes previamente estabelecidas (Figura 14). Além disso, na aba *Resultados* é possível verificar a proporção da imagem em cada classe.




Figura 14 – À esquerda, imagem original e à direita, imagem classificada pelo software após aplicação da RNA.

#### *Inventário de sobrevivência*

Imagens obtidas a partir de VANTs podem ser utilizadas para a realização do inventário florestal de sobrevivência. O Inventário de sobrevivência é utilizado para avaliar se a qualidade do plantio. Na Figura 15, observa-se uma imagem obtida por um VANT, com identificação das mudas em fase inicial de desenvolvimento e o resultado da classificação (imagem binarizada).








Figura 15 - Imagem obtida por VANT com identificação das mudas e resultado da classificação.

#### *Fator de empilhamento*

Imagens obtidas a partir de câmeras digitais simples podem ser utilizadas para a estimação do fator de empilhamento para quantificação do volume de pilhas de madeira. O fator de empilhamento é utilizado para a conversão do volume em estéreo em metros cúbicos, ou seja, representa os espaços vazios na pilha de madeira. Um exemplo de uma imagem digital com resultado da classificação é apresentado na Figura 16. No capítulo 2 é apresentado um caso de uso específico do sistema para quantificação do volume de madeira em caminhões.



Figura 16 - Imagem digital de pilha de madeira para estimação do fator de empilhamento e resultado da classificação.

### *Tamanho de copa*

Imagens obtidas a partir de satélites podem ser utilizadas para avaliação do tamanho de copas e sua ocupação em espaço para crescimento. Na Figura 17, pode-se observar copas de um plantio de palmito formado por diversas espécies, bem como o resultado da classificação pelo sistema NeuroDic. Através do sistema é possível avaliar e comparar o tamanho e crescimento do plantio de palmitos.







Figura 17 - Imagem de satélite e classificação de um plantio de palmito utilizando o sistema *NeuroDic*.

#### *Infestação de acácia em plantio de eucalipto*

Imagens na região do infravermelho, obtidas a partir de satélites, podem ser utilizadas para avaliação do grau de infestação de uma espécie em plantios de outra espécie. A Figura 18 apresenta uma imagem de satélite demonstrando o caso de infestação.






Figura 18 - Exemplo da classificação da infestação de acácia em plantios de eucalipto com uso de imagem de satélite.

#### *Cobertura do dossel*

Imagens obtidas com câmeras manuais podem ser utilizadas para avaliação da cobertura do dossel de florestas. Na Figura 19 se encontra um exemplo de aplicação do *NeuroDIC* para classificação da cobertura vegetal do dossel.






Figura 19 – Classificação da cobertura vegetal do dossel florestal.

#### *Área foliar afetada por doença*

Imagens obtidas a partir de câmeras manuais podem ser utilizadas para quantificação da proporção da área foliar afetada por doença. Na Figura 20 se encontra um exemplo de aplicação do *NeuroDIC* para quantificação da proporção da área foliar afetada por doença.




Figura 20 – Classificação de área foliar afetada por doença

## 5. DISCUSSÃO

O objetivo desse estudo foi apresentar o sistema computadorizado para estimação do fator de empilhamento utilizando redes neurais artificiais – NeuroDIC, para auxiliar os gestores florestais, acadêmicos e extensionistas nas tomadas de decisões. Foram apresentados os princípios básicos do sistema, destacando suas características, seu principal uso e possíveis aplicações do software no setor florestal.

O sistema *NeuroDIC* 2.0 permite a importar imagens digitais nos formatos usuais, aplicação de diversos filtros de imagens, treinamento, validação e aplicação de redes neurais de forma rápida e simples.

Ele pode ser utilizado em qualquer sistema operacional e dispõe de oito filtros que permitem trabalhar com diferentes imagens e padrões de captura (luminosidade, contraste, cores, etc.).

O uso de imagens digitais é cada vez mais recorrente no setor florestal. Muitos desses usos têm como objetivo a definição de padrões na imagem, classificação de regiões e seus atributos. Um bom exemplo é o uso de imagens no inventário florestal, que podem ser utilizadas para extrair informações da produtividade da floresta. O Neurodic pode ser utilizado para classificar extratos produtivos da floresta com base nos valores digitais dos pixels das imagens.

Além disso, pode ser utilizado para definir quando desbastar uma floresta, com base em informações de cobertura do dossel. É possível avaliar o grau de competição por luz entre as árvores e recomendar ou não, redução da densidade no povoamento.

É possível ainda avaliar a intensidade de ataque de uma doença, com base na proporção de área foliar atingida. Essa informação pode ajudar a decidir pelo combate ou não da doença antes de atingir o ponto de dano econômico.

## **6. CONCLUSÕES**

O projeto *Neurodic* 2.0 permite classificar imagens digitais de modo eficiente utilizando redes neurais artificiais, podendo ser utilizado para diversos fins no setor florestal, inclusive para estimação do fator de empilhamento.



## 7. REFERÊNCIAS BIBLIOGRÁFICAS

BERTOLA, A. **Uso de fotografias digitais para quantificar o volume sólido de madeira empilhada**. Dissertação de mestrado, Viçosa, 18 fevereiro 2002. 64.

MACHADO, S. A.; FIQUEIREDO FILHO, A. **Dendrometria**. Curitiba: [s.n.], 2003.

BRAGA, A. D. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2ª. ed. Rio de Janeiro: LTC, 2007.

BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de Redes Neurais Artificiais para estimação do volume de árvores. **Ciência da Madeira**, Pelotas, Maio 2014. 58-67.

HEATON, J. **Programming Neural Networks with Encog3 in Java**. 2ª. ed. [S.I.]: Heaton Research Incorporated, 2011. 240 p.

MARQUES FILHO, O.; VIERIA NETO, H. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999.

ESQUEF, I. A.; ALBUQUERQUE, M. P.; ALBUQUERQUE, M. P. **Processamento Digital de Imagens**. Centro Brasileiro de Pesquisas Físicas. [S.I.], p. 12. 2003.

MUSCI, M. Sistemas Multimídia., p. 17-25, 2014. Disponível em: <[www.musci.com.br/multimedia/ImagensDesenhos3D.pdf](http://www.musci.com.br/multimedia/ImagensDesenhos3D.pdf)>. Acesso em: 14 julho 2014.

THOMÉ, A. G. **Notas de aula: Processamento de Imagens**. UFRJ. Rio de Janeiro. 2013.

## **CAPÍTULO 2**

### **ESTIMAÇÃO DO VOLUME DE MADEIRA EMPILHADA PELO PROCESSAMENTO DE IMAGENS DIGITAIS**

#### **1. INTRODUÇÃO**

De acordo com Instituto Nacional de Metrologia, Normalização e Qualidade Industrial – INMETRO, a unidade de medida estéreo, empregada nas operações envolvendo produção, colheita, baldeio, transporte e comercialização de madeira roliça pode ser definida como o volume de uma pilha de madeira, contida num cubo cuja arestas meçam um metro, nele incluídos os espaços vazios normais entre as toras ou toretas, sendo estes espaços os presentes numa pilha de toras ou toretas acomodadas umas às outras longitudinalmente (INMETRO, 1999).

A utilização da unidade estéreo ainda é permitida na comercialização de madeira roliça, apesar de não ser uma unidade admitida pelo Sistema Internacional de Unidades (SI), conforme portaria nº 337 do INMETRO (INMETRO, 2011). Apesar das constantes tentativas de substituí-la por uma medida mais precisa do volume real de madeira da pilha, desconsiderando os

espaços vazios, o estéreo tem sido amplamente usado por ser uma unidade obtida facilmente no campo, dependendo apenas das medições de comprimento, largura e altura da pilha de madeira.

Na prática, o que a maioria das empresas florestais no Brasil fazem é obter a razão entre o volume estéreo e o volume real da pilha, denominado de fator de empilhamento.

Conhecendo-se o volume de uma pilha, em estéreo, obtido pela medição das suas dimensões, o volume sólido de madeira da pilha pode ser obtido dividindo-se o volume em estéreo pelo fator de empilhamento. Esse fator é muito utilizado em processos de compra e venda de madeira, quando se tem a necessidade de quantificar o volume de madeira pós-colheita que está sendo negociado. Fato é que, quando esse fator é desconhecido, é comum a utilização de um fator médio, definido como base em medições de outras pilhas ou mesmo com base na literatura.

Segundo Bertola (2002) e Rezende (1988), características como os diâmetros e comprimentos das toras de madeira, a espessura da casca, a forma de empilhar, a espécie, a idade das árvores, entre outros fatores afetam o volume de madeira empilhada de tal forma que a utilização de um fator médio resulta, às vezes, em erros nas estimativas. O uso de um único fator de empilhamento para todas as condições assume que todos os povoamentos apresentam uma mesma distribuição de frequências ou todas as árvores são semelhantes, o que é uma suposição incorreta e inválida.

O ideal ao se utilizar fatores de empilhamento para estimação do volume real de madeira empilhada é sempre calcular o fator de acordo com as principais características da madeira com que se está trabalhando. Na maioria das vezes isso não é possível, dada a falta de tempo e recursos para realizar a cubagem rigorosa de todas as toras na pilha. Uma alternativa rápida e de menor custo é a utilização de imagens digitais e redes neurais artificiais aliadas a softwares especializados para processamento e estimação do fator de empilhamento em escritório.

Redes neurais artificiais (RNA) são redes de neurônios artificiais, sendo aproximações grosseiras, ou seja, simplificações das redes e neurônios encontrados nos cérebros biológicos. Consistem em sistemas computacionais paralelos (camadas) constituídos de várias unidades de processamento simples (neurônios artificiais) conectadas entre si de uma maneira específica para executar uma determinada tarefa. (BULLINARIA, 2009).

## **2. OBJETIVO**

O presente trabalho teve como objetivo apresentar caso de uso de estimação do volume de madeira empilhada em caminhões, utilizando processamento de imagens digitais e redes neurais. Também foi objetivo avaliar a eficiência do sistema *Neurodic* para este propósito.

### 3. MATERIAL E MÉTODOS

#### *Fonte de dados*

A madeira utilizada no estudo foi proveniente de um talhão pertencente a uma empresa de reflorestamento do centro-oeste paulista plantado com um híbrido de *Eucalyptus grandis* x *Eucalyptus urophylla*, com idade de 8,5 anos e espaçamento silvicultural de 3,0 X 3.0 m. O corte e processamento das árvores foi realizado por um Feller Buncher e uma Garra Traçadora, respectivamente. O transporte e carregamento dos caminhões foram realizados por um Forwarder.

Cada pilha carregada sobre os caminhões foi fotografada transversalmente ao comprimento das toras, a uma distância aproximada de 2,5 metros. Em cada uma foram tiradas seis fotos, sendo uma da porção superior esquerda (SE), superior central (SC), superior direita (SD), inferior esquerda (IE), inferior direita (ID) e uma central (CE). Na Figura 1 é apresentado esquema da área fotografada da pilha pelas seis fotos tiradas.




Figura 1 – Porção da pilha de madeira que cada foto abrangeu. SE - superior esquerda; SC – superior central; SD – superior direito; ID – inferior direito; IE – inferior esquerdo e CE – central.

As fotos foram tiradas utilizando uma câmera digital Nikon Coolpix L820, com resolução de imagem de 16 megapixels. Ao todo foram fotografadas 7 pilhas, totalizando 42 fotos.

#### *Volume cúbico e estéreo*

O volume cúbico de cada pilha foi determinado através da cubagem de cada tora pela fórmula de Huber:

$$V = AS_{1/2} L$$



onde:

$V$  = volume da tora,  $m^3$

$AS_{1/2}$  = área seccional da tora na metade de seu comprimento,  $m^2$

$L$  = comprimento da tora,  $m$ .

O volume cúbico da pilha foi determinado através do somatório dos volumes individuais das toras. O volume em estéreo foi calculado pela medição das dimensões da pilha no caminhão. A altura foi tomada duas vezes em cada pilha na porção central, uma de cada lado, com o auxílio de uma régua graduada, conforme Figura 2.



Figura 2 – Medida da altura de madeira no caminhão, sendo  $H$  a altura medida, em metros. Pilha meramente ilustrativa do processo, não amostrada.

A largura de cada feixe foi a medida da largura interna do caminhão e o comprimento foi determinado pela média dos comprimentos das toras. O volume estéreo de cada feixe foi calculado da seguinte forma:

$$V_{st} = \frac{H_1 + H_2}{2} L C$$

em que:

$V_{st}$  = volume estéreo,  $m^3$ ;

$H_1$  = primeira altura tomada da pilha,  $m$ ;

$H_2$  = segunda altura tomada da pilha, m.

L = largura do caminhão, m.

C = comprimento médio das toras na pilha, m.

A partir dos volumes estéreos e cúbicos, se derivou o fator de empilhamento com casca, tido como verdade de campo.

### *Classificação das imagens digitais*

Para estimação do fator de empilhamento de pilhas de madeira sobre caminhões foi utilizado o software *NeuroDIC 2.0* (<http://neuroforest.ucoz.com>). O *NeuroDIC* foi desenvolvido utilizando a linguagem de programação Java e ambiente de desenvolvimento o IDE (Integrated Development Environment) Netbeans 7.1 e a JDK 7.3 (Java Development Kit). O sistema utiliza a biblioteca Encog 3 para a treinamento e geração das RNA (HEATON, 2011). O software é gratuito e pode ser utilizado em qualquer sistema operacional.

O software *Neurodic 2.0* conta com os seguintes filtros de imagem: Contrast, Curves, Gain, Invert, Solarize, Threshold, BlackWhite e GrayLevels.

A seguir é apresentada uma descrição sucinta de cada filtro de imagem.

- Contrast: Filtro básico para alterar o brilho e contraste da imagem original
- Curves: Aplica uma curva de transferência em cada canal da imagem
- Gain: Semelhante ao Contrast, mas permite maiores variações.
- Invert: Inverte todos os pixels da imagem, convertendo a imagem em um negativo.
- Solarize: semelhante ao Invert, entretanto a função de transformação tem formato em “V”.
- Threshold: Transforma a imagem colorida em uma imagem preto branco. Pixels com valor maior e menor do que o parâmetro definido são transformados em branco e preto, respectivamente.
- BlackWhite: Transforma a imagem em preto e branco simples.
- GrayLevels: Imagem é transformada para escala de cinzas.

Antes de importar as imagens para o programa, cada uma foi editada de forma a abranger as porções da pilha, conforme já exemplificado na Figura 1. Para cada imagem foram aplicados os filtros de imagens, sempre buscando a melhor configuração de filtros que evidenciasse as toras na imagem.

Após aplicação dos filtros de imagem, foram selecionadas amostras para as duas classes definidas para classificação: madeira e vazio. Entende-se como madeira as feições transversais das toras, enquanto que vazio são as porções da imagem diferentes de madeira.

Para definição dos filtros utilizados no treinamento das Redes Neurais Artificiais, foram analisados os histogramas dos pixels de cada filtro para identificar padrões de distribuição para as classes madeira e vazio, utilizando os dados coletados na amostragem.

Os valores dos pixels nas bandas vermelho, verde e azul para os filtros selecionados foram utilizados para treinando de RNA's, tendo como variável saída o valor da classe (1 para classe madeira e 2 para classe vazio).

Para cada imagem foram treinadas 10 RNA's, sendo escolhida a melhor dentre elas para aplicação, com base em estatísticas de treinamento (*bias*, Raiz Quadrada Média do Resíduo (RQME) e Coeficiente de Correlação). O tipo de RNA foi Multilayer Perceptron (MLP), utilizando o algoritmo de treinamento Resilient Propagation. A arquitetura da rede consistiu de cinco neurônios na camada oculta, com a função sigmoïdal nas camadas oculta e de saída. O critério de parada foi com base no erro médio de 0,000001 ou 30 mil ciclos, o que atingiu primeiro.

Ao todo foram treinadas 420 redes e escolhidas 42 dentre elas, sendo uma para cada imagem. As redes foram aplicadas e cada imagem classificada foi comparada a imagem original visualmente, analisando a qualidade da classificação após aplicação das redes neurais.

Os fatores de empilhamento foram obtidos utilizando a proporção da imagem atribuída a cada classe na imagem.

Foram obtidos 42 fatores de empilhamento no total. Foi calculada a média entre eles resultando em um fator de empilhamento médio. Esse fator foi

comparado ao fator de empilhamento calculado pela cubagem das toras, tido como verdade de campo.

Foi ainda realizado estudo dos custos associados aos dois processos para obtenção dos fatores de empilhamento pela cubagem de todas as toras e pelo processamento digital de imagens. Foram considerados nos custos os recursos gastos com processamento das informações, mão de obra para medição das pilhas e dos caminhões e aquisição de imagens.

#### 4. RESULTADOS

Na Tabela 1 são apresentadas as principais características das toras cubadas e dos feixes durante o processo de estimação do volume cúbico das cargas.

Tabela 1 – Principais características das toras cubadas e dos feixes do estudo

Número total de toras	1.134
Diâmetro médio (cm)	17,24
Desvio padrão do diâmetro (cm)	1,6
Comprimento médio (cm)	251
Desvio padrão do comprimento (cm)	7,9
Volume (m <sup>3</sup> )	66,53
Estéreo (m <sup>3</sup> )	99,09
Fator de empilhamento	1,49

Na Figura 2 são apresentados exemplos dos resultados visuais de uma imagem após aplicação dos filtros disponíveis na versão do *NeuroDIC 2.0*.

Na Figura 3 (Apêndice) são apresentados os histogramas dos valores dos pixels em cada banda (vermelho, verde e azul) para cada filtro disponível no software (exceto monocromáticos). Os valores dos pixels foram agrupados em classes com amplitude de nove, tendo o valor expresso com base na frequência de ocorrência, em porcentagem.




Figura 2 - Exemplos de resultados alcançados após aplicação dos diferentes filtros de imagens disponibilizados no sistema. Imagem central é a imagem original.

Os filtros que apresentaram melhor separação entre as classificações “madeira” e “vazio” de acordo com os histogramas apresentados foram os filtros Contrast, Curve e Gain. O filtro que apresentou pior separação foi o Solarized.

Os filtros utilizados no treinamento das Redes Neurais Artificiais foram os filtros Contrast e Gain, devido ao comportamento dos histogramas e aspectos visuais das imagens transformadas.

Na Figura 4 são apresentadas duas imagens, uma da pilha original e a outra após aplicação da RNA, como exemplo da classificação realizada pelo software NeuroDIC.



Figura 4 – Foto original da pilha, à esquerda, e imagem após aplicação da RNA, à direita.

A partir das 42 imagens, calculou-se o fator de empilhamento médio e o volume, em  $m^3$ . Na Tabela 2 são apresentados os resultados comparativos entre os valores obtidos através da cubagem e do processamento digital das imagens (PDI) utilizando o *NeuroDIC 2.0*.

Tabela 2 – Resultados comparativos entre os valores obtidos através da cubagem e do processamento digital das imagens (PDI).

Estéreo ( $m^3$ )	Cubagem		PDI		Diferença (%)
	Volume ( $m^3$ )	Fator empilhamento	Volume ( $m^3$ )	Fator empilhamento	
99,09	66,53	1,49	67,81	1,46	1,90

Na Tabela 3 são apresentados os custos contabilizados nas atividades de cubagem e PDI. Os custos totais para estimação do fator de empilhamento

pelo processo de cubagem das toras foram de R\$ 1.480,00, enquanto que pelo PDI utilizando RNA foram gastos R\$ 175,00. Isso representa uma redução de aproximadamente 90% nos custos associados à atividade.

Tabela 3 - Custos contabilizados nos processos de cubagem e PDI

<b>Processo</b>	<b>Atividade</b>	<b>Quantidade</b>	<b>Custo Unitário</b>	<b>Custo Total</b>
Cubagem	Medição de toras	2 diárias*	R\$ 714,98	R\$ 1.430,0
	Medição das dimensões das pilhas	2 horas	R\$ 12,50	R\$ 25,00
	Processamento	1 hora	R\$ 25,00	R\$ 25,00
<b>Total</b>				<b>R\$ 1.480,0</b>
PDI	Aquisição das imagens	2 horas	R\$ 12,50	R\$ 25,00
	Medição das dimensões das pilhas	2 horas	R\$ 12,50	R\$ 25,00
	Processamento	5 horas	R\$ 25,00	R\$ 125,00
<b>Total</b>				<b>R\$ 175,00</b>

\*Equipes terceirizadas com 3 pessoas.



## 5. DISCUSSÃO

O *NeuroDIC* foi desenvolvido utilizando a linguagem de programação Java e ambiente de desenvolvimento o IDE (Integrated Development Environment) Netbeans 7.1 e a JDK 7.3 (Java Development Kit). O software é gratuito e pode ser utilizado em qualquer sistema operacional para classificação de imagens digitais utilizando Redes Neurais Artificiais.

A utilização dos filtros de imagens, Contrast e Gain, permitiram obter imagens mais nítidas e com uma melhor separação entre as classes madeira e vazio do que a imagem original, o que possibilitou um treinamento eficiente das redes neurais. A avaliação dos histogramas dos filtros é de suma importância para indicar quais devem ser utilizados no treinamento. Filtros antagônicos, como por exemplo, Contrast e Invert não devem ser utilizados concomitantemente no treinamento, por apresentarem valores de pixels opostos para a mesma classe na imagem.

Na Figura 5 é apresentado um exemplo da porção superior de uma pilha de madeira. A linha tracejada em vermelho indica a posição em que a altura da pilha foi medida no caminhão.




Figura 5 – Porção superior de uma pilha de madeira, indicando posição da altura medida no caminhão (linha vermelha tracejada)

Como pode ser observado, há uma grande parte da porção superior da pilha abaixo da linha tracejada não preenchida por madeira, portanto pertencente à classe vazio. É de suma importância que, ao fotografar pilhas de madeira para quantificar o fator de empilhamento, esses espaços vazios sejam contabilizados nas imagens, pois fazem parte do estéreo calculado no campo.

A etapa de seleção de amostras para treinamento das redes neurais artificiais é crucial no processo de classificação da imagem. É importante garantir uma boa amostragem dos pixels em cada classe, buscando abranger o maior número de cores e tonalidades possível. Essa prática evita que pixels sejam erroneamente classificados pela falta de amostragem.

O fator de empilhamento calculado no campo foi de 1,49 e volume cúbico de 66,53 m<sup>3</sup>, enquanto que o fator calculado pelo processamento digital das imagens utilizando RNA foi de 1,46 e volume cúbico de 67,81 m<sup>3</sup> (desvio de 1,9%). Esses resultados foram mais precisos que aqueles encontrados por Bertola, 2002 e Silva, 2003, que encontraram desvios médios de 2,7% e 2,5%, respectivamente.

Imagens digitais comumente apresentam distorções geométricas, ocasionadas pelo sistema de projeção cônica central das câmeras fotográficas.

Essas distorções são radioconcêntricas, de modo que, quanto mais distantes os objetos estejam do centro das fotografias, maiores serão as distorções. Ou seja, toras de madeira fotografadas longe do centro da foto serão observadas de lado, alterando a área seccional original. Na Figura 6 é possível verificar o efeito da distorção geométrica na imagem.




Figura 6 – Toras fotografadas de lado, evidenciando efeito da distorção geométrica.

A referida distorção geométrica nas fotos pode resultar em *bias* ao classificar a imagem. Uma alternativa encontrada para tentar diminuir esse efeito foi utilizar partes de imagens da pilha, onde as toras pudessem ser visualizadas perpendicularmente ao comprimento.

Ao utilizar a média das imagens tomadas em diferentes partes da pilha, deve-se garantir que o número de fotos e suas posições são representativas do fator de empilhamento da pilha inteira. Além disso, o processo de seleção e edição das imagens para posterior treinamento e aplicação das redes neurais será arbitrário, ficando a cargo do usuário selecionar as melhores imagens e determinar, como por exemplo, a quantidade de fotos e suas dimensões.

Desse modo, é possível calcular diferentes fatores de empilhamento para a mesma pilha de madeira, devido ao processo de escolha e edição das fotos amostradas. Para evitar esse fato, pode-se utilizar apenas uma imagem, onde a pilha fosse fotografada inteira com as feições transversais das toras visualizadas sem distorções. A principal técnica utilizada para esse fim é a ortorretificação, através da qual se realiza a conversão do sistema de projeção das fotografias, passando-se do sistema cônico para o ortogonal. (MENESES, 2007). Dessa forma seria determinado apenas um fator de empilhamento, representativo de toda a pilha de madeira.

O processo de ortorretificação exige que várias fotos sejam tiradas de forma padronizada, sempre a uma mesma distância da pilha em diferentes posições, para que parte de uma foto seja sobreposta em outra, criando um mosaico de imagens. Para isso, é necessário definir uma metodologia de obtenção de imagens, o que não foi possível realizar nesse estudo.

Estudos posteriores são necessários, principalmente para melhorar a metodologia de obtenção das fotos e possibilitar o cálculo de apenas um fator de empilhamento por pilha, reduzindo a interferência do profissional na escolha e manipulação das imagens. Essa é uma etapa importante para permitir o uso dessa tecnologia em larga escala, pois torna o processo padronizado e possível de ser auditado.

## **6. CONCLUSÕES**

A diferença média entre o volume cúbico calculado no campo e pelo processamento digital de imagens utilizando RNA foi de 1,9%, indicando que a metodologia adotada nesse estudo pode ser utilizada para quantificar volume cúbico de cargas de madeira empilhadas sobre caminhões.

Comparado ao processo convencional de cubagem de toda a carga para estimação do fator de empilhamento, houve redução de aproximadamente 90% dos custos da atividade ao adotar o processamento digital de imagens utilizando redes neurais artificiais.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

BERTOLA, A. **Uso de fotografias digitais para quantificar o volume sólido de madeira empilhada**. Dissertação de mestrado, Universidade Federal de Viçosa, Viçosa, 18 fevereiro 2002. 64.

BULLINARIA, J. A. **Introduction of Neural Computation**. Notas de aula, 2009. Disponível em: <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. Acesso em: 14 julho 2014.

HEATON, J. **Programming Neural Networks with Encog3 in Java**. 2<sup>a</sup>. ed. [S.I.]: Heaton Research Incorporated, 2011. 240 p.

INMETRO. Instituto Nacional de Metrologia, Normalização e Qualidade Industrial, Portaria nº 130, 07 dezembro 1999. 3.

INMETRO. Instituto Nacional de Metrologia, Normalização e Qualidade Industrial, Portaria nº 337, 29 agosto 2011. 1.

MENESES, L. F. **Ortorretificação de fotografias aéreas de pequeno formato obtidas com câmera digital convencional**. Trabalho Técnico, João Pessoa, 2007. 74.

REZENDE, A.V. **Análise dos métodos de estimação do volume sólido da madeira e do comportamento do fator de empilhamento para *Eucalyptus grandis***. Dissertação de mestrado, Universidade Federal de Viçosa, Viçosa, 1988. 131.

SILVA, M. C. **Determinação do volume de madeira empilhada através do processamento de imagens digitais**. Dissertação de Mestrado, Universidade Federal de Viçosa, Viçosa, 2003. 74.

# APÊNDICE



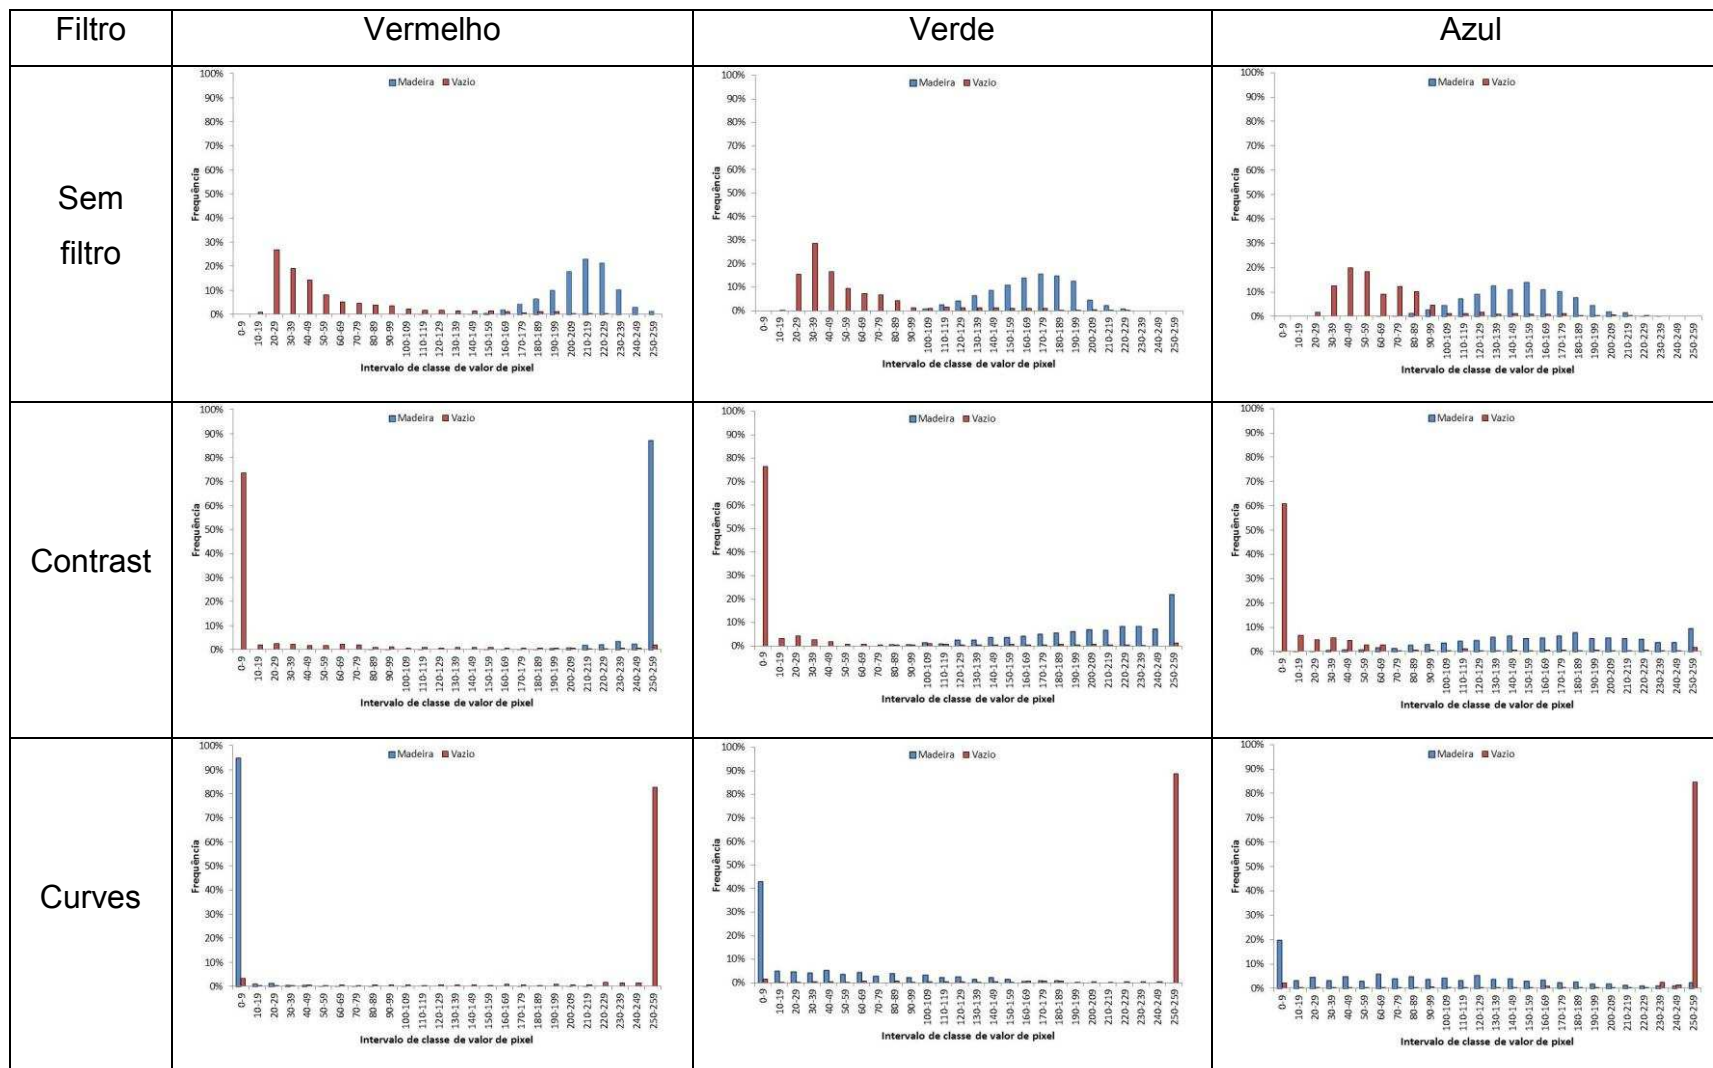


Figura 3 - Histogramas dos valores dos pixels em cada banda (vermelho, verde e azul) para cada filtro disponível no software (exceto monocromáticos).

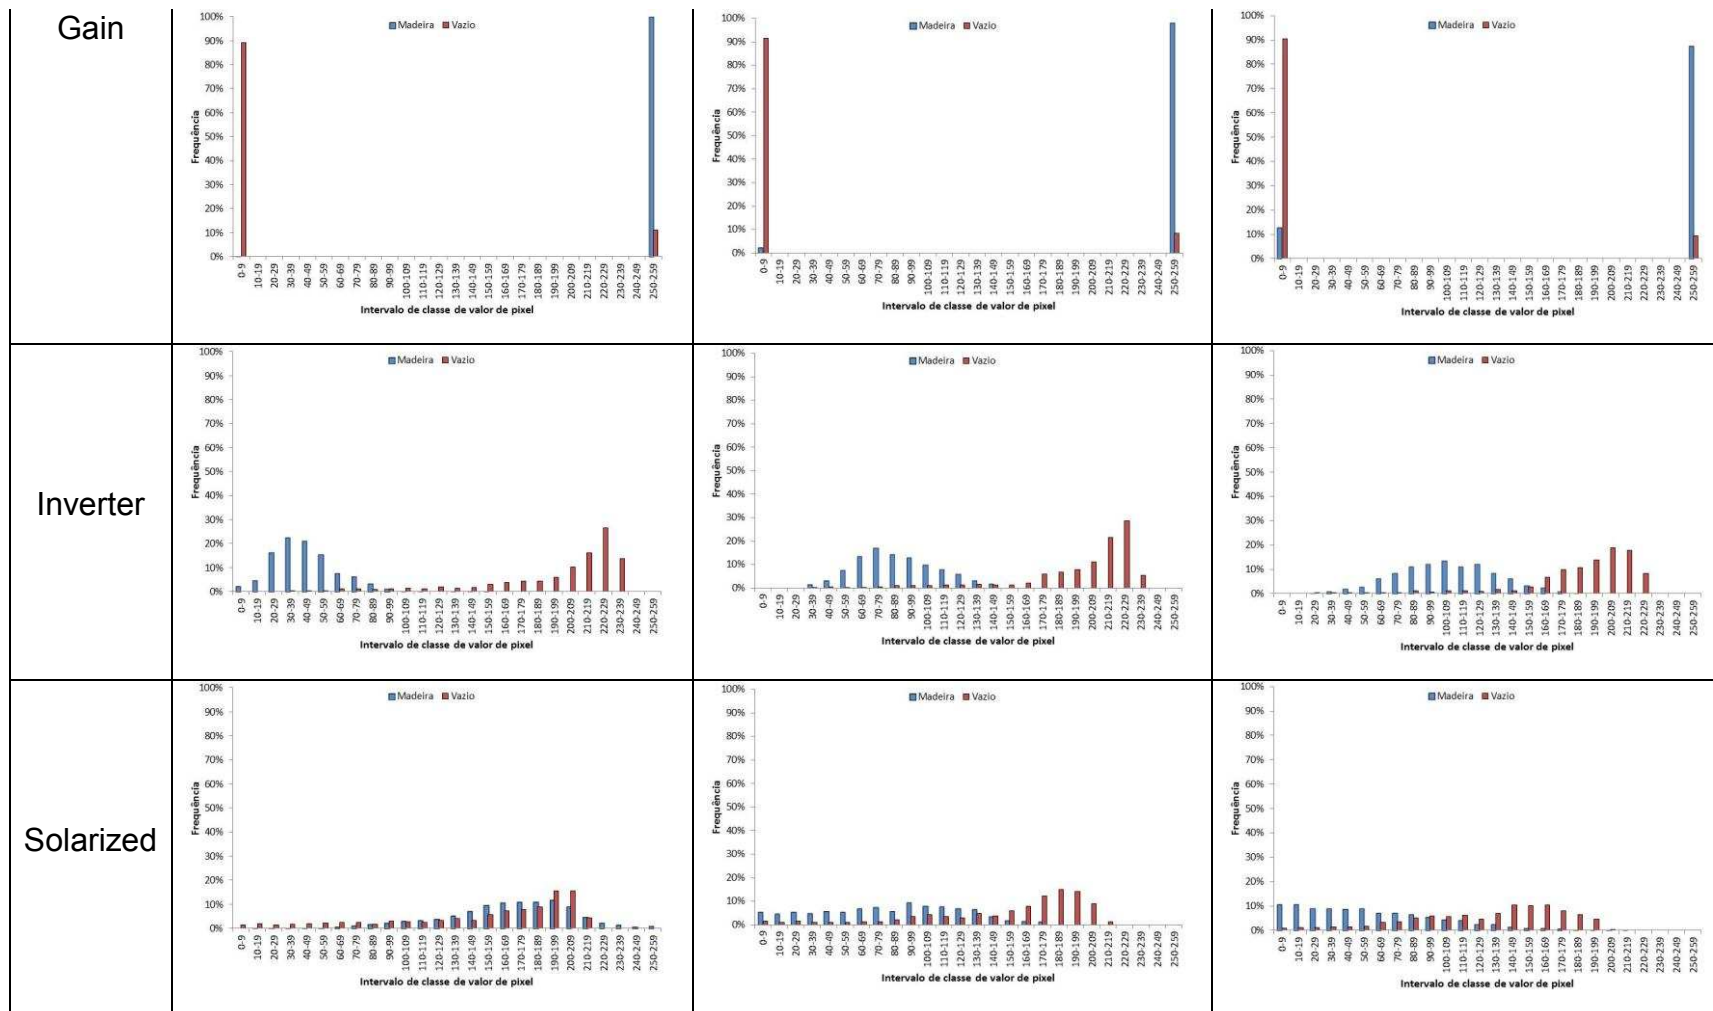


Figura 3 Cont. - Histogramas dos valores dos pixels em cada banda (vermelho, verde e azul) para cada filtro disponível no software (exceto monocromáticos).