

# UM ESTUDO DE CASO DE REDES NEURAIS ARTIFICIAIS PARA A DETECÇÃO DE OBJETOS DEFEITUOSOS NUMA ESTEIRA DE PRODUÇÃO AUTOMATIZADA

**Ingrid Martins Valente Costa**  
ingridmvalente@gmail.com

**Symone Gomes Soares Alcalá**  
symone@ufg.br

**Lorena Cândida Mendonça**  
lorena.candida12@gmail.com



*Com a evolução das tecnologias, sistemas de visão têm possibilitado a realização de inspeções automatizadas. Eles repassam para máquinas a capacidade da visão, podendo extrair automaticamente características e indicar anormalidades em produtos. Atualmente, a maioria dos sistemas de visão reconhecem padrões de cores e poucos são capazes de reconhecer defeitos em produtos. Este artigo propõe uma metodologia para pré-processamento de imagens digitais e classificação de objetos defeituosos e de objetos não defeituosos utilizando Redes Neurais Artificiais (RNAs). A metodologia proposta consiste em: aquisição das imagens (câmera Logitech HD Webcam C270), segmentação (método Otsu's), melhoramento (filtragem mediana), extração de características (matriz de coocorrência) e reconhecimento de padrões (RNAs). Como estudo de caso, são classificadas imagens digitais de caixas numa esteira transportadora. A Webcam fotografou 430 imagens de uma caixa com defeito e de uma caixa sem defeito, ambas com formato de um cubo com arestas de 3,5cm, em diferentes ângulos e iluminações. A arquitetura da RNA foi definida empregando o método 10-fold cross-validation, para determinar o melhor número de neurônios na camada oculta, e o algoritmo Scaled Conjugate Gradient Backpropagation, para realizar o aprendizado da rede. A RNA conseguiu classificar eficientemente e corretamente 100% das imagens digitais de caixas defeituosas e não defeituosas.*

*Palavras-chave: Inteligência Artificial, Backpropagation, matriz de coocorrência, Qualidade de Produtos, Sistema de Visão*

## 1. Introdução

Em uma indústria, assegurar a qualidade dos produtos e dos processos é imprescindível para seu sucesso. Visto que, a qualidade de produtos é relacionada, principalmente, a não presença de defeitos e sua ocorrência pode afetar a credibilidade da marca associada. Nesse sentido, uma maneira de verificar a conformidade dos produtos é realizando a inspeção visual.

A inspeção permite detectar anormalidades nos produtos produzidos, com o intuito de atender às normas e às expectativas dos consumidores. Geralmente, ela é feita manualmente, acarretando em altos custos, falhas e dificuldades na padronização. Com a evolução das tecnologias, sistemas de visão têm possibilitado a realização de inspeções automatizadas. Eles repassam para máquinas a capacidade da visão, podendo extrair automaticamente características e indicar anormalidades em produtos.

Sistemas deste tipo possibilitam exatidão e repetitividade em medições sem contato, pelo fato de suprimir fatores como subjetividade, fadiga, vagareza e custos inerentes à inspeção humana (FELICIANO; SOUZA; LETA, 2010). Por isso, são mais eficientes, seguros e rápidos, pois certificam a qualidade do produto em toda a linha de montagem, uma vez que eles vão além da capacidade humana de detecção visual.

Os sistemas de visão podem ser usados para classificar objetos e detectar defeitos em diversas aplicações industriais. Por exemplo, Bhatt e Pant (2015) utilizaram um sistema de visão para classificar maçãs segundo aspectos físicos, como tamanho, cor e defeitos externos. Martins (2017) elaborou um sistema de apoio ao motorista que identifica e reconhece placas de trânsito. Andrade (2013) substituiu a inspeção humana pela inspeção automatizada com o objetivo de classificar cores de embalagens de defensivos agrícolas. Pessota (2013) propôs um método para classificação de classes de feijão por meio da coloração de suas películas.

Um sistema de visão pode ser dividido nas seguintes fases: aquisição da imagem, segmentação, melhoramento da imagem, extração de características e reconhecimento de padrões (BACKES; JUNIOR, 2016). A aquisição envolve a captura da imagem digital de produtos. A segmentação e o melhoramento são empregues, respectivamente, para destacar a porção relevante e para aumentar a qualidade da imagem. Ambas as etapas são importantes

para eliminar aspectos, como ruídos, que poderiam comprometer as etapas posteriores. A extração de características envolve capturar informações relevantes acerca da imagem segmentada que são essenciais para sua classificação. A última fase é feita por algoritmos de classificação, que utilizam as características extraídas para a classificação dos produtos segundo um conjunto de categorias, como por exemplo, produto defeituoso e produto não defeituoso.

Os algoritmos de classificação são desenvolvidos utilizando métodos de Inteligência Artificial (IA). Por meio da IA, agentes inteligentes podem ser criados para realizar tarefas que exigem inteligência quando feitas por humanos (RUSSELL; NORVIG, 2010). De acordo com Mohanan et al. (2016), os modelos de IA usados para reconhecimento de padrões são correspondência por padrão, abordagem estatística, abordagem sintática/estrutural, Redes Neurais Artificiais (RNAs), modelo baseado na lógica fuzzy e modelos híbridos. Dentre estes, RNAs se destacam por sua capacidade de tolerância a falhas. Por exemplo, Capizzi et al. (2016) desenvolveram uma RNA para classificar defeitos na cor e na textura de laranjas.

Atualmente, a maioria dos sistemas de visão reconhecem padrões de cores e poucos são capazes de reconhecer defeitos. Sendo assim, este artigo propõe uma metodologia para pré-processamento de imagens digitais e classificação de objetos defeituosos e de objetos não defeituosos utilizando RNAs. Para isso, são realizadas as seguintes fases: aquisição das imagens (câmera Logitech HD Webcam C270), segmentação (método *Otsu's*), melhoramento (filtragem mediana), extração de características (matriz de coocorrência) e reconhecimento de padrões (RNAs). Como estudo de caso, são classificadas imagens digitais de caixas numa esteira transportadora.

Com o intuito de desenvolver o artigo, este foi organizado em cinco seções. A primeira seção compreende o presente texto o qual apresenta a introdução e a contextualização do tema. A seção 2 detalha o referencial teórico. A seção três expõe a metodologia empregue na condução da pesquisa. A seção quatro discute os resultados da aplicação da metodologia proposta. A seção cinco apresenta as considerações finais do estudo e sugestões para trabalhos futuros.

## 2. Referencial teórico

Esta seção descreve as duas fases mais importantes de um sistema de visão, sendo que a seção 2.1 trata de técnicas para a extração de características e a seção 2.2 aborda um modelo de IA para reconhecimento de padrões.

### 2.1 Técnicas para extração de características de imagens

O funcionamento de qualquer algoritmo de classificação depende da quantidade e da qualidade das entradas inseridas. Sendo assim, a escolha da técnica para extração de características a ser adotada deve ser condizente com o problema abordado. Uma técnica eficiente para extrair informações de textura de imagens é a Matriz de Coocorrência de Nível de Cinza (MCNC), em que a textura é classificada pela distribuição espacial dos níveis de cinza em uma vizinhança.

A matriz retrata as combinações de valores de brilho de *pixel* (níveis de cinza) de forma tabular (CAPIZZI et al., 2016). Ela mostra a frequência com que um valor de *pixel*, com valor de nível de cinza  $i$ , ocorre em relação a outro valor de *pixel*, conhecido como *pixel* vizinho, com valor de nível de cinza  $j$ . De modo que, cada elemento  $P(i, j)$ , da matriz de coocorrência  $\mathbf{P}$  de tamanho  $N_g \times N_g$ , é o número de ocorrências de pares de *pixel* com valor  $i$  e de *pixel* com valor  $j$ , que estão a uma distância  $d$  (PATHAK; BAROOAH, 2013). Cumpre destacar que  $N_g$  é número de níveis de cinza.

Dada uma imagem  $\mathbf{I}$  de tamanho  $N \times N$ , a matriz de coocorrência  $\mathbf{P}$  pode ser matematicamente definida como:

$$P(i, j) = \sum_{x=1}^N \sum_{y=1}^N \begin{cases} 1, & \text{se } \mathbf{I}(x, y) = i \text{ e } \mathbf{I}(x + \Delta_x, y + \Delta_y) = j \\ 0, & \text{caso contrário} \end{cases} \quad (1)$$

Em que  $i$  é a linha correspondente da matriz  $\mathbf{P}$ ;  $j$  é a coluna correspondente da matriz  $\mathbf{P}$ ;  $(x, y)$  indica o nível de cinza de um *pixel* localizado na linha  $x$  e na coluna  $y$  da imagem  $\mathbf{I}$ ;  $\Delta_x$  e  $\Delta_y$  são os deslocamentos que indicam a distância entre o *pixel* de interesse e seu *pixel* vizinho.

A MCNC pode ser usada para calcular as características de textura como contraste, entropia, energia e homogeneidade. Por exemplo, a equação 2 determina a intensidade do contraste entre um *pixel* e seus vizinhos:

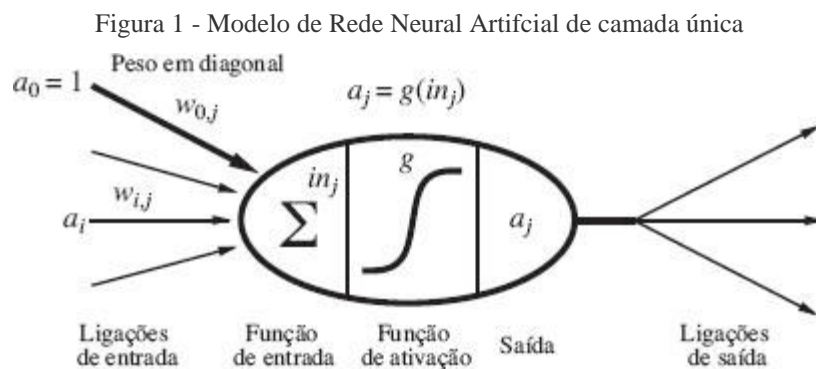
$$\text{Contraste} = \frac{1}{(N_g - 1)^2} \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j)^2 p(i, j) \quad (2)$$

Em que  $p(i, j)$  é o valor do elemento na linha  $i$  e na coluna  $j$  na matriz  $\mathbf{P}$  normalizada.

## 2.2 Redes neurais artificiais

RNAs são modelos de IA inspirados no funcionamento do sistema nervoso biológico. A fim de solucionar um problema, neurônios se interconectam para empenharem juntos na resposta a um estímulo de entrada (MOHANAN et al., 2016). As principais características de RNAs são: aprendizado – capacidade que a RNA tem de iniciar sem conhecimento e poder ser treinada utilizando um conjunto de dados; generalização – capacidade de produzir a melhor saída para um exemplo não utilizado no treinamento; paralelismo potencial massivo – neurônios são disparados concomitantemente ao longo do processamento de dados; robustez – mesmo que alguns neurônios não funcionem bem, ainda assim todo o sistema poderá ter um bom desempenho; e correspondência parcial – a qual indica que os dados conhecidos não coincidem exatamente com novos acontecimentos (KASABOV, 1998).

Uma RNA é formada por um conjunto de unidades conectadas, também conhecidas como neurônios ou nós (RUSSELL; NORVIG, 2010). McCulloch e Pitts (1943) *apud* Russell e Norvig (2010) desenvolveram um modelo de RNA de camada única, também conhecido como *perceptron*. Ele se ativa quando a combinação linear das entradas ultrapassa um limiar pré-estabelecido. Esse modelo está exposto na Figura 1.



Fonte: RUSSELL; NORVIG (2010)

Como mostra a Figura 1, o modelo exhibe um neurônio  $j$  que recebe sinais de entrada ( $a_i = 1, \dots, n$ ) os quais são conectados por ligações direcionais. Cada ligação possui um peso associado ( $w_{ij}$ ) que indica a força de conexão de  $i$  para  $j$ . Cada neurônio possui uma entrada fictícia  $a_0 = 1$ . Após relacionar os pesos, aplica-se uma função de ativação  $g$  e tem-se uma saída correspondente  $a_j$ , obtida como:

$$a_j = g \left( \sum_{i=0}^n w_{ij} a_i \right) \quad (3)$$

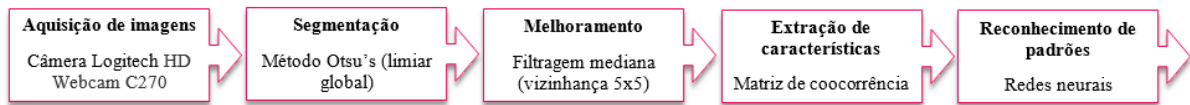
Para que uma RNA receba entradas e forneça saídas desejadas, ela deve passar por um processo de aprendizagem, que é realizado em várias iterações, para a obtenção dos pesos finais. O processo interrompe quando um critério de parada estabelecido é atingido. Os algoritmos de treinamento são responsáveis por esse processo. Em RNAs de camada única, algoritmos de treinamento como a regra de aprendizagem *perceptron* ou a regra de descida pelo gradiente por regressão logística pode ser adotado. RNAs de única camada não são capazes de lidar com problemas não linearmente separáveis (RUSSELL; NORVIG, 2010).

Por isso, RNAs com múltiplas camadas têm sido amplamente adotadas, devido à capacidade de lidar com problemas mais complexos. Elas também são conhecidas como *Perceptrons* de Múltiplas Camadas – em inglês *Multilayer Perceptrons* (MLPs). O *Backpropagation* é o algoritmo de treinamento para MLPs mais conhecido. O algoritmo *Scaled Conjugate Gradient Backpropagation* (SCGB) é uma versão mais rápida do algoritmo *Backpropagation*, em que as derivadas parciais de segunda ordem são utilizadas para alterar a taxa de aprendizado (MØLLER, 1993).

### 3. Metodologia

Com o intuito de realizar a inspeção automática de caixas numa esteira transportadora, propôs-se a metodologia exposta na Figura 2. A primeira etapa consiste na obtenção de imagens das caixas, utilizando a câmera Logitech HD *Webcam* C270, com resolução máxima de 1280x960.

Figura 2 - Metodologia para a inspeção automática de produtos



Fonte: Elaborado pelos autores

A imagem capturada se encontra no sistema *Red, Green e Blue* (RGB), que é então convertida para o sistema YCbCr. O canal Y contém a luminância, o canal Cb contém a crominância azul e o canal Cr contém a crominância vermelha. O canal Y representa a intensidade de luz e os canais Cb e Cr representam a colorização. A mudança no espaço de cores é necessária para extrair características referentes à luminância e à crominância das imagens (CAPIZZI et al., 2016). Essas características são essenciais para segmentar a imagem.

A próxima etapa, segmentação, é utilizada para extrair o objeto da porção considerada como fundo da imagem. Para isso, emprega-se o método *Otsu's* que obtém um limiar global a partir do canal Cr da imagem. O limiar atua como uma fronteira delimitando o espaço preenchido pelo objeto e o espaço conhecido como fundo na imagem.

A etapa seguinte, melhoramento, produz imagens com maior qualidade, permitindo uma maior eficiência do algoritmo de classificação. Para esse fim, foram eliminados ruídos restantes do processo de segmentação utilizando filtro da mediana, em que cada pixel da imagem é substituído pela mediana da vizinhança. Neste artigo, a vizinhança adotada foi 5x5.

Em seguida, a extração de características da imagem é feita utilizando MCNC, tendo contraste como característica (CAPIZZI et al., 2016), conforme mostrado na seção 2.1. Para cada canal, são determinadas quatro matrizes de coocorrência empregando distância igual a 1 e quatro direções – 0°, 45°, 90° e 135°. Logo após, um valor de contraste é obtido utilizando cada matriz, totalizando 12 características. Além disso, o valor médio de cada canal é calculado. As médias calculadas permitem saber os valores gerais dos canais YCbCr da imagem segmentada. Dessa forma, utilizando uma imagem são obtidas 15 características que serão utilizadas como entradas em algoritmos de classificação.

Para o treinamento de um algoritmo de classificação, é preciso criar um conjunto de dados de imagens constituído por duas matrizes, **X** e **Y**, obtidas como:



$$\mathbf{X} = \begin{bmatrix} f_{1,1} & \dots & f_{1,m} \\ \dots & \dots & \dots \\ f_{15,1} & \dots & f_{15,m} \end{bmatrix} \quad (4)$$

$$\mathbf{Y} = \begin{bmatrix} y_{1,1} & \dots & y_{1,m} \\ y_{2,1} & \dots & y_{2,m} \end{bmatrix} \quad (5)$$

Em que  $\mathbf{X}$  é a matriz de entrada com tamanho  $15 \times m$ ,  $\mathbf{Y}$  é a matriz de saída com tamanho  $2 \times m$  e  $m$  é o número de imagens. Para cada imagem  $c$ , são armazenadas 15 características ( $f_{1,c}$ , ...,  $f_{15,c}$ ) em uma coluna de  $\mathbf{X}$  e a classe ( $y_{1,c}$ , ...,  $y_{2,c}$ ) em uma coluna de  $\mathbf{Y}$ . Sendo que existem duas classes: "caixa sem defeito" e "caixa com defeito". Para uma imagem  $c$  pertencente à classe "caixa sem defeito", atribui-se  $y_{1,c} = 0$  e  $y_{2,c} = 1$ ; e para uma imagem  $c$  pertencente à classe "caixa com defeito", atribui-se  $y_{1,c} = 1$  e  $y_{2,c} = 0$ .

A última etapa, referente ao reconhecimento de padrões, foi desenvolvida utilizando um MLP treinado com o algoritmo SCGB. Para isso, deve-se determinar o melhor número de neurônios na camada oculta e as amostras (ou imagens) para treino, teste e validação. Com o conjunto de dados definido ( $\mathbf{X}$  e  $\mathbf{Y}$ ), dividiu-se randomicamente 65% dos dados para treino, 20% para teste e 15% para validação. Os dados de treino são responsáveis pelo aprendizado (treinamento) da RNA, os dados de validação são usados para verificar a acurácia da RNA durante o aprendizado e os dados de teste são empregues para autenticar a acurácia da RNA após o aprendizado em um conjunto de dados que não foi utilizado no treinamento.

O melhor número de neurônios a ser utilizado na camada oculta foi encontrado com o método *k-fold cross-validation* que divide aleatoriamente um conjunto de dados  $\mathbf{D}$  em  $k$  subconjuntos mutuamente exclusivos  $\{\mathbf{D}_1, \mathbf{D}_2, \mathbf{D}_3, \dots, \mathbf{D}_k\}$ . O resultado do método, para um número de neurônios, é a média dos valores de erro dos  $k$  subconjuntos, sendo que cada subconjunto é usado como dados de teste, ao passo que os outros  $k-1$  conjuntos são divididos aleatoriamente em um conjunto de dados de treinamento (75%) e de validação (25%) (SOARES; ANTUNES; ARAÚJO, 2013). A estimativa da validação de dados, ou seja, o valor médio de erro obtido, é um número que depende da divisão do conjunto de dados (KOHAVI, 1995). Evidencia-se que o método seleciona o número de neurônios que primeiro exibir a menor porcentagem de classificações incorretas.




Em seguida, uma RNA, com arquitetura MLP, foi treinada com o algoritmo SCGB e o melhor número de neurônios.

#### 4. Resultados e discussões


Os resultados descritos nessa seção foram obtidos utilizando *software* MATLAB R2016a. Para o primeiro passo da metodologia proposta, foram adquiridas imagens das caixas numa esteira transportadora. Logo, a *Webcam* fotografou 430 imagens de caixa com defeito e de caixa sem defeito, ambas com formato de um cubo com arestas de 3,5cm, em diferentes ângulos e iluminações. A caixa com defeito apresenta imperfeição na pintura. A Figura 3 apresenta algumas imagens de caixa sem defeito e a Figura 4 exibe algumas imagens de caixa com defeito.

Figura 3 - Algumas imagens de caixas sem defeito



Fonte: Elaborado pelos autores


Figura 4 - Algumas imagens de caixas com defeito



Fonte: Elaborado pelos autores


As Figuras 5 e 6 expõem o resultado de duas imagens após as etapas de segmentação e de melhoramento.

Figura 5 - Pré-processamento de imagem de uma caixa sem defeito



Fonte: Elaborado pelos autores

Figura 6 - Pré-processamento de imagem de uma caixa com defeito

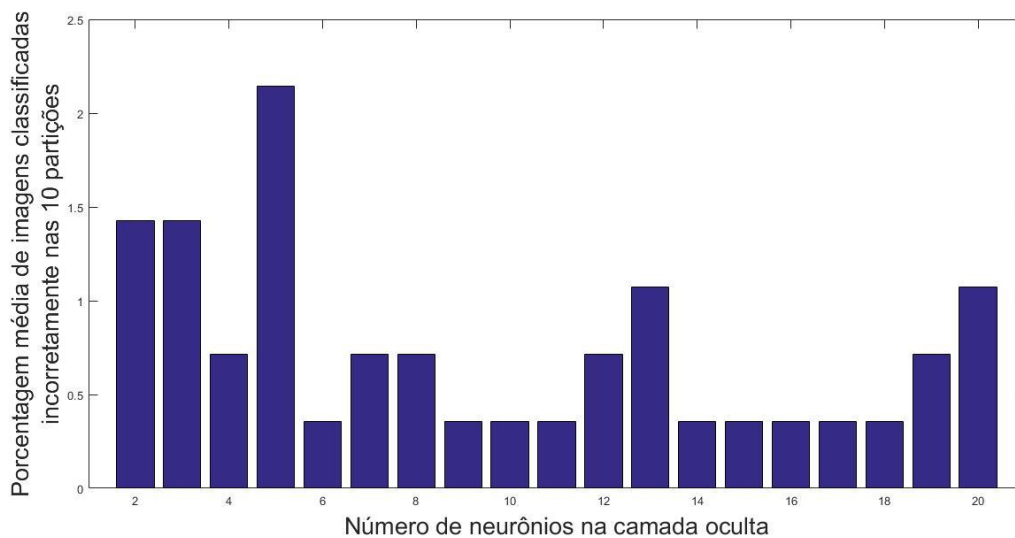


Fonte: Elaborado pelos autores

Após o melhoramento das imagens, realizou-se o processo de extração de características e armazenou o conjunto de dados resultante da extração: uma matriz  $X$  de tamanho  $15 \times 430$  e uma matriz  $Y$  de tamanho  $2 \times 430$ . Então,  $X$  e  $Y$  foram usadas para treinar (65%), validar (15%) e testar (20%) a RNA. Com a finalidade de determinar o melhor número de neurônios

na camada oculta, o método *10-fold cross-validation* foi empregue utilizando apenas os dados de treino com número de neurônios variando de 2 a 20. Os dados de treino foram divididos em 10 subconjuntos, sendo que em cada execução do método, um subconjunto foi utilizado para teste e as nove partições restantes para treino (75%) e validação (25%). O desempenho desse método para cada número de neurônio é mostrado na Figura 7, onde o desempenho foi medido utilizando a porcentagem média (nos 10 subconjuntos de teste) de imagens classificadas incorretamente.


Figura 7 - Desempenho da Rede Neural Artificial no método *10-fold cross-validation*



Fonte: Elaborado pelos autores

Na Figura 7, verifica-se que o menor erro foi obtido com números de neurônios iguais a 6, 9, 10, 11, 14, 15, 16, 17, 18. Sendo assim, foram escolhidos seis neurônios, como mostra a Figura 8.

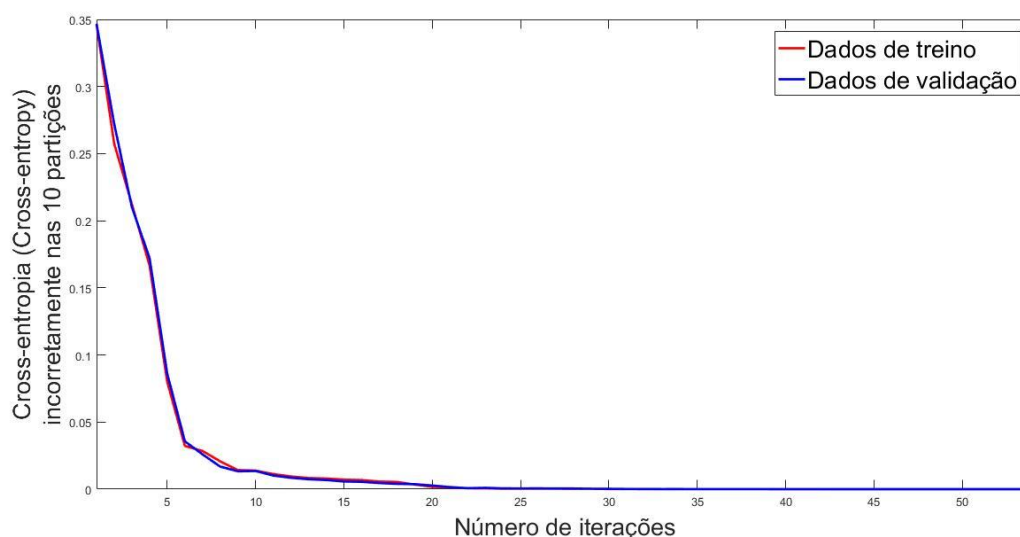
Figura 8 - Configuração da Rede Neural Artificial com 6 neurônios na camada oculta



Fonte: Elaborado pelos autores

As funções de ativação escolhidas foram: sigmoide tangente hiperbólica (*tansig*) para a camada oculta e máxima suave (*softmax*) para a camada de saída. O treinamento da RNA foi feito utilizando o algoritmo SCGB com os parâmetros padrões do *software* MATLAB: máximo de iterações igual a 1000, meta de desempenho igual a 0, entre outros (MATHWORKS, 2018a). O desempenho da RNA durante o treinamento foi medido utilizando a função entropia cruzada (*crossentropy*) (MATHWORKS, 2018b). A Figura 9 exibe o desempenho da RNA nos dados de treino e validação. O treinamento foi interrompido automaticamente após 53 iterações.

Figura 9 - Desempenho da Rede Neural Artificial no processo de treinamento



Fonte: Elaborado pelos autores

A Tabela 1 mostra a porcentagem de classificações corretas e incorretas da RNA nos dados de treino, de validação e de teste. Nota-se que o desempenho da RNA foi de 100% em todos os dados, isto é, a RNA conseguiu classificar eficientemente imagens de caixas defeituosas e não defeituosas em todos os dados. Por isso, pode-se concluir que a metodologia proposta possui eficácia na classificação de caixas defeituosas e não defeituosas numa esteira transportadora.

Tabela 1 - Porcentagem de classificações corretas e incorretas da Rede Neural Artificial

Dados	Classificações corretas	Classificações incorretas
-------	-------------------------	---------------------------

---

Treino	100%	0,00%
Validação	100%	0,00%
Teste	100%	0,00%

---

Fonte: Elaborado pelos autores

## 5. Considerações finais

A utilização de imagens digitais de objetos para controlar a qualidade de produtos é indispensável em razão de evitar falhas e custos adicionais decorrentes da inspeção manual. O método proposto de classificação de produtos utilizando uma RNA contribuiu para a maior confiabilidade na classificação de objetos em defeituosos ou em não defeituosos. Como trabalho futuro, espera-se a aplicação da metodologia proposta em uma empresa com o intuito de verificar a acurácia do modelo em uma linha de produção real.

## REFERÊNCIAS

- ANDRADE, Eduardo de. **Classificação de Cores de Embalagens de Defensivos Agrícolas Utilizando Redes Bayesianas**. 2013. 97 f. Dissertação (Pós-Graduação em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Universidade Federal do Paraná, Curitiba, 2013.
- BACKES, André Ricardo; JUNIOR, Jarbas Joaci de Mesquita Sá. **Introdução à Visão Computacional Usando MATLAB**. Rio de Janeiro: Alta Books Editora, 2016.
- BHATT, Ashutosh Kumar; PANT, Durgesh. Automatic Apple Grading Model Development Based on Back Propagation Neural Network and Machine Vision, and Its Performance Evaluation. **Ai & Society**, London, v. 30, n. 1, p. 45-56, 2015. Disponível em: <https://doi.org/10.1007/s00146-013-0516-5>. Acesso em: 17 abr. 2018.
- CAPIZZI, Giacomo et al. A Novel Neural Networks-based Texture Image Processing Algorithm for Orange Defects Classification. **International Journal of Computer Science & Applications**, pp. 45 – 60, v. 13, n. 2, 2016.
- FELICIANO, Flávio F.; SOUZA, Igor L de; LETA, Fabiana R. Visão Computacional Aplicada à Metrologia Dimensional Automatizada: Considerações Sobre sua Exatidão. **Engevista**, v. 7, n. 2, 2010.
- KASABOV, Nikola K. **Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering**. Second Printing. Massachusetts Institute of Technology: A Bradford book, 1998.
- KOHAVI, Ron. A Study of Cross-validation and Bootstrap for Accuracy Estimation and Model Selection. In: **The International Joint Conference on Artificial Intelligence (IJCAI)**. 1995. p. 1137-1145.
- MARTINS, Marconi Amorim. **Identificação de Placas de Trânsito Através da Classificação de Imagens Usando Redes Neurais Artificiais**. 2017. 45 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Eletrônica e Telecomunicações) – Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Patos de Minas, 2017.

MATHWORKS. **Trainscg**: Scaled Conjugate Gradient Backpropagation. Disponível em:  
<<https://www.mathworks.com/help/nnet/ref/trainscg.html>>. Acesso em: 29 mar. 2018a.

MATHWORKS. **Crossentropy**: Neural Network Performance. Disponível em:  
<<https://www.mathworks.com/help/nnet/ref/crossentropy.html>>. Acesso em: 6 maio 2018b.

MØLLER, Martin Fodsette. A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning. **Neural Networks**, v. 6, n. 4, p. 525-533, 1993.

MOHANAN, Neeraja et al. A Brief Description of Pattern Recognition Techniques. **Imperial Journal of Interdisciplinary Research**, v. 2, n. 8, 2016.

PATHAK, Biswajit; BAROOAH, Debajyoti. Texture Analysis Based on the Gray-level Co-occurrence Matrix Considering Possible Orientations. **International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering**, v. 2, n. 9, p. 4206-4212, 2013. Disponível em:  
<https://pdfs.semanticscholar.org/580e/9785eb5b1d1dcb2528edb3977c13e2e8ce60.pdf>. Acesso em: 6 maio 2018.

PESSOTA, Jorge Henrique. **Sistema Especialista Aplicado à Inspeção da Qualidade Visual de Grãos de Feijão**. 2013. 83 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Nove de Julho, São Paulo, 2013.

RUSSELL, Stuart J.; NORVIG, Peter. **Artificial Intelligence: A Modern Approach**. Malaysia; Pearson Education Limited, 2010.

SOARES, Symone; ANTUNES, Carlos Henggeler; ARAÚJO, Rui. Comparison of a Genetic Algorithm and Simulated Annealing for Automatic Neural Network Ensemble Development. **Neurocomputing**, v. 121, p. 498-511, 2013.