



## ESTUDO DA CLASSIFICAÇÃO REFINADA DE FRUTAS PARA CONTROLE DE QUALIDADE UTILIZANDO REDES NEURAIS ARTIFICIAIS

Aline Mara Oliveira <sup>\*1</sup>, Daniel Silva de Souza<sup>2</sup>

<sup>1</sup>FEELT – Universidade Federal de Uberlândia

<sup>2</sup>FEELT – Universidade Federal de Uberlândia

**Resumo** - Com a globalização e a difusão de informação o consumidor passou a se tornar cada vez mais exigente em relação aos produtos que consome. Essa realidade não é diferente no setor agrícola, onde as pessoas usam critérios rigorosos em relação à qualidade dos produtos que chegam em suas mesas. Nesse contexto, existe a necessidade de melhorar o processo de inspeção dos frutos afim de diminuir os altos índices de insatisfação dos consumidores e garantir maior qualidade nos produtos finais oferecidos no comércio. Para isso, foram utilizadas nesse trabalho estratégias para automatizar a seleção de frutas por meio de ferramentas computacionais e redes neurais.

**Palavras-Chave** - Classificação refinada, controle de qualidade, mapas de Kohonen, processamento de imagens.

### REFINED FRUIT CLASSIFICATION STUDY FOR QUALITY CONTROL USING ARTIFICIAL NEURAL NETWORKS

**Abstract** - With globalization and the diffusion of information the consumer has become increasingly demanding with regard to the products that they consume. This reality is no different in the agricultural sector, where people use strict criteria regarding the quality of the products that arrive at their tables. In this context, there is a need to improve the fruit inspection process in order to reduce the high levels of consumer dissatisfaction and to guarantee a better quality in the final products offered in the trade. For this, strategies were used in this paper to automate fruit selection through computational tools and neural networks.

**Keywords** - Refined classification, quality control, Kohonen maps, image processing.

### I. INTRODUÇÃO

Atualmente, existem várias aplicações em que são projetados e construídos sistemas de visão artificial com a finalidade de inspecionar ou supervisionar os produtos. Um sistema de visão

computacional é constituído por hardware e software. A parte que compõe o hardware inclui: sistema de iluminação, sistema de aquisição de imagens, sistema de processamento e sistema de atuação. O software é composto por: melhoria de sinal, segmentação, análise da forma, análise da cor, análise da textura e tomadas de decisão. Excluindo-se a fase de iluminação, em todas as demais é possível aplicar o uso de redes neurais.

A utilização da visão computacional e inteligência artificial com a intenção de aproximar à visão humana vem sendo usada por diversos estudos e para diferentes finalidades. Em [8] a rede neural é utilizada na classificação de laranjas, em [10] na classificação de cores de maçãs, em [4] na classificação de pistaches, em [9] na classificação de castanha de caju e em [7] no estudo da qualidade de frutos. Outras aplicações encontradas para inteligência artificial no segmento agrícola, foram a prevenção da floração e a maturidade fisiológica da soja com o uso de redes neurais artificiais [3] e classificação de frutos com o uso de redes MLP e RBF [1].

Em pesquisas realizadas com consumidores verificou-se que o tomate apresenta um índice de insatisfação muito elevado se comparado com outros 31 produtos [6]. Os estudos mostram também que, desde a década de 70, os consumidores estão insatisfeitos com o preço e a qualidade do tomate [6]. Em uma outra pesquisa, foi traçado o perfil dos consumidores de tomates dos mercados de Campinas (SP) [2]. Os critérios que mais influenciam na compra do tomate pelo consumidor são primeiramente aparência, em seguida textura e sabor[2]. Na opinião dos consumidores um tomate ideal é aquele com coloração vermelha, uniforme e sem presença de injúrias[2]. Verificou-se também que a mistura de padrões não é desejada, o que gera um nível de insatisfação de 65,6 % entre os consumidores [2].

O uso de visão computacional em conjunto com uma rede neural competitiva do tipo Mapas de Kohonen apresenta potencial para fornecer uma solução em relação a aparência e textura do tomate, que são dois fatores que influenciam a aquisição do produto. Por meio do uso de uma rede neural competitiva os tomates podem ser agrupados em grupos (*clusters*) que possuem características iguais. Com essa separação consegue-se melhorar a qualidade do produto final. Sendo assim, objetivo deste trabalho é propor um método de

\*aline\_m\_oliv@yahoo.com.br

separação de tomates por meio de visão computacional e redes neurais.

## II. MAPAS DE KOHONEN

Os mapas auto organizáveis são uma arquitetura de rede neural do tipo reticulada com aprendizado competitivo. São estruturas em essência competitivas onde os neurônios da rede competem entre si para se conhecer qual entre eles é o vencedor por meio do cálculo da distância Euclidiana. Sendo que, aquele com o menor de distância Euclidiana é considerado o vencedor para o padrão apresentado.

Adicionalmente, as conexões laterais demonstram como a saída do neurônio vencedor influenciará os demais neurônios da rede. Essas conexões laterais são fornecidas por meio do mapa topológico de vizinhança. Os mapas topológicos mostram como estarão organizados espacialmente os neurônios da rede, frente ao comportamento de seus vizinhos, sendo que normalmente são formados por uma dimensão (*array*) ou duas dimensões (*grade*).

Um dos principais critérios para vizinhança consiste em especificar um raio de abrangência  $R$  que será utilizado pelos neurônios da rede, visando definir seus respectivos vizinhos. Sendo assim, para um determinado neurônio  $j$ , seus vizinhos serão todos aqueles que estarão a uma distância máxima que seja menor ou igual a  $R$ . Para o ajuste dos pesos do neurônio vencedor e vizinhos, quando  $r$  é unitário, se utiliza a tática de atualizar os vizinhos com metade da taxa de aprendizado. Para o neurônio vencedor, é aplicada a regra explicitada pela equação 1 e para os neurônios vizinhos é aplicada a regra da equação 2.

$$w^{(v)} \leftarrow w^{(v)} + \eta(x^{(k)} - w^{(v)}) \quad (1)$$

$$w^{(n)} \leftarrow w^{(n)} + \frac{\eta}{2}(x^{(k)} - w^{(n)}) \quad (2)$$

As instruções computacionais do algoritmo que explicam a fase de treinamento são:

- Definir o mapa topológico;
- Iniciar o vetor de pesos de cada neurônio  $\{w(j)\}$  considerando os limites dos valores de cada variável de entrada da rede;
- Montar o conjunto de vizinhança  $\{\Omega_j(R)\}$ ;
- Obter o conjunto de amostras de treinamento  $\{x(k)\}$ ;
- Normalizar os vetores de amostras e de pesos;
- Especificar a taxa de aprendizagem  $\{\eta\}$ ;
- Iniciar o contador de número de épocas  $\{\text{épocas} \leftarrow 0\}$ ;

Repetir as instruções:

Para todas as amostras de treinamento  $\{x(k)\}$ , fazer:

- Calcular as distâncias euclidianas entre  $x(k)$  e  $w(j)$ ;
- Declarar como vencedor o neurônio  $j$  que contenha a menor distância euclidiana;
- Ajustar o vetor de pesos do vencedor conforme a regra 1;
- Ajustar o vetor de pesos dos neurônios vizinhos ao vencedor conforme a regra 2;
- Diminuir a taxa de aprendizagem;
- Épocas  $\leftarrow$  épocas + 1.

Para a fase de operação são as seguintes instruções:

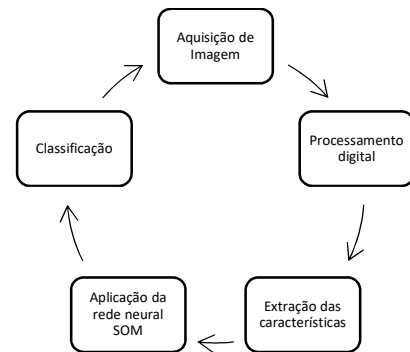
- Apresentar a amostra  $\{x(k)\}$  a ser classificada e normalizar;
- Assumir os vetores de pesos  $\{w(j)\}$  já ajustados durante a fase de treinamento;
- Executar as seguintes instruções:
- Calcular as distâncias euclidianas entre  $x$  e  $w(j)$ ;
- Declarar como vencedor o neurônio  $j$  que contenha a menor distância euclidiana;
- Localizar o neurônio vencedor dentro do mapa auto organizável;
- Associar a amostra à classe que foi identificada;
- Disponibilizar a eventual classe em que a amostra foi associada.

A simples estrutura em conjunto aliada com a dinâmica de treinamento diferenciada, faz dos mapas auto organizáveis de Kohonen uma ferramenta eficiente para aplicação em problemas que envolvem classificação de padrões e identificação de agrupamentos de dados com características próprias, características que se alinham perfeitamente com os objetivos deste trabalho.

## III. METODOLOGIA

A Figura 1 apresenta os procedimentos adotados para a realização deste trabalho. Assim que o programa é inicializado a imagem é carregada e, em seguida, processada. O processamento da imagem é realizado por meio de métodos computacionais para facilitar e simplificar a análise dos dados na ferramenta de mapas de Kohonen.

Figura 1: Fluxograma de processo.



A etapa de aquisição da imagem é de fundamental importância para que as etapas seguintes do processo venham a ocorrer de forma satisfatória, ou seja, ela é crucial para o bom desempenho do protótipo. Na etapa de processamento da imagem todos os distúrbios oriundos da aquisição da imagem são amenizados ao máximo para que a interferência dos mesmos seja minimizada.

Após a redução dos ruídos, a imagem processada é utilizada na extração das características de interesse, que serão utilizadas como entrada para os mapas de Kohonen. Por meio desses mapas, as características são processadas e avaliadas. Sendo assim, a rede forma um mapa de densidade topográfica. Ao atribuir a cada entrada um neurônio responsável pelo o seu

reconhecimento, quando uma entrada semelhante é apresentada, a rede forma regiões de agrupamento por características semelhantes constituindo assim os denominados *clusters*. O processo de treinamento da rede é não supervisionado, ou seja, não possui vetor de saída desejada para cada valor de entrada classificada pela rede, apenas os dados da entrada são apresentados para o treinamento.

O processo se repete para cada imagem processada até que todas as imagens tenham sido devidamente classificadas nos respectivos clusters.

#### IV. RESULTADOS E DISCUSSÕES

A tarefa de seleção de tomates é muito subjetiva, de forma que, cada indivíduo tem um modo e padrão de seleção e leva em conta muitos fatores para realizar a sua classificação. O modelo proposto considera três características: área e componentes Cr e Cb.


Durante o treinamento da rede neural foram utilizadas 120 imagens de tomates no formato jpeg de 640 por 480 pixels com resolução horizontal e vertical de 96 dpi. A Figura 2 ilustra um exemplo de imagem utilizada no treinamento.

Figura 2: Imagem capturada do tomate



A topologia aplicada foi a linear. A Figura 3 apresenta a disposição dos neurônios após o treinamento.

Figura 3: Posição dos Neurônios da Rede após o treinamento



Na Figura 3 pode-se observar a disposição dos neurônios após o treinamento e o processo de clusterização executado pela rede neural. Observa-se que todos os *clusters* foram preenchidos e selecionados por pelo menos um elemento do conjunto de entradas.

Para o processo de validação da rede foram utilizadas duas amostras de tomates, uma com 7 tomates e a outra com 11 tomates, ambas diferentes das amostras utilizadas no treinamento da rede. A rede neural foi especificada com 16 neurônios, conforme no treinamento, visando uma classificação mais refinada dos tomates. Com a amostra de 11 tomates foi realizado um teste de verificação visual. As imagens 4 e 5 mostram os resultados obtidos.

Figura 4: Teste com amostra de onze tomates




Figura 5: Separação de onze tomates pela rede



Observando as Figuras 4 e 5, pode se notar que a quantidade de neurônios foi adequada, pois a rede conseguiu ter classificação mais fina dos tomates, agrupando aqueles com características próximas no mesmo grupo.

No segundo teste foi utilizada uma amostra de sete tomates. A separação obtida pela rede neural foi comparada com a classificação realizada por um voluntário. A rede neural obteve os resultados apresentado nas figuras 6 e 7.

Figura 6: Treinamento com amostra de sete tomates




Figura 7: Separação da amostra 2



Como se pode observar a rede manteve o padrão de separação dos tomates, mantendo os vermelhos no grupo 1, os meio-esverdeados no grupo 2 e o verde no grupo 4. A separação sugerida pelo o voluntário está representada na Figura 8.

Figura 8: Separação de sete tomates feita por um voluntário



Comparando a classificação realizada pela rede (Figura 7) e a realizada pela a voluntária (Figura 8), pode-se perceber que a classificação de uma para outra diferiu apenas em dois tomates que foram trocados de clusters, um que estava no cluster 2 foi para o cluster 1 e um que estava no cluster 1 foi para o cluster 2. Considerando que a classificação do voluntário foi a correta, a rede obteve então um aproveitamento de 71,4 %.

Entretanto não podemos desconsiderar neste caso o elemento subjetividade. A subjetividade é uma característica implícita a cada ser humano e faz com que cada um tenha uma forma diferente de percepção diante das coisas que são apresentadas a eles. Sendo assim, as redes neurais, como não possuem essa característica, ficam em ligeira desvantagem em relação às escolhas feitas por um ser humano. Entretanto, mesmo apresentando desvios relacionados à subjetividade, os Mapas de Kohonen possuem potencial e apresentaram bons resultados na classificação de tomates. A rede neural apresentou aproveitamento médio de 76,61 %, o que pode ser

considerado como um bom resultado para uma rede de treinamento não supervisionado. Os resultados podem ser melhorados com o aperfeiçoamento do processamento de imagens dos tomates, pois a iluminação é um fator crítico durante a coleta de dados. Observou-se que os desvios foram maiores com tomates vermelhos e de tamanhos menores, gerando distúrbios nos valores das características destes tomates. Outro fator que também pode contribuir para o melhor desempenho da rede é a utilização de uma maior quantidade de tomates com características variadas de tamanho e coloração.

## V. CONCLUSÃO

Com a realização deste trabalho ficou evidenciado que os Mapas de Kohonen possuem potencial para serem utilizados em tarefas de classificação de tomates. Este tipo de tarefa vem de encontro as características de classificação da rede neural competitiva. Observou-se também que quanto maior e mais diversificado o número de amostras para treino melhor será o funcionamento da rede. A maior variedade de amostras melhora o desempenho da rede pois os vetores de pesos representarão melhor os padrões semelhantes apresentados.

Como trabalhos futuros um melhor processamento de imagens com minimização da iluminação poderá ser realizado e também novos testes, com mais voluntários e maior quantidade e variedade de tomates.

## REFERÊNCIAS

- [1] ALRAJEH, K. M.; ALZOHAIYR, T. A. A. Date fruits classification using MLP and RBF neural networks. *International Journal of Computer Applications*, v. 41, n. 10, 2012.
- [2] ANDREUCCETTI, C.; FERREIRA, M. D.; TAVARES, M. Reclamações e exigências dos consumidores de tomate de mesa em supermercados de Campinas-SP. Parte do projeto de pesquisa UNIMAC (Unidade Mecânica de Auxílio à colheita financiado pela FAPESP, São Paulo, 2007.
- [3] ELIZONDO, D. A. et al. Neural network models for predicting flowering and physiological maturity of soybean. *Transactions of the ASAE*, v. 37, n. 3, p. 981–988, 1994.
- [4] GHAZANFARI, A.; IRUDAYARAJ, J.; KUSALIK, A. Grading pistachio nuts using a neural network approach. *Transactions of the ASAE-American Society of Agricultural Engineers*, v. 39, n. 6, p. 2319–2324, 1996.
- [5] KADER, A. A. et al. Effect of fruit ripeness when picked on flavor and composition in fresh market tomatoes. *J. Amer. Soc. Hort. Sci.*, v. 102, n. 6, p. 724–731, 1977.
- [6] KADER, A. A. et al. Composition and Flavour Quality of Fresh Market Tomatoes as Influenced by Some Postharvest Handling Procedures. *Journal of American Horticultural Science*, v. 103, n. 1, p. 6–13, 1978.
- [7] KAUR, M.; SHARMA, R. Quality Detection of Fruits by Using ANN Technique. *IOSR Journal of Electronics and Communication Engineering (IOSR-JECE) Volume*, v. 10, [s.d.].

- [8] KONDO, N. et al. Machine vision based quality evaluation of Iyokan orange fruit using neural networks. Computers and electronics in agriculture, v. 29, n. 1, p. 135–147, 2000.
- [9] NAGPURE, V. Review on Back Propagation Neural Network Application for Grading of Cashew Nuts. [s.d.].
- [10] NAKANO, K. Application of neural networks to the color grading of apples. Computers and electronics in agriculture, v. 18, n. 2, p. 105–116, 1997.