

CONEM 2016
CONGRESSO NACIONAL DE
ENGENHARIA MECÂNICA

21-25
AGOSTO DE 2016
FORTALEZA - CEARÁ

Uso de Redes Neurais na construção de uma esteira separadora de frutas

Amaro Pereira Borges Junior, amaro.borges@hotmail.com¹

Pablo Diogo Siqueira Brito, pablo_diogo@hotmail.com¹

José Bismark de Medeiros, jose.bismark@univasf.edu.br¹

Eduard Montgomery Meira Costa, eduard.montgomery@univasf.edu.br¹

¹Universidade Federal do Vale do São Francisco-Univasf, Av. Antonio Carlos Magalhães, 510, Country Club - Campus Juazeiro, Juazeiro-Ba, CEP: 48.902-300

Resumo: A tecnologia surge de forma imprescindível para que se possa estar apto e em condições de atuar de forma competitiva nos diversos ramos de trabalho. A indústria fruticultora não é diferente de outros segmentos de mercado, ou seja, a mesma necessita de inovações para se manter presente na concorrência de mercado livre e até mesmo se destacar frente a outros concorrentes, assim a automação industrial é uma alternativa viável e fundamental. Essa necessidade supracitada se mostra bastante presente para fruticultura irrigada da região de Juazeiro-BA/Petrolina-PE, no Vale do São Francisco, este trabalho tem por finalidade apresentar o desenvolvimento de um protótipo de esteira selecionadora de frutas, que faz uso da inteligência artificial, por redes neurais e técnicas de reconhecimento de padrões, para seleção de frutas. Foca-se na arquitetura da rede Perceptron de Múltiplas Camadas (MLP), fazendo uso dos seguintes algoritmos de extração de características: Momentos Invariantes para distinguir entre diferentes frutas e Histograma para distinguir entre diferentes estados de maturação.

Palavras-chave: Automação industrial, reconhecimento de padrões, indústria fruticultora.

1. INTRODUÇÃO

Os parâmetros para se manter competitivo em determinado segmento acabam variando bastante e obrigando as partes envolvidas a estarem presentes nas modificações ocorridas. Há a necessidade de busca na melhoria da produtividade e racionalização dos recursos investidos, a fim de atender as necessidades da sociedade e do mercado (Rosário, 2005).

Sabe-se que a agroindústria é um dos pilares do desenvolvimento econômico do Brasil, abastecendo mercado interno e externo. As atividades praticadas nesse setor ainda demonstram práticas arcaicas e que não possibilitam o dinamismo e praticidade das operações. Muitas atividades são executadas de forma manual, de modo a deixar o processo lento e permitir o subjetivismo. Assim percebe-se a importância da automatização industrial, ou seja, permitir que os processos sejam feitos de forma automática. A automatização está ligada a sugestão de movimento automático, repetitivo, e mecânico (Silveira, 1998). No contexto agrícola, vale ressaltar a operação de separação de frutas, que costumeiramente é feita de forma manual, retardando toda a sequência de processos subsequentes necessários para o destino final da fruta. Essa atitude acaba por não inserir a atividade em uma situação em que se possa competir de forma adequada com a concorrência no mercado externo e até mesmo interno.

Dessa forma, com foco no auxílio a melhoramento na cadeia de produção de frutas, neste trabalho apresenta-se a construção de uma esteira com a utilização de inteligência artificial, que deve ter a habilidade para armazenar conhecimento e usar o mesmo para solucionar situações diversas, possibilitando a busca de praticidade e otimização no processo da separação de frutas. Busca-se aplicar o conceito de que a inovação tem um papel importante no desenvolvimento e aperfeiçoamento de etapas de dado segmento, referindo-se à introdução de qualquer tipo de melhoria em um produto, processo ou organização da produção dentro de um sistema sem alteração na estrutura industrial. Os elementos mais importantes de um sistema inteligente são: a representação do conhecimento, o raciocínio e a aprendizagem.

Na proposta aqui sugerida optou-se pela utilização das redes neurais para fazer as implementações necessárias da automatização do processo de selecionar frutas, porque estas podem aprender e processar dados de modo a conseguir obter identificação de padrões estabelecidos. Assim, a mesma é dotada de técnicas para que seja possível este reconhecimento de padrões. Rede neural é definida como a combinação entre os neurônios em uma ou mais camadas e interligando os mesmos através das sinapses (Ludwig e Costa, 2007).

1.1 Utilização da Rede Neural Artificial

A rede neural é um método bastante eficaz de reconhecimento de padrões, que é uma área de pesquisa cujo objetivo é a classificação de objetos em um número de categorias ou classes. A utilização da rede neural se baseia inicialmente por uma etapa de aprendizagem, em que um conjunto de amostras é apresentado à rede, a qual se extrai automaticamente as características necessárias para representar a informação fornecida.

A teoria de redes neurais artificiais consolida-se como um paradigma para abordagem de ampla classe dos problemas complexos, em que extensas massas de dados devem ser modelados e analisados em um contexto multidisciplinar, envolvendo, tanto os aspectos estatísticos e computacionais como os dinâmicos e de otimização (Kovács, 2002).

Uma rede neural é um processador paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso (Haykin, 2001).

2. OBJETIVO

O objetivo desse artigo é apresentar a proposta e o desenvolvimento de um protótipo de esteira selecionadora de frutas (protótipo de uma linha de produção), que faz uso da inteligência artificial, por redes neurais e técnicas de reconhecimento de padrões, para seleção de frutas. As frutas escolhidas para a análise foram banana prata e manga Tommy Atkins, que são variedades populares em todo o mundo e típicas da região do Vale do São Francisco. A esteira deve ser capaz de selecionar as frutas em função da forma, reconhecendo assim se a fruta se trata de manga ou banana e também fazer o reconhecimento com relação à cor das frutas, sendo um indicativo de maturação, demonstrando se esta é madura ou não madura.

3. METODOLOGIA

O sistema de seleção de frutas proposto funciona de forma contínua e as frutas que se desejam selecionar são colocadas enfileiradas sobre a esteira, Fig.1, em um ponto de entrada. Este protótipo é constituído por estrutura de madeira, com um motor de acionamento acoplado a uma polia, de forma que ao ser acionado o motor confere movimento a esteira. É um modelo experimental reduzido, possível de ser ampliado para aplicações industriais. As dimensões principais são o comprimento de 150 cm, altura de 90 cm e largura de 42 cm. O motor de acionamento é um motor universal 110V, 100W. Estas frutas são transportadas pela esteira e em determinado ponto adentram uma câmara de iluminação feita por uma lâmpada fluorescente de 35W, de forma a adquirir as imagens das frutas através de uma câmera, não deixando a iluminação externa interferir nos resultados. Essa imagem, por sua vez, é analisada e o sistema de controle aciona os atuadores para movimentarem a fruta para o repositório adequado.



Figura 1. Esteira construída

Para o problema de seleção de frutas foi adotado o aprendizado da rede neural do tipo supervisionado, em que um agente externo ou professor indica para cada entrada o valor da saída, de forma que os pesos da Rede Neural devem ser ajustados durante o treinamento minimizando o erro médio quadrático. A vantagem deste tipo de aprendizado é que para o problema em questão é fácil implementar um professor que indique de que fruta se trata e qual o estado de maturação, também é fácil avaliar o desempenho da rede e sobretudo, este problema se trata de classificação de objetos, sendo indicado o aprendizado supervisionado.

Se tratando de aprendizado supervisionado, é indicada a arquitetura perceptron, como o perceptron simples é incapaz de resolver problemas linearmente inseparáveis, é utilizado o perceptron de múltiplas camadas, permitindo assim resolver problemas mais complexos.

O projeto da arquitetura de uma rede neural envolve o número de camadas ocultas e neurônios por camada, assim como as funções de ativação de cada camada. A escolha dos parâmetros da arquitetura da rede é um tanto empírica, já que não se pode afirmar a existência de uma regra geral que os defina com precisão (BRAGA; LUDEMIR;

CARVALHO, 2011). Duas camadas ocultas é o necessário para obter a aproximação de qualquer função (Cybenko, 1988). Com o objetivo de construir uma rede neural com arquitetura mínima que obtenha um menor erro quadrático médio, foi testado 3 arquiteturas diferentes, a primeira com 2 camadas escondidas e 10 neurônios cada, a segunda tem o mesmo número de camadas com 24 neurônios cada, a terceira possui 3 camadas, sendo que as duas primeiras possuem 20 neurônios e a última 4.

Para o treinamento da rede é comum dividir os dados em três grupos (BEALE;HAGAN;DEMUTH,2015):

- Conjunto de treino: Utilizado para o treinamento propriamente dito, ajuste de pesos e bias.
- Conjunto de validação: Tem por finalidade verificar durante o treinamento como evolui o erro da rede para dados diferentes do treinamento, evitando a perda da generalização. É utilizada para medir o desempenho do treinamento, monitorando o seu erro até alcançar o erro mínimo, salvando os pesos e bias encontrados.
- Conjunto de teste: Utilizado para verificar o desempenho da rede, não altera os pesos e bias.

Para o treinamento da Rede Neural, foi utilizado o algoritmo de Levenberg-Marquadt, que é bastante eficiente quando se trata de redes que não possuem muitas conexões a serem ajustadas, já que este utiliza uma matriz quadrada com dimensão da ordem do número de conexões.

As rotinas referentes à rede neural, tais como: montagem da arquitetura, treinamento e simulação, foram desenvolvidas em Matlab, utilizando a Neural Network Toolbox, que já possui estas rotinas implementadas para se trabalhar com a rede perceptron de múltiplas camadas. O processamento de imagem, tais como: filtros, mudança de sistema de cores e outras operações, também foram desenvolvidas em Matlab, fazendo uso do Image Processing Toolbox, que possui várias operações de processamento de imagem implementadas.



Figura 2. Câmara escura

O processo de aquisição de imagens para o treinamento foi realizado dentro da câmara escura, Fig.2, de forma a padronizar o ambiente tanto para o treinamento quanto para a simulação, já que diferentes níveis de luminosidade afetam o histograma e o processamento de imagem, utilizando uma webcam Multilaser Wc046 que conta com 16 megapixels e resolução de 640x480. Foram utilizados para o treinamento 8 mangas e mais 8 bananas, sendo extraído 5 fotos de cada fruta, já que uma fruta pode ser rotacionada para se retirar outra foto, considerando-se uma nova fruta, totalizando 80 fotos, 40 para cada tipo de fruta. Para a simulação foram utilizadas 4 mangas e 4 bananas, sendo que no momento da extração da imagem, um relé é responsável pelo desligamento momentâneo do motor da esteira, de forma a evitar que o movimento da fruta atrapalhe a qualidade da imagem, em seguida o relé volta a ligar o motor dando continuidade ao processo.

Para a leitura de sensores e controle dos atuadores, necessitou-se do uso do Arduino Uno, que é uma ambiente de desenvolvimento microcontrolado, que faz uso do microcontrolador ATmega328P. O Arduino envia e recebe informações de um computador, Fig.3, através de comunicação serial, ou seja, o computador realiza a extração e processamento da imagem, assim como a aplicação dos dados na rede neural, e envia as informações para o Arduino, que através de suas saídas digitais controla os atuadores.




Figura 3. Descrição do Sistema geral

Para a separação das frutas, foram construídos dois atuadores, o primeiro atuador, Fig.4, é responsável pela separação quanto ao tipo de fruta, este fica na superfície da esteira, apoiado em um suporte horizontal, de forma que um servo motor do tipo 9g SG90 move uma pá de um lado da esteira para o outro, desviando as frutas para seu respectivo repositório. O segundo atuador, Fig.5, possui um fuso com comprimento de 50 cm e diâmetro de 1/4" acoplado a um motor DC 12V, 6500rpm, de forma que uma chapa metálica soldada a uma porca e presa nas laterais (inserido em fendas) de uma caixa de madeira 50cm x 26cm, possa correr do início ao fim sem rotacionar, servindo como um trilho que tem por finalidade separar quanto à maturação, onde fica os repositórios para cada possibilidade de fruta, quatro no total.



Figura 4. Atuador 1



Figura 5. Atuador 2

Para a classificação quanto à maturação, foi considerado que a cor é um bom indício do estado de maturação para as frutas, Fig.6, visto que estas com o decorrer do tempo liberam gás etileno que é responsável por quebrar as moléculas de clorofila presente na casca do fruto, que lhes conferem a cor verde quando não maduras, e também para fins de exportação uma fruta verde não é indicada, sendo esta concebida como não madura. Portanto, foi considerado que uma manga que apresenta uma maior coloração vermelha ou amarela é madura, e uma banana com uma maior coloração amarela é madura, a fruta que apresentar maior presença de verde é considerada não madura.




Figura 6. Fotos das frutas de interesse, retiradas na câmara de luz independente.

Com isso, se tornou necessário o estudo dos métodos de extração de características. A rede neural tem a necessidade de realizar a verificação dos dados, selecionando os apropriados para a utilização. O software utilizado para tal foi o Matlab, que tem ferramentas adequadas para estas avaliações. Dentre as abordagens para tratamento de dados duas tem maior destaque, a primeira tem por objetivo de refutar dados de pouca relevância e a segunda busca reduzir a dimensão desses dados (Ludwig e Costa, 2007).

A escolha do método de extração de característica é dependente do problema proposto, sendo de importância fundamental se fazer uma escolha criteriosa para não implicar em erros e imprecisões. Optou-se pela utilização do momento invariante para se conseguir fazer distinção de forma nas frutas escolhidas, no caso manga e banana. As aplicações de momentos invariantes envolvem reconhecimento de padrões de imagem que tratam com matrizes de pixels de elevada dimensão (Ludwig e Costa, 2007).

Para a classificação através da textura, foi utilizado histograma como método de extração de características, que são distribuições de frequências de dados de uma classe, podendo ser aplicado em inúmeros sistemas de cores, escala de cinza, RGB, HSV e outros. O histograma indica a frequência absoluta dos pixels que contém uma determinada intensidade, de forma que uma imagem 640x480 tem apenas, no caso do sistema RGB por exemplo, 255 valores, o que viabiliza a técnica de reconhecimento de padrões por meio de redes neurais.

Para o uso de histogramas no reconhecimento de maturação, foi utilizado o sistema HSV ao invés do RGB, devido a este abranger na componente H (matriz) as componentes verde, amarela e vermelha, uma por vez, já para o sistema RGB, o amarelo é uma soma das componentes R e G, como tanto a manga e banana podem possuir trechos de cor amarela, fica melhor caracterizado o problema utilizando sistema HSV.


O processo de reconhecimento de padrões necessita de uma etapa anterior, responsável por decompor a imagem em unidades expressivas, relevantes para o problema, eliminando as partes que não interessam e os ruídos, este é o processo chamado de segmentação. A segmentação está contida na área de Processamento de Imagens, e é necessária para a detecção de forma pelo momento invariante, neste trabalho foram adotados os seguintes processamentos: conversão para escala de cinza, filtro Gaussiano para remoção de ruídos, binarização pelo método de Otsu, deixando a imagem em duas cores, branco ou preto, aplicação do filtro Laplaciano para detectar as bordas da fruta, que é o que interessa para o reconhecimento de forma.

4. RESULTADOS


A partir da aquisição de imagens foi possível compor um banco de dados utilizado no treinamento da rede neural. Para o treinamento foi testado 3 arquiteturas diferentes de Rede Neural, isto para cada aplicação, reconhecimento de forma ou textura, sendo escolhido para uso no processo de separação, aquela que obteve o menor erro médio quadrático durante o processo de validação, com um menor número de épocas utilizadas.

Das amostras destinadas ao treinamento, 50% foi utilizado para o conjunto de treino, 25% para validação e 25% para o teste.


Como critério de parada para o treinamento, foi utilizado um gradiente mínimo de 10⁻⁸, não foi definido um tempo máximo de simulação, deixando o tempo que for necessário, número máximo de épocas no treinamento igual a 100, e o parâmetro número máximo de falhas igual a 6, fazendo com que o processo de validação seja interrompido quando o erro aumentar 6 vezes consecutivas, garantindo a generalização da rede.



(a)



(b)



(c)

Figura 7. Arquiteturas utilizadas, arquitetura 1(a), arquitetura 2(b) e arquitetura 3(c).

O número de entradas de cada arquitetura depende do método de extração de características utilizado, se é histograma ou momento invariante.

4.1. Treinamento da Rede Neural para Mangas Segundo Estado de Maturação

Para o treinamento da rede neural utilizando o histograma da componente H do sistema HSV, obtiveram-se os seguintes erros médios quadráticos para as três arquiteturas, Tabela 1.

Tabela 1. Erro médio quadrático para as arquiteturas disponíveis.

Arquitetura	Erro Médio Quadrático	Número de Épocas
1	$9,5036 \times 10^{-10}$	9
2	$4,1401 \times 10^{-9}$	13
3	$6,2142 \times 10^{-6}$	19

De acordo com os erros obtidos durante o processo de treinamento, a melhor arquitetura para o problema em questão, é a do tipo 1, já que esta possui o menor erro e atinge este valor em um menor número de épocas, como pode-se observar as curvas do erro médio quadrático para os conjuntos de treino, validação e teste, obtidas através do Neural Network Toolbox do Matlab.




Figura 8. Resultado do treinamento para classificação de manga quanto à textura.

4.2. Treinamento da Rede Neural para Bananas Segundo Estado de Maturação

Para o treinamento da rede neural utilizando o histograma da componente H do sistema HSV, obtiveram-se os seguintes erros médios quadráticos para as três arquiteturas, Tabela 2.

Tabela 2 – Erro médio quadrático para as arquiteturas disponíveis.

Arquitetura	Erro Médio Quadrático	Número de Épocas
1	$3,3989 \times 10^{-11}$	12
2	$4,4459 \times 10^{-10}$	16
3	$8,7494 \times 10^{-9}$	14

De acordo com os erros obtidos durante o processo de treinamento, a melhor arquitetura para o problema em questão, é a do tipo 1, já que esta possui o menor erro e atinge este valor em um menor número de épocas, como se observa as curvas do erro médio quadrático para os conjuntos de treino, validação e teste, obtidas através do Neural Network Toolbox do Matlab.




Figura 9 - Resultado do treinamento para classificação de manga quanto a textura.

4.3. Processamento de Imagens

Seguindo-se as etapas de segmentação foram obtidos os seguintes resultados dispostos na Figura 10.




Figura 10. Resultados obtidos das etapas de segmentação.

A escolha de banana para demonstrar os resultados, foi meramente ilustrativa.

4.4. Treinamento da Rede Neural para Reconhecimento de Forma

Para o treinamento da rede neural utilizando o Momento Invariante para reconhecimento do tipo de fruta, banana ou manga, obtiveram-se os seguintes erros médios quadráticos para as três arquiteturas – Tabela 3:

Tabela 3 – Erro médio quadrático para as arquiteturas disponíveis.

Arquitetura	Erro Médio Quadrático	Número de Épocas
1	0,001202	21
2	0,004359	29
3	0,020448	28

De acordo com os erros obtidos durante o processo de treinamento, a melhor arquitetura para o problema em questão, é a do tipo 1, já que esta possui o menor erro e atinge este valor em um menor número de épocas, como pode-se observar as curvas do erro médio quadrático para os conjuntos de treino, validação e teste, obtidas através do Neural Network Toolbox do Matlab.




Figura 11. Resultado do treinamento para classificação das frutas quanto a forma.

4.5. Simulação do Protótipo

O processo de simulação é o teste final realizado em condições reais, utilizando dados distintos dos utilizados na fase de treinamento, ou seja, novas frutas foram utilizadas, sendo estas colocadas na esteira, onde foi realizada a aquisição da imagem, e lançada à rede neural apenas a entrada e não existindo um agente externo que indique a saída desejada do processo. Para a simulação foi alcançado o resultado de 95% de acertos para maturação e 85% de acerto para forma.

5. CONCLUSÃO

Após terminar todas as etapas de construção do protótipo conseguiu-se executar o seu funcionamento de forma correta, atendendo aos objetivos estabelecidos. Conforme apresentado foi possível se fazer a distinção por forma (banana e manga) a partir da utilização do momento invariante, obtendo-se bons resultados. Da mesma forma a distinção quanto à textura foi realizada com um bom aproveitamento através de histogramas em HSV. Após as etapas aqui discutidas, tem-se um protótipo funcional que pode ser ampliado, de forma a contribuir com o agronegócio, sendo utilizado na seleção de frutas para exportação ou mesmo para o pequeno comércio, sem contar que a abordagem aqui utilizada para o reconhecimento quanto a forma e textura pode ser adaptada para outras aplicações, desde que se tenha feito a devida análise.

6. REFERÊNCIAS

- BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B., 2015. Neural Network Toolbox – User's guide The MathWorks, BRAGA, A. P.; LUDEMIR, T. B.; CARVALHO, A. P. L. F., 2011 Redes neurais artificiais: Teoria e aplicações. 2ªed. Rio de Janeiro: LTC.
- CYBENKO, G., 1988. Continuous valued neural networks with two hidden layers are sufficient. Technical report, Department of Computer Science, Tufts University.
- HANSELMAN, D.; LITTLEFIELD, B. 2003. MATLAB 6: Curso completo. Prentice Hall, São Paulo.
- HAYKIN, S., 2001 Redes Neurais: Princípios e prática. 2. ed. Porto Alegre: Bookman.
- KOVÁCS, Z. L., 2002. Redes neurais artificiais: Fundamentos e aplicações. 4.ed. São Paulo: Livraria da Física.
- LUDWIG, Oswaldo Jr., e COSTA, Eduard M. M., 2007 Redes Neurais: Fundamentos e Aplicações com Programas em C. Editora Ciência Moderna, Rio de Janeiro, RJ.
- ROSÁRIO, João M., 2005. Princípios de Mecatrônica, Pearson-Prentice Hall, São Paulo, SP.
- SILVEIRA, P. R. da - WINDERSON, E. S., 1998. Automação e Controle Discreto. 8. ed. São Paulo: Érica.

7. RESPONSABILIDADE AUTORAL

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluídos no seu trabalho

Use of Neural Networks in the construction of a sorting running machine fruit

Amaro Pereira Borges, amaro.borges@hotmail.com¹

Pablo Diogo Siqueira Brito, pablo_diogo@hotmail.com¹

José Bismark de Medeiros, jose.bismark@univasf.edu.br¹

Eduard Montgomery Meira Costa, eduard.montgomery@univasf.edu.br¹

¹Universidade Federal do Vale do São Francisco-Univasf, Av. Antonio Carlos Magalhães, 510, Country Club - Campus Juazeiro, Juazeiro-Ba, CEP: 48.902-300

Abstract. The technology comes from essential way so that you can be fit and able to operate competitively in the various lines of work. The industry fruit is no different from other market segments, so it needs innovation to stay present in free-market competition and even stand out against other competitors, and industrial automation is a viable and important alternative. This above need to show enough gift for irrigated fruit of Juazeiro-BA Region / Petrolina, in the São Francisco Valley, this work aims to present the development of a sorter mat prototype fruit, which makes use of artificial intelligence by neural networks and pattern recognition techniques for selection of fruit. Focuses on Perceptron network architecture Multilayer (MLP), making use of the following feature extraction algorithms: Invariant Moments to distinguish between different fruits and Histogram to distinguish between different states of maturation.

Keywords: industrial automation, pattern recognition, industry fruit.

RESPONSIBILITY NOTICE

The four authors are the only responsible for the printed material included in this paper.