

**UNIJUÍ - UNIVERSIDADE REGIONAL DO NOROESTE DO ESTADO DO RIO
GRANDE DO SUL**

FÁBIO RONEI RODRIGUES PADILHA

**RECONHECIMENTO DE VARIEDADES DE SOJA ATRAVÉS DO
PROCESSAMENTO DE IMAGENS DIGITAIS USANDO REDES NEURAIS
ARTIFICIAIS**

Ijuí

2007

FÁBIO RONEI RODRIGUES PADILHA

**RECONHECIMENTO DE VARIEDADES DE SOJA ATRAVÉS DO
PROCESSAMENTO DE IMAGENS DIGITAIS USANDO REDES NEURAIAS
ARTIFICIAIS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação do Departamento de Física Estatística e Matemática da Universidade Regional do Noroeste do Estado do Rio Grande do Sul para a obtenção do título de Mestre em Modelagem Matemática.

Orientador: Prof. Dr. Oleg Khatchatourian

Ijuí

2007

**UNIJUÍ - UNIVERSIDADE REGIONAL DO NOROESTE DO ESTADO DO RIO
GRANDE DO SUL**

DeFEM – DEPARTAMENTO DE FÍSICA, ESTATÍSTICA E MATEMÁTICA

DeTEC – DEPARTAMENTO DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA

A Comissão Examinadora, abaixo assinada, aprova a Dissertação

**RECONHECIMENTO DE VARIEDADES DE SOJA ATRAVÉS DO
PROCESSAMENTO DE IMAGENS DIGITAIS USANDO REDES NEURAIS
ARTIFICIAIS**

Elaborada por

FÁBIO RONEI RODRIGUES PADILHA

Como requisito para a obtenção do grau de Mestre em Modelagem Matemática

Comissão Examinadora

Prof. Dr. Oleg Khatchatourian - UNIJUÍ (Orientador)

Prof. Dr. Fernando Pedro Reis Brod - Kepler Weber

Prof. Dr. Luciano Pivoto Specht - UNIJUÍ

Ijuí, RS, 28 de Fevereiro de 2007.

Aos meus pais, Nelson (in memoriam) e Ordalina, pelo amor, carinho, dedicação e estímulo que sempre ofereceram, pelas angústias e preocupações passadas por minha causa, dedico-lhes essa conquista como gratidão.

AGRADECIMENTOS

A Deus, por ter-me concedido saúde, luz, força e perseverança necessárias para que eu superasse todas as adversidades e seguisse em frente rumo à conquista de mais uma importante etapa na minha vida.

Aos meus pais, Nelson (in memorian) e Ordalina, que independente das dificuldades, mostraram-me sempre o caminho certo a seguir, participando incansavelmente de minhas alegrias e tristezas, dando sugestões importantes na escolha das melhores oportunidades.

Aos meus irmãos Marta, Júlio e Juliano (in memorian), pela amizade, alegria e bons momentos compartilhados.

A Camila, que sempre esteve ao meu lado, mostrando-se amiga e companheira, que com muito amor e carinho deram-me suporte para enfrentar os problemas encontrados.

Ao meu orientador Prof. Dr. Oleg Khatchatourian pela orientação, pela dedicação, pelo constante incentivo, pela paciência e pela amizade, com os quais foi possível a concretização deste trabalho.

Aos meus amigos e colegas Delair e Gustavo, que compartilharam comigo cada dia a dia, dividindo sucessos, angústias, conquistas e fracassos, sempre com muita amizade.

Aos colegas do curso pelos bons momentos vividos durante estes dois anos de convivência.

A Geni, que com muita disposição, demonstrou-se sempre atenciosa as dúvidas e solicitações realizadas.

A todos os professores do mestrado e funcionários do Departamento de Física, Estatística e Matemática pelo conhecimento e dedicação.

A CAPES e a UNIJUÍ pelo apoio financeiro a esta pesquisa.

É muito melhor arriscar coisas grandiosas, alcançar triunfos e glórias, mesmo expondo-se a derrota, do que formar fila com os pobres de espírito que nem gozam muito, nem sofrem muito, porque vivem nessa penumbra cinzenta que não conhece vitória nem derrota.

Theodore Roosevelt

RESUMO

Neste trabalho foram aplicadas Redes Neurais Artificiais (RNA) auxiliadas pelo Processamento de Imagens Digitais (PID) com a finalidade de identificar algumas variedades de soja analisando para isto a forma e tamanho dos grãos. O objetivo é utilizar uma metodologia para diminuir gastos relacionados à área da agricultura, visando contribuir com estudos que se baseiam na taxonomia das variedades. Atualmente, isto é determinado por inspeção visual, uso de produtos químicos e testes de DNA, com alto custo. A forma e tamanho dos grãos são normalmente empregados para identificação das variedades. Por se tratarem de características hereditárias, geralmente são influenciadas por mudanças no ambiente, especialmente durante o aumento da umidade dos grãos. Por este motivo, foram selecionadas sementes que se encontravam em torno de 10% de umidade, permitindo assim, diminuir esta influência na variação da forma dos grãos durante as análises. Para um estudo de caso, foram coletadas no laboratório de sementes da Cooperativa Agropecuária e Industrial (COTRIJUÍ), com sede no município de Ijuí/RS, as seguintes variedades de soja: EMBRAPA 133 (BRS 133), EMBRAPA 184 (BRS 184), COODETEC 205 (CD 205), COODETEC 206 (CD 206), EMBRAPA 48 (EMB 48), SYNGENTA 8350 (NK 8350), FEPAGRO 10 (RS 10) e MONSOY 8000 RR (MSOY 8000 RR), safra 2005/2006. O processamento das imagens foi dividido em cinco etapas descritas a seguir. Aquisição da imagem: As imagens da amostra de cada variedade foram fotografadas por uma máquina fotográfica Coolpix995, Nikon, com resolução de 3.34 megapixels. Pré-processamento: Um filtro de *anti-aliasing* foi aplicado para obter tons acinzentados da imagem. Segmentação: Estando os grãos da imagem separados, foi usado o Método de Prewitt para detecção das bordas dos grãos, dilatação dessas bordas e remoção de segmentos não necessários para avaliação. Representação: As características da morfologia de cada grão foram extraídas do resultado da segmentação. Assim, cada grão foi numerado sequencialmente, facilitando sua representação. Concluindo esta fase, as matrizes correspondentes a cada grão foram transformadas em vetores colunas que serviram como dados de contribuição para rede neural da próxima etapa. Reconhecimento e Interpretação: Foram inseridos os dados providos pela fase prévia em uma RNA para identificar os padrões morfológicos dos grãos. A rede configurada foi composta de 16900 neurônios na camada de entrada, 90 neurônios na 1ª camada oculta, 70 neurônios na 2ª camada oculta, 60 neurônios na 3ª camada oculta e 8 neurônios na camada de saída, utilizando como função de transferência entre os neurônios a função sigmóide (logística). O treinamento da rede foi realizado através do algoritmo de aprendizagem *backpropagation - multilayer feedforward network* para alguns padrões referindo-se as características das variedades. A precisão de classificação ficou acima de um terço do total de grãos analisados por cada cultivar. Os resultados mostraram que o modelo de redes neurais foi capaz de identificar as variedades de soja mostrando-se uma ferramenta eficaz no processo de reconhecimento. As simulações realizadas permitiram escolher a arquitetura de RNA (número de camadas e de neurônios) garantindo um bom desempenho.

ABSTRACT

In this work were applied Artificial Neural Network (RNA) assisted by the Digital Images Processing (PID) with the purpose of identify some soya beans varieties analyzing for this the grains shape and size. The goal is to use a methodology to decrease expenses related to the agriculture area, aiming contribute with studies that are based in taxonomy of varieties. Currently, that is determined for visual inspection, DNA and tests using chemical products, with high cost. The grains shape and size are currently use for varieties identification. By they care for hereditary characteristics, are generally influenced by changes in the environment, especially during the grains humidity increase. Therefore, they were selected seeds that were found around of the 10% of humidity, allowing thus, decrease this variation influence in the grains shape during the analyses. For a study of case, they were collected in the laboratory of seeds of the Cooperative Agriculture and Industrial COTRIJUÍ, with venue in municipality of Ijuí/RS, the next varieties of soya beans: EMBRAPA 133 (BRS 133), EMBRAPA 184 (BRS 184), COODETEC 205 (CD 205), COODETEC 206 (CD 206), EMBRAPA 48 (EMB 48), SYNGENTA 8350 (NK 8350), FEPAGRO 10 (RS 10) and MONSOY 8000 RR (MSOY 8000 RR), harvest 2005/2006. The image processing was divided in five stages to follow. Acquisition of the images: The samples images of each variety were photographed by camera Coolpix995, Nikon, with resolution of 3.34 megapixels. Preprocessing: The *anti-aliasing* filter was applied to obtain ash-grey tones of the image. Segmentation: Being the separated image grains, it was used Method of Prewitt for grains edges detection, dilation of these edges and removal of segments not necessary for evaluation. Representation: The characteristics of morphology of each grain were extracted of the result of segmentation. Therefore, each grain was numbered for a subsequent numbering, facilitating your representation. Concluding this stage, the matrixes corresponding to each grain were transformed in vectors columns that served as input data in the neural network in the next stage. Recognition and interpretation: They were inserted the data provided by the previous stage in RNA to identify the grains morphologic patterns. The configured net was composed of 16900 neurons in the input layer, 90 neurons in the 1st hidden layer, 70 neurons in the 2nd hidden layer, 60 neurons in the 3rd hidden layer and 8 neurons in the output layer, using eat transfer function between neurons the function sigmoid (logistic). The training of a network was realized by algorithm *backpropagation – multilayer feedforward network* for some patterns referring varieties characteristics. The classification precision stayed above a third from the grains total analyzed by each variety. The results showed that the neural network model was able to identify the soya bean varieties showing an effective tool in the recognition process. The accomplished simulations allowed to choose RNA architecture (layers number and of neurons) guaranteeing a good performance.

SUMÁRIO

INTRODUÇÃO	16
1 REVISÃO BIBLIOGRÁFICA	18
1.1 INTRODUÇÃO	18
1.2 ANÁLISE DE SEMENTES	18
1.2.1 Importância das Sementes como Material de Pesquisa	18
1.2.2 Laboratório de Análise de Sementes	19
1.2.3 Dimensões Características	20
1.2.4 Definição de Variedade	23
1.2.5 Normas para Identificação de Cultivares	24
1.2.6 Tamanho das Sementes	25
1.2.7 Beneficiamento	28
1.3 SOJA	30
1.3.1 Análise de Sementes de Soja	30
1.3.2 Variedades de Soja	31
1.3.3 Tamanho da Semente de Soja e Qualidade Fisiológica	32
1.3.4 Identificação de Cultivares	33
1.3.5 Características de algumas Cultivares de Soja	33
1.4 IMAGENS DIGITAIS	40
1.4.1 Definição	40
1.4.2 Pixel e Conectividade	40
1.5 PROCESSAMENTO DE IMAGENS DIGITAIS	41
1.5.1 Aquisição da Imagem	43
1.5.2 Pré-Processamento	44
1.5.3 Segmentação	44
1.5.4 Representação e Descrição	45
1.5.5 Reconhecimento e Interpretação	45
1.6 REDES NEURAS ARTIFICIAIS	45
1.6.1 Definição	45
1.6.2 Redes Neurais Biológicas	46
1.6.3 Histórico das Redes Neurais Artificiais	47
1.6.4 Classificação das Redes Neurais	48
1.6.5 Rede Perceptron	51

1.6.6 Mapeamento do Cérebro e da Máquina.....	53
1.6.7 Arquitetura e Topologia das Redes Neurais	56
2 MATERIAIS E MÉTODOS	59
2.1 INTRODUÇÃO	59
2.2 ESCOLHA DOS CULTIVARES	59
2.3 ANÁLISE ESTATÍSTICA DAS DIMENSÕES	59
2.4 APLICAÇÃO DE REDES NEURAS NO PROCESSAMENTO DE IMAGENS	60
2.5 PROCESSAMENTO DAS IMAGENS.....	60
2.6 ARQUITETURA DA REDE NEURAL	66
2.7 TREINAMENTO DA REDE NEURAL.....	68
2.7.1 Algoritmo de treinamento.....	70
3 RESULTADOS E DISCUSSÕES	74
3.1 INTRODUÇÃO	74
3.2 RESULTADO DA ANÁLISE ESTATÍSTICA DAS DIMENSÕES.....	74
3.3 ETAPAS DO TREINAMENTO DA RNA	77
3.4 TESTES REALIZADOS.....	78
3.4.1 Reconhecimento dos Padrões	78
3.4.2 Análise de Reconhecimento	81
CONCLUSÃO.....	86
REFERÊNCIAS BIBLIOGRÁFICAS	88
APÊNDICE A - FLUXOGRAMA DO ALGORITMO DE TREINAMENTO.....	94

LISTA DE FIGURAS

Figura 1: Representação das três dimensões do elipsóide (Fonte: Weber, 2001)	22
Figura 2: (A) Vista lateral da semente de soja. (B) Vista frontal da semente de soja (Fonte: Embrapa Soja, 2000)	30
Figura 3: Cultivar BRS 133	34
Figura 4: Cultivar BRS 184	35
Figura 5: Cultivar CD 205	35
Figura 6: Cultivar CD 206	36
Figura 7: Cultivar EMB 48	37
Figura 8: Cultivar NK 8350	38
Figura 9: Cultivar RS 10	39
Figura 10: Cultivar MSOY 8000RR	39
Figura 11: Imagem Monocromática "Goldhill" para destaque de uma região de 17x17 pixels	40
Figura 12: Ilustração de tipos de conectividade de pixels vizinhos	41
Figura 13: Etapas de um sistema de PID	43
Figura 14: Neurônio Biológico (KOVACS, 1996)	47
Figura 15: Taxonomia das Redes Neurais	50
Figura 16: Neurônio Artificial projetado por McCulloch	52
Figura 17: Rede neural tipo MLP (Fonte: Tatibana, 2006)	52
Figura 18: Representação das direções de propagação do sinal funcional e do erro (Fonte: Ramos, 2001)	53
Figura 19: Gráficos das funções de transferência (Fonte: MATLAB Versão 7.0)	57
Figura 20: Imagem original dos grãos de soja	60
Figura 21: Imagem em tons de cinza	61
Figura 22: Bordas detectadas pelo Método de Prewitt	61
Figura 23: Dilatação dos contornos	62
Figura 24: Preenchimento dos grãos	62
Figura 25: Limpeza das bordas dos grãos e remoção dos contornos descontínuos	63
Figura 26: Remoção de objetos menores que 700 pixels	63
Figura 27: Imagem original com os grãos identificados	64
Figura 28: Representação do grão através da matriz	65
Figura 29: Imagem binária do grão de soja	67

Figura 30: Arquitetura da rede neural utilizada.....	68
Figura 31: Vetores objetivos	69
Figura 32: Dados de convergência durante o treinamento	77
Figura 33: Curva de convergência do erro SSE durante o treinamento	78
Figura 34: Esboço das imagens utilizadas para avaliação da RNA.....	82
Figura 35: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade BRS 133.....	82
Figura 36: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade BRS 184.....	83
Figura 37: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade CD 205.....	83
Figura 38: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade CD 206.....	83
Figura 39: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade EMB 48	84
Figura 40: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade NK 8350	84
Figura 41: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade RS 10	84
Figura 42: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade MSOY 8000RR	85

LISTA DE TABELAS

Tabela 1: Comparação entre cérebro e computador	55
Tabela 2: Comparação entre computadores e neurocomputadores	55
Tabela 3: Funções de Transferência	57
Tabela 4: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar BRS 133 (N=50).....	74
Tabela 5: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar BRS 184 (N=50).....	74
Tabela 6: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar CD 205 (N=50).....	75
Tabela 7: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar CD 206 (N=50).....	75
Tabela 8: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar EMB 48 (N=50).....	75
Tabela 9: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar NK 8350 (N=50).....	75
Tabela 10: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar RS 10 (N=50)	75
Tabela 11: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar MSOY 8000 RR (N=50)	76
Tabela 12: Comparação estatística das dimensões entre as cultivares (N=50)	76
Tabela 13: Dados de excentricidade e esfericidade das variedades de soja	76
Tabela 14: Resultado da análise da imagem BRS133.jpg	79
Tabela 15: Resultado da análise da imagem BRS184.jpg	79
Tabela 16: Resultado da análise da imagem CD205.jpg	79
Tabela 17: Resultado da análise da imagem CD206.jpg	80
Tabela 18: Resultado da análise da imagem EMB48.jpg	80
Tabela 19: Resultado da análise da imagem NK8350.jpg.....	80
Tabela 20: Resultado da análise da imagem RS10.jpg.....	81
Tabela 21: Resultado da análise da imagem MSOY8000RR.jpg.....	81
Tabela 22: Valores ótimos do reconhecimento para as variedades	85

LISTA DE SÍMBOLOS

a	Eixo maior do sólido	[mm]
b	Eixo médio do sólido	[mm]
b.u	Base úmida	[-]
BAM	Memória Associativa Bidirecional	[-]
BSB	Estado cerebral em uma caixa	[-]
B4	Conectividade entre quatro neurônios vizinhos	[-]
B8	Conectividade entre oito neurônios vizinhos	[-]
c	Eixo menor do sólido	[mm]
D_l	Diâmetro linear máximo da partícula	[mm]
D_p	Diâmetro da esfera de mesmo volume da partícula	[mm]
DNA	Ácido desoxirribonucléico	[-]
E	Erro entre a saída da rede neural com a saída desejada	[-]
E^t	Margem de erro aceita pela rede neural	[-]
EP	Elemento de processamento	[-]
$f(a)$	Função de ativação	[-]
$f(x, y)$	Função bidimensional da intensidade luminosa	[-]
G	Grau de esfericidade	[adimensional]
J^T	Matriz jacobiana	[-]
JPEG	Joint photographic experts group	[-]
K+	Potássio	[-]
MLP	Perceptron de múltiplas camadas	[-]
N	Número de grãos por amostra de variedade de soja	[-]
Na	Sódio	[-]
PID	Processamento de Imagens Digitais	[-]
R	Número de entradas da rede neural	[-]
RAS	Regras para análise de sementes	[-]
RNA	Rede Neural Artificial	[-]
S1	Número de neurônios na 1ª camada da rede neural	[-]
S2	Número de neurônios na 2ª camada da rede neural	[-]
S3	Número de neurônios na 3ª camada da rede neural	[-]

S_4	Número de neurônios na camada de saída da rede neural	[-]
t	Vetor de saída desejado pela rede neural	[-]
USB	Universal serial bus	[-]
V	Volume médio dos grãos de soja	[mm ³]
V_{ec}	Volume da esfera circunscrita	[mm ³]
V_S	Volume do sólido	[mm ³]
x	Abcissa espacial	[-]
X	Vetor de entradas de um neurônio	[-]
y	Ordenada espacial	[-]
Y	Vetor de saídas de um neurônio	[-]

SÍMBOLOS GREGOS

ϕ	Esfericidade	[adimensional]
η	Constante que define o tamanho do passo do aprendizado	[-]

INTRODUÇÃO

O aparecimento de novas tecnologias na área da computação provocou um aumento significativo nas pesquisas de novos algoritmos computacionais que tentam simular o comportamento humano em tarefas cotidianas. Esta tecnologia vem sendo frequentemente usada para auxiliar em vários procedimentos nas mais diversas áreas como, por exemplo, a utilização do computador na realização do processamento de imagens de órgãos, tecidos ou células, adquiridas em exames médicos, a fim de realizar a automação de diagnósticos patológicos, facilitando assim o trabalho dos profissionais, permitindo que os laboratórios mantenham a qualidade ao manipular elevado número de amostras diárias (FAILACE, 1995).

Hoje em dia são utilizadas técnicas tradicionais já conhecidas de processamento de imagens, que são implementadas através de cálculos matemáticos. Em destaque a estas pesquisas podem-se citar as Redes Neurais Artificiais.

Redes Neurais Artificiais são estruturas computacionais que simulam os cálculos sinápticos realizados pelo sistema nervoso biológico, tentando assim reproduzir a inteligência humana artificialmente. Desde sua criação, tem-se utilizado as RNA para identificação de padrões e assim, imaginou-se a possibilidade de utilizá-las para o reconhecimento de padrões em imagens.

A soja é um dos grãos leguminosos de maior importância produzidos no mundo e há algum tempo vem se tornando cada vez mais presente na alimentação da população. Além de possuir um valor acessível de mercado, facilitando sua obtenção em diversas camadas sociais, é responsável por transformações diárias na economia mundial.

Os maiores produtores mundiais deste cereal são os Estados Unidos, Brasil e Argentina nos quais a sua produção durante a safra 2005/2006 foram respectivamente, 80, 60 e 42 milhões de toneladas (ANUÁRIO BRASILEIRO DA SOJA, 2005).

Em termos mundiais, o plantio de soja atingiu 92,4 milhões de hectares na safra 2004/05. Para 2005/06, há indicativos de que o mundo todo cultivará 91,8 milhões de hectares, que poderão resultar em uma produção global de 220,9 milhões de toneladas (ANUÁRIO BRASILEIRO DA SOJA, 2005).

Em se tratando do principal produto agrícola de exportação brasileira, a soja também beneficia o setor secundário, pois ao redor das regiões de sua abrangência criam-se inúmeras indústrias de processamento, que produzem óleos e farelos de soja, assegurando emprego para vários trabalhadores nas mais diversas áreas.

Para o processo de classificação artificial de grãos de soja é necessário o desenvolvimento de modelos que permitam estabelecer o relacionamento entre a entrada de padrões de classificação, análise/processamento desta informação e convergência para uma saída de classificação definida. A rede neural deve aprender a reconhecer padrões de entrada, que contém valores de propriedades físicas e definir a classe adequada de saída da rede, ou seja, dada à entrada de um determinado vetor de padrão de qualidade, escolher em que categoria/classe de saída este produto será mais bem enquadrado. A rede neural deverá considerar a interatividade de todos os componentes vetoriais de entrada, sendo que cada componente individualmente representa uma propriedade física no processo de classificação.

Estes procedimentos podem ser aperfeiçoados pelo desenvolvimento de ferramentas computacionais que facilitem o processamento e análise de imagens realizadas manualmente e sujeitos, muitas vezes à falha humana. O presente estudo avalia a utilização da RNA no processamento dessas imagens, para que se possam identificar as variedades de soja, auxiliando assim os profissionais da agricultura no reconhecimento de padrões presentes em tais produtos.

Neste trabalho foram aplicadas Redes Neurais Artificiais para identificação de variedades de soja através da forma e tamanho dos grãos, tendo como objetivo a redução de gastos durante os procedimentos servindo de suporte para os profissionais responsáveis por este fim.

Esta dissertação está organizada da seguinte maneira: no capítulo 1 é feita uma revisão da teoria do processo de análise de sementes, em especial, sementes de soja; um estudo sobre o Processamento de Imagens Digitais, bem como do modelo de Redes Neurais Artificiais. No capítulo 2 encontra-se descritos os materiais usados e a metodologia empregada para o processamento das imagens adquiridas e a configuração da rede neural utilizada. E finalmente no capítulo 3 apresentam-se os resultados encontrados através de estudos estatísticos e pela rede neural configurada.

1 REVISÃO BIBLIOGRÁFICA

1.1 INTRODUÇÃO

Neste capítulo será apresentado um estudo geral sobre a análise de sementes tomando como objeto de estudo, sementes de soja. A seguir, enfoca-se o conceito de imagens digitais e as etapas de seu processamento. Prosseguindo, define-se Redes Neurais Artificiais, caracterizando sua estrutura, configuração e funcionamento. Por fim, a revisão de literatura é então direcionada para o modelo matemático existente para a padronização de objetos em imagens digitais, priorizando a identificação de variedades de soja.

1.2 ANÁLISE DE SEMENTES

1.2.1 Importância das Sementes como Material de Pesquisa

Como material de pesquisa, a semente apresenta algumas características que a tornam de incorporável valor.

Em primeiro lugar vem seu tamanho e forma. Normalmente a semente é pequena, o que possibilita guardar, em recipientes relativamente pequenos, um grande número delas, permitindo assim repetir uns cem números de vezes, determinada observação. Sua forma, de maneira geral tendendo a arredondada, facilita enormemente sua manipulação, diretamente com as mãos ou pinças. A semente é um órgão que usualmente se beneficia da desidratação e isto permite conservá-la em bom estado durante muito tempo. Os pesquisadores sabem a comodidade que isto acarreta, pois é freqüente não se poder realizar um estudo para quando programado, e a semente, desde bem conservada, permite que o trabalho seja realizado no momento adequado.

Não bastassem tais características, a semente é um órgão que, não obstante uma organização morfológica muito simples apresenta organização fisiológica e bioquímica altamente complexa, permitindo, praticamente, qualquer tipo de estudo da área da Biologia Vegetal.

1.2.2 Laboratório de Análise de Sementes

A importância de um laboratório de análise de sementes sempre foi inquestionável. No entanto, o marco evolutivo de seu destaque foi com a instituição da Lei de Proteção de Cultivares, que protegeu os direitos da propriedade intelectual na área de melhoramento genético de espécies vegetais.

Com o desenvolvimento de cultivares mais produtivas e responsivas nos campos, tornou-se imprescindível a profissionalização do setor sementeiro, visando qualidade, e também a modernização da indústria de sementes, devido à competição estabelecida entre as empresas que se adequaram à mudança de comportamento de mercado, onde o marketing e atendimento ao cliente ganharam importância fundamental.

As benesses advindas do programa de melhoramento transformaram a semente no veículo transportador de toda a tecnologia agregada e exigiu mecanismos mais intensos de aferição de sua qualidade, sendo assim necessário um suporte laboratorial integrado ao sistema de produção de sementes bem mais profícuo, provendo o apoio técnico para aprimoramento do produto e correções de falhas do processo de produção.

A semente tem sua qualidade avaliada por um conjunto de índices, o somatório dos atributos genético, físico, fisiológico e sanitário, que são determinados pela análise de uma amostra representativa de um lote. A análise de sementes representa os procedimentos técnicos utilizados para avaliar a qualidade e a identidade da amostra.

O laboratório de sementes, visto como o centro da verificação da qualidade é uma unidade constituída e credenciada especificamente para proceder à análise e emitir o respectivo boletim. De acordo com a legislação pertinente, baseia-se nas Regras para Análise de Sementes (RAS), que se fundamentam na uniformidade dos procedimentos e especificam padrões para os diferentes métodos de análises empregados, assim como os tamanhos máximos para os lotes de sementes e o peso mínimo da amostra média ou submetida e da amostra de trabalho para os diferentes tipos de testes.

A quantidade de sementes analisadas em um laboratório é muito pequena em relação ao tamanho do lote a qual representa. Se o lote não for homogêneo ou se houver erro na amostragem, as informações serão incorretas e comprometedoras, podendo beneficiar ou prejudicar os usuários das sementes analisadas. Dessa forma, é necessário proceder de acordo com métodos pré-estabelecidos e, rigorosamente seguidos, para a coleta de amostras.

1.2.2.1 Objetivo do Laboratório de Sementes

O objetivo principal do laboratório é gerar informações detalhadas sobre o potencial de desempenho das sementes, através de testes especializados e padronizados, que são importantes na identificação de problemas e suas possíveis causas, para minimizar riscos em qualquer das fases de produção, ou seja, da pré-colheita até o momento de semeadura.

O cotidiano da prestação de serviço em um laboratório de sementes contempla uma rotina estabelecida através de recebimentos de amostras médias, protocolo, homogeneização, preparação da amostra de trabalho, realização das análises solicitadas pelo produtor, arquivo de contra-amostra, emissão de laudos, boletins e entrega de resultados.

Os principais testes efetuados são: análise de pureza, verificação de cultivares, exame de sementes nocivas, germinação, teor de umidade, peso das sementes, dano de máquina, tetrazólio e envelhecimento acelerado.

1.2.3 Dimensões Características

Dentre as técnicas para medida do diâmetro médio de uma semente está a picnometria, onde é determinado o seu volume. A partir do volume de uma forma geométrica que seja semelhante ao volume do material de estudo, é possível determinar o diâmetro médio deste.

Segundo Arnost Jr. (1997), outra técnica que pode ser utilizada é a análise de imagens que fornece o diâmetro médio de Feret e o raio médio de Martin. Podem também ser determinadas através desta técnica outras dimensões da partícula como comprimento e largura, que são importantes para o caso de materiais cuja forma difere bastante de uma esfera.

Vários pesquisadores descrevem o tamanho de grãos e sementes através de medidas das dimensões dos três eixos através de micrômetros ou paquímetros.

Dutra et al. (1988) empregaram as médias aritmética e geométrica dos três eixos principais e o diâmetro efetivo no cálculo do volume de sementes de grama, obtendo resultados que predizem aproximadamente os valores determinados.

Verificou-se que as dimensões de sementes de soja aumentam com o teor de umidade até 25% b.u., mas através de uma forma de dependência linear (DESPHPANDE et al., 1993).

1.2.3.1 Esfericidade

As técnicas de picnometria e de análise de imagens também são utilizadas para determinação da esfericidade da partícula, que é um parâmetro para caracterizar a forma do material.

Sartori (1986), utilizando picnometria, determinou a esfericidade dos materiais soja, milho, arroz, vidro e areia através da seguinte equação:

$$\phi = \frac{D_p}{D_l} \quad (1.1)$$

onde: D_p é o diâmetro da esfera de mesmo volume que a partícula (mm) e D_l é o diâmetro linear máximo da partícula (mm).

Arnosti Filho (1997) determinou a esfericidade de sementes de *Brachiaria Brizantha* através da técnica de análise de imagens utilizando o analisador GALAI que segue a equação:

$$\phi = \frac{\text{Área Projetada}}{\text{Perímetro}^2} \cdot 4\pi \quad (1.2)$$

Curry apud Mohsenin (1970), determinou o cálculo da esfericidade através do método descrito pelas equações (1.3) e (1.4):

$$\phi = \frac{V_s}{V_{ec}} \quad (1.3)$$

$$\phi = \frac{\sqrt[3]{a \cdot b \cdot c}}{a} \quad (1.4)$$

onde: ϕ é a esfericidade (adimensional), V_s é o volume do sólido (mm^3), V_{ec} é o volume da esfera circunscrita (mm^3) e a, b, c são os eixos ortogonais do sólido (mm).

1.2.3.2 Grau de Esfericidade

O grau de esfericidade pode ser determinado conforme a metodologia de Cavalcanti Mata et al. (1986) por meio da seguinte fórmula:

$$G = \frac{b \cdot c}{a} \quad (1.5)$$

onde: a, b, c são os eixos ortogonais do sólido (mm).

1.2.3.3 Área Superficial e Volume do Grão de Soja

Carnaham et al. (1969) consideraram o grão de soja como um elipsóide perfeito a fim de calcular a sua área superficial. As três dimensões do elipsóide foram representadas pelos semi-eixos a, b e c , conforme a Figura 1 e a equação que determina a área superficial é dada pela equação (1.6). Sua resolução numérica foi feita aplicando-se a quadratura de Gauss-Chebyshev na solução da integral interna e quadratura de Gauss-Legendre para a solução da integral externa.

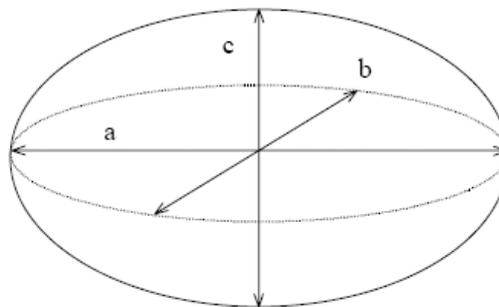


Figura 1: Representação das três dimensões do elipsóide (Fonte: Weber, 2001)

$$S = 2 \cdot a \cdot b \int_{-1}^1 \int_{-1}^1 \frac{\sqrt{1 - A_b \cdot X^2 - A_c \cdot u^2 \cdot (1 - X^2)}}{\sqrt{1 - u^2}} du dX \quad (1.6)$$

onde:

$$u = \frac{Y}{1 - X^2}, \quad Y = \frac{y}{b}, \quad X = \frac{x}{a}, \quad A_b = 1 - \frac{c^2}{a^2} \quad \text{e} \quad A_c = 1 - \frac{c^2}{b^2}. \quad (1.7)$$

Ainda levando-se em conta o grão de soja como um elipsóide perfeito, pode-se determinar o seu volume aproximado, através da equação dada por:

$$V = \frac{4}{3} \cdot \pi \cdot a \cdot b \cdot c \quad (1.8)$$

1.2.4 Definição de Variedade

De acordo com Ronzelli (1996), variedade é a população de plantas que, pela aparência e pelo comportamento, pode ser distinguida de outras populações na mesma espécie, de acordo com os interesses do homem. É o resultado de gerações avançadas por polinização aberta ou livre de todas as combinações possíveis entre genótipos selecionados, com base na capacidade combinatória que apresentam e podem ser uma linha pura, uma população mendeliana ou um clone. É o mesmo que variedade agrônômica ou cultivada.

Segundo Ronzelli (1996) variedade é a subdivisão de uma espécie cultivada que se distingue de outra ou de outras pela aparência e/ou pelo comportamento, ou seja, por característica ou características perfeitamente identificáveis ou identificáveis de ordem morfológica, fisiológica, bioquímica ou outra.

Borém (1997) define variedade como um grupo de plantas com características distintas uniformes e estáveis. Uma variedade deve apresentar sua própria identidade e a que a distingue das demais. Os descritores varietais que conferem identidade às variedades podem ser: ciclo, cor das sementes, caracteres morfológicos, reação a doenças, produção de grãos, padrões izoenzimáticos ou de ácidos nucleicos. A estabilidade da variedade é importante para a sua identificação de geração após geração.

O termo cultivar, que tem sido usado como sinônimo de variedade foi utilizado a partir da contração das palavras inglesas “*cultivated variety*” (variedade cultivada) (SARTORI, 2001).

Tendo em vista a igualdade de definições utilizadas por diversos autores, será utilizado durante o desenvolvimento deste trabalho o termo “variedade” para relacionar o termo “cultivar” e vice-versa.

1.2.5 Normas para Identificação de Cultivares

Existem algumas regras para análise de sementes dentre as quais se destacam:

- a) Verificar qual a porcentagem de sementes da amostra média que está de acordo com a cultivar nela indicadas;
- b) Verificar o número de outras cultivares presentes em uma amostra retirada da porção “semente pura” para a análise da pureza.

A determinação é válida somente para cultivares indicadas pelo remetente e se houver a disponibilidade de uma amostra padrão para comparar com a amostra em exame. Essa análise deverá ser realizada sempre que os padrões de qualidade da cultivar incluir tolerâncias máximas de “outras cultivares”.

Nos testes para verificação de cultivares, muitos detalhes são deixados a critério do especialista que faz o exame. Nesse caso, este deve ter atenção para o conjunto de conhecimentos e experiências encontrados na bibliografia nacional ou internacional.

A determinação é realizada, dependendo do problema em questão, sobre sementes, plântulas ou plantas desenvolvidas em laboratório, casa de vegetação, câmara de crescimento ou campo. As características a serem comparadas podem ser de natureza morfológica, fisiológica, citológica, química e bioquímica.

Normalmente as sementes da amostra em análise são comparadas com as sementes de uma amostra padrão. No caso de cultivares que são suficientemente uniformes para uma ou mais características (espécies autógamas) é feita uma contagem do número de sementes, plântulas ou plantas que não são autênticas. Se a cultivar não é suficientemente uniforme (espécies alógamas) é feita uma contagem das plantas atípicas e um julgamento geral é expresso quanto à autenticidade da amostra sob exame.

A verificação de cultivares só é confiável no caso de se dispor de instalações, equipamentos e outras facilidades, para o estudo do caráter particular a ser pesquisado. Em geral é necessário ter, no laboratório: equipamentos e reagentes para exames morfológicos, citológicos, testes químicos e de germinação de sementes; em casa de vegetação e câmara de crescimento: condições ambientais controladas e adequadas para induzir o desenvolvimento das características a serem avaliadas; em campo: condições climáticas, edáficas e culturais

para permitir o normal desenvolvimento das características a serem avaliadas, com suficiente proteção contra pragas e doenças.

Em todos os casos o exame deverá ser feito por pessoal treinado, com conhecimento das características morfológicas, fisiológicas ou outras, das cultivares em estudo.

Para as características morfológicas, as sementes devem ser examinadas com auxílio de lupas e microscópios adequados, quando necessário. Para as características de cor, as sementes devem ser analisadas sob luz natural ou de espectro limitado, como a luz ultravioleta. Para as características químicas, as sementes devem ser tratadas com reagentes adequados e anotadas a reação de cada semente.

Em alguns gêneros como *Glycine*, as verificações de diferença de cor, brilho, tamanho, forma da semente, coloração e formato do hilo, podem ser feitas por exame visual direto sob luz natural ou ultravioleta, ou sob aumento. Em *Glycine max* o tegumento das sementes apresenta uma reação da enzima peroxidase, que permite a separação das cultivares em dois grupos: um com alta atividade, designada como reação positiva e outro com baixa atividade, caracterizada como negativa.

Para auxiliar a identificação das cultivares de soja (*Glycine max*) pode-se usar o teste de hipocótilo, que é baseado no pigmento antocianina no hipocótilo das plântulas, que pode variar da cor púrpura à verde. As sementes são colocadas para germinar em substrato de areia ou solo. A avaliação deve ser feita de 5 a 10 dias após a semeadura, observando-se a coloração do hipocótilo da plântula.

Na determinação de sementes, o resultado será expresso em porcentagem ou em número de sementes de outras cultivares presentes no material em exame.

1.2.6 Tamanho das Sementes

Os efeitos que o tamanho das sementes exerce sobre o comportamento da própria semente e da planta resultante vêm sendo estudados há bastante tempo. De acordo com Gelmond (1972) o primeiro trabalho de pesquisa a respeito foi realizado por Boss, em 1893. Trata-se, pois, de assunto muito estudado, mas não inteiramente entendido.

1.2.6.1 Efeitos sobre a Germinação e o vigor das Plântulas

O tamanho da semente não deveria ter influência sobre a germinação, pois este é um fenômeno que depende de outros fatores (como a viabilidade da semente, condições ambientais, etc.), mas não do tamanho. Todavia, em uma população não beneficiada de sementes, pode-se observar certa relação mensurável entre sua capacidade de germinar e seu tamanho sendo constituída das menores sementes (Delouche, 1980). Essa relação tem-se mostrado mais evidente em variedades de sementes pequenas, como o eucalipto (Aguilar et al., 1987; Silva et al., 1994), azevém-perene (Naylor, 1980), nabo e repolho (Hanumaiah et al., 1973), não obstante ter sido também observada em milho (Scotii et al., 1977), em soja (Wetzel, 1975; Armstrong et al., 1988). Nessas variedades, de acordo com os resultados obtidos por esses pesquisadores, as menores sementes de lotes não beneficiados apresentaram germinação significativamente menor do que as de tamanhos maiores. Frequentemente, as sementes que constituem essa fração são tão pequenas e ocorrem em proporção tão baixa no lote que, durante o beneficiamento, são usualmente descartadas.

Se o tamanho nem sempre afeta a germinação em si, não se pode dizer o mesmo em relação à maneira pela qual esta se processa; em outras palavras, o tamanho afeta o vigor da plântula resultante. Usualmente, sementes de maior tamanho originam plântulas mais vigorosas que, em condições variáveis de campo, podendo resultar em “stands” diferentes em favor das maiores.

O tamanho da semente parece que influi principalmente sobre o peso da plântula resultante (Carleton et al., 1972), sendo razoável que assim seja, uma vez que as sementes grandes são aquelas que dispõem de maior quantidade de substâncias de reserva para o desenvolvimento do eixo embrionário.

Se o efeito que o tamanho da semente exerce sobre o peso da plântula dela resultante está relativamente esclarecido pela pesquisa, não se pode dizer o mesmo com relação ao efeito exercido sobre a velocidade de germinação. Resultados não significativos (Egli et al., 1990, com soja, Toon et al., 1991, com *Pinus caribaea*), em que as grandes germinaram significativamente mais rápido do que as pequenas (Beveridge et al., 1959, com alfafa) e resultados em que as pequenas germinaram significativamente mais rápido do que as grandes (Burris et al., 1973, com soja) têm sido relatados.

1.2.6.2 Efeitos sobre a Fase de Crescimento Inicial

O tamanho da semente tem efeito pronunciado sobre o crescimento inicial das plantas, diminuindo essa intensidade à medida que as plantas se desenvolvem. Uma planta proveniente de uma semente pequena tem, no início, seu desenvolvimento mais lento do que o de uma proveniente de semente grande. Com o passar do tempo, ela se recupera e acaba atingindo o tamanho característico da variedade. Trabalhos de diversos autores têm dado suporte para esta hipótese (Trupp et al., 1971, com *Bromus inermis*; Burris et al., 1973, com soja; Egli et al., 1990, com soja; Gray et al., 1991, com cenoura).

1.2.6.3 Efeitos sobre a Produção

Os resultados obtidos têm sido divergentes. Encontra-se um número praticamente igual de trabalhos que afirmam ser o tamanho da semente um fator que influi significativamente sobre a produção, como os que dizem o contrário. Para as mesmas cultivares, autores diferentes têm encontrado resultantes diferentes. Burris et al. (1973) e Johnson et al. (1974) trabalhando, em ambos os experimentos, com a cultivar Amsoy obtiveram resultados opostos: no primeiro, houve uma influência significativa do tamanho da semente e no segundo, nenhuma. No próprio trabalho de Burris et al. (1973) fica evidenciado esse conflito de resultados, pois a cultivar Amsoy respondeu significativamente ao tamanho da semente num ano (1970), mas não no subsequente.

É provável que o efeito do tamanho da semente se faça sentir de maneira diversa de acordo com o produto a ser utilizado (raízes, caules, folhas, madeira, fibra, flores, frutos e grãos), bem como conforme a época em que esse produto vai ser colhido. Parece que o tamanho da semente tem influência significativa sobre o crescimento inicial das plantas, e que é semelhante a um “efeito residual”, ou seja, reduz-se à medida que passa o tempo. Se o produto for colhido relativamente cedo, a semente de maior tamanho pode dar origem a maior produção. Assim, em plantas que se consomem as folhas ou de que se consomem os frutos ainda imaturos (milho verde, quiabo e vagem para salada, pepino para pickles, etc.) podem-se esperar, com mais probabilidade efeito desse tipo.

Austin et al. (1967), por exemplo, verificaram, em cenoura, que as plantas obtidas a partir de sementes grandes produziram significativamente mais do que as de sementes

pequenas, até 15 semanas após a semeadura. Avaliações feitas 24 semanas após a semeadura, já mostraram diferença alguma entre as várias classes de tamanhos de sementes.

A explicação mais comumente apresentada para a possível influência do tamanho da semente sobre o vigor das plântulas e posterior comportamento da planta tem sido a de que as sementes grandes possuem maior tecido de reserva, podendo, portanto originar plântulas “mais nutridas”. Todavia, esta explicação foi demonstrada por Lopez et al. (1973) e Ries et al. (1973) não ser necessariamente verdadeira. Esses autores verificaram em trigo que a semente grande tem um comportamento superior ao de uma semente pequena apenas quando reflete um maior teor de proteínas. Se, por qualquer motivo, a semente de menor tamanho tiver conteúdo protéico maior do que o da semente grande, seu comportamento será melhor.

É importante salientar também que, em algumas circunstâncias, as sementes de maior tamanho podem apresentar pior desempenho porque as condições ambientais de produção não foram favoráveis para sua qualidade (NAKAGAWA, 1973, 1981) ou por terem sofrido mais danos mecânicos que as demais classes.

1.2.7 Beneficiamento

O beneficiamento envolve todas as operações de preparo das sementes pós-colheita, tais como: pré-limpeza, limpeza, classificação e melhoramento da qualidade física das sementes. Com isto, visa melhorar ou aprimorar as características de um lote de sementes, com a eliminação das impurezas, das sementes de outras cultivares, das sementes da cultivar que apresentem características indesejáveis e da posterior separação em frações mais uniformes.

O beneficiamento das sementes é feito baseando-se em diferenças de características físicas existentes entre a semente e as impurezas. A separação só é possível entre materiais que apresentem uma ou mais características diferenciais que possam ser detectadas pelos equipamentos.

O beneficiador de sementes tem condições de escolher entre um grande número de máquinas que possam separar materiais diferentes entre si pelo tamanho (comprimento, largura e espessura), forma, peso, textura e cor.

1.2.7.1 Tamanho

Num lote de sementes recém colhido, uma das características em que se encontra maior grau de variabilidade é no tamanho das partículas que o constituem, de sorte que esta característica, tamanho das sementes e das partículas contaminantes, é uma das mais empregadas em processos de beneficiamento. Pode-se dizer que a separação das partículas com base em diferenças de tamanho se constitui no ponto de partida do beneficiamento de lotes de sementes. O tamanho de uma partícula qualquer é definido pelas dimensões de seu comprimento, largura e espessura. Essa última dimensão, contudo, em muitas variedades, não é muito bem definida e, por isso, de difícil mensuração.

A separação das sementes entre si, ou das impurezas, baseada na largura ou na espessura é realizada por meio de peneiras planas ou cilíndricas. Estas peneiras podem ser construídas de chapas metálicas com perfuração, ou de malhas de arame entrelaçado.

Já sementes que apresentem igual largura e espessura, mas difiram quanto ao comprimento, podem ser separadas pelos discos alveolados, ou pelos cilindros alveolados.

1.2.7.2 Forma

A forma é uma das características que mais varia entre as sementes das diferentes cultivares. A separação feita pelas peneiras é relacionada com a forma, normalmente quando se usam as peneiras de perfurações triangulares. De modo semelhante, o separador de cilindros alveolados e o de discos alveolados realizam a separação baseados nesta característica. Entretanto, existe um separador em espiral que separa as sementes de forma arredondada das de forma achatada.

1.2.7.3 Cor

As sementes com características físicas idênticas que diferem somente pela coloração podem ser separadas por meio de catadeiras ou selecionadoras eletrônicas. O órgão básico deste aparelho é uma célula foto-elétrica, calibrada para separar sementes de cores diferentes. Estas máquinas apresentam um dispositivo especial que expõe semente por semente ao sensor eletrônico que a compara com um padrão eletrônico ou padrão de cor. Se a intensidade da cor da semente ou a reflexão da luz obtida for comparável, a semente continua seu trajeto até a

descarga final. Se estiver fora da escala padrão, é desviada do fluxo principal por meio de um sistema de ar comprimido ou outro dispositivo.

1.3 SOJA

A soja é um dos grãos mais produzidos no mundo e há algum tempo vem se tornando mais presente na alimentação da população mundial. A classificação botânica da soja segue as seguintes denominações: Espécie: *Glycine max (L.) Merril*; Gênero: *Glycine*; Família: *Leguminosae*; Ordem: *Rosales*; Subclasse: *Archichlamidease*; Classe: *Dicotyledoneal*; Divisão: *Angiospermal*.

1.3.1 Análise de Sementes de Soja

A semente de soja apresenta formato que varia de elíptica, oblonga, oval a obovada, sendo, portanto, eurispérmica. A Figura 2 mostra a representação esquemática de uma semente de soja com suas partes constituintes.

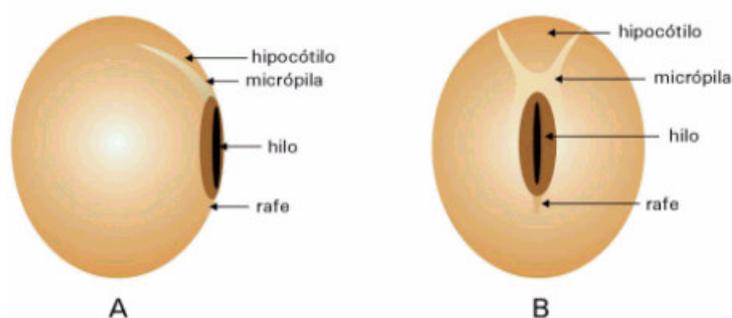


Figura 2: (A) Vista lateral da semente de soja. (B) Vista frontal da semente de soja (Fonte: Embrapa Soja, 2000)

A análise morfológica de grãos de soja representa os procedimentos técnicos utilizados para avaliar a identidade da amostra.

A qualidade de sementes tem sido atribuída à sua pureza física, ao elevado potencial genético, à alta germinação e vigor, à ausência de danos mecânicos, à boa sanidade e à uniformidade de tamanho. Este último é um atributo importante no aspecto visual para a comercialização e essencial para regulagem de semeadoras. Nesse sentido, Smith e Camper (1975) recomendam a classificação de sementes de soja, visando atingir uma melhor uniformidade de distribuição de sementes na semeadura e estandes mais uniformes.

A padronização das sementes de soja pelo tamanho tem sido uma prática que tem se tornado rotineira no Brasil e uma exigência do mercado (Lima, 1996). O efeito do tamanho de sementes de soja na sua qualidade fisiológica tem sido relatado em alguns trabalhos (Bunch, 1962; Hartwig et al., 1970; Souza, 1988; Lima, 1996; Beckert et al., 2000).

Segundo Carvalho et al. (2000), o tamanho das sementes não tem influência sobre a germinação, mas afeta o vigor da plântula resultante, sendo que as sementes de maior tamanho originam plântulas mais vigorosas e, em condições variáveis de campo, podem resultar em culturas mais desenvolvidas.

A quantidade de sementes analisadas em um laboratório é muito pequena em relação ao tamanho do lote a qual representa. Se o lote não for homogêneo ou se houver erro na amostragem, as informações serão incorretas e comprometedoras, podendo beneficiar ou prejudicar os usuários das sementes analisadas. Dessa forma, é necessário proceder de acordo com métodos pré-estabelecidos e, rigorosamente seguidos, para a coleta das amostras.

Os estudos morfológicos podem auxiliar na identificação botânica do cultivar, na interpretação dos testes de laboratório e no reconhecimento da cultivar em bancos de sementes.

1.3.2 Variedades de Soja

Segundo Gomes (1975), as variedades de soja distinguem-se entre si pelo ciclo vegetativo, porte e pelo tamanho das plantas, comprimento e forma das folhas, cor das folhas, cor e forma das sementes bem como constituição química das sementes.

Há outras classificações, em que podem ser consideradas a altura e porte das plantas, a forma das vagens, a forma, o tamanho e a cor das sementes, os hilos e os cotilédones.

Estas análises contribuem para o estudo dos mecanismos de dispersão, sucessão e regeneração natural das cultivares.

1.3.2.1 Normas para Classificação Oficial da Soja

De acordo com as Regras para Análise de Sementes (1992), a soja em relação ao tamanho é classificada em quatro grupos:

- a) Graúda: Grãos com diâmetro acima de 7,505 mm;

- b) Média: Grãos com diâmetro de 6,320 a 7,505 *mm*;
- c) Miúda: Grãos com diâmetro de 5,330 a 6,320 *mm*;
- d) Misturada: É a soja que não se enquadra em qualquer dos grupos anteriores.

Para o enquadramento em qualquer dos três primeiros grupos citados acima, a soja deverá apresentar, no mínimo 75% (em peso) de grãos com as dimensões correspondentes.

É classificada em quatro classes, segundo a cor: amarela, verde, marrom e preta. Para o enquadramento em uma dessas classes o percentual máximo permitido de grãos de outra classe é de 10%. Toda a soja que não estiver enquadrada nas classes citadas é classificada como mista. A soja com a casca verde ou pérola, mas cujo interior é amarelado ou esbranquiçado, em corte transversal, é considerada amarela.

1.3.3 Tamanho da Semente de Soja e Qualidade Fisiológica

Dentre as espécies produtoras de grãos, cultivadas no Brasil, a soja (*Glycine max (L.) Merrill*) é considerada uma das culturas de maior potencial econômico para a comercialização interna e externa. Esse fato se deve não só ao valor econômico dos grãos de soja para consumo, as grandes possibilidades de utilização do produto devido aos seus altos teores de óleo e proteína e a boa valorização comercial de seus resíduos (Couto et al., 1998). O Brasil figura como o país que apresenta as melhores condições para expandir a produção e prover o esperado aumento da demanda mundial, já tendo alcançado a produtividade de grãos de soja obtida pelos Estados Unidos da América (Embrapa Soja, 2004).

Segundo Marcos (1998), a qualidade fisiológica de sementes pode afetar indiretamente a produção da lavoura, ao influenciar a velocidade e a percentagem de emergência das plântulas e o estande final, ou diretamente, influenciando o vigor da planta. A qualidade de sementes tem sido atribuída à sua pureza física, ao elevado potencial genético, à alta germinação e vigor, à ausência de danos mecânicos, à boa sanidade e à uniformidade de tamanho. Este último é um atributo importante no aspecto visual para a comercialização e essencial para regulação de semeadoras. Nesse sentido, Smith et al. (1975) recomendam a classificação de sementes de soja, visando atingir uma melhor uniformidade de distribuição de sementes na semeadura e culturas mais uniformes.

Com base nos resultados apresentados, conclui-se que:

- a) O tamanho das sementes influencia a sua qualidade fisiológica durante o armazenamento;
- b) As sementes de tamanho médio apresentam maior potencial de armazenamento;
- c) As sementes de maior tamanho, por sua vez, apresentam menor germinação e vigor ao final do armazenamento.

1.3.4 Identificação de Cultivares

Com o advento da nova lei de proteção de cultivares, a identificação inequívoca de tornou-se extremamente importante. A identificação de cultivares dentro de uma espécie é feita normalmente com base em caracteres morfológicos. Esses caracteres, extensivamente usados pelos melhoristas, resultam da interação entre o genótipo e o ambiente. Por causa dos efeitos dessa interação, torna-se difícil a comprovação da distinguibilidade de cultivares obtida de ambientes distintos. Buscando solucionar esta limitação os melhoristas utilizam cultivares denominadas “testemunhas”. No entanto, este procedimento nem sempre é suficiente para a caracterização genotípica de uma cultivar ou linhagem, requerimento necessário para a sua distinguibilidade.

Os marcadores moleculares surgem então como uma solução para essa caracterização inequívoca, visto que as análises são feitas com base no DNA de cada cultivar, que apresentam muito mais variação do que as observadas com base em caracteres morfológicos, permitindo assim que cultivares muito semelhantes sejam discriminadas. Essa análise se assemelha com os testes de paternidade, muito comuns hoje em dia.

1.3.5 Características de algumas Cultivares de Soja

1.3.5.1 Cultivar EMBRAPA 133

A cultivar EMBRAPA 133 (BRS 133), ilustrada na Figura 3, foi desenvolvida pelo Centro Nacional de Pesquisa de Soja - Embrapa Soja e avaliada oficialmente, no Estado do

Paraná, nos ensaios de Avaliação Intermediária e Final das safras 1993/94, 1994/95 e 1995/96, com a sigla BR91-12418.

A BRS 133 tem como origem uma planta selecionada na população F5 do cruzamento FT-Abyara x BR83-147, conduzida pelo método genealógico modificado.

Na média de 30 ambientes em que foi testada, a BRS 133 apresentou produtividade média de 3.600 kg/ha, sendo 8,5% mais produtiva que a cultivar padrão BR-16. É uma cultivar do grupo de maturação semiprecoce, apresentando médias de 121 dias para maturação e 79 cm de altura de planta. Possui hábito de crescimento determinado e boa resistência ao acamamento e à deiscência de vagens. É resistente às doenças cancro da haste, mancha "olho-de-rã" e pústula bacteriana. Tem como características morfológicas flor branca, pubescência marrom, vagem marrom clara e semente de tegumento amarelo-fosco, com hilo marrom.

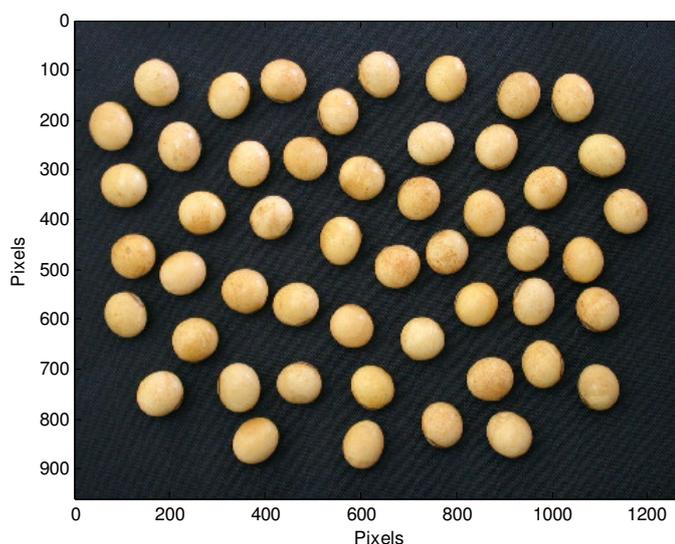


Figura 3: Cultivar BRS 133

1.3.5.2 Cultivar EMBRAPA 184

A cultivar EMBRAPA 184 (BRS 184), ilustrada na Figura 4, foi desenvolvida pelo Centro Nacional de Pesquisa de Soja - Embrapa Soja e avaliada oficialmente, no Estado do Paraná.

É uma cultivar do grupo de maturação médio, apresentando 78 cm de altura de planta. Possui hábito de crescimento determinado e boa resistência ao acamamento e à deiscência de vagens. É resistente às doenças cancro da haste e mancha "olho-de-rã". Tem como características morfológicas flor roxa, pubescência marrom e hilo marrom.

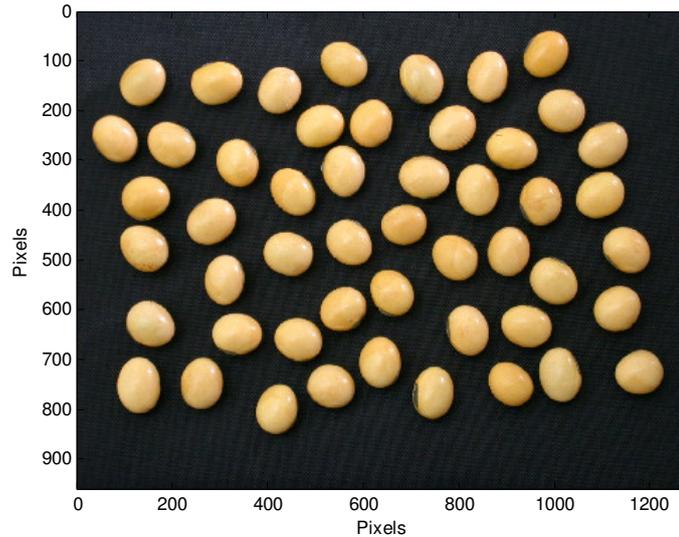


Figura 4: Cultivar BRS 184

1.3.5.3 Cultivar COODETEC 205

A COODETEC 205 (CD 205), ilustrada na Figura 5, é uma cultivar do grupo de maturação tardio, apresentando médias de 132 dias para maturação e 83 cm de altura de planta. Possui hábito de crescimento determinado, resistência ao acamamento e tolerante deiscência de vagens. É resistente às doenças cancro da haste, mancha "olho-de-rã", pústula bacteriana e crestamento bacteriano. Tem como características morfológicas flor roxa, pubescência marrom e hilo marrom.

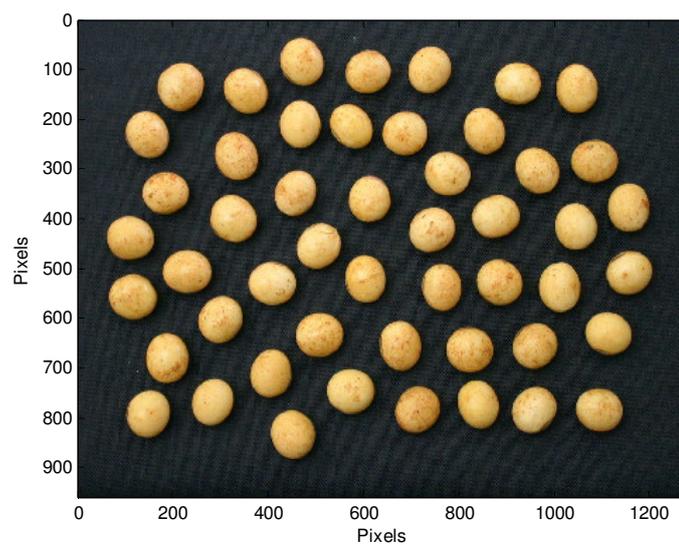


Figura 5: Cultivar CD 205

1.3.5.4 Cultivar COODETEC 206

A COODETEC 206 (CD 206), ilustrada na Figura 6, é uma cultivar do grupo de maturação semi-precoce, apresentando médias de 123 dias para maturação e 84 cm de altura de planta. Possui hábito de crescimento determinado e tolerante resistência à deiscência de vagens. É resistente às doenças cancro da haste, mancha "olho-de-rã" e pústula bacteriana. Tem como características morfológicas flor roxa, pubescência marrom e hilo preto.

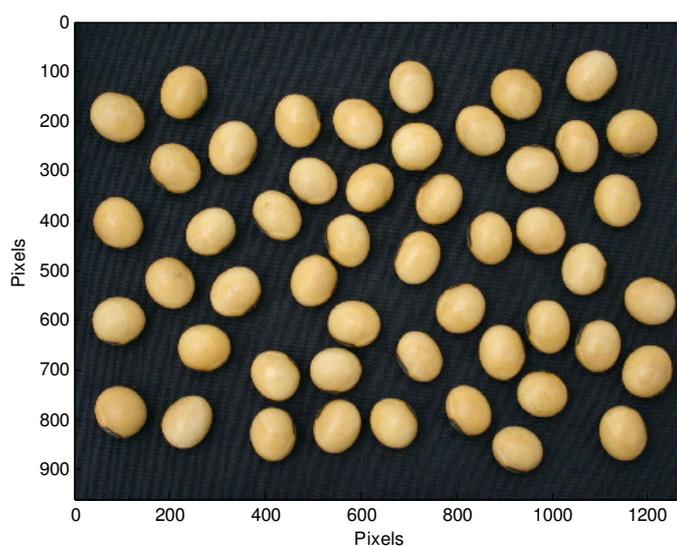


Figura 6: Cultivar CD 206

1.3.5.5 Cultivar EMBRAPA 48

A cultivar EMBRAPA 48 (EMB 48), ilustrada na Figura 7, foi desenvolvida pelo Centro Nacional de Pesquisa de Soja - Embrapa Soja e avaliada oficialmente, no Estado do Paraná, nos ensaios de Avaliação Intermediária e Final das safras 1991/92, 1992/93 e 1993/94.

Esta tem como origem uma planta selecionada do cruzamento (Davis x Paraná) x (IAS 4 x Br5), conduzida pelo método genealógico modificado.

Na média de 32 ambientes em que foi testada, a EMB 48 apresentou produtividade média de 3428 kg/ha, sendo 11,5% e 14,1% superior às cultivares padrões FT - Guaíra e IAS 5, respectivamente.

É uma cultivar do grupo de maturação precoce, apresentando 63 cm de altura de planta. Possui hábito de crescimento determinado e boa resistência ao acamamento e à

deiscência de vagens. É resistente às doenças mancha "olho-de-rã", podridão parda da haste e pústula bacteriana. Tem como características morfológicas flor branca, pubescência cinza e hilo marrom claro.

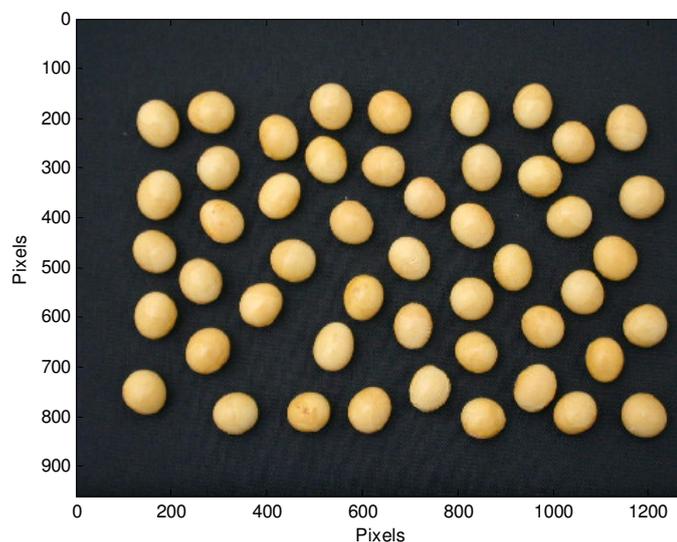


Figura 7: Cultivar EMB 48

1.3.5.6 Cultivar SYNGENTA 8350

A cultivar SYNGENTA 8350 (NK 8350), ilustrada na Figura 8, foi desenvolvida pelo Centro Nacional de Pesquisa de Soja - Embrapa Soja e avaliada oficialmente, no Estado do Paraná, nos ensaios de Avaliação Intermediária e Final das safras 1993/94, 1994/95 e 1995/96, com a sigla BR91-12418.

A NK 8350 tem como origem uma planta selecionada na população F5 do cruzamento Willians x Essex, conduzida pelo método genealógico modificado.

É uma cultivar do grupo de maturação precoce, apresentando médias de 120 dias para maturação e 90 cm de altura de planta. Possui hábito de crescimento indeterminado e boa resistência ao acamamento e à deiscência de vagens. É resistente às doenças cancro da haste e podridão parda haste. Tem como características morfológicas flor branca, pubescência cinza e hilo marrom claro.

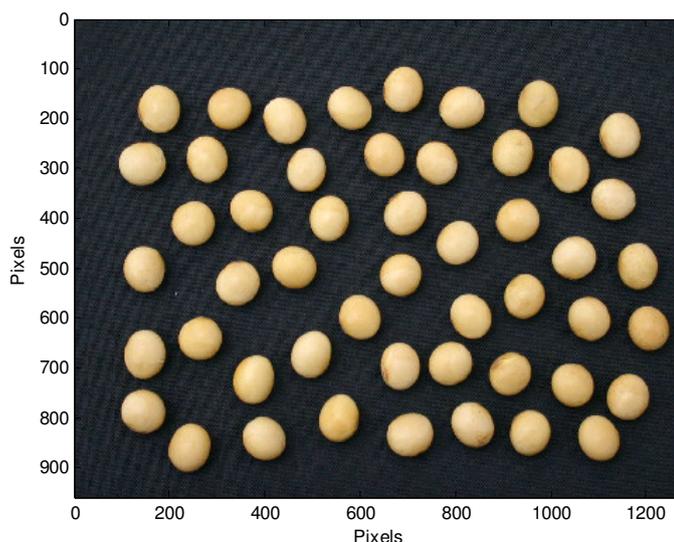


Figura 8: Cultivar NK 8350

1.3.5.7 Cultivar FEPAGRO 10

A cultivar FEPAGRO 10 (RS 10), ilustrada na Figura 9, foi desenvolvida pela Fundação Estadual de Pesquisa Agropecuária - FEPAGRO nos ensaios de Avaliação Intermediária e Final das safras 1992/93, 1993/94 e 1994/95, com a sigla JC 8971.

A RS 10 tem como origem uma planta selecionada na população F6 do cruzamento IPAGRO 20 x Pel 7803 (Forrest x Hood), conduzida pelo método genealógico modificado.

Na média dos ambientes em que foi testada, a RS 10 apresentou produtividade média de 3446 kg/ha. É uma cultivar do grupo de maturação tardio, apresentando médias de 147 dias para maturação e 96 cm de altura de planta. Possui hábito de crescimento determinado e boa resistência ao acamamento e à deiscência de vagens. É resistente às doenças cancro da haste, pústula bacteriana e fogo selvagem. Tem como características morfológicas flor roxa, pubescência cinza, vagem cinza e semente de tegumento amarelo, com hilo marrom.

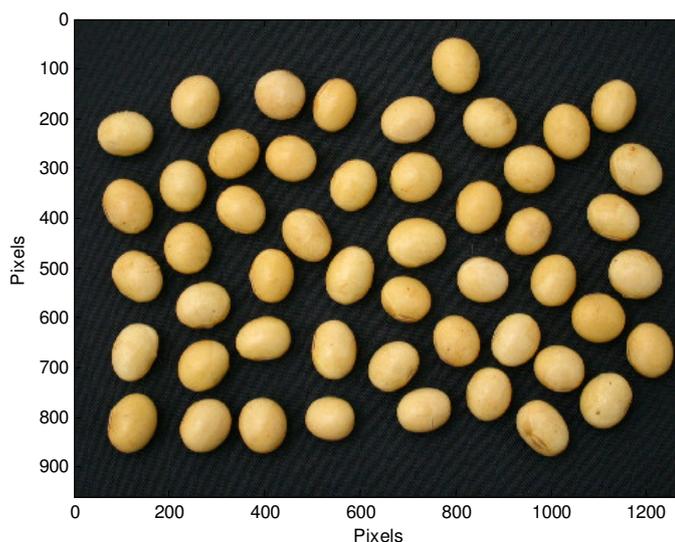


Figura 9: Cultivar RS 10

1.3.5.8 Cultivar MONSOY 8000 RR

A cultivar MONSOY 8000 RR (MSOY 8000 RR), ilustrada na Figura 10, foi desenvolvida pelo Grupo Monsanto - Empresa Monsoy.

É uma cultivar do grupo de maturação semi-precoce, apresentando médias de 121 dias para maturação e 77 cm de altura de planta. Possui hábito de crescimento determinado e boa resistência ao acamamento e à deiscência de vagens. É resistente às doenças cancro da haste, mancha "olho-de-rã" e pústula bacteriana. Tem como características morfológicas flor roxa, pubescência cinza e hilo preto imperfeito.

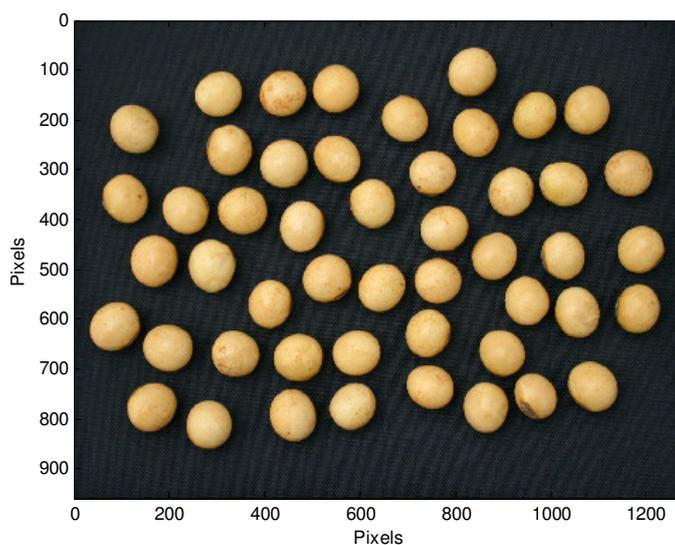


Figura 10: Cultivar MSOY 8000RR

1.4 IMAGENS DIGITAIS

1.4.1 Definição

Uma imagem digital ou imagem monocromática é uma função bidimensional $f(x,y)$ da intensidade luminosa, onde x e y denotam coordenadas espaciais, que por convenção: $x = [1, 2, \dots, M]$ e $y = [1, 2, \dots, N]$. O valor de f no ponto (x, y) é proporcional ao brilho (ou nível de cinza) da imagem neste ponto, como ilustrado na

Figura 11. Esta apresenta uma região em destaque em que se podem observar os pixels e os níveis de cinza ou níveis de luminância de cada um deles.



Figura 11: Imagem Monocromática "Goldhill" para destaque de uma região de 17x17 pixels

1.4.2 Pixel e Conectividade

Um pixel é o elemento básico em uma imagem. A forma mais comum para o pixel é a forma retangular ou quadrada. O pixel é também um elemento de dimensões finitas na representação de uma imagem digital.

Frequentemente, a organização de uma imagem sob a forma de uma matriz de pixels é feita em uma simetria quadrada. Isto se deve a facilidade de implementação eletrônica, seja dos sistemas de aquisição seja dos sistemas de visualização de imagens. Este tipo de organização provoca o aparecimento de dois problemas importantes nas técnicas de processamento.

Em primeiro lugar um pixel não apresenta as mesmas propriedades em todas as direções, isto é, ele é anisotrópico. Esta propriedade faz com que um pixel tenha quatro vizinhos de borda e quatro vizinhos de diagonal. Esta característica obriga que seja definido o tipo de conectividade que será utilizada, ou B4 (considerando apenas os vizinhos de borda) ou B8 (considerando os vizinhos de borda e os de diagonal), como ilustrado na Figura 12.

O segundo problema é consequência direta do primeiro, ou seja, as distâncias entre um ponto e seus vizinhos não é a mesma para qualquer tipo de vizinho. Será igual a 1 para vizinhos de borda e $\sqrt{2}$ para aqueles na diagonal.

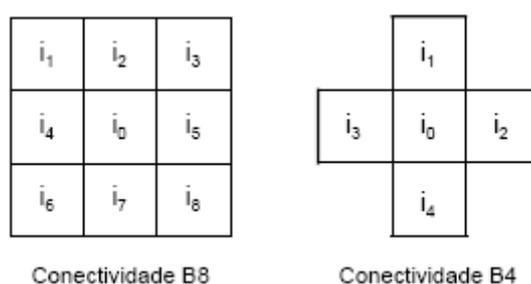


Figura 12: Ilustração de tipos de conectividade de pixels vizinhos

1.5 PROCESSAMENTO DE IMAGENS DIGITAIS

O processamento de imagens digitais é uma área que vem crescendo nos últimos tempos. Vários temas científicos são abordados e na maioria das vezes em caráter interdisciplinar, como por exemplo: a compreensão de imagens, análise em multiresolução e em multi-frequência, análise estatística, codificação e a transmissão de imagens, etc.

Segundo NEVES (2001), o processamento de imagens trata da aquisição de dados de uma imagem adquirida através de algum meio de digitalização e sua manipulação a fim de se obter informações específicas da mesma, realçando as informações importantes e removendo as desnecessárias. Este processo facilita a manipulação bem como a análise dos dados obtidos da imagem, os quais são usados para solução de diversos problemas, tais como: descoberta automática de fissuras em materiais, contagem de glóbulos brancos em amostras de sangue, cálculo do volume sanguíneo nas câmaras do coração, contagem de microorganismos em amostras orgânicas, entre outros.

As imagens são produzidas através de inúmeros dispositivos físicos, nos quais se destacam: câmeras, vídeo câmeras, equipamentos de radiografia, microscópios eletrônicos, magnéticos e de força atômica, radares, equipamento de ultra-som, etc. A produção e

utilização de imagens podem ter vários objetivos, sendo para um simples divertimento até aplicações militares, médicas ou tecnológicas. O objetivo é extrair informações úteis para cada aplicação desejada, sendo através de um observador ou de uma máquina.

De acordo com Gonzales et al. (2000), as técnicas de processamento digital de imagens começaram a ter aplicações no início do século XX, com o envio de imagens por meio de cabos submarinos entre Londres e Nova Iorque para a publicação em jornais. As imagens eram codificadas no transmissor e decodificadas no receptor, para o qual havia necessidade de melhoramento na qualidade da imagem.

Segundo Martins (2004), o grande salto nas técnicas de processamento de imagens ocorreu com o surgimento dos computadores de grande porte no período da corrida espacial, aliado à necessidade de análise e melhoramento das imagens de televisão, enviadas por sondas espaciais nas missões para a Lua, para Marte (missões Marine) e também nos vôos tripulados para a Lua.

Atualmente, o processamento de imagens é utilizado em várias áreas de aplicação do conhecimento humano para resolver uma grande variedade de problemas e que, normalmente, requerem métodos capazes de melhorar a informação visual para análise e interpretação humana ou a percepção automática das máquinas. Como exemplo para a análise e interpretação humana tem-se as imagens melhoradas por tratamento digital; aplicações na área médica com imagens de raios-X e ultrassonografia; na geologia o estudo das imagens de satélites; na restauração de figuras da arqueologia e fotos naturais; na medicina nuclear e na melhoria de imagens transmitidas por ondas de rádio e etc. Como exemplo para a percepção automática de máquinas tem-se o reconhecimento automático de caracteres; processamento automático de impressões digitais; reconhecimento automático da face humana; guiagem de robôs; processamento automático de imagens de satélites para o reconhecimento de queimadas, etc. (MARTINS, 2004).

A análise digital de dados, como por exemplo, imagens digitais de sensoriamento remoto orbital, possibilitaram um grande desenvolvimento das técnicas voltadas para a análise de dados multidimensionais, adquiridos por diversos tipos de sensores. Estas técnicas têm recebido o nome de processamento digital de imagens.

O objetivo da utilização do PID é melhorar o aspecto visual de certas estruturas e fornecer outros subsídios para a sua interpretação, gerando produtos que possam ser submetidos a outros processamentos.

A área de processamento digital de imagens tem atraído grande interesse nas últimas décadas, principalmente através da evolução tecnológica da computação digital e o desenvolvimento de novos algoritmos para lidar com sinais bidimensionais.

O PID pode ser dividido em cinco etapas: aquisição da imagem, pré-processamento, segmentação, representação/descrição e reconhecimento/interpretação (GONZALES, 1993).

A Figura 13 descreve as etapas do processamento de imagens digitais.

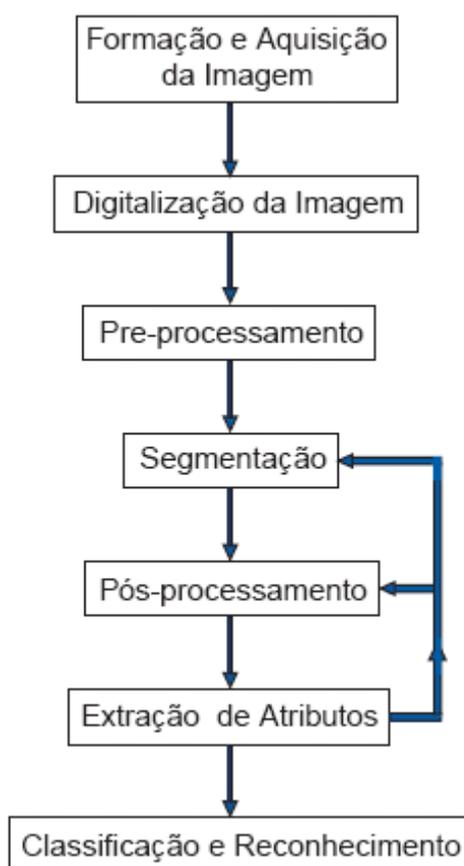


Figura 13: Etapas de um sistema de PID

1.5.1 Aquisição da Imagem

A primeira etapa, a aquisição da imagem, pode ser realizada através de variados meios como, aparelho de raios-X, ultra-som, ressonância magnética, sensor de sinais e até mesmo simples câmeras digitais.

1.5.2 Pré-Processamento

Após aquisição da imagem a próxima etapa é o pré-processamento da imagem. A principal função do pré-processamento é utilizar métodos e ou algoritmos, para melhorar a imagem e realçar as principais características para a execução do processamento como, por exemplo, o aumento de contraste, a suavização para tons de cinza em caso de imagem colorida, a remoção de ruídos introduzidos no processo de aquisição da imagem e o isolamento de regiões conforme a textura.

1.5.3 Segmentação

A segmentação subdivide uma imagem em suas partes ou objetos constituintes. A segmentação deve parar quando os objetos de interesse na aplicação tiverem sido isolados. Assim, segmentar significa dividir uma imagem na menor porção possível, de modo que se possa caracterizar um segmento de imagem, baseando-se em alguma informação adquirida da própria imagem. Em geral, a segmentação é uma das mais difíceis tarefas em um processamento de imagem, sendo esta, uma etapa determinante para o sucesso da análise.

A saída da segmentação é um conjunto de pixels, que constituem o limite de uma região ou todos os pontos desta, dependendo de cada caso os dados são convertidos para uma forma adequada ao processamento da imagem (GONZALEZ, 1993).

Segundo Lucca (1998), as técnicas empregadas para segmentação automática de imagens podem ser agrupadas em três principais categorias: ajuste de regiões (*region fitting*), crescimento de regiões (*region growing*) e detecção de bordas (*edge detection*).

Segmentações produzidas por algoritmos que empregam técnicas de detecção de bordas, baseiam-se em encontrar limites entre regiões homogêneas de diferentes propriedades, e necessitam de operadores específicos que realcem as bordas antes da segmentação. Uma borda é o limite entre duas regiões com propriedades de níveis de cinza relativamente distintas e sua detecção pode ser feita automaticamente por operadores de derivadas locais denominados de gradientes, os quais são implementados usando janelas (máscaras) de vários tamanhos. Técnicas de detecção de bordas têm sido largamente empregadas para segmentar imagens ópticas. Alguns exemplos de operadores de bordas usados em tais imagens são os gradientes de Canny, Prewitt, Sobel, Marr-Hildreth, Log, Roberts, e Zerocross, os quais utilizam máscaras de tamanhos 2×2 , 3×3 ou 5×5 (GONZALES, 1993).

Devido à gama de imagens adquiridas de diversos meios diferentes não existe um método geral de segmentação de imagens, pois possuem várias características diferentes.

A escolha de um método adequado depende das características da imagem, das operações de pós-segmentação (reconhecimento de formas, interpretação, localização, etc.) e das características a serem analisadas (contornos, regiões, formas, etc.).

Muitas das dificuldades encontradas em segmentação de imagens podem ser reduzidas através da suavização adequada da imagem, durante a etapa de pré-processamento.

1.5.4 Representação e Descrição

Uma representação é a transformação dos dados em uma forma adequada para em seguida finalizar o processamento. Um método também deve ser especificado para descrever os dados de maneira que os traços interessantes sejam realçados.

Descrição também chamada de seleção de característica trata da extração de características que resultam em alguma quantidade de informações interessantes ou características que são básicas para diferenciar uma classe de objetos de outra.

Nesta etapa deve ser feita a manipulação dos dados para que possam ser inseridos em uma rede neural, que na proposta deste trabalho será usada na próxima etapa.

1.5.5 Reconhecimento e Interpretação

Reconhecimento é o processo que atribuirá um rótulo para um objeto baseado na informação fornecida pelos descritores. Interpretação envolve atribuição de significado para um conjunto de objetos reconhecidos.

Este reconhecimento será realizado através de técnicas de redes neurais que será demonstrado no próximo capítulo.

1.6 REDES NEURAIAS ARTIFICIAIS

1.6.1 Definição

Redes Neurais Artificiais é a parte da computação que tenta imitar a capacidade que o homem possui de raciocinar utilizando-se de diversas técnicas de programação para resolver

determinados tipos de problemas. Na área da informática ela é conhecida como inteligência artificial. Estas técnicas se baseiam no cálculo sináptico que ocorre no sistema nervoso dos mamíferos, tentando assim, reproduzir a inteligência dos mesmos de modo artificial.

1.6.2 Redes Neurais Biológicas

O neurônio biológico é basicamente o dispositivo computacional elementar do sistema nervoso que possui muitas entradas e uma saída. As entradas ocorrem através das conexões sinápticas, que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por estes axônios são pulsos elétricos conhecidos como impulsos nervosos ou potenciais de ação, constituindo a informação que o neurônio processará de alguma forma para produzir como saída um impulso nervoso no seu axônio (KOVACS, 1996).

Segundo Kovacs (1996), o cérebro humano é considerado o mais fascinante processador, sendo composto por aproximadamente 10 bilhões de neurônios. Todas as funções e movimentos do organismo estão relacionados ao funcionamento destas pequenas células. Os neurônios estão conectados uns aos outros através de sinapses, e juntos formam uma grande rede, chamada rede neural. As sinapses transmitem estímulos através de diferentes concentrações de Na⁺ (Sódio) e K⁺ (Potássio), sendo estendidos por todo o corpo humano. Esta grande rede neural proporciona uma fabulosa capacidade de processamento e armazenamento de informações.

O sistema nervoso é formado por um conjunto extremamente complexo de neurônios. Nesses, a comunicação é realizada através de impulsos. Quando um impulso é recebido, o neurônio o processa, e passado um limite de ação, dispara um segundo impulso que produz uma substância neurotransmissora o qual flui do corpo celular para o axônio que por sua vez pode estar ou não conectado a um dendrito de outra célula. O neurônio que transmite o pulso pode controlar a frequência de pulsos aumentando ou diminuindo a polaridade na membrana pós-sináptica. Eles têm um papel essencial na determinação do funcionamento, comportamento e do raciocínio do ser humano. Ao contrário das redes neurais artificiais, redes neurais naturais não transmitem sinais negativos, sua ativação é medida pela frequência (contínua e positiva) com que emite os pulsos. As redes naturais não são uniformes como as redes artificiais e apresentam uniformidade apenas em alguns pontos do organismo.

Seus pulsos não são síncronos ou assíncronos, devido ao fato de não serem contínuos, o que as difere das redes artificiais.

Baseada na célula nervosa básica chamada neurônio, como qualquer célula biológica, o neurônio é delimitado por uma fina membrana celular que além da sua função biológica normal, possui propriedades que permitem a transmissão de sinais elétricos.

De acordo com a Figura 14, o neurônio é dividido em três partes principais:

- a) Dendritos: Tem por função, receber os estímulos transmitidos por outros neurônios;
- b) Corpo do neurônio: Também chamado de soma, o qual é responsável por coletar e combinar informações vindas de outros neurônios. É o centro dos processos metabólicos da célula nervosa;
- c) Axônio: Responsável pela condução do impulso nervoso na saída do neurônio.

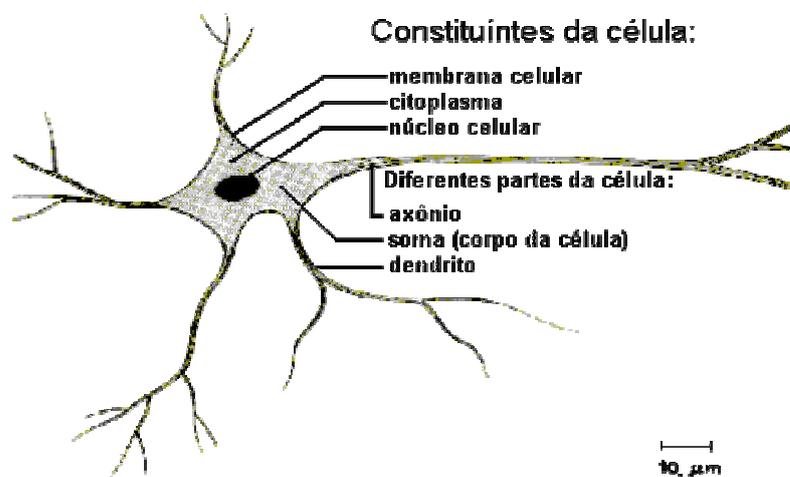


Figura 14: Neurônio Biológico (KOVACS, 1996)

1.6.3 Histórico das Redes Neurais Artificiais

As redes neurais artificiais têm sua evolução baseada na contribuição individual de inúmeros pesquisadores destacando-se entre eles as publicações de: McCulloch e Pitts (1943), Hebb (1949) e Rosenblatt (1957). Estes trabalhos introduziram o primeiro modelo de redes

neurais simulando “máquinas”, o modelo básico de rede de auto-organização e o modelo Perceptron de aprendizado supervisionado, respectivamente.

Alguns pesquisadores da área de redes neurais entendem que ocorreram poucas pesquisas na área durante os anos 60 e 70. Um novo progresso significativo reiniciou-se com a publicação dos trabalhos de Hopfield (1982) relatando a utilização de redes simétricas para otimização e de Rumelhart et al. (1986) que introduziram o poderoso algoritmo de retro-propagação (*backpropagation*).

A seguir segue cronologicamente alguns dos principais contribuidores na pesquisa de redes neurais artificiais:

1943 - Mcculloch e Pitts - Apresentam o primeiro modelo de redes neurais simulando “máquinas”.

1949 - Donald Hebb - Apresenta o modelo básico de rede de Auto-organização.

1958 - John Von Neumain – “*The computer and the brain*”, modelos de neurônios usando relés e válvulas.

1956 - Albert Utley - “*Informons*”, separador linear que ajusta seus parâmetros de entrada.

1958 - Frank Rosenblatt (Cornell University) - “Perceptrons”, generalização dos modelos de Mcculloch/Pitts.

1959 - Bernard Widrow e Marcian Hoff (Stanford University) - “Adaline and Madaline” - Perceptrons melhorados.

1969 - Marvin Minsky e Papert - livro “Perceptrons”.

1.6.4 Classificação das Redes Neurais

Existem várias maneiras de classificar os diferentes tipos de redes neurais. A forma mais comum é através do método de aprendizado, se este aprendizado é dinâmico ou estático, supervisionado ou não supervisionado. Os termos estáticos ou dinâmicos referem-se como a rede altera o seu comportamento como função do tempo. Redes estáticas têm seu comportamento congelado, isto é, os pesos da rede são determinados na implementação e não se alteram à medida que novos valores são introduzidos (SILVA, 1998). Dois exemplos deste tipo são as redes neurais de Hamming e Hopfield. A rede de Hamming consiste de duas sub-redes, a sub-rede inferior, a qual aceita entradas de um padrão binário codificado e a sub-rede

superior, a qual determina qual o padrão aprendido possui a menor distância de Hamming em relação ao padrão de entrada. Os padrões da rede de Hamming são pré-definidos e não podem ser modificados a não ser por uma intervenção manual.

A rede de Hopfield binária se comporta de maneira similar à rede de Hamming. Dada uma entrada, a rede escolhe o padrão armazenado que possui a menor distância de Hamming em relação a esse padrão de entrada. A rede de Hopfield trabalha através da conexão dos nós de saída com todos os outros nós de entrada da rede e possui somente uma camada de nós que age tanto como nó de entrada como nó de processamento. A rede de Hopfield processa até que seja encontrado um padrão que não se altere mais.

Ambas as redes são simples de se projetar e implementar, devido a sua simplicidade, sendo consideradas as preferidas na implementação prática.

Redes dinâmicas mudam seu comportamento temporalmente e provavelmente são as redes mais usadas. Estas redes também podem ser classificadas como redes não supervisionadas ou supervisionadas, dependendo de como são condicionadas. Uma comparação pode ser feita nos métodos de aprendizado dinâmico com condicionamento em psicologia. O aprendizado não supervisionado é análogo ao condicionamento em psicologia. O condicionamento reforça o estímulo ao relacionamento aprendido. É fornecida uma entrada a quem está aprendendo que reage com uma saída. Este aprendizado é repetido até que seja decidido que o elemento que está aprendendo tenha aprendido o relacionamento. Pensa-se então que o elemento consegue associar as entradas e decidir qual será a saída apropriada, eventualmente uma nova entrada dará a mesma saída (KOVACS, 1996).

Aprendizado supervisionado é a forma mais usada de aprendizado em redes neurais, normalmente feito pelo algoritmo de retropropagação. Aprendizado supervisionado é análogo ao condicionamento operante em psicologia, no qual as respostas são reforçadas e não os estímulos. Para se ter o aprendizado supervisionado é necessárias amostras conhecidas. As saídas são calculadas de acordo com as entradas fornecidas à rede. O supervisor compara a saída da rede com a saída desejada e determina em que nível a rede deve ser “excitada” ou “inibida”. Então a rede modifica seu comportamento de acordo com a estratégia de supervisão (KOVACS, 1996).

O algoritmo de retropropagação usa este conceito na forma de um gradiente regressivo. O algoritmo move a rede de uma superfície de erro desconhecido para um mínimo local ou global.

O gradiente e sua direção são determinados por cálculo através de uma função de erro. Este erro é retropropagado através da rede para determinar como os pesos devem ser ajustados para um melhor comportamento. O nome retropropagação deve-se a este algoritmo.

Na prática, as redes não ficam aprendendo todo o tempo. Elas normalmente são desenvolvidas, treinadas e uma vez validadas, tem seu treinamento interrompido e o comportamento congelado com relação ao tempo.

Através da construção da rede e seleção dos seus pesos, qualquer função multidimensional ou associação entre entradas e saídas da rede pode ser aprendida pela mesma (BULLOCK et al., 1992).

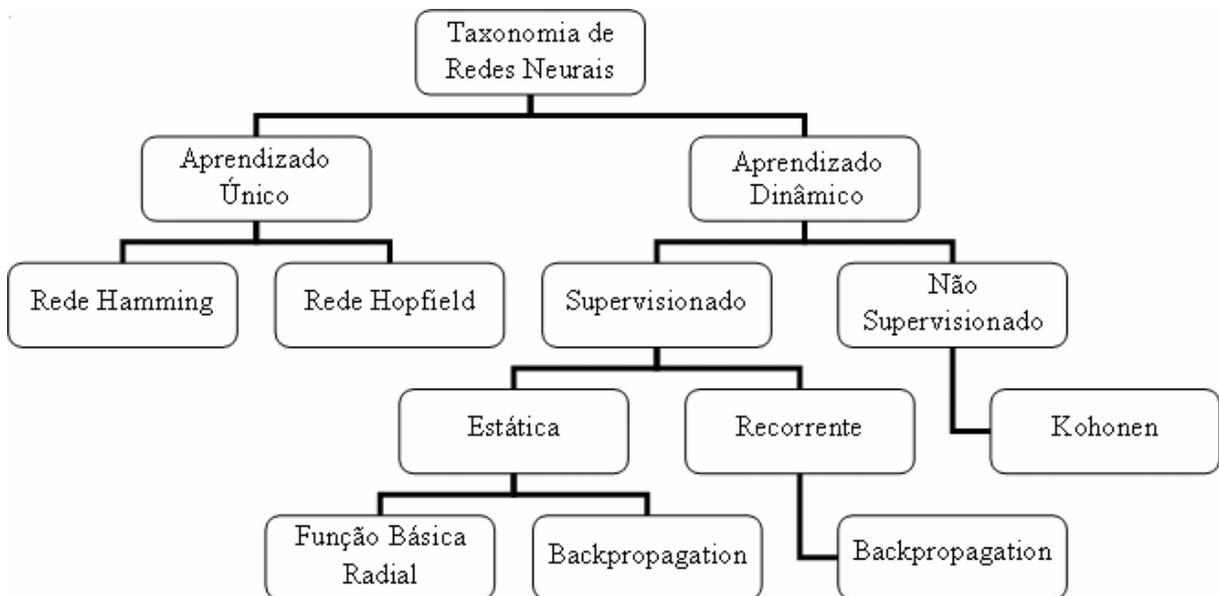


Figura 15: Taxonomia das Redes Neurais

A propriedade mais importante das redes neurais é a habilidade de aprender com seu ambiente e com isso melhorar seu desempenho. O aprendizado da rede (treinamento) é feito através de um processo iterativo de ajustes de seus pesos. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados (SILVA, 1998).

Segundo Ramos (2001), a rede neural se baseia nos dados para extrair um modelo geral. Portanto, a fase de aprendizado deve ser rigorosa e verdadeira, a fim de se evitar

modelos espúrios. Todo o conhecimento de uma rede neural está armazenado nas sinapses, ou seja, nos pesos atribuídos às conexões entre os neurônios. De 50 a 90% do total de dados devem ser separados para o treinamento da rede neural, dados estes escolhidos aleatoriamente, a fim de que a rede aprenda as regras e não decore exemplos. O restante dos dados só é apresentado à rede neural na fase de testes a fim de que ela possa "deduzir" corretamente o inter-relacionamento entre os dados.

1.6.5 Rede Perceptron

No final da década de 1950, Rosenblatt na Universidade de Cornell, deu prosseguimento as idéias de Mcculloch. Ele criou uma genuína rede de múltiplos neurônios do tipo discriminadores lineares e chamou esta rede de Perceptron. Um Perceptron é uma rede com os neurônios dispostos em várias camadas. Os neurônios que recebem diretamente as entradas da rede constituem o que se chama de camada de entrada (ROSENBLATT, 1957).

Os neurônios que recebem como entradas as saídas daqueles da camada de entrada constituem a segunda camada e assim sucessivamente até a camada final que é a camada de saída. As camadas internas que não são nem a de entrada e nem a de saída são geralmente referidas como camadas intermediárias, escondidas ou ocultas.

A operação de uma unidade de processamento, proposta por McCulloch e Pitts em 1943, pode ser resumida da seguinte maneira:

- a) Sinais são apresentados à entrada;
- b) Cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- c) É feita a soma ponderada dos sinais que produz um nível de atividade;
- d) Se este nível de atividade exceder certo limite ("limiar") a unidade produz uma determinada resposta de saída.

A Figura 16 apresenta o neurônio proposto com as entradas X , função de ativação $f(a)$ e saída Y .

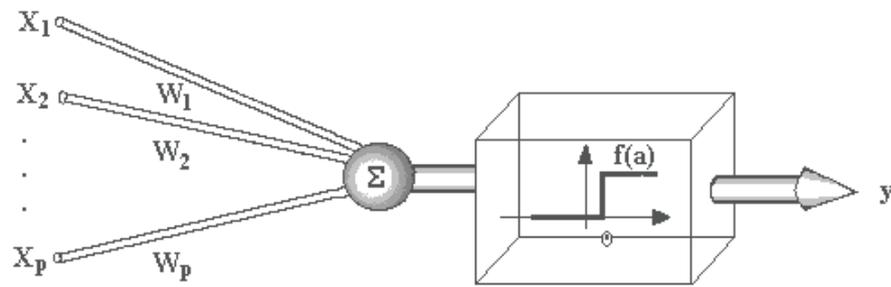


Figura 16: Neurônio Artificial projetado por McCulloch

1.6.5.1 Perceptron de Múltiplas Camadas

Rumelhart et al. (1986) através de suas pesquisas demonstraram que é possível treinar redes neurais com camadas intermediárias, resultando no modelo de redes neurais artificial mais utilizado atualmente, as redes Perceptron de Múltiplas Camadas (MLP), treinadas com o algoritmo de retropropagação (*backpropagation*). Este tipo de rede pode possuir uma ou mais camadas intermediárias onde cada uma possui uma função específica. A camada de entrada é responsável pela recepção dos padrões de entrada, a camada de entrada se liga à camada intermediária através de conexões. As conexões guardam os pesos que serão futuramente multiplicados pelas entradas, garantindo o conhecimento da rede. A camada de saída recebe os valores da camada intermediária fornecendo a resposta da rede.

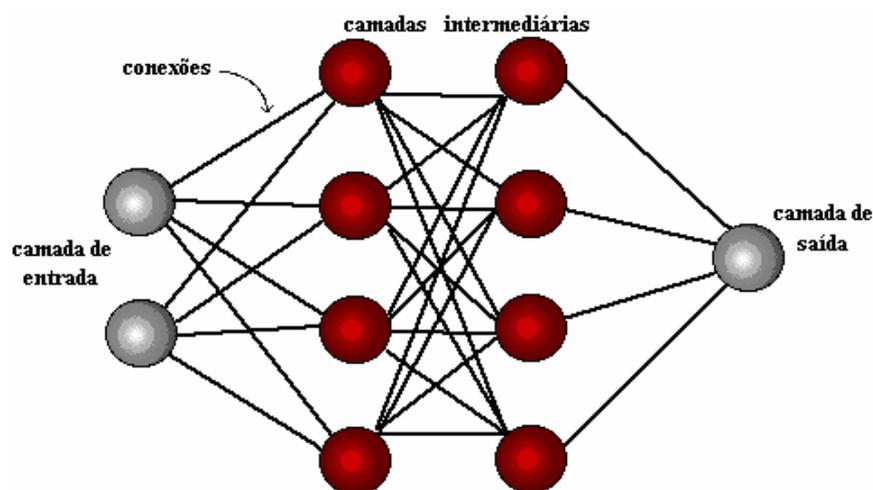


Figura 17: Rede neural tipo MLP (Fonte: Tatibana, 2006)

A Figura 17 apresenta uma arquitetura do tipo MLP com duas camadas intermediárias. A rede apresentada como exemplo possui todas as conexões, o que significa que um neurônio em qualquer camada da rede está conectado a todas as outras unidades (neurônios) na camada anterior. O fluxo de sinais através da rede é feito positivamente, da esquerda para a direita, camada a camada.

Segundo SILVA (1998), as arquiteturas do tipo MLP constituem os modelos neurais artificiais mais utilizados e conhecidos. Tipicamente, esta arquitetura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias (ou escondidas) de unidades computacionais e uma camada de saída. Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para a saída. Esta arquitetura representa uma generalização do Perceptron apresentado anteriormente. As redes do tipo MLP têm sido utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade. Seu treinamento é do tipo supervisionado e utiliza um algoritmo muito popular chamado retropropagação do erro (*error backpropagation*). Este algoritmo é baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento (HAYKIN, 1994).

A rede bem definida, com número correto de camadas, neurônios e pesos corretos, permite que a relação entre um conjunto de padrões de entrada e saídas seja processada por uma rede neural treinada e estabilizada.

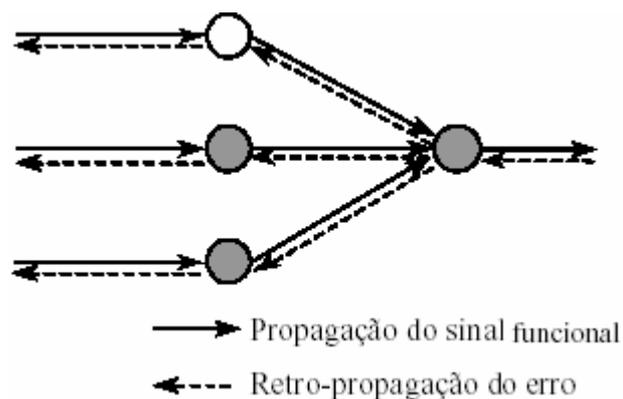


Figura 18: Representação das direções de propagação do sinal funcional e do erro (Fonte: Ramos, 2001)

1.6.6 Mapeamento do Cérebro e da Máquina

O dispositivo computacional mais poderoso conhecido pelo homem é o cérebro humano. Uma criança de três anos pode executar inúmeras tarefas com extrema facilidade que

foge em muito as potencialidades dos computadores mais sofisticados. Esta consegue reconhecer dúzias de rostos e centenas de objetos dos mais diferentes ângulos, em condições diferentes de luz, manipular um ambiente complexo, compreendendo e usando um vocabulário complexo incluindo gestos. Enormes esforços em pesquisas, com pouco sucesso tem sido gastos na tentativa de reproduzir em computadores versões limitadas de algumas destas potencialidades que o cérebro realiza. Em contrapartida os computadores conseguem realizar inúmeras atividades com extrema rapidez que levaria muito tempo para a maioria dos humanos, tais como complexos cálculos aritméticos com baixa probabilidade de erro.

Existe um grande antagonismo entre a mente humana e os computadores, visto que a capacidade de rápido processamento aritmético é muito difícil para os humanos e tão fácil para as máquinas, em contra partida o simples reconhecimento facial é extremamente simples para humanos e tão complexo para as máquinas.

Se duas cabeças pensam melhor do que uma, um cientista gostaria muito de ter uma mente extra para trabalhar. Esta mente extra o possibilitaria continuar o trabalho quando fosse descansar.

De todos os dispositivos dentro da caixa de ferramentas disponíveis para um pesquisador até agora, o computador é o que mais se assemelha a uma mente podendo processar milhões de dados instantaneamente. Porém a mente humana é capaz de fazer julgamentos, o que ainda não é tão simples para os computadores, tudo que os computadores podem fazer é o que são programados pelo homem.

Classificação de padrões é um exemplo de tarefa que os computadores tradicionais não conseguem fazer a menos que bem programados. Ao contrário dos humanos, a maioria dos computadores não pode lidar com situações que não tenham sido explicitamente programados para executar. Quando algo não se enquadra no programa, o computador simplesmente “não processa”.

Redes neurais são técnicas que fazem mais do que apenas processar milhares de números. Estas ferramentas computacionais permitem o uso da experiência, quase que como humanos, permitindo trabalhar com novas situações.

Até agora, cientistas encontraram pelo menos duas formas onde as redes neurais artificiais e a mente humana são similares:

- a) Ambas trabalham surpreendentemente bem em tarefas diversas que são problemas para técnicas computacionais tradicionais;

b) Ninguém sabe precisamente como ambas funcionam.

As redes neurais artificiais aparecem como modelos matemáticos simplificados do sistema nervoso central, resultante de três componentes básicos derivados do estudo do cérebro: neurônios, forças sinápticas e mecanismos de aprendizado. Os dois primeiros componentes das redes neurais artificiais são a base construtora que determina a estrutura, tamanho e capacidade da rede.

O terceiro componente, os mecanismos de aprendizado, determinam como a rede se comportará. Neurônios e forças sinápticas em redes neurais são análogas, porém não são as mesmas estruturas encontradas no cérebro. Os trabalhos reais da parte biológica são também muito complexos para serem simulados.

Os modelos neurais procuram aproximar o processamento dos computadores ao cérebro. As redes neurais artificiais possuem um grau de interconexão similar à estrutura do cérebro e um moderno computador convencional, a informação é transferida em tempos específicos dentro de um relacionamento com um sinal para sincronização.

Na Tabela 1 é apresentada de forma comparativa às relações existentes entre o cérebro humano e o computador.

Tabela 1: Comparação entre cérebro e computador

Parâmetro	Cérebro	Computador
Material	Orgânico	Metal e plástico
Velocidade	Milisegundos	Nanosegundos
Tipo de Processamento	Paralelo	Seqüencial
Armazenamento	Adaptativo	Estático
Controle de Processos	Distribuído	Centralizado
Número de elementos processados	10 e 11 à 10 e 14	10 e 5 à 10 e 6
Ligações entre elementos processados	10.000	<10

Fonte: Tatibana, 2006

O mesmo paralelo, conforme Tabela 2, pode ser traçado comparando o computador com as redes neurais. Para tanto, a comparação não se dará com um computador específico encontrado no mercado, mas sim com o paradigma predominante nos computadores atuais.

Tabela 2: Comparação entre computadores e neurocomputadores

Computadores	Neurocomputadores
Executa programas	Aprende

Executa operações lógicas	Executa operações não lógicas, transformações, comparações
Depende do modelo ou do programador	Descobre as relações ou regras dos dados e exemplos
Testa uma hipótese por vez	Testa todas as possibilidades em paralelo

Fonte: Tatibana, 2006

1.6.7 Arquitetura e Topologia das Redes Neurais

As conexões entre as camadas combinadas com a função de transferência na estrutura do neurônio podem gerar inúmeras estruturas diferentes. Algumas das mais utilizadas foram nomeadas pelos seus inventores como Perceptron, redes Hopfield, *feedforward*, etc. Segundo Laesch (1996), em relação a suas estruturas, as redes neurais devem ser consideradas divididas em diversos níveis existentes:

- a) Micro-Estrutura: Quais são as características de cada neurônio na rede;
- b) Meso-Estrutura: Como é organizada a rede;
- c) Macro-Estrutura: Como podem redes diferentes ser colocadas juntas para executar tarefas ou endereçar problemas de grande escala.

1.6.7.1 Micro-Estrutura Neural

É definida pelas características apresentadas pelos neurônios que formam a rede neural. Entre as características que diferem um neurônio do outro, e que podem ser modificadas para um novo desempenho, citam-se a mudança da função de transferência e adição de novos parâmetros ou funções para a rede (tais como viés, ganho e limiares adaptativos).

Viés é uma entrada adicional que pode ser acrescentada ao neurônio artificial. O valor deste viés não é adquirido de nenhum outro neurônio, mas é acrescentado dentro da estrutura do neurônio, seu peso é ajustado como os demais pesos das conexões através do aprendizado (LAESCH, 1996).

Na Figura 19 e Tabela 3 se encontram algumas funções de transferência tipicamente utilizadas na construção de redes neurais artificiais.

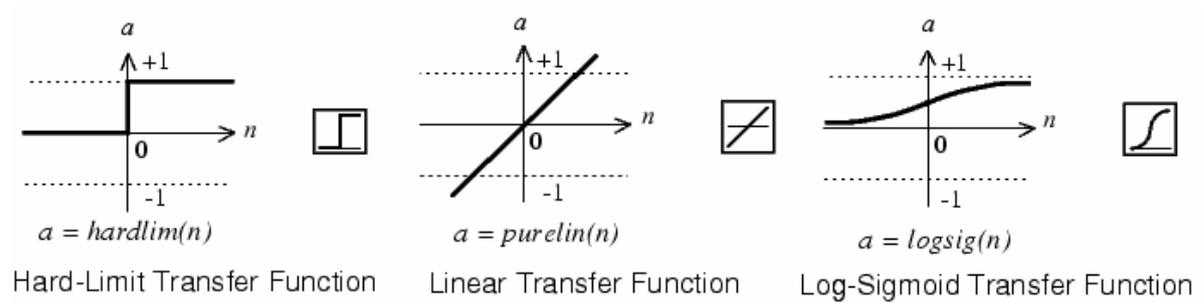


Figura 19: Gráficos das funções de transferência (Fonte: MATLAB Versão 7.0)

Tabela 3: Funções de Transferência

Função	Características	Equação
Linear	Usada tipicamente para buffers de entrada e saída de dados. É usada também em BSB e Hopfield.	$f(s) = s$
Sinal	Usada em paradigmas como perceptron	$f(s) = \begin{cases} +1 & \text{se } s \geq 0 \\ -1 & \text{se } s < 0 \end{cases}$
Passo	Pode ser usada no lugar da função de transferências Perceptron, ou em BAM baseada em 0.	$f(s) = \begin{cases} +1 & \text{se } s \geq 0 \\ 0 & \text{se } s < 0 \end{cases}$
Hopfield/BAM	Usada em redes Hopfield e BAM. Caso $s = 0$, o valor de saída do EP é igual ao valor anteriormente calculado.	$f(s) = \begin{cases} +1 & \text{se } s \geq 0 \\ -1 & \text{se } s < 0 \\ \text{inalterado} & \text{se } s = 0 \end{cases}$
Logística ou Sigmóide	Função de transferência sigmoideal usada tradicionalmente em redes feedforward de aprendizagem backpropagation. Usada também em redes Hopfield, BAM e BSB.	$f(s) = \frac{1}{1 + e^{-2s}}$

Fonte: Laesch, 1996

1.6.7.2 Meso-Estrutura Neural

Neste nível são consideradas a distribuição e a organização física dos neurônios da rede artificial. Para isso devem ser considerados:

- a) Número de camadas;
- b) Número de neurônios por camada;
- c) Tipo de conexões (*forward, backward, lateral*);
- d) Grau de conectividade entre os neurônios: um a um, conectividade plena, esparsa, randômica, etc.

Estas características são alteráveis em qualquer rede neural, sendo essências na distinção dos diferentes tipos de classes e arquiteturas das redes neurais. Considerando estas características, podemos identificar cinco estruturas diferentes de rede (LAESCH, 1996):

- a) Multicamadas: Redes *feedforward*;
- b) Camada Simples: Redes conectadas lateralmente;
- c) Bicamadas: Redes *feedforward / feedback*;
- d) Multicamadas: Redes cooperativas;
- e) Redes Híbridas.

1.6.7.3 Macro-Estrutura Neural

Muitas vezes é difícil definir qual arquitetura de rede se encaixa melhor a um determinado problema. Segundo Laesch (1996), neste caso, deseja-se desenvolver um sistema para interagir redes neurais. Isto nos leva a considerar as macro-estruturas neurais. Estas podem ser criadas pela fusão de duas ou mais redes dentro de uma única estrutura, a qual passa a ser tratada como uma rede simples. Esta estrutura é conhecida também como redes fortemente acopladas.

A maior dificuldade de projetar um sistema de redes neurais complexo é determinar o número, o tipo e o tamanho das redes, especificando seus padrões de conexões.

2 MATERIAIS E MÉTODOS

2.1 INTRODUÇÃO

Neste capítulo são apresentados os materiais utilizados, a descrição dos equipamentos, as metodologias usadas no processamento das imagens dos grãos de soja. Também é feita a descrição do modelo de redes neurais (configuração/arquitetura) utilizado para a identificação dos cultivares.

2.2 ESCOLHA DOS CULTIVARES

A região noroeste do Estado do Rio Grande do Sul é uma das maiores produtoras de grãos do Brasil. O município de Ijuí, inserido neste contexto, é caracterizado pela presença de uma das cooperativas mais bem preparadas para o manuseio de grãos (COTRIJUÍ – Cooperativa Agropecuária e Industrial). Devido esta razão, decidiu-se fazer a escolha de cultivares de soja produzida nas últimas safras e que fazem parte da produção do grupo de associados da COTRIJUÍ. São elas: EMBRAPA 133 (BRS 133), EMBRAPA 184 (BRS 184), COODETEC 205 (CD 205), COODETEC 206 (CD 206), EMBRAPA 48 (EMB 48), SYNGENTA 8350 (NK 8350), FEPAGRO 10 (RS 10) e MONSOY 8000 RR (MSOY 8000 RR), safra 2005/2006.

2.3 ANÁLISE ESTATÍSTICA DAS DIMENSÕES

Para determinar as variações das dimensões presentes nas cultivares estudadas, foram realizadas medidas através de um paquímetro da marca Mitutoyo com calibração de 0,05mm.

Escolheram-se, aleatoriamente, cinquenta sementes de cada cultivar para as medições de comprimento, largura e espessura, sendo anotadas as medidas máximas e mínimas. Considerou-se comprimento a medida do ápice à base da semente, largura e espessura a região mediana da semente.

Para cada uma das variáveis estudadas, calculou-se a média aritmética, o desvio padrão, o erro padrão e a amplitude de variação.

Por fim, determinou-se a média da excentricidade e esfericidade, calculadas para cada uma das variedades.

2.4 APLICAÇÃO DE REDES NEURAI NO PROCESSAMENTO DE IMAGENS

Com a intenção de propor uma forma de automatizar a análise morfológica de grãos de soja na identificação de algumas cultivares e validar a utilização de redes neurais artificiais na padronização de imagens que não seguem um padrão rígido, optou-se para este trabalho o desenvolvimento de uma ferramenta (*toolbox*) utilizando a plataforma MATLAB Versão 7.0.

2.5 PROCESSAMENTO DAS IMAGENS

Como visto no capítulo 1, o processamento de imagem é dividido em cinco etapas. Para a primeira etapa, a aquisição das imagens, foi adquirida imagens digitais de algumas variedades de grãos de soja.

Para a realização das fotos, as sementes foram colocadas sobre uma superfície plana composta por um material presente em câmaras escuras (preto e fosco), utilizado em estúdios fotográficos. Os grãos foram fotografados por uma câmera digital Coolpix995 da marca Nikon, acoplada a um tripé e ângulo de captação superior reto de 90°, com resolução fina de 1280 x 960 pixels sob luz fluorescente. A câmera foi conectada a um adaptador que converteu as imagens em uma saída USB que por sua vez foi conectado ao computador onde as imagens foram salvas em formato JPEG.

A partir da segunda etapa são executados procedimentos no software MATLAB através da ferramenta desenvolvida durante este trabalho.

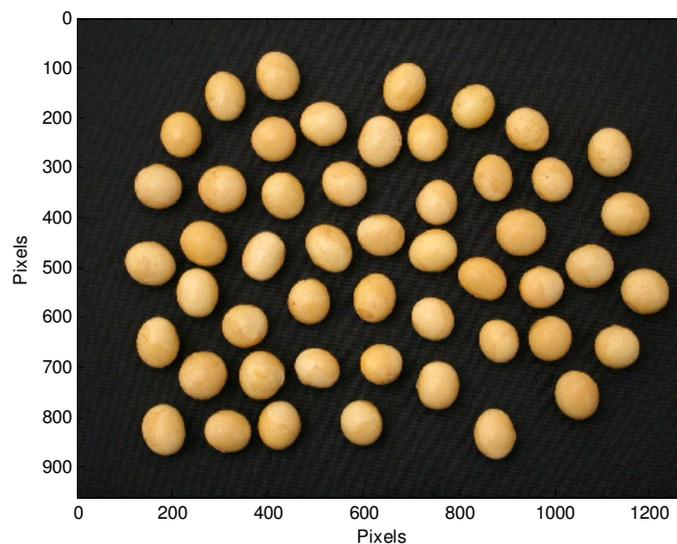


Figura 20: Imagem original dos grãos de soja

A imagem a ser processada, ilustrada na Figura 20, é inserida ao programa onde na etapa de pré-processamento é feita a suavização em tons de cinza através da função *rgb2gray*, conforme Figura 21.

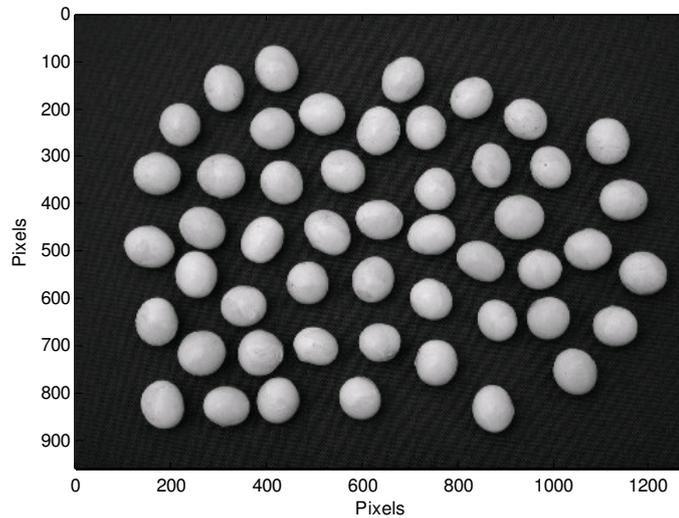


Figura 21: Imagem em tons de cinza

Esta função retorna uma matriz, onde cada posição da matriz representa um pixel e seu valor representa um tom de cinza do referido pixel.

Na próxima etapa é realizada a segmentação, onde se utilizou alguns métodos para efetuar a detecção dos contornos dos grãos. De acordo com a característica das imagens obtidas, o Método de Prewitt apresentou o melhor resultado na detecção dos contornos, conforme Figura 22.

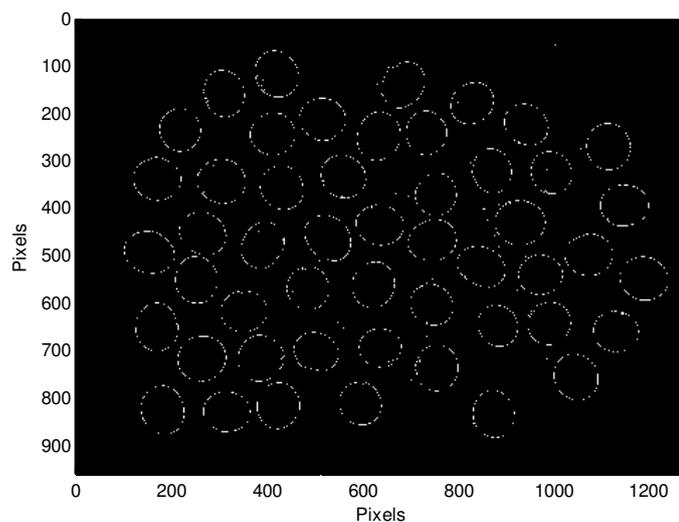


Figura 22: Bordas detectadas pelo Método de Prewitt

Contudo, como pode ser observado, o resultado não foi satisfatório, apresentando contornos fracos e descontínuos. Assim, foi necessário realizar a dilatação dos contornos com a função *imdilate*, obtendo um bom resultado de acordo com a Figura 23.

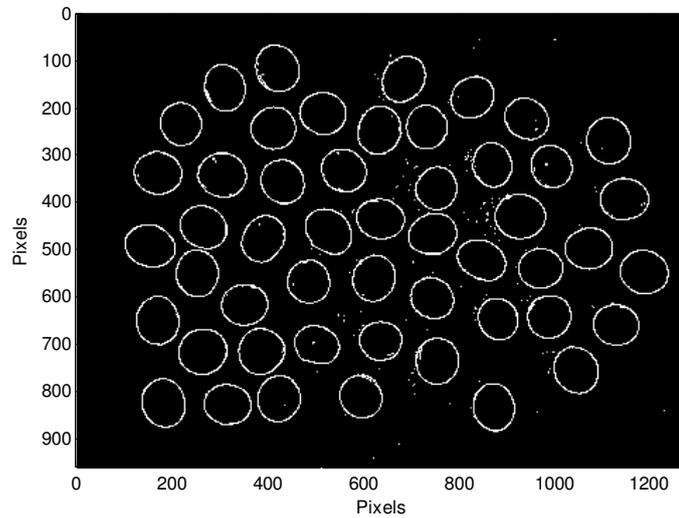


Figura 23: Dilatação dos contornos

A dilatação dos contornos ainda resultou em alguns contornos descontínuos, então se aplicou a função *imfill*, que preenche todos os grãos que possuíam contornos contínuos, como mostra a Figura 24.

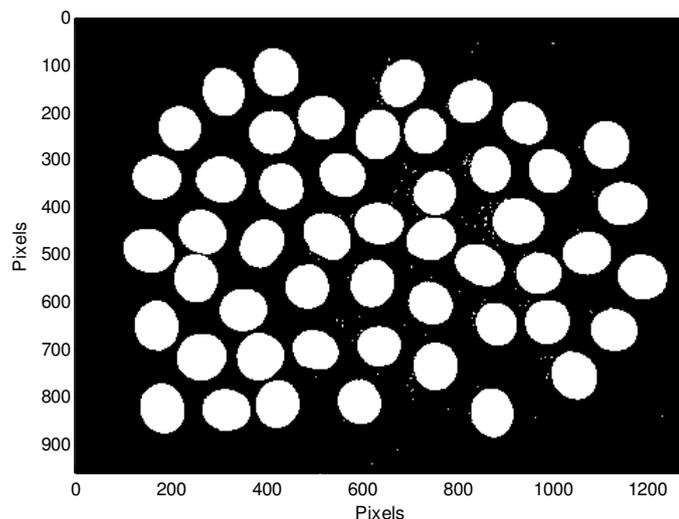


Figura 24: Preenchimento dos grãos

Devido à dilatação dos contornos executada anteriormente, alguns grãos perderam suas características, dificultando a identificação dos padrões nas etapas posteriores. Por isso, utilizou-se a função *imerode* para limpar as bordas dos grãos reduzindo a dilatação realizada

anteriormente. Logo, os contornos descontínuos também foram removidos como pode ser visto na Figura 25.

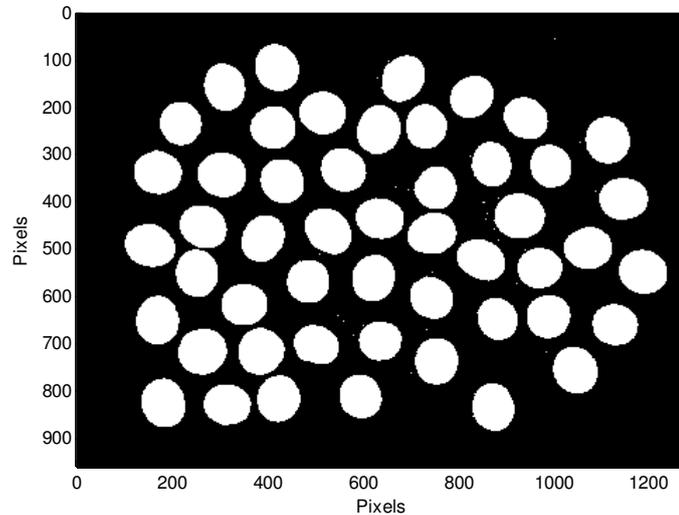


Figura 25: Limpeza das bordas dos grãos e remoção dos contornos descontínuos

Finalizando a etapa de segmentação foi realizada a remoção dos ruídos através da função *bwareaopen*. Assim, aglomerados de pixels que poderiam ser considerados como objetos a serem identificados, mas que por sua vez não representavam os grãos e sim algum tipo de interferência, foram retirados da imagem, como pode ser observado na Figura 26.

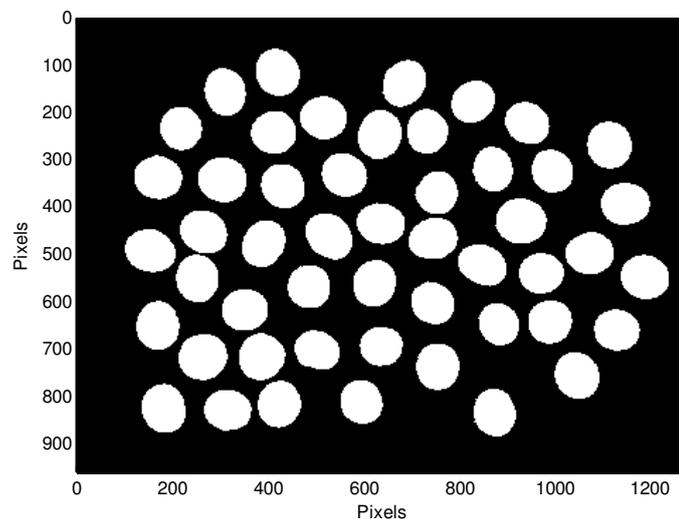


Figura 26: Remoção de objetos menores que 700 pixels

Para isto, foi passado para a função o tamanho dos aglomerados de pixels que se deseja remover, sendo definido para isto a remoção de objetos menores de 700 pixels, finalizando assim, a etapa de segmentação.

Após a segmentação, iniciou-se a etapa de representação onde foram extraídas da imagem resultante, as características para a identificação morfológica de cada grão.

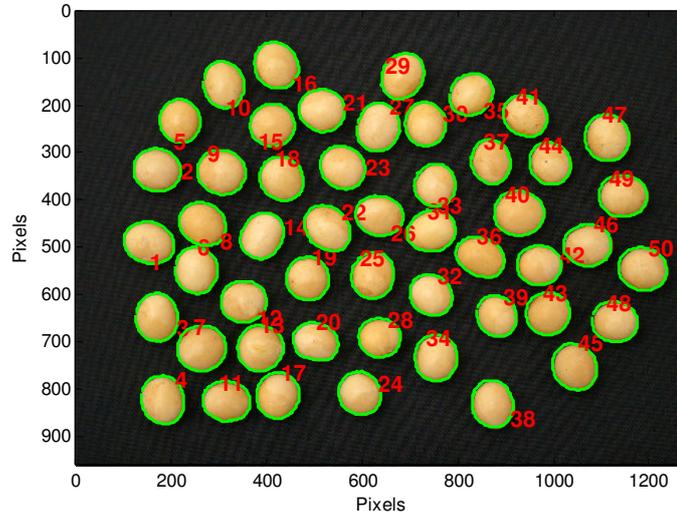


Figura 27: Imagem original com os grãos identificados

Para isso, aplicou-se a função *bwboundaries*, que retornou as coordenadas de cada pixel e uma numeração seqüencial para cada grão, ilustrado na Figura 27.

Através destas coordenadas resultantes da função, extraíram-se da imagem os pixels de cada grão identificados por uma matriz. Devido aos diferentes formatos dos grãos, obtiveram-se matrizes de dimensões variadas. Para resolver este problema foi feita uma varredura nestas matrizes a fim de se identificar a maior dimensão possível entre elas.

Assim, as matrizes menores foram preenchidas com zeros para igualar a dimensão entre todas. Após este processo, cada grão foi definido em termos de valores binários em um grid de dimensão 130 x 130 pixels. A Figura 28 mostra o esquema de um grão de soja através de uma matriz em um grid de tamanho 70 x 70 pixels.

Finalizando esta etapa, as matrizes correspondentes a cada grão foram transformadas em vetores coluna para que pudessem ser inseridas como dados de entrada na rede neural na próxima etapa.

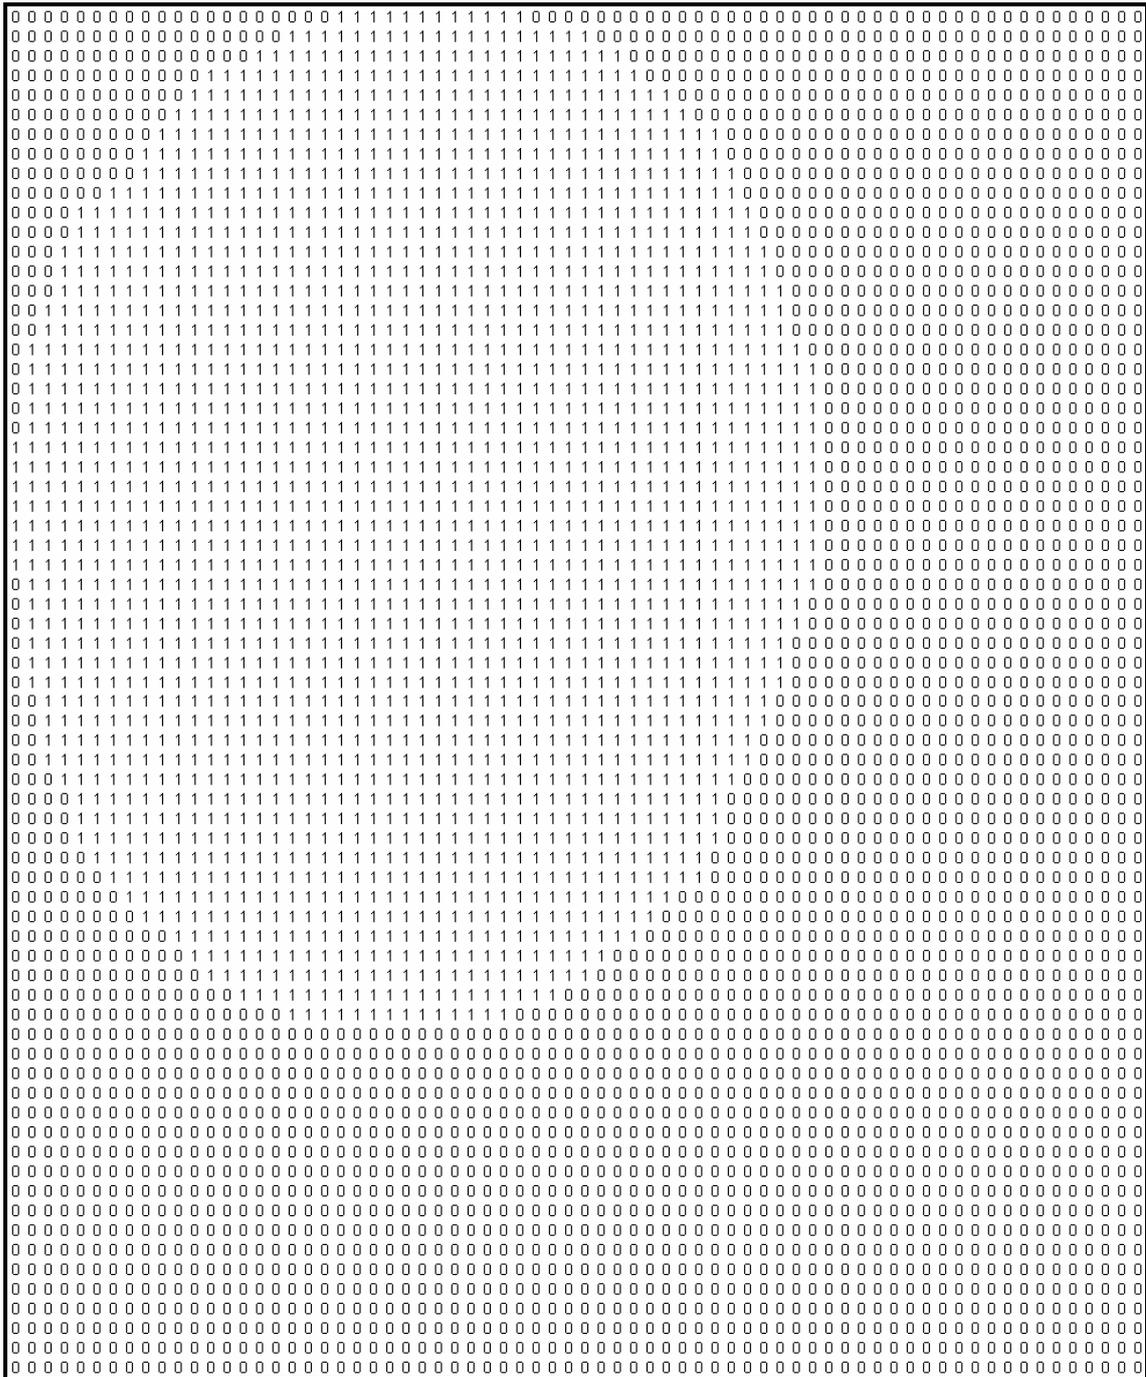


Figura 28: Representação do grão através da matriz

Na etapa de reconhecimento e interpretação, os dados fornecidos pela etapa anterior são inseridos em uma rede neural artificial, onde são identificados os padrões morfológicos (variedades) dos grãos. O padrão de cada grão é mostrado um a um, bem como o número total de grãos identificados por padrão. E ao final é mostrada a porcentagem do número de grãos encontrados por cada padrão.

2.6 ARQUITETURA DA REDE NEURAL

De acordo com Rich (1993), Tafner (1995), Russeell (1995), Laesch (1996) e Haykin (2001), a arquitetura de rede neural indicada para o tipo de reconhecimento de padrões para este trabalho é a rede *feedforward* (propagação) multicamadas, e seu aprendizado está relacionado através do algoritmo de aprendizado *backpropagation* (retropropagação).

Para a criação da referida rede foi utilizada a função *newff*, a qual cria um objeto de rede que requer quatro argumentos de entrada, conforme segue:

- 1º) O primeiro argumento é uma matriz $R \times 2$ que contém os valores mínimos e máximos para cada elemento do vetor de entrada R , onde R configura também o número de entradas da rede;
- 2º) O segundo argumento é um vetor que contém os tamanhos de cada camada;
- 3º) O terceiro argumento é um vetor celular que contém os nomes das funções de transferência para cada camada;
- 4º) O quarto e último argumento contém o nome da função de treinamento utilizada.

A função *newff* juntamente com os parâmetros, responsáveis pela criação do objeto de rede utilizado na implementação é descrita na linha de código abaixo.

```
net = newff(minmax(vetor_grao),[S1 S2 S3 S4],{'logsig' 'logsig' 'logsig' 'logsig'},'traincgb')
```

Os dados que serão inseridos na rede estão limitados entre os valores 0 e 1 devido aos procedimentos executados na etapa de segmentação, onde 0 significa a cor preta e 1 a cor branca como pode ser visto na Figura 29. As matrizes de pixels resultantes da segmentação foram transformadas em vetores colunas e armazenadas na variável *vetor_grao*.

Como pode ser visto na linha de código acima, a variável *vetor_grao* é passada como argumento para a função *minmax*, que retorna uma matriz com os valores mínimo e máximo de cada linha da matriz *vetor_grao*, onde cada linha representa uma entrada da rede

neural. Assim, o número de linhas da matriz resultante da função *minmax* define o número de entradas da rede. A matriz *vetor_grao* é definida na fase de treinamento.

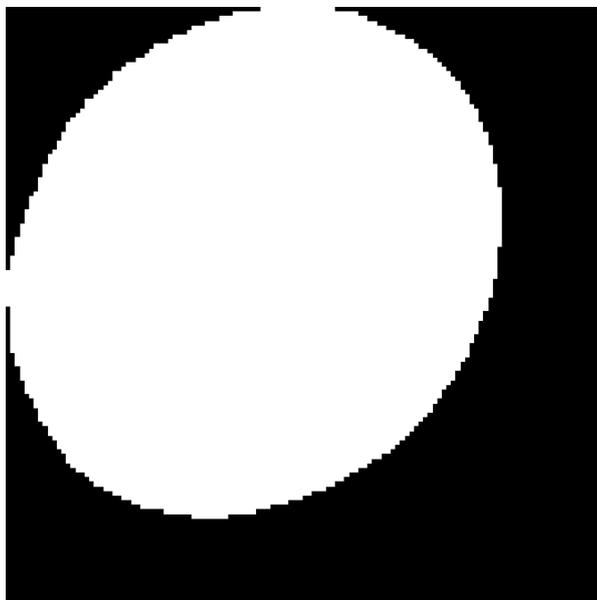


Figura 29: Imagem binária do grão de soja

A variável *S1* é o número de neurônios da primeira camada oculta definida por 90, a variável *S2* é o número de neurônios da segunda camada oculta definida por 70 e *S3* é o número de neurônios da terceira camada oculta definida por 60. Por sua vez, a variável *S4* é o número de neurônios da camada de saída, definida por 8, onde cada saída representa um padrão (cultivar) a ser reconhecido, os quais também foram definidos na etapa de treinamento.

O próximo argumento passado à função *newff* é o termo `{'logsig' 'logsig' 'logsig' 'logsig'}`, que configura a micro-estrutura da rede, definindo a função de transferência sigmóide (logística) para todas as camadas ocultas e para a camada de saída. Esta função generaliza as saídas de cada neurônio em valores entre 0 e 1.

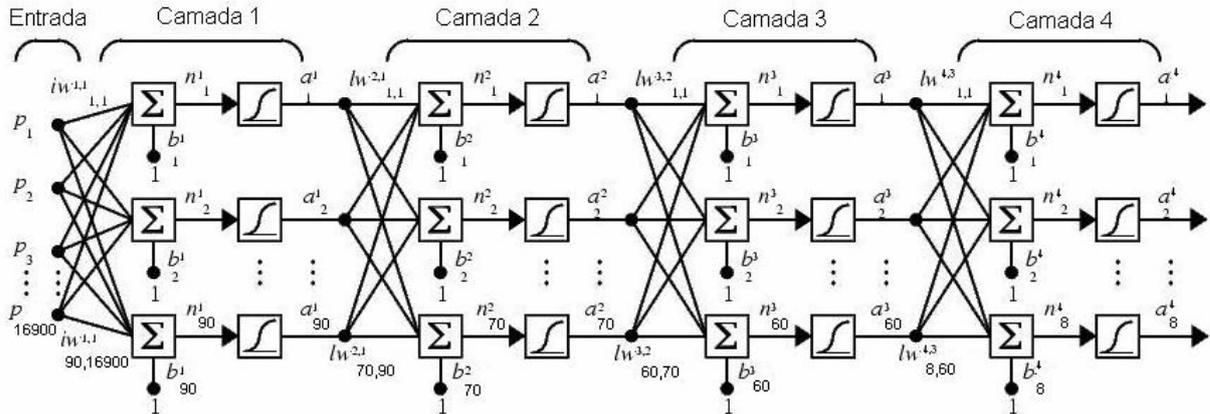


Figura 30: Arquitetura da rede neural utilizada

O último parâmetro define a função *traincgb* como função de treinamento da rede.

A Figura 30 ilustra a configuração do modelo neural através da camada de entrada, camadas ocultas e camada de saída bem como o número de neurônios constituintes em toda a arquitetura.

2.7 TREINAMENTO DA REDE NEURAL

Após a configuração da arquitetura da rede neural foi executado o treinamento para o reconhecimento das variedades de soja. Para isso, foi definido um conjunto de treinamento e um conjunto de saídas desejadas. O conjunto de treinamento foi submetido à etapa de pré-processamento, que resultou em uma matriz de dimensão 16900 por 50, onde cada coluna representa um grão reconhecido no conjunto de treinamento.

Estabelecidas às dimensões do conjunto de treinamento, definiu-se o conjunto de saídas desejadas (vetores objetivos) como sendo uma matriz 50 por 8 em que as colunas representam à saída desejada para cada grão e as linhas representam os padrões a serem treinados, ou seja, cada coluna foi preenchida com zeros exceto na posição que representa esse padrão onde foi inserido o valor 1, formando uma matriz de rótulos para os grãos do conjunto de treinamento, conforme a Figura 31

BRS 133	BRS 184	CD 205	CD 206	EMB 48	NK 8350	RS 10	MSOY 8000RR
1	0	0	0	0	0	0	0
0	1	0	0	0	0	0	0
0	0	1	0	0	0	0	0
0	0	0	1	0	0	0	0
0	0	0	0	1	0	0	0
0	0	0	0	0	1	0	0
0	0	0	0	0	0	1	0
0	0	0	0	0	0	0	1

Figura 31: Vetores objetivos

Antes de iniciar o treinamento foram definidos alguns parâmetros para a função *traincgb*. O primeiro parâmetro é referente à margem de erro aceita pela rede, (*net.trainParam.goal* = 0,00001), que foi definido como 0,00001. O segundo parâmetro é a quantidade de vezes que o conjunto de treinamento será apresentado à rede, chamada de época (*net.trainParam.epochs* = 10000), definida em 10000. Estes dois parâmetros são fundamentais, pois são os parâmetros de parada do treinamento da rede. O treinamento é finalizado quando a rede atinge a margem de erro ou quando alcança a quantidade de épocas definida.

Ao término da definição dos parâmetros foi iniciado o treinamento da rede, para o qual se utilizou a função *train* como mostra a linha de código a seguir.

$$[net, tr] = train(net, vetor_grao, padroes)$$

A função *train* possui três argumentos de entrada como descritos abaixo.

1º) *net*: É o objeto de rede o qual será treinado;

2º) *vetor_grao*: É a matriz com o conjunto de treinamento;

3º) *padroes* : É a matriz com as saídas desejadas (objetivos), ou seja, os padrões a serem aprendidos pela rede (cultivares).

O retorno desta função é o objeto da rede treinada e um vetor com informações sobre o processo de aprendizado.

2.7.1 Algoritmo de treinamento

O algoritmo de treinamento é dividido em duas etapas, a etapa de *feedforward* (propagação), e a etapa *backpropagation* (retropropagação), como pode ser observado no fluxograma do Apêndice A.

Inicia-se o algoritmo atribuindo o valor 1 para a variável *época*, identificando a primeira iteração da rede. Em seguida são atribuídos valores randômicos as matrizes de pesos da camada oculta $IW_{90,16900}$ e da camada de saída $LW_{8,60}$.

Feito isto, atribui-se a rede um vetor com os valores do primeiro segmento do conjunto de treinamento $p_{16900,1}$, que identifica os primeiros grãos a serem treinados. Neste ponto inicia-se a etapa *feedforward*, onde são calculados os valores de saída da camada oculta conforme a equação (2.1).

$$a_{90,1}^1 = f \left(IW_{90,16900} \cdot p_{16900,1} + b_{90,1}^1 \right) \quad (2.1)$$

Nesta equação é multiplicada a matriz de pesos da camada oculta com o vetor contendo os dados do conjunto de treinamento, sendo somado as constantes dos neurônios $b_{90,1}^1$. Este valor é aplicado à função de transferência, definida na implementação da rede, gerando um vetor de saída dos neurônios da camada oculta $a_{90,1}^1$.

Seguindo para a próxima camada, tem-se a matriz dos pesos multiplicada pelo vetor de saída da 1ª camada, caracterizando a propagação da rede.

$$a_{70,1}^2 = f \left(LW_{70,90} \cdot a_{90,1}^1 + b_{70,1}^2 \right) \quad (2.2)$$

Na equação (2.2) tem-se a multiplicação da matriz de pesos da referida camada com o vetor de saída da camada anterior $a_{90,1}^1$ e somado as constantes dos neurônios $b_{70,1}^2$. Este valor é aplicado novamente à função de transferência, gerando um vetor de saída $a_{70,1}^2$.

Para a última camada oculta, toma-se a matriz dos pesos multiplicada pelo vetor $a_{70,1}^2$, prosseguindo a propagação.

$$a_{60,1}^3 = f(LW_{60,70} \cdot a_{70,1}^2 + b_{60,1}^3) \quad (2.3)$$

Para a equação (2.3) tem-se a multiplicação da matriz de pesos da 3ª camada com o vetor de dados da etapa anterior, adicionado as constantes dos neurônios $b_{60,1}^3$. O resultado aplicado à função de transferência dá origem a um vetor de saída $a_{60,1}^3$.

Para a camada de saída às equações são semelhantes, sendo a matriz de pesos desta camada multiplicada pelo vetor de saída da 3ª camada, finalizando a propagação da rede.

$$a_{8,1}^4 = f(LW_{8,60} \cdot a_{60,1}^3 + b_{8,1}^4) \quad (2.4)$$

O vetor $a_{8,1}^4$ representa a saída da rede, que é usado para comparar com o vetor de saída desejado t , no qual é calculado o erro E . Este é comparado com a margem de erro aceita pela rede definida por E' . Se o erro for menor ou igual à margem de erro aceita, o algoritmo é finalizado, pois assim, a rede é definida como treinada, caracterizando o primeiro parâmetro de parada. Caso contrário verifica-se o segundo parâmetro de parada, definido pela variável *época*. Se esta atingir o máximo de iterações definidas, o algoritmo pára e a rede não foi capaz de alcançar a margem de erro estipulada, ou seja, não alcançou o aprendizado desejado. Porém, se a variável *época* for menor que o valor máximo de iterações definidas, o algoritmo continua, iniciando assim a etapa *backpropagation*.

Nesta etapa são calculados os erros da camada de saída e da 3ª camada oculta, onde a equação que calcula o erro desta camada oculta depende do cálculo do erro da camada de saída, caracterizando a retropropagação.

Nas equações (2.5) e (2.6) é calculado por primeiro o erro para a camada de saída $\delta_{8,1}^4$, multiplicando-se a matriz jacobiana J^T das funções de transferência da referida camada

e o erro da saída da rede $(a-t)_{8,1}$. Este erro é utilizado para calcular as correções dos pesos da camada de saída $\Delta LW_{8,60}$, o qual é multiplicado pela constante η que define o tamanho do passo do aprendizado a cada iteração da rede bem como a saída da 3ª camada que é a entrada da camada de saída $(a^3)_{1,60}$.

$$\delta_{8,1}^4 = \text{grad } f = J^T \cdot (a-t)_{8,1} \quad (2.5)$$

$$\Delta LW_{8,60} = \eta \cdot \delta_{8,1}^4 \cdot (a^3)_{1,60} \quad (2.6)$$

Para o cálculo do erro da camada oculta $\delta_{1,60}^3$, multiplica-se o erro da camada de saída $(\delta^4)_{1,8}^T$ pelos antigos pesos da mesma camada $LW_{8,60}$. Já para o cálculo do erro da camada oculta $\delta_{1,70}^2$, multiplica-se o erro da 3ª camada $(\delta^3)_{1,60}^T$ pelos antigos pesos da mesma camada $LW_{60,70}$ e assim para o cálculo do erro da camada $\delta_{1,90}^1$, conforme as equações (2.7), (2.8) e (2.9).

$$\delta_{1,60}^3 = (\delta^4)_{1,8}^T \cdot LW_{8,60} \quad (2.7)$$

$$\delta_{1,70}^2 = (\delta^3)_{1,60}^T \cdot LW_{60,70} \quad (2.8)$$

$$\delta_{1,90}^1 = (\delta^2)_{1,70}^T \cdot LW_{70,90} \quad (2.9)$$

As correções para os pesos da camada oculta $\Delta IW_{16900,90}$ são obtidas através do produto da constante η pela derivada da função de transferência da camada oculta $f'(a^1)_{90,90}$, pelo erro da 2ª camada oculta $(\delta^2)_{90,1}^T$ bem como pelos valores de entrada da rede $(p)_{1,16900}^T$, descritos pela equação (2.10).

$$\Delta IW_{16900,90} = \eta \cdot f'(a^1)_{90,90} \cdot (\delta^2)_{90,1}^T \cdot (p)_{1,16900}^T \quad (2.10)$$

Para finalizar, as correções dos pesos são somadas aos pesos antigos conforme as equações (2.11) e (2.12), terminando assim uma iteração da rede.

$$IW_{16900,90} = IW_{16900,90} + \Delta IW_{16900,90} \quad (2.11)$$

$$LW_{8,60} = LW_{8,60} + \Delta LW_{8,60} \quad (2.12)$$

Logo, a variável *época* é incrementada novamente, passando para a próxima iteração.

3 RESULTADOS E DISCUSSÕES

3.1 INTRODUÇÃO

Neste capítulo são apresentados e discutidos os principais resultados obtidos a partir da metodologia utilizada neste trabalho.

Inicialmente, são avaliadas e comparadas as características dos grãos de soja, com a análise das medidas de posição e dispersão das dimensões bem como o cálculo da excentricidade e esfericidade. Em seguida, são apresentadas as etapas do treinamento da rede neural através dos dados de convergência e a curva do erro descrita durante o treinamento.

No final, é feita a apresentação dos resultados dos testes de confiabilidade do modelo proposto, considerando a porcentagem e a frequência de reconhecimento dos padrões estipulados na etapa de treinamento da RNA.

3.2 RESULTADO DA ANÁLISE ESTATÍSTICA DAS DIMENSÕES

Nas Tabelas 4 a 11 se encontram os resultados estatísticos das dimensões para cada cultivar representadas pelo comprimento (*a*), largura (*b*) e espessura (*c*), com a análise alguns parâmetros.

Tabela 4: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar BRS 133 (N=50)

Variáveis	Médias	Desvio padrão	Erro padrão (%)	Amplitude de variação
<i>a (mm)</i>	6,79	0,14	2,00	6,55 - 7,05
<i>b (mm)</i>	6,27	0,09	1,21	6,00 - 6,45
<i>c (mm)</i>	5,43	0,18	2,57	5,00 - 5,80

Tabela 5: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar BRS 184 (N=50)

Variáveis	Médias	Desvio padrão	Erro padrão (%)	Amplitude de variação
<i>a (mm)</i>	7,14	0,18	2,54	6,75 - 7,55
<i>b (mm)</i>	6,16	0,15	2,13	5,85 - 6,45
<i>c (mm)</i>	5,14	0,23	3,30	4,65 - 5,50

Tabela 6: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar CD 205 (N=50)

Variáveis	Médias	Desvio padrão	Erro padrão (%)	Amplitude de variação
<i>a (mm)</i>	7,15	0,13	1,83	6,95 - 7,40
<i>b (mm)</i>	6,48	0,15	2,10	6,20 - 6,80
<i>c (mm)</i>	5,71	0,15	2,11	5,40 - 6,10

Tabela 7: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar CD 206 (N=50)

Variáveis	Médias	Desvio padrão	Erro padrão (%)	Amplitude de variação
<i>a (mm)</i>	7,72	0,15	2,16	7,40 - 8,05
<i>b (mm)</i>	6,81	0,16	2,19	6,5 - 7,10
<i>c (mm)</i>	5,52	0,18	2,48	5,20 - 5,90

Tabela 8: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar EMB 48 (N=50)

Variáveis	Médias	Desvio padrão	Erro padrão (%)	Amplitude de variação
<i>a (mm)</i>	6,81	0,17	2,33	6,50 - 7,35
<i>b (mm)</i>	6,21	0,16	2,32	5,90 - 6,60
<i>c (mm)</i>	5,34	0,19	2,69	5,00 - 5,70

Tabela 9: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar NK 8350 (N=50)

Variáveis	Médias	Desvio padrão	Erro padrão (%)	Amplitude de variação
<i>a (mm)</i>	6,75	0,15	2,19	6,40 - 7,05
<i>b (mm)</i>	6,23	0,11	1,49	5,95 - 6,45
<i>c (mm)</i>	5,63	0,18	2,50	5,05 - 6,00

Tabela 10: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar RS 10 (N=50)

Variáveis	Médias	Desvio padrão	Erro padrão (%)	Amplitude de variação
<i>a (mm)</i>	7,96	0,35	4,97	7,05 - 8,60
<i>b (mm)</i>	6,88	0,28	3,90	6,35 - 7,70
<i>c (mm)</i>	6,22	0,27	3,77	5,70 - 6,75

Tabela 11: Medidas de posição e dispersão do comprimento, largura e espessura da cultivar MSOY 8000 RR (N=50)

Variáveis	Médias	Desvio padrão	Erro padrão (%)	Amplitude de variação
<i>a</i> (mm)	7,26	0,17	2,43	7,00 - 7,60
<i>b</i> (mm)	6,72	0,21	2,98	5,90 - 7,05
<i>c</i> (mm)	6,10	0,28	3,99	5,55 - 6,90

As sementes apresentaram entre si uma pequena variabilidade biométrica, problema este, ligado diretamente ao reconhecimento de padrões.

Na Tabela 12 tem-se a comparação estatística das dimensões das cultivares.

Tabela 12: Comparação estatística das dimensões entre as cultivares (N=50)

Cultivares	<i>a</i> (mm)	<i>b</i> (mm)	<i>c</i> (mm)
BRS 133	6,79	6,27	5,43
BRS 184	7,14	6,16	5,14
CD 205	7,15	6,48	5,71
CD 206	7,72	6,81	5,52
EMB 48	6,81	6,21	5,34
NK 8350	6,75	6,23	5,63
RS 10	7,96	6,88	6,22
MSOY 8000RR	7,26	6,72	6,10

Em relação às medidas, o comprimento médio ficou na faixa de 6,75 a 7,96 mm, a largura na faixa de 6,16 a 6,88 mm e a espessura na faixa de 5,14 a 6,22 mm.

Na Tabela 13 estão apresentados os dados de excentricidade, esfericidade e volume das variedades de soja analisadas.

Tabela 13: Dados de excentricidade e esfericidade das variedades de soja

Cultivares	Excentricidade (b/a)	Esfericidade (ϕ)	Volume (V)
BRS 133	0,9238	0,9043	121,09
BRS 184	0,8633	0,8533	118,32
CD 205	0,9054	0,8975	138,58
CD 206	0,8818	0,8574	151,91
EMB 48	0,9122	0,8943	118,28
NK 8350	0,9235	0,9167	123,84
RS 10	0,8648	0,8782	178,46
MSOY 8000 RR	0,9259	0,9195	155,82

3.3 ETAPAS DO TREINAMENTO DA RNA

A rede foi treinada pelo método *backpropagation*, descrito anteriormente, utilizando oito variedades de soja: BRS 133, BRS 184, CD 205, CD 206, EMB 48, NK 8350, RS 10 e MSOY 8000RR. Para cada variedade foi associada uma saída distinta, definida na etapa de treinamento.

A

Figura 32 mostra os dados de convergência durante o treinamento através da função *traincgb*.

```

** Warning in INIT
** Network "input{1}.range" has a row with equal min and max values.
** Constant inputs do not provide useful information.

TRAINCGB-srchcha, Epoch 0/10000, SSE 454.566/1e-005, Gradient 483.68/1e-006
TRAINCGB-srchcha, Epoch 20/10000, SSE 205.788/1e-005, Gradient 57.2031/1e-006
TRAINCGB-srchcha, Epoch 40/10000, SSE 141.971/1e-005, Gradient 82.9396/1e-006
TRAINCGB-srchcha, Epoch 60/10000, SSE 100.217/1e-005, Gradient 83.1637/1e-006
TRAINCGB-srchcha, Epoch 80/10000, SSE 66.3811/1e-005, Gradient 90.9342/1e-006
TRAINCGB-srchcha, Epoch 100/10000, SSE 42.2767/1e-005, Gradient 74.359/1e-006
TRAINCGB-srchcha, Epoch 120/10000, SSE 21.5944/1e-005, Gradient 83.966/1e-006
TRAINCGB-srchcha, Epoch 140/10000, SSE 8.59621/1e-005, Gradient 29.0052/1e-006
TRAINCGB-srchcha, Epoch 160/10000, SSE 4.06992/1e-005, Gradient 10.8216/1e-006
TRAINCGB-srchcha, Epoch 180/10000, SSE 2.59011/1e-005, Gradient 2.36156/1e-006
TRAINCGB-srchcha, Epoch 200/10000, SSE 2.1099/1e-005, Gradient 0.449872/1e-006
TRAINCGB-srchcha, Epoch 220/10000, SSE 1.94579/1e-005, Gradient 6.00067/1e-006
TRAINCGB-srchcha, Epoch 240/10000, SSE 1.02703/1e-005, Gradient 0.543344/1e-006
TRAINCGB-srchcha, Epoch 260/10000, SSE 0.0409091/1e-005, Gradient 0.31815/1e-006
TRAINCGB-srchcha, Epoch 280/10000, SSE 0.00956734/1e-005, Gradient 0.0564004/1e-006
TRAINCGB-srchcha, Epoch 300/10000, SSE 0.00307272/1e-005, Gradient 0.0136663/1e-006
TRAINCGB-srchcha, Epoch 320/10000, SSE 0.000490797/1e-005, Gradient 0.0061128/1e-006
TRAINCGB-srchcha, Epoch 340/10000, SSE 7.5931e-005/1e-005, Gradient 0.000814912/1e-006
TRAINCGB-srchcha, Epoch 352/10000, SSE 8.42069e-006/1e-005, Gradient 0.000125275/1e-006
TRAINCGB, Performance goal met.

```

Figura 32: Dados de convergência durante o treinamento

O gráfico da Figura 33 mostra a curva de convergência do treinamento, que iniciou com pouco mais de 10^2 e após 352 iterações (épocas) atingiu a meta desejada de 10^{-5} (0,00001) para o erro.

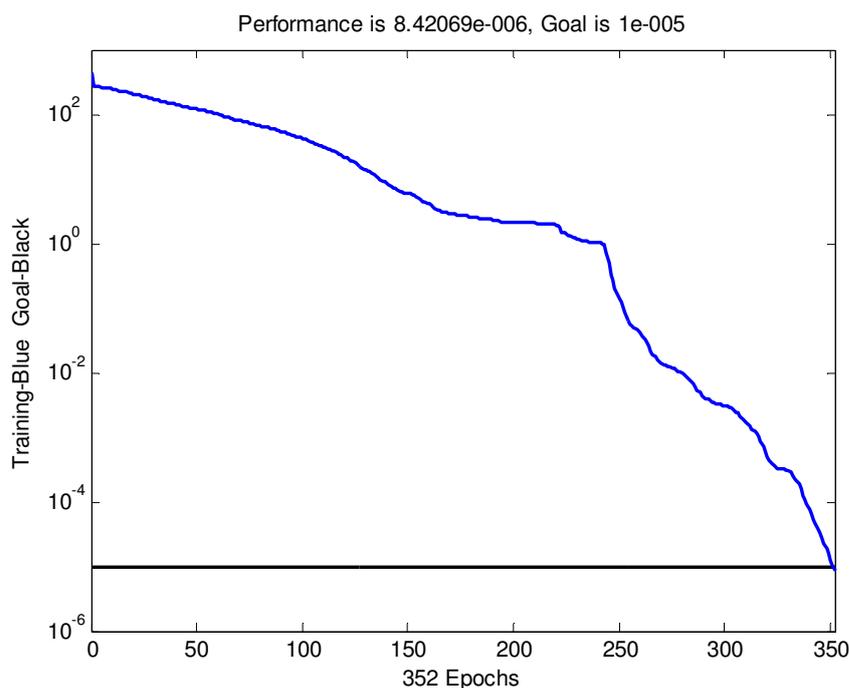


Figura 33: Curva de convergência do erro SSE durante o treinamento

3.4 TESTES REALIZADOS

A rede neural após atingir o treinamento foi armazenada em um arquivo de extensão *mat* do MATLAB. Esta foi submetida a vários testes, utilizando como entrada as imagens contendo as variedades de soja discriminadas da seguinte forma: BRS133.jpg, BRS184.jpg, CD205.jpg, CD206.jpg, EMB48.jpg, NK8350.jpg, RS10.jpg e MSOY8000RR.jpg.

Os resultados dos testes encontram-se nas próximas seções.

3.4.1 Reconhecimento dos Padrões

As imagens das variedades utilizadas para os testes eram compostas de 50 grãos cada, mas este número acabou sendo reduzido em alguns casos devido à etapa de segmentação, na qual nem todos os grãos foram detectados devido a algumas falhas durante o processamento.

Nas Tabelas 14 a 21 são apresentados os resultados obtidos após as análises das imagens de cada cultivar, as quais mostram o número de grãos identificados por padrão, à respectiva porcentagem e a quantidade de grãos presentes nas imagens.

Tabela 14: Resultado da análise da imagem BRS133.jpg

Imagem analisada: Variedade BRS 133		
Total de grãos identificados por padrão		
Padrão identificado	Quantidade de grãos	Porcentagem
BRS 133	15	34,09%
BRS 184	4	9,09%
CD 205	10	22,72%
CD 206	0	0%
EMB 48	4	9,09%
NK 8350	9	20,45%
RS 10	0	0%
MSOY 8000RR	2	4,55%
Total	44	100%

Tabela 15: Resultado da análise da imagem BRS184.jpg

Imagem analisada: Variedade BRS 184		
Total de grãos identificados por padrão		
Padrão identificado	Quantidade de grãos	Porcentagem
BRS 133	7	14,29%
BRS 184	27	55,1%
CD 205	4	8,16%
CD 206	1	2,04%
EMB 48	0	0%
NK 8350	1	2,04%
RS 10	6	12,24%
MSOY 8000RR	3	6,12%
Total	49	100%

Tabela 16: Resultado da análise da imagem CD205.jpg

Imagem analisada: Variedade CD 205		
Total de grãos identificados por padrão		
Padrão identificado	Quantidade de grãos	Porcentagem
BRS 133	9	23,08%
BRS 184	7	17,95%
CD 205	14	35,9%
CD 206	0	0%
EMB 48	5	12,82%
NK 8350	3	7,69%
RS 10	0	0%
MSOY 8000RR	1	2,56%
Total	39	100%

Tabela 17: Resultado da análise da imagem CD206.jpg

Imagem analisada: Variedade CD 206		
Total de grãos identificados por padrão		
Padrão identificado	Quantidade de grãos	Porcentagem
BRS 133	0	0%
BRS 184	3	6%
CD 205	0	0%
CD 206	27	54%
EMB 48	0	0%
NK 8350	0	0%
RS 10	16	32%
MSOY 8000RR	4	8%
Total	50	100%

Tabela 18: Resultado da análise da imagem EMB48.jpg

Imagem analisada: Variedade EMB 48		
Total de grãos identificados por padrão		
Padrão identificado	Quantidade de grãos	Porcentagem
BRS 133	9	18,37%
BRS 184	3	6,12%
CD 205	5	10,2%
CD 206	0	0%
EMB 48	20	40,82%
NK 8350	12	24,49%
RS 10	0	0%
MSOY 8000RR	0	0%
Total	49	100%

Tabela 19: Resultado da análise da imagem NK8350.jpg

Imagem analisada: Variedade NK 8350		
Total de grãos identificados por padrão		
Padrão identificado	Quantidade de grãos	Porcentagem
BRS 133	8	17,02%
BRS 184	1	2,13%
CD 205	4	8,51%
CD 206	0	0%
EMB 48	15	31,91%
NK 8350	19	40,43%
RS 10	0	0%
MSOY 8000RR	0	0%
Total	47	100%

Tabela 20: Resultado da análise da imagem RS10.jpg

Imagem analisada: Variedade RS 10

Total de grãos identificados por padrão

Padrão identificado	Quantidade de grãos	Porcentagem
BRS 133	0	0%
BRS 184	4	8%
CD 205	0	0%
CD 206	11	22%
EMB 48	0	0%
NK 8350	0	0%
RS 10	29	58%
MSOY 8000RR	6	12%
Total	50	100%

Tabela 21: Resultado da análise da imagem MSOY8000RR.jpg

Imagem analisada: Variedade MSOY 8000RR

Total de grãos identificados por padrão

Padrão identificado	Quantidade de grãos	Porcentagem
BRS 133	3	6,38%
BRS 184	4	8,51%
CD 205	2	4,26%
CD 206	4	8,51%
EMB 48	0	0%
NK 8350	0	0%
RS 10	1	2,13%
MSOY 8000RR	33	70,21%
Total	47	100%

3.4.2 Análise de Reconhecimento

Com o objetivo de avaliar o grau de reconhecimento da rede neural, realizaram-se testes para os cultivares aqui estudados. Para isto, foram tiradas 10 fotos separadas em grupos contendo 5, 10, 15, 20, 25, 30 e 35 grãos para cada variedade a fim de identificar o número de sementes necessárias em cada foto para melhor confiabilidade do modelo proposto. A Figura 34 esboça os grupos de fotos selecionados que serviram como testes para a RNA.

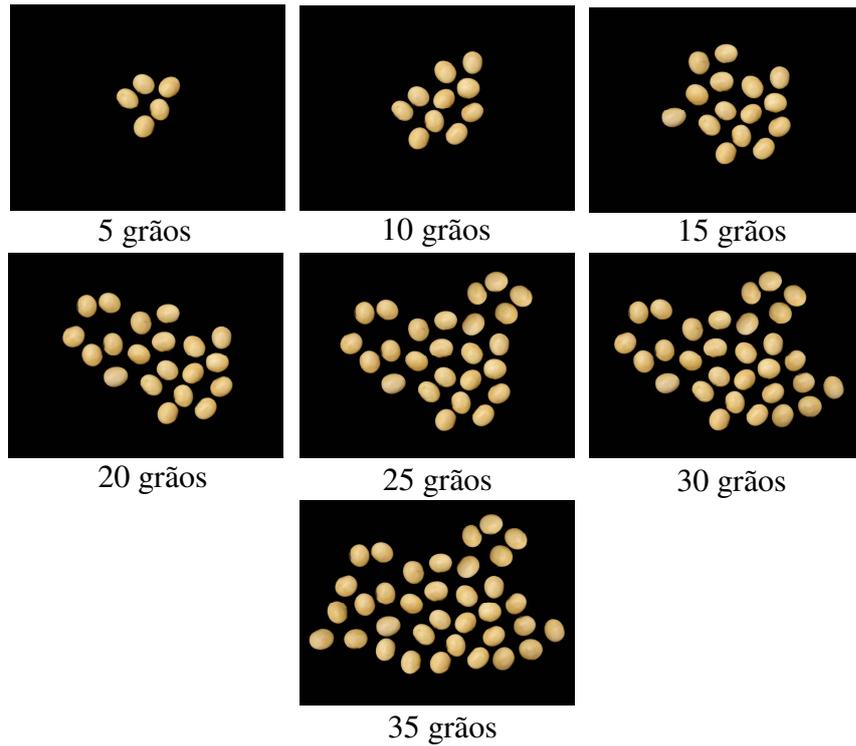


Figura 34: Esboço das imagens utilizadas para avaliação da RNA

As Figuras 35 a 42 mostram os gráficos resultantes do reconhecimento em relação aos grupos de fotos, os quais ilustram a frequência de reconhecimento bem como uma linha de tendência para cada caso.

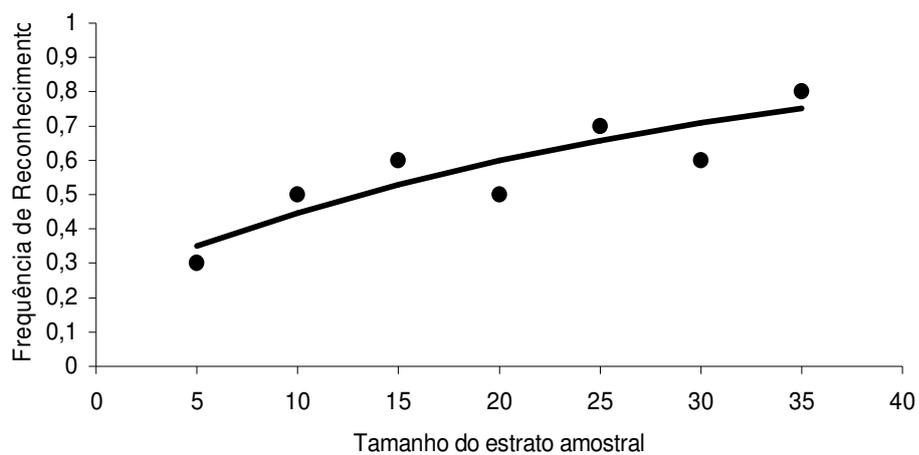


Figura 35: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade BRS 133

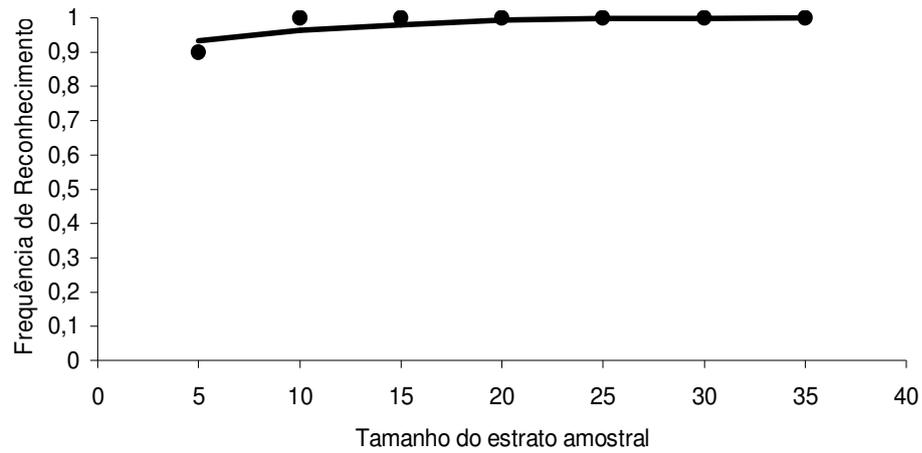


Figura 36: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade BRS 184

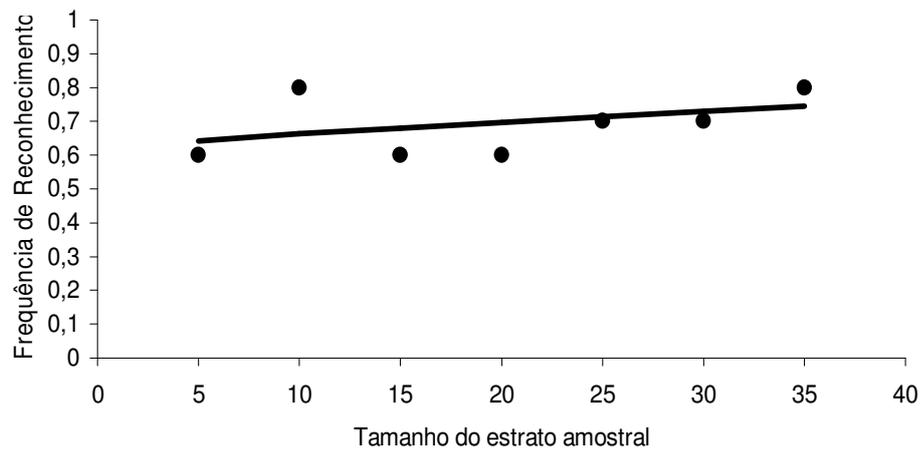


Figura 37: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade CD 205

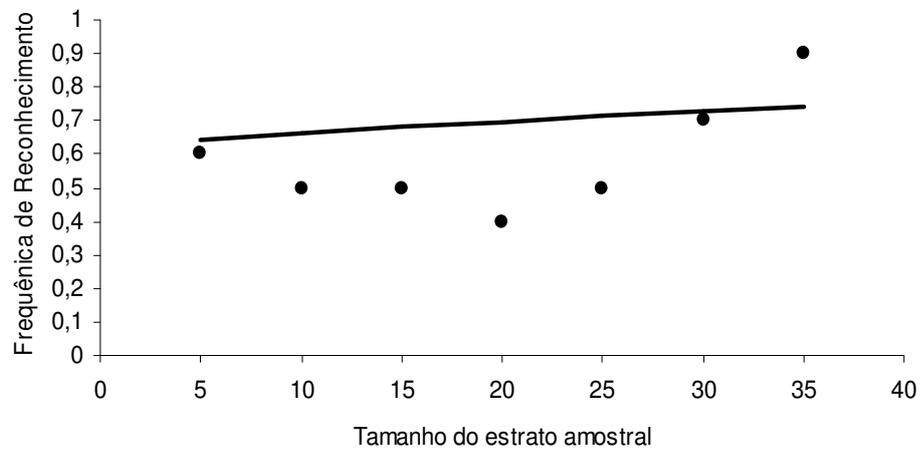


Figura 38: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade CD 206

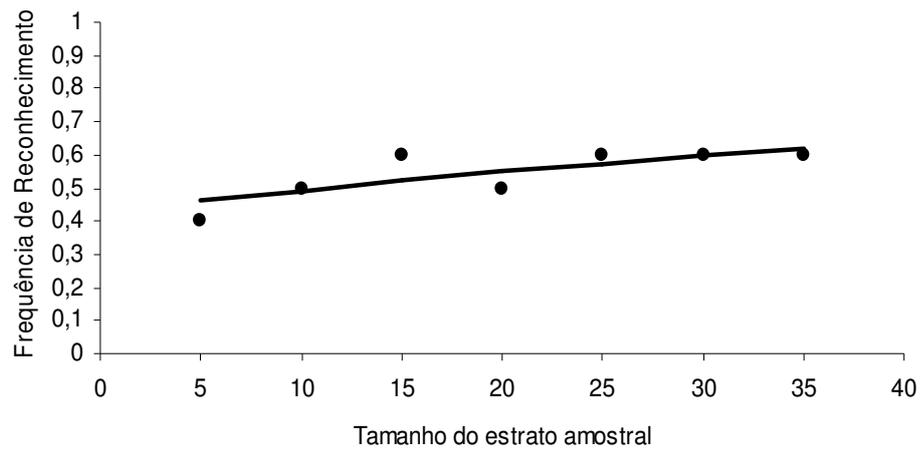


Figura 39: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade EMB 48

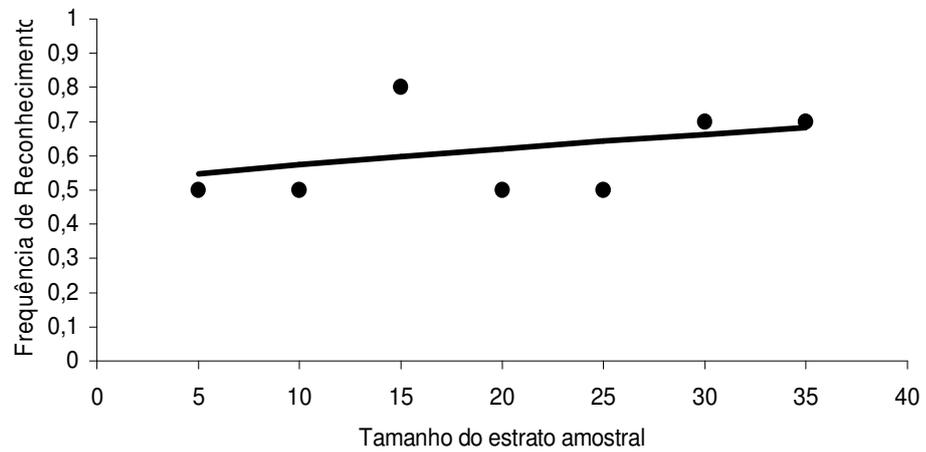


Figura 40: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade NK 8350

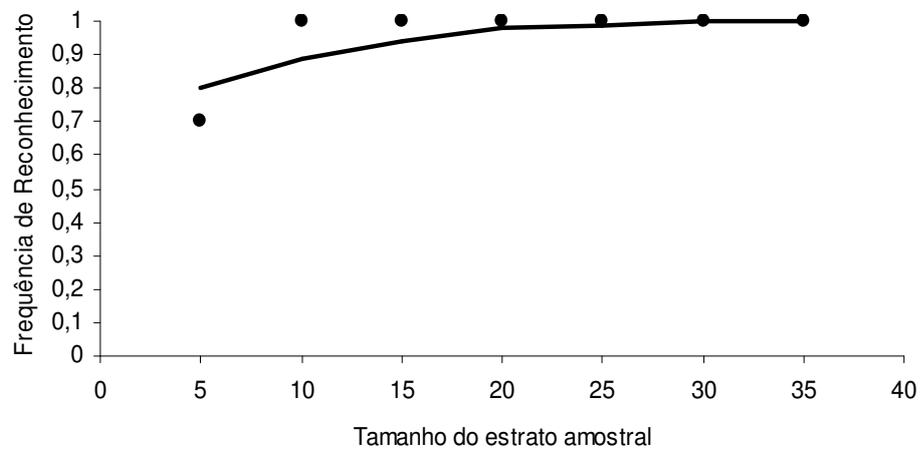


Figura 41: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade RS 10

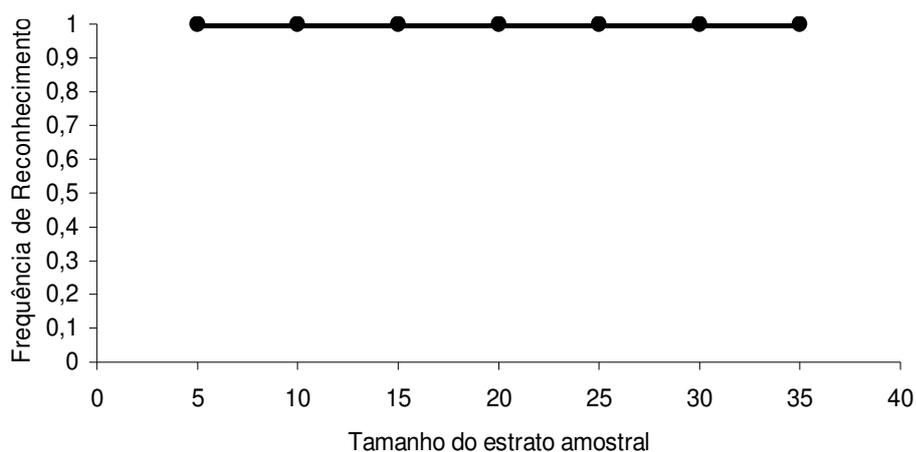


Figura 42: Influência do tamanho do estrato amostral sobre o reconhecimento da variedade MSOY 8000RR

Pode-se observar que com o aumento do número de grãos por foto, existe uma melhora significativa na identificação das variedades, mostrando-se um fator importante no reconhecimento das mesmas. Alguns gráficos como os encontrados nas Figuras 36, 41 e 42 tiveram resultados significativos quanto à frequência de reconhecimento, atingindo um alto grau de precisão com apenas 10 grãos por foto. Os gráficos das Figuras 35, 37 e 38 apresentaram resultados intermediários quanto ao reconhecimento, necessitando para isto um maior número de grãos nas imagens. Já os gráficos das Figuras 39 e 40 tiveram os piores resultados, onde o percentual de identificação não passou dos 70%.

Os valores ideais para o número de grãos e a respectiva porcentagem de reconhecimento atingido pela rede neural se encontram na Tabela 22.

Tabela 22: Valores ótimos do reconhecimento para as variedades

	BRS 133	BRS 184	CD 205	CD 206	EMB 48	NK 8450	RS 10	MSOY 8000RR
Número de grãos	35	15	35	35	30	35	15	15
Porcentagem	80%	100%	80%	90%	60%	70%	100%	100%

Nota-se que os cultivares que alcançaram 100% de reconhecimento foram aqueles em que o número de grãos foi reduzido em relação aos outros.

CONCLUSÃO

Neste trabalho foram utilizadas Redes Neurais Artificiais em conjunto com o Processamento de Imagens Digitais para a identificação de algumas variedades de soja com o objetivo de reduzir custos relacionados a este procedimento.

O modelo proposto foi configurado por uma rede *feedforward* multicamadas com aprendizado *backpropagation*, geralmente utilizado para este tipo de reconhecimento de padrões.

Ao longo do desenvolvimento deste estudo foram realizados inúmeros treinamentos visando chegar à melhor configuração da rede neural para o problema de identificação das variedades.

A melhor rede neural obtida utilizou 16900 entradas, 90 neurônios na 1ª camada intermediária, 70 neurônios na 2ª camada intermediária, 60 neurônios na 3ª camada intermediária e 8 neurônios na camada de saída, $\alpha = 0,1$ (passo de treinamento), $\beta = 0,95$ (momento), 10000 épocas de treinamento e 8 amostras para o treinamento.

Durante os testes realizados, a rede neural apresentou resultados satisfatórios, obtendo uma média de acerto acima de um terço do total de grãos analisados por variedade (N=50), mostrando que apesar da diminuição das informações fornecidas pelos dados inseridos na rede, ela foi capaz de generalizar os pesos das conexões do modelo proposto para a identificação das oito variedades de soja utilizadas neste estudo: BRS 133, BRS 184, CD 205, CD 206, EMB 48, NK 8350, RS 10 e MSOY 8000 RR.

Os resultados obtidos durante a verificação da frequência de reconhecimento dos padrões, mostraram que com o aumento do número de grãos (amostras) por foto houve uma melhora considerável na porcentagem de identificação. Através disto, definiu-se que o número “ótimo” de grãos ficou em torno dos 35 por imagem, obtendo um intervalo de 60 a 100% de reconhecimento para as variedades analisadas individualmente.

É possível afirmar que redes neurais artificiais associadas ao processamento de imagens são ferramentas que se adaptam adequadamente a projetos ligados a diferenciação taxonômica entre cultivares, podendo ser treinadas para tomar decisões de acordo com as características definidas.

A precisão de classificação ficou acima de um terço do total de grãos analisados por cada cultivar. Os resultados mostraram que o modelo de redes neurais foi capaz de identificar as variedades de soja mostrando-se uma ferramenta eficaz no processo de reconhecimento. As

simulações realizadas permitiram escolher a arquitetura de RNA (número de camadas e de neurônios) garantindo um bom desempenho.

Por outro lado, os resultados obtidos sugerem que a precisão pode ser melhorada adicionando mais características durante o treinamento da RNA, como cor, textura, etc.

Em trabalhos futuros, podem-se configurar outras arquiteturas de redes neurais para análise das imagens com o interesse de diminuir as etapas de pré-processamento, incorporar funcionalidades para a ferramenta desenvolvida, verificando sua utilização em outros tipos de reconhecimento e implementar um programa independente de plataforma para sua validação junto a profissionais na área da agricultura.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] AGUIAR, I. B., SADER, R., KRONKA, S. N., TAKAOKA, N. M. Efeitos do tamanho sobre o potencial de armazenamento de sementes de *Eucalyptus citriodora*. Hook. **Revista Brasileira de Sementes**, 9(1):63-72, 1987.
- [2] ANDRADE, M. C. **Um Algoritmo Interativo para Suavização e Segmentação de Imagens Digitais**. Centro de Desenvolvimento da Tecnologia Nuclear – CDTN. UFMG, Belo Horizonte, MG.
- [3] ANUÁRIO Brasileiro da Soja. Santa Cruz do Sul: Gazeta Santa Cruz, 2005.
- [4] ARMSTRONG, J. E. Baskin, C. C., DELOUCHE, J. C. Effect of mechanically sizing soybean on seed quality. **Journal of Seed Technology**, 12(1):54-8, 1988.
- [5] ARNOST JR., S. **Desenvolvimento de um Secador Transportador do Tipo Esteira com Escoamento Cruzado e Caracterização de Sementes de Gramíneas**. São Carlos: UFSCAR, 1997. Tese (Doutorado em Engenharia Química), Faculdade de Engenharia Química, Universidade Federal de São Carlos, 1997.
- [6] AUSTIN, R. B., LONGDEN, P. C. Some effects of seed size and maturity on the yield of carrot crops. **Journal of Horticultural Science**, 42:339-53, 1967.
- [7] AZEVEDO, F. M., L. M., OLIVEIRA, R. C. **Redes Neurais com Aplicações em Controle e em Sistemas Especialistas**, Visual Books, Florianópolis, 2000.
- [8] BECKERT, O. P. et al. **Absorção de água e potencial fisiológico em sementes de soja de diferentes tamanhos**. Sci. Agric., Piracicaba, v. 57, n. 4, p. 671-675, 2000.
- [9] BEVERIDGE, J. L., WILSIE, C. P. **Influence of depth at planting, seed size and variety on emergence and seedling vigor alfafa**. Agronomy Journal, 51:731-4, 1959.
- [10] BÓREM, A. **Melhoramento de Plantas**. Viçosa, UFV, p. 231, 232, 519, 545, 1997.
- [11] BULLOCK, D. et al. **Neural Networks for your toolbox**. Agricultural Engineering, July, 1992.
- [12] BUNCH, H. D. **Problems in seed processing**. Seed World, Chicago. v. 90, n. 9, p. 8-11, 1962.
- [13] BURRIS, J. S., EDJE, O. T., WAHAB, A. H. **Effect of seed size on seedling performance in soybean. II. Seedling growth and photosynthesis and field performance**. Crop Science, 13(2):207-10, 1973.
- [14] BRASIL, Ministério da Agricultura e Reforma Agrária. **Regras para análise de sementes**. Brasília: SNDA/DNDV/CLAV, 365 p., 1992.

- [15] CAVALCANTI MATA, M. E. R. M., ARAGÃO, R. F., SANATANA, E. F., SILVA, F.A.S. Estudo da morfologia geométrica em grãos. **Revista Nordestina de Armazenagem**, Campina Grande, v. 3, n. 1, p. 3-30, 1986.
- [16] CARLETON, A. E., COOPER, C. V., **Seed size effects upon seedling vigor of three forage legumes**. Crop Science. 12:183-6, 1972.
- [17] CARNAHAM, B.; LUTHER, H.A.; WILKES, J. O. **Applied numerical methods**. New York: John Wiley, 1969.
- [18] CARVALHO, N. M., NAKAGAWA, J. **Sementes: Ciência, Tecnologia e Produção**. 4. ed. Jaboticabal: Funep, 2000.
- [19] COUTO, S. M., ALVARENGA, L. C. Resistência de sementes de soja aos impactos – energia limite. **Revista Brasileira Armazenamento**. Viçosa, v. 23, n. 2, p. 03-09, 1998.
- [20] DELOUCH, J. **Environmental effects on seed development and seed quality**. Horstscience, 15(6):775-80, 1980.
- [21] DESHPANDE, S. D., BAL, S., OJHA, T. P. **Physical properties of soybeans**. Agric. Eng. Res., 56, pp. 89-98, 1993.
- [22] DUTRA, S. K., NEMA, V. K., BHARDWAJ, R. K. **Physical properties of gram**. J. Agric. Eng. Res., 39, pp. 259-268, 1988.
- [23] EGLI, D. B., TEKRONNY, D. M. & WIRALAGA, R. A. Effect soybean seed vigor and size on seedling growth. **Journal of Seed Technology**, 14(1):1-11, 1990.
- [24] EMBRAPA Soja. **A cultura da soja no Brasil**. Londrina: Embrapa Soja, 2000. CD-ROM.
- [25] EMBRAPA SOJA. **Tecnologia de Produção de Soja - Região Central do Brasil 2004**. Londrina, 2004.
- [26] FAILACE, Renato. **Hemograma: manual de interpretação**. 6 ed. Porto Alegre: Editora Artes Médicas Sul Ltda, 1995.
- [27] FAUSETT, L. **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**, Englewood Cliffs, NJ: Prentice-Hall Intern., 1994.
- [28] FRICK, M. A. D. **Aplicação de Redes Neurais Artificiais no Processamento de Imagens para análise morfológica dos eritrócitos nas anemias**. Curso de graduação em Ciência da Computação, Monografia de Conclusão de Curso, UNICRUZ, RS, 2005.
- [29] GELMOND, H. **Relationship between seed size and seedling vigor in cotton**. Proceedings of the International Seed Testing Association, 37:797-801, 1972.

- [30] GOMES, R. P., **A Soja**. Ed. Livraria Nobel, São Paulo, 1975.
- [31] GONZALES, R. C., WOODS, R. E. **Processamento de Imagens Digitais**. Ed. Edgard Blücher – LTDA, São Paulo - SP, 2000.
- [32] GRAY, D., STECKEL, J. R. A., DREW, R. L. K., KEEFE, P. D. **The contribution of seed characters to carrot plant and root size variability**. Seed Science and Technology, 19:655-64, 1991.
- [33] HANUMAIAH, L., ANDREWS, C. H. **Effects of seed size in cabbage and turnips on performance of seeds, seedlings and plants**. Proceedings of the Association of Official Seed Analysts, 63:177-25, 1973.
- [34] HARTWIG, E. E., EDWARDS, J. C. J. **Effects of morphological characteristic upon seed yield of soybean**. Agron. J., Madison, v. 62, n. 1, p. 64 - 65, 1970.
- [35] HAYKIN, S. **Neural Networks: A Comprehensive Foundation**, Prentice Hall, New Jersey, 1994.
- [36] HAYKIN, S. **Redes neurais: princípios e prática**. 2.ed., traduzido por Paulo Martins Engel, Porto Alegre: Bookman, 2001.
- [37] JOHNSON, O. R., LUEDDERS, V. D. Effects of planted seed size on emergence and yield in soybeans. **Agronomy Journal**, 66:117-8, 1974.
- [38] KOVACS, L. Z. **Redes Neurais Artificiais: Fundamentos e Aplicações**, 2.ed., Editora Collegium Cognition e Edição Acadêmica, 1996.
- [39] KUNG, S. Y., Diamantaras K. I. **Principal Component Neural Networks, Theory and Applications**.
- [40] LIMA, R. M. **Efeito do tamanho das sementes sobre alguns atributos fisiológicos e agrônômicos**. Associação brasileira dos produtores de sementes: Anuário Abrasem, Brasília, DF, p. 39-43, 1996.
- [41] LAESCH, C., SARI, S. T. **Redes Neurais Artificiais, Fundamentos e Modelos**. Ed. da FURB, Blumenau, 1996.
- [42] LOPEZ, A., GRABE, D. F. **Effect of protein content on seed performance in wheat**. Proceedings of the Association Official Seed Analysts, 63:106-15, 1973.
- [43] LUCCA, E. V. D. **Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética**. Instituto Nacional de Pesquisas Espaciais (INPE), 1998.
- [44] MARCOS FILHO, J. **Soja: Tecnologia da Produção. Avaliação da qualidade de sementes de soja**. Piracicaba: Editor G. M. S. Câmara. p.206-243, 1998.

- [45] MARTINS, A. M. **Retoque digital via linhas de nível**. Uberlândia: UFU, 2004. Dissertação (Mestrado em Ciência da Computação), Faculdade de Ciência da Computação, Universidade Federal de Uberlândia, 2004.
- [46] MATLAB Versão 7.0 **Neural Network Toolbox 4.0.1 Release Notes**. The MathWorks, 2004.
- [47] MILLER, R. K. **Neural Networks**, Lilburn: The Fairmont, 1990.
- [48] MOHSENIN, N. N. **Physical properties of plant and animal materials**. New York: Gordon and Breach Science Publishers, 1970.
- [49] NAKAGAWA, J. **Estudos sobre os efeitos de algumas doses de adubo fosfatado na cultura do amendoim**. Botucatu: UNESP, 1973. Tese (Doutorado em Ciências Biológicas), Faculdade de Ciências Médicas e Biológicas, 1973.
- [50] NAKAGAWA, J. **Efeitos da época de semeadura na produção e qualidade de sementes de soja (*Glycine max (L.) Merril*)**. Botucatu: UNESP, 1981. Tese (Livre-Docência), Faculdade de Ciências Agrônômicas, 1981.
- [51] NAYLOR, R. E. L. **Effects of seed size and emergence time on subsequent growth of perennial rye grass**. *New Phytologist*, 84: 313-8, 1980.
- [52] NEVES, S. C. M., PELAES, E. G. **Estudo e Implementação de Técnicas de Segmentação de Imagens**. *Revista Virtual de Iniciação Acadêmica da UFPA - Universidade Federal do Pará - Departamento de Engenharia Elétrica e de Computação*. v. 1, n. 2, Belém - Pará, 2001. Disponível em: <<http://www.ufpa.br/revistaic>> Acesso em 17 mar. 2006.
- [53] PUZZI, D. **Abastecimento e Armazenagem de Grãos**. Campinas: Instituto Campineiro de Ensino Agrícola, 1986.
- [54] RAMOS, J. P. S. **Aplicação de redes neurais artificiais multicamadas estáticas no processo de seleção de frutos**. Campinas: UNICAMP, 2001. Tese (Doutorado em Engenharia Agrícola), Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, 2001.
- [55] RICH, E., KNIGHT, K. **Inteligência Artificial**. Tradução: Maria Cláudia Santos Ribeiro. Revisão técnica Álvaro Antunes. Ed. Makron Books, São Paulo - SP, 1993.
- [56] RIES, S. K., EVERSON, E. H. Protein content and seed size relationships with seedling vigor of wheat cultivars. ***Agronomy Journal***, 65:884-6, 1973.
- [57] RONZELLI, P. J. **Melhoramento Genético de Plantas**. Curitiba, UFPR/ SCA/DFP, p. 125, 126, 127, 191, 200 e 214, 1996.
- [58] ROSENBLATT, F. **The Perceptron: A Perceiving and Recognizing Automation**, Technical Report 85-460-1, Cornell Aeronautical Laboratory, 1957.

- [59] RUMELHART, D., HINTON, WILLIAMS **Learning Internal Representations by Error Propagation, in Parallel Distributed Processing.** MIT Press, Cambridge, 1986.
- [60] RUSSELL, S. J., NORVIG, P., **Artificial Intelligence: a Modern Approach.** Ed. Prentice-Hall, New Jersey – EUA, 1995.
- [61] SARTORI, D. J. M. **Transferência de calor em leite deslizante.** Rio de Janeiro: UFRJ, 1986. Tese (Doutorado em Engenharia Química), Faculdade de Engenharia Química, Universidade Federal do Rio de Janeiro, 1986.
- [62] SARTORI, J. A. **Qualidade dos grãos de milho após o processo de secagem.** Campinas: UNICAMP, 2001. Dissertação (Mestrado em Engenharia Agrícola), Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, 2001.
- [63] SCHALKOFF, R. J. **Artificial Neural Networks,** New York: McGraw-Hill, 1997.
- [64] SCOTTI, C. A., KRZYZANOWSKI, F. C. **Influência do tamanho da semente sobre a germinação e o vigor em milho.** Londrina, Fundação Instituto Agrônomo do Paraná, 10p. (Bol. Técnico, 5), 1977.
- [65] SILVA, A., KASAI, F. S., CASTELLANI, E. D., AGUIAR, I. B., CARVALHO, N. M. Influência do tamanho sobre a qualidade das sementes de *Eucalyptus maculate*. Hook. **Revista Brasileira de Sementes**, 16(2):187-90, 1994.
- [66] SILVA, L. N. C. **Análise e síntese de estratégias de aprendizado para redes neurais.** Campinas: UNICAMP, 1998. Dissertação (Mestrado em Computação), Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 1998.
- [67] SMITH, T. J., CAMPER, H. M. **Effect of seed size on soybean performance,** Agron. J., Madison, v. 67, n. 5, p. 681-684, 1975.
- [68] SOUZA, L. C. F. **Efeito da classificação por tamanho de sementes de soja (*Glycine max (L) Merrill*) sobre a germinação, vigor, desempenho das plantas no campo e qualidade das sementes colhidas.** Viçosa: UFV, 1998. Dissertação (Mestrado em Engenharia Agrícola), Faculdade de Engenharia Agrícola, Universidade Federal de Viçosa, Viçosa, 1988.
- [69] TAFNER, M. A., XEREZ, M., FILHO, I. W. R. **Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação.** Ed. da FURB, Blumenau, 1995.
- [70] TATIBANA, C. Y., KAETSU, D. Y. **Redes Neurais.** Disponível em: <<http://www.din.uem.br/ia/neurais>> Acesso em 15 jan. 2006.
- [71] TOON, P. G., HAINES, R. J., DIETERS, M. J., **Relationship between seed weight, germination time and seedling height growth in *Pinus caribaea* Morelet var. *hondurensis* Barret and Golfari.** Seed Science and Technology, 19:397-402, 1991.

- [72] TRUPP, C. R., CARLSON, I. T. **Improvement of seedling vigor of smooth brome grass (*Bromus inermis* Leyss) by recurrent selection for high seed weight.** Crop Science, 11:225-8, 1971.
- [73] WEBER, E. A. **Excelência em Beneficiamento e Armazenagem de Grãos.** Canoas: Salles, 2005.
- [74] WETZEL, C. T. **Some effects of seed size on performance of soybeans.** State College: MSU, Tese (PhD), Mississippi State University, 177p., 1975.
- [75] WIDROW, B., LEHR A. M. **Backpropagation and its Applications,** Neural Network Computing for Electric Power Industry.

APÊNDICE A - FLUXOGRAMA DO ALGORITMO DE TREINAMENTO

