

RECONHECIMENTO DE VARIEDADES DE SOJA POR MEIO DO PROCESSAMENTO DE IMAGENS DIGITAIS USANDO REDES NEURAIIS ARTIFICIAIS

OLEG KHATCHATOURIAN¹, FÁBIO R. R. PADILHA²

RESUMO: Neste trabalho, foi aplicado o processamento de imagens digitais auxiliado pelas Redes Neurais Artificiais (RNA) com a finalidade de identificar algumas variedades de soja por meio da forma e do tamanho das sementes. Foram analisadas as seguintes variedades: EMBRAPA 133, EMBRAPA 184, COODETEC 205, COODETEC 206, EMBRAPA 48, SYNGENTA 8350, FEPAGRO 10 e MONSOY 8000 RR, safra 2005/2006. O processamento das imagens foi constituído pelas seguintes etapas: 1) Aquisição da imagem: as amostras de cada variedade foram fotografadas por máquina fotográfica Coolpix995, Nikon, com resolução de 3.34 megapixels; 2) Pré-processamento: um filtro de *anti-aliasing* foi aplicado para obter tons acinzentados da imagem; 3) Segmentação: foi realizada a detecção das bordas das sementes (Método de Prewitt), dilatação dessas bordas e remoção de segmentos não-necessários para a análise. 4) Representação: cada semente foi representada na forma de matriz binária 130x130, e 5) Reconhecimento e interpretação: foi utilizada uma rede neural *feedforward* multicamadas, com três camadas ocultas. O treinamento da rede foi realizado pelo método *backpropagation*. A validação da RNA treinada mostrou que o processamento aplicado pode ser usado para a identificação das variedades consideradas.

PALAVRAS-CHAVE: propriedades morfológicas de soja, análise morfológica de sementes, reconhecimento de padrões.

SOYBEAN VARIETIES RECOGNITION THROUGH THE DIGITAL IMAGE PROCESSING USING ARTIFICIAL NEURAL NETWORK

ABSTRACT: Digital image processing with Artificial Neural Network (ANN) was used to identify some soybean varieties through the form and size of the seeds. The following varieties were analyzed: EMBRAPA 133, EMBRAPA 184, COODETEC 205, COODETEC 206, EMBRAPA 48, SYNGENTA 8350, FEPAGRO 10 and MONSOY 8000 RR, 2005/2006 harvest. The image processing was constituted by the following stages: 1) Image acquisition: the samples of each variety were photographed by photographic camera Coolpix995, Nikon, with resolution of 3.34 megapixels; 2) Pre-processing: an anti-aliasing filter was applied to convert the true-color image to the grayscale intensity image; 3) Segmentation: it was made the seeds edges detection (Method of Prewitt), edge dilation and removal of needless segments; 4) Representation: each seed was represented in the form of a binary matrix 130x130, and 5) Recognition and interpretation: feedforward multiple-layer network was used with three hidden layers. The training of the network was accomplished by backpropagation. The validation of the trained ANN showed that applied processing can be used for identification of the considered soybean varieties.

KEYWORDS: soybean morphological properties, morphologic analysis of seeds, pattern recognition.

INTRODUÇÃO

A qualidade das sementes de soja depende de vários fatores, como, por exemplo, pureza física, elevado potencial genético, alta germinação e vigor, ausência de danos mecânicos, boa sanidade e uniformidade de tamanho. A padronização de sementes de soja pelo tamanho tem sido prática rotineira no Brasil e exigência de mercado (LIMA, 1996). O efeito do tamanho das sementes em sua qualidade fisiológica tem sido relatado em alguns trabalhos (BECKERT et al., 2000;

¹ Eng^o Mecânico, Professor Titular, Departamento de Física, Estatística e Matemática, UNIJUI, Ijuí – RS, olegkha@unijui.edu.br

² Mestre em Modelagem Matemática, Professor Substituto, Departamento de Matemática, UFSM, Santa Maria - RS.

Recebido pelo Conselho Editorial em: 15-9-2007

Aprovado pelo Conselho Editorial em: 20-10-2008

SOUZA, 1998; SANTOS et al., 2005). Segundo CARVALHO & NAKAGAWA (2000), o tamanho não tem influência sobre a germinação, mas afeta o vigor da planta resultante, e sementes de maior tamanho geralmente originam plantas com maior vigor. A forma e o tamanho de sementes influenciam também sobre a resistência aerodinâmica da massa de sementes no processo de aeração (KHATCHATOURIAN & SAVICKI, 2004). A uniformidade do tamanho das sementes de soja é considerada um atributo importante no aspecto visual para a comercialização e essencial para a regulagem de semeadoras, tendo grande importância tanto para agricultores como para fabricantes de alimentação (SHAHIN et al., 2006). Atendendo à demanda do mercado nos últimos anos, foram lançadas várias cultivares de soja para o consumo *in natura* e para a indústria de alimentos.

Atualmente, o processo de identificação de sementes é realizado por inspeção visual (que é muito impreciso), uso de produtos químicos e testes de DNA com alto custo. Ao mesmo tempo, estudos morfológicos podem auxiliar na identificação botânica das variedades, na interpretação de testes em laboratórios e no reconhecimento de cultivares em bancos de sementes. O uso do processamento de imagens digitais (GONZALEZ & WOODS, 2000 e 2002) no computador é boa alternativa à identificação visual. Esse processamento junto com Redes Neurais Artificiais pode ser aplicado para a identificação de variedades de sementes (SAPIRSTEIN, 1995; PALIWAL et al., 2001; VISEN et al., 2002; PALIWAL et al., 2003). Por exemplo, KEEFE & DRAPER (1986), NEUMAN et al. (1987) e DUBEI et al. (2006) realizaram a identificação para várias cultivares de trigo, e SAKAI et al. (1996) e MARINI et al. (2004) para arroz. No caso de soja, o procedimento parecido foi aplicado somente para avaliações de tamanhos ou uniformidades de tamanhos de sementes (COBER et al., 1997; SHAHIN et al., 2006).

No presente trabalho, foi feito um experimento para identificar algumas cultivares de soja, aplicando processamento de imagens digitais com a utilização de Redes Neurais Artificiais para reconhecimento e interpretação. Para ter certeza de que a análise morfológica das sementes permite distinguir as diferentes cultivares de soja, foram feitas medições das características geométricas das sementes para cada cultivar (volume de cada amostra foi de 50 sementes). Utilizando um paquímetro, foram medidos os eixos principais das sementes, considerando cada uma como um elipsoide de três eixos diferentes. Apesar da semelhança visual das sementes, os resultados mostraram que as combinações das características geométricas (forma, excentricidade, tamanho máximo e mínimo, etc.) são diferentes para as cultivares analisadas. Mesmo assim, para “perceber” essas diferenças, foi necessária alta qualidade das imagens iniciais e arquitetura adequada da RNA aplicada.

Uma Rede Neural Artificial pode ser interpretada como um conjunto de unidades de processamento (neurônios artificiais) interconectadas entre si, formando vários subconjuntos estruturais de camadas (entrada, intermediárias e saída) e conexões entre as camadas. A rede neural é capaz de armazenar o conhecimento baseado em aprendizagem (experiência) e disponibilizar esse conhecimento para uso (HAYKIN, 1999). O presente trabalho utiliza uma ferramenta desenvolvida na plataforma MATLAB 7.0 (2004) para automatizar esse processo.

Foram aplicadas cinco etapas para o processamento de imagens: aquisição da imagem, pré-processamento, segmentação, representação, reconhecimento e interpretação. A RNA foi utilizada na etapa final.

O objetivo principal deste trabalho é identificar as variedades de soja (EMBRAPA 133, EMBRAPA 184, COODETEC 205, COODETEC 206, EMBRAPA 48, SYNGENTA 8350, FEPAGRO 10 e MONSOY 8000 RR, safra 2005/2006) por meio da forma e do tamanho das sementes, aplicando processamento de imagens digitais auxiliado pelas Redes Neurais Artificiais (RNA).

MATERIAL E MÉTODOS

Variedades de soja analisadas

Para o estudo realizado, foram escolhidas no laboratório de sementes da Cooperativa Agropecuária e Industrial (COTRIJUÍ), com sede no município de Ijuí - RS, as seguintes variedades: 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.

Aquisição de imagens

Para a realização das fotos, as sementes foram colocadas sobre uma superfície plana composta por material presente em câmaras escuras (preto e fosco), utilizado em estúdios fotográficos. As sementes foram fotografadas por 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 conectada ao computador onde as imagens foram salvas em formato JPEG (Figura 1).

Pré-processamento

A partir dessa etapa, todos os procedimentos foram executados aplicando o *software* MATLAB 7.0 (2004), por meio da ferramenta desenvolvida. A imagem a ser processada (Figura 1) foi inserida no programa no qual, na etapa de pré-processamento, foi aplicado um filtro de *anti-aliasing* (técnica utilizada para melhorar a definição do sinal, eliminando os detalhes serrilhados associados às imagens originais obtidas) para suavização em tons de cinza (Figura 2). Esse procedimento retornou uma matriz, para a qual cada elemento representa um *pixel*, e seu valor representa um tom de cinza do referido *pixel*.




FIGURA 1. Imagem original das sementes de soja. **Original image of the soybean seeds.**




FIGURA 2. Imagem em tons de cinza. **Ashy tone image.**

Segmentação

Para efetuar a detecção dos contornos das sementes, foram utilizados vários métodos, por exemplo, de Prewitt, de Sobel, de Roberts, de Canny, etc. (GONZALEZ & WOODS, 2002). Neste trabalho, foi escolhido o Método de Prewitt, que apresentou o melhor resultado na detecção dos contornos (Figura 3).




FIGURA 3. Bordas detectadas pelo método de Prewitt. **Contours detected by the method of Prewitt.**

Para eliminar os contornos fracos e descontínuos, foi realizada dilatação desses contornos, obtendo melhor resultado (Figura 4). Depois foi usado um aplicativo para preencher todas as sementes com contornos contínuos, sendo realizada limpeza das bordas das sementes e remoção dos contornos descontínuos. Finalizando a etapa de segmentação, foi realizada a remoção de ruídos que caracterizavam aglomerados com até 700 *pixels*, que poderiam ser considerados como objetos a serem identificados, mas que, por sua vez, não representavam as sementes e, sim, algum tipo de interferência na imagem (Figura 5).

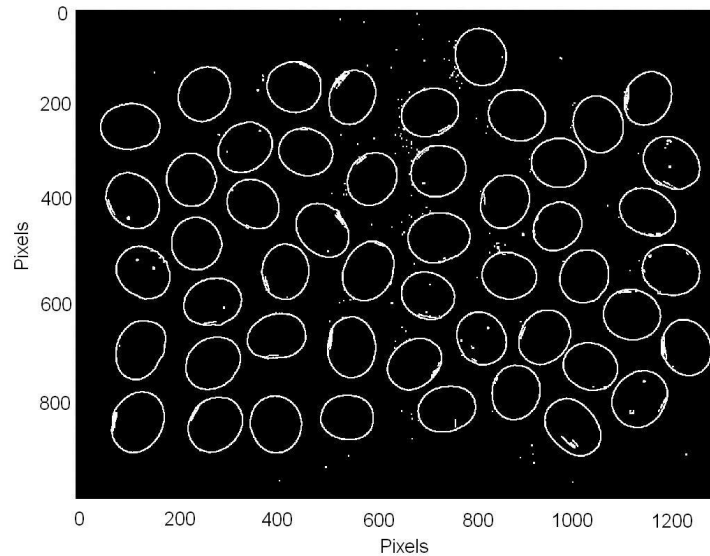


FIGURA 1. Dilatação dos contornos. **Dilation of the contours.**

Representação

A imagem representada na Figura 5 foi usada para extrair as características necessárias para a identificação morfológica de cada semente. O aplicativo fez uma numeração sequencial de todas as sementes (Figura 6) e relacionou um conjunto de *pixels* com cada semente. Esse conjunto foi inscrito em outro conjunto de *pixels* que formou um retângulo com lados paralelos aos eixos coordenados. Devido às diferentes formas, tamanhos e posições das sementes, as dimensões desses retângulos foram desiguais. Para que cada semente analisada pudesse caber no retângulo, foi escolhido aquele com as dimensões máximas.




FIGURA 5. Imagem obtida pela remoção de objetos menores que 700 *pixels*. **Image obtained by removal of objects smaller than 700 pixels.**




FIGURA 6. Imagem original das sementes identificadas. **Original image of the identified seeds.**

Os *pixels* que representam uma semente, receberam o valor 1; outros que somente completaram o retângulo, receberam o valor 0. Então, cada semente foi representada por uma matriz binária de mesma forma para todas as sementes. Depois de vários testes, foi definido que a forma dessa matriz não poderia ser menor de 130x130 *pixels* para não prejudicar o processo de identificação das sementes. Na Figura 7, apresenta-se o esquema de uma semente de soja por meio de uma matriz de tamanho 30x30 *pixels* (para facilitar a apresentação, a matriz real de 130x130 foi reduzida para 30x30).




FIGURA 7. Representação da semente por meio da matriz. **Seed representation by matrix.**

A imagem binária da mesma semente está apresentada na Figura 8, em que os *pixels* com valor 0 têm cor preta, e com valor 1, cor branca.

Finalizando essa etapa, as matrizes correspondentes a cada semente foram transformadas em vetores colunas 16.900x1 para que pudessem ser inseridas como dados de entrada na rede neural da próxima etapa.




FIGURA 8. Imagem binária da semente de soja. **Binary image of the soybean seed.**

Configuração da rede neural

As sementes de soja analisadas são bastante parecidas pela forma e pelo tamanho. Por isso, a arquitetura da rede neural (número de camadas ocultas, quantidade de neurônios em cada camada, etc.) foi escolhida de maneira que essas pequenas diferenças fossem “percebidas”. A arquitetura da rede neural utilizada neste trabalho (Figura 9) para o reconhecimento dos padrões foi a rede *feedforward* multicamadas. Seu aprendizado foi realizado por meio do algoritmo *backpropagation*. A rede foi composta por 16.900 elementos na camada de entrada, três camadas ocultas com 90; 70 e 60 neurônios, e uma camada de saída com oito neurônios. As camadas ocultas e a camada de saída possuíam biases.

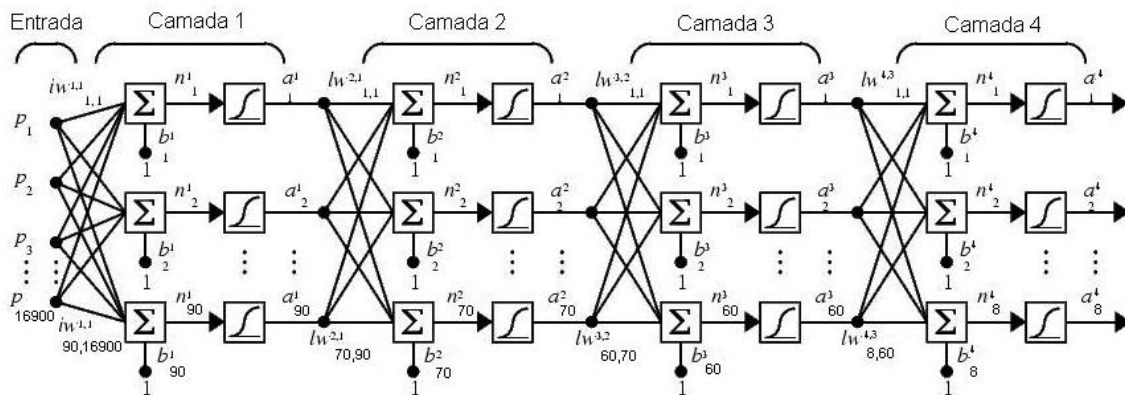


FIGURA 9. Arquitetura da rede neural utilizada. **Architecture of the used artificial neural network.**

Treinamento da rede neural

Depois da configuração da arquitetura, a rede foi submetida ao treinamento para desenvolvimento do modelo de RNA. Esse desenvolvimento foi realizado em duas etapas: treinamento e validação. Os dados com valores de entrada e de saída conhecidos foram divididos em dois conjuntos. O primeiro conjunto de dados foi usado para o treinamento da RNA; o segundo conjunto foi usado para a validação, isto é, para testar a capacidade da RNA treinada em identificar as variedades.

Para o treinamento, foi utilizado um conjunto de 35 sementes para cada uma das oito variedades de soja estudadas. A etapa de representação para cada variedade de soja resultou em uma matriz de dimensão 16.900x35 (em total, 16.900x280). Cada coluna dessa matriz representa uma semente reconhecida no conjunto de treinamento, isto é, vetor de entrada. Para todas as sementes da mesma variedade, corresponde um mesmo vetor de saída (vetor-objetivo ou resposta desejada para a rede neural). Esses vetores (vetores-colunas unitários da base canônica) são apresentados na Tabela 1 para todas as variedades estudadas. Então, para o treinamento, foram formadas duas

matrizes: uma matriz de entrada de dimensão 16.900x280 e outra matriz de saída de dimensão 8x280.

O procedimento para ajustar os pesos da rede neural (treinamento do algoritmo) envolveu três fases: a propagação do vetor de entrada, a retropropagação do erro e o ajuste dos pesos.

Backpropagation (regra delta generalizada, GDR) é um algoritmo de treinamento geralmente usado para redes de múltiplas camadas e funções de transferência não-lineares. Neste trabalho, os vetores de entrada e os vetores-objetivo são usados para treinar a rede neural até que ela possa associar os vetores de entrada com os vetores-objetivo correspondentes.

TABELA 1. Vetores-objetivo para cada variedade estudada. **Objective vectors for each studied variety.**

BRS 133	BRS 184	CD 205	CD 206	BEM 48	NK 8350	RS 10	MSOY RR
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

Designando a matriz dos pesos para a primeira camada oculta como $W^{(1)}$, o vetor de saída para a primeira camada $a^{(1)}$ (entrada para a segunda camada oculta) pode ser escrito como:

$$a_{90 \times 1}^{(1)} = f(W_{90 \times 16900}^{(1)} p_{16900 \times 1} + b_{90 \times 1}^{(1)}) \quad (1)$$

em que,

p - vetor de entrada (conjunto de treinamento);

b - bias, e

f - função de transferência (sigmoide binária), sendo o índice superior relacionado com o número da camada.

Usando as matrizes próprias dos pesos para cada camada e aplicando os vetores de saída da camada anterior como os vetores de entrada para a camada posterior, os vetores de saída para a segunda e terceira camadas podem ser escritos na forma:

$$a_{70 \times 1}^{(2)} = f(W_{70 \times 90}^{(2)} a_{90 \times 1}^{(1)} + b_{70 \times 1}^{(2)}) \quad (2)$$

$$a_{60 \times 1}^{(3)} = f(W_{60 \times 70}^{(3)} a_{70 \times 1}^{(2)} + b_{60 \times 1}^{(3)}) \quad (3)$$

Continuando a etapa *feedforward*, o vetor de saída $a^{(4)}$, para a camada de saída, pode ser calculado da seguinte forma:

$$a_{8 \times 1}^{(4)} = f(V_{8 \times 60} a_{60 \times 1}^{(3)} + b_{8 \times 1}^{(4)}) \quad (4)$$

em que,

V - matriz de pesos para a camada de saída.

Durante a retropropagação, os pesos da rede (elementos das matrizes $W^{(1)}$, $W^{(2)}$, $W^{(3)}$, V e bias b) são ajustados para minimizar o erro quadrático total, determinado pela diferença entre os vetores-objetivo dados e os vetores de saída calculados da rede para cada iteração.

O algoritmo *backpropagation* utiliza o método de gradientes conjugados com algoritmo de ajuste de Powell-Beale. A condição de parada inclui a tolerância na relação total do erro quadrático e o limite do número de treinamentos impostos (épocas).

A rede neural foi considerada treinada quando os valores de saída estavam dentro do erro estipulado (0,00001). Para os 280 vetores de entrada, foram necessárias 420 iterações (épocas).

RESULTADOS E DISCUSSÃO

Reconhecimento dos padrões

Para avaliar o grau de semelhança (ou diferença) entre as variedades das sementes consideradas, antes de realizar a validação da rede neural treinada, aplicando-a nas sementes não utilizadas na fase de treinamento, a rede neural foi submetida a testes utilizando os mesmos vetores de entrada que foram aplicados durante o treinamento da RNA. Os resultados na forma de matriz são mostrados na Tabela 2. Cada coluna dessa matriz corresponde a uma das variedades de soja considerada. Cada elemento (não-diagonal) dessa coluna apresenta a percentagem de uma parte dessa variedade reconhecida como outra variedade representada pela linha correspondente. Os valores máximos para cada coluna foram localizados na diagonal principal da matriz (marcados com a cor cinza), o que possibilitou o reconhecimento das variedades pelo método aplicado. Justamente a posição do valor máximo na coluna serviu para detectar a variedade de soja.

TABELA 2. Resultado de reconhecimento de padrões pela RNA treinada (valores percentuais).
Result of recognition of patterns for trained RNA (percentage ratio).

	BRS 133	BRS 184	CD 205	CD 206	EMB 48	NK 8350	RS 10	MSOY 8000RR
BRS133	42,9	11,4	17,1	0	5,7	14,3	0	5,7
BRS184	8,6	62,9	11,4	2,9	0	0	8,6	5,7
CD 205	20	8,6	42,9	0	17,1	5,7	0	2,9
CD 206	0	0	0	68,6	0	0	22,9	5,7
EMB 48	8,6	0	8,6	0	48,6	20,0	0	0
NK8350	17,1	0	14,3	0	25,7	60,0	0	0
RS 10	0	11,4	0	25,7	0	0	57,1	2,9
MSOY 8000RR	2,9	5,7	5,7	2,9	2,9	0	11,4	77,1
Total	100	100	100	100	100	100	100	100

A matriz apresentada pode ser considerada como uma espécie de matriz de correlações entre as variedades de sementes, indicando certo grau de semelhança das características morfológicas das distintas variedades. Por exemplo, pode-se concluir que as cultivares EMB 48 e NK 8350 são muito parecidas morfológicamente. Analogamente, pode-se verificar que os pares BRS 133 e CD 205, CD 206 e RS 10 também possuem certo grau de semelhança. As sementes de MSOY 8000 RR e BRS 184 são mais individuais, o que facilita sua identificação.

Validação da RNA

Para a validação da rede neural treinada e a determinação do número representativo de sementes na amostra para cada variedade, foram analisadas dez fotos com o mesmo número de sementes (estrato amostral) recolhidas aleatoriamente de 50 sementes da variedade considerada. Os volumes de amostra escolhidos foram iguais a 5; 10; 15; 20; 25; 30 e 35 sementes para cada variedade. O número de reconhecimentos verdadeiros dividido por 10 (número de amostras para cada tamanho amostral) foi chamado de frequência de reconhecimento. Na Figura 8, apresenta-se a frequência de reconhecimento com a variação do número de sementes em cada amostra.

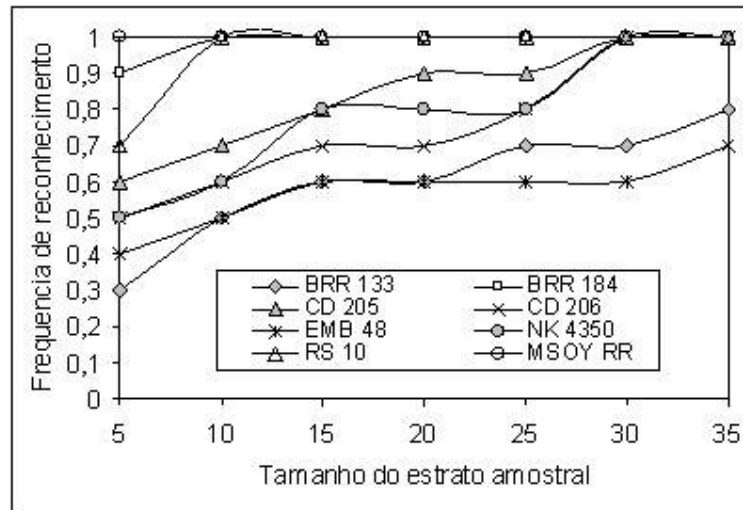


FIGURA 8. Influência do tamanho do estrato amostral sobre o reconhecimento das variedades.
Influences of the sample size on the varieties recognition.

Pode-se observar que, com o aumento do tamanho do estrato amostral, a qualidade do reconhecimento das variedades melhora significativamente, mostrando-se um fator importante no reconhecimento. Como foram esperados, os melhores resultados de reconhecimento prevaleceram para as cultivares MSOY 8000 RR, RS 10 e BRS 184. As demais cultivares mostraram frequência de reconhecimento um pouco reduzida. Para melhorar a possibilidade de reconhecimento das cultivares em trabalhos futuros, podem ser consideradas a textura e a cor das sementes. Também, a fronteira da semente na matriz binária (Figuras 7 e 8) pode ser suavizada empregando os números fracionários entre 0 e 1, expressando, assim, que parte do *pixel* da fronteira pertence à semente.

CONCLUSÕES

As cultivares de soja EMBRAPA 133, EMBRAPA 184, COODETEC 205, COODETEC 206, EMBRAPA 48, SYNGENTA 8350, FEPAGRO 10 e MONSOY 8000 RR podem ser identificadas por meio da análise das propriedades morfológicas das sementes de soja aplicando processamento de imagens digitais em conjunto com Redes Neurais Artificiais. Devido à semelhança das sementes de soja, para atingir os resultados satisfatórios na identificação, a arquitetura da RNA foi bastante complexa (a rede utilizou vetor de 16.900 elementos na camada de entrada, 90 neurônios na primeira camada oculta, 70 na segunda, 60 na terceira e 8 neurônios na camada de saída). Pelo mesmo motivo, é necessário alta qualidade de imagens digitais empregadas. Os melhores resultados de reconhecimento mostraram as cultivares MONSOY 8000 RR, FEPAGRO 10 e EMBRAPA 184.

REFERÊNCIAS

- BECKERT, O.P.; MIGUEL, M.H.; MARCOS FILHO, J. Absorção de água e potencial fisiológico em sementes de soja de diferentes tamanhos. *Scientia Agrícola*, Piracicaba, v.57, n.4, p.671-5, 2000.
- CARVALHO, N.M.; NAKAGAWA, J. *Sementes: ciência, tecnologia e produção*. 4.ed. Jaboticabal: Funep, 2000. 588 p.
- COBER, E.R.; VOLDENG, H.D.; FREGEAU-REID, J.A. Heritability of seed shape and seed size in soybean. *Crop Science*, Madison, v.37, n.6, p.1767-9, 1997.
- DUBEL, B.P.; BHAGWAT, S.G.; SHOUCHE, S.P.; SAINIS, J.K. Potential of artificial neural networks in varietal identification using morphometry of wheat grains. *Biosystems Engineering*, London, v.95, n.1, p.61-7, 2006.

- GONZALEZ, R.C.; WOODS, R.E. *Processamento de imagens digitais*. São Paulo: Edgard Blücher, 2000. 509 p.
- GONZALEZ, R.C.; WOODS, R.E. *Digital image processing*. 2nded. New York: Prentice Hall, 2002. 793 p.
- HAYKIN, S. *Neural networks: A comprehensive foundation*. 2nded. Upper Saddle River: Prentice-Hall, 1999. 842 p.
- KEEFE, P.D.; DRAPER, S.R. The measurement of new characters for cultivar identification in wheat using machine vision. *Seed Science Technology*, Cambridge, v.14, p.715-724, 1986.
- KHATCHATOURIAN, O.A.; SAVICKI, L.D. Mathematical modelling of airflow in an aerated soya bean store under non-uniform conditions. *Biosystems Engineering*, London, v.88, n.2, p.201-11, 2004.
- LIMA, R.M. *Efeito do tamanho das sementes sobre alguns atributos fisiológicos e agronômicos*. Brasília: Anuário Abrasem, 1996. p.39-43.
- MARINI, F.; ZUPAN, J.; MAGRI, A.L. On the use of counterpropagation artificial neural networks to characterize Italian rice varieties. *Analytica Chimica Acta*, Amsterdam, v.510, n.2, p.231-40, 2004.
- MATLAB Versão 7.0. Neural Network Toolbox 4.0.1 Release Notes. *The MathWorks*, 2004. 840 p.
- NEUMAN, M.R.; SAPIRSTEIN, H.D.; SHWEDYK, E.; BUSHUK, W. Discrimination of wheat class and variety by digital image analysis of whole grain samples. *Journal of Cereal Science*, Kidlington, v.6, n.2, p.125-32, 1987.
- PALIWAL, J.; VISEN, N.S.; JAYAS, D.S. Evaluation of neural network architectures for cereal grain classification using morphological features. *Journal of Agricultural Engineering Research*, Silsoe, v.79, n.4, p.361-70, 2001.
- PALIWAL, J.; VISEN, N.S.; JAYAS, D.S.; WHITE, N.D.G. Cereal grain and dockage identification using machine vision. *Biosystems Engineering*, London, v.85, n.1, p.51-7, 2003.
- SAKAI, N.; YONEKAWA, S.; MATSUZAKI, A.; MORISHIMA, H. Two dimensional image analysis of the shape of rice and its application to separating varieties. *Journal of Food Engineering*, Oxford, v.27, n.4, p.397-407, 1996.
- SANTOS, P.M. dos; REIS, M.S.; SEDIYAMA, T.; ARAÚJO, E.F.; CECON, P.R.; SANTOS, M.R. dos. Efeito da classificação por tamanho da semente de soja na sua qualidade fisiológica durante o armazenamento. *Acta Science Agronomy*, Maringá, v.27, n.3, p.395-402, 2005.
- SAPIRSTEIN, H.D. Varietal identification by digital image analysis. In: WRIGLEY, C.W. (Ed.). *Identification of food-grain varieties*. St Paul: American Association of Cereal Chemists, 1995. p.91-130.
- SHAHIN, M.A.; SYMONS, S.J.; POYSA, V.W. Determining soya bean seed size uniformity with image analysis. *Biosystems Engineering*, London, v.94, n.2, p.191-8, 2006.
- 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*. 1998. 109 f. Dissertação (Mestrado em Produção e Beneficiamento de Sementes) - Universidade Federal de Viçosa, Viçosa, 1998.
- VISEN, N.S.; PALIWAL, J.; JAYAS, D.S.; WHITE, N.D.G. Specialist neural networks for cereal grain classification. *Biosystems Engineering*, London, v.82, n.2, p.151-9, 2002.