

## Introdução

Latas metálicas são amplamente utilizadas na indústria por sua leveza, reciclabilidade, facilidade de estocagem e preço reduzido. Sua capacidade de entregar produtos sem danos e seguros aos clientes é de suma importância principalmente no caso da indústria alimentícia. As latas comumente utilizadas na indústria são compostas de duas partes principais: o corpo da lata e a tampa. Uma série de defeitos podem surgir durante os processos de fabricação dessas partes, sendo a tampa a maior fonte de defeitos, já que é composta de mais partes [1] [4].

Um dos processos da montagem da tampa é a inserção de uma alavanca para a abertura da lata sem a necessidade de ferramentas, essa alavanca é unida com a tampa através de um rebite. Essa união muitas vezes pode falhar, fazendo com que a alavanca se solte sem abrir a lata, ou nos piores casos apresentar uma fratura causando vazamentos e a contaminação do alimento. O presente trabalho vai trazer a implementação da identificação de fratura no rebite das tampas metálicas utilizando uma rede neural convolucional, assim como uma comparação com uma implementação que tem o mesmo objetivo, mas utilizando os métodos tradicionais de visão computacional, descrita em [3].

## Materiais e métodos

Para a implementação utilizando redes neurais convolucionais foi utilizada a biblioteca *fastai* [2] disponível em Python. Essa biblioteca simplifica o processo de teste e construção de uma rede neural convolucional. Como treinar uma rede neural convolucional partindo do zero é um processo muito custoso, e já existem redes pré-treinadas para tarefas de identificação de objetos, decidiu-se utilizar do treinamento por transferência de conhecimento. Como arquitetura da rede, foi escolhida a rede ResNet-50 pré-treinada para classificação de imagens. A implementação utilizando os métodos clássicos de visão computacional iniciou com uma binarização da imagem através de análise de histograma, seguida por operações morfológicas de abertura e fechamento para a eliminação de ruídos. Após a imagem filtrada utilizou-se de um algoritmo de componentes conexos para a identificação do rebite. Para classificar o rebite como fraturado ou não utilizou-se duas técnicas, uma através da análise da circularidade do rebite (CAMDC) e outra através de descritores de Fourier em conjunto com uma rede neural *feed-forward* com *backpropagation* (FDANN). A implementação com métodos clássicos é descrita em mais detalhes em [3].

## Experimentos

Para os experimentos foram utilizadas 320 imagens classificadas por um especialista, sendo 96 classificadas como defeituosas e 224 como não-defeituosas. Foram utilizadas as mesmas imagens do trabalho [3], elas foram capturadas em um ambiente controlado, a única variável era a posição do rebite na imagem. Inicialmente foram utilizadas as imagens completas, com visão de toda a tampa metálica, mas a rede não foi capaz de aprender a diferenciar as tampas com rebites fraturados dos não-fraturados. Para resolver este problema foi utilizado como entrada uma imagem de 100x100 pixels, com o rebite no centro da imagem, um exemplo de rebite fraturado e não-fraturado pode ser visto na Figura 1.




Figura 1: Exemplo de rebites. (a) Fraturado. (b) Não-fraturado.

Cada uma das classes, rebites fraturados e não fraturados, foram divididas em um conjunto de teste e um conjunto de validação, sendo que para cada classe 20% das imagens foram selecionadas aleatoriamente para o conjunto de validação. Com os pesos pré-treinados carregados, foram feitas 5 épocas para treinar a rede para o novo conjunto de dados, este primeiro estágio do treinamento modifica apenas os pesos da rede de decisão na saída da rede convolucional, não modificando as matrizes de convolução. Para continuar o treinamento a rede foi “descongelada”, permitindo o ajuste das matrizes de convolução, e mais 5 épocas foram executadas.

## Resultados

Na Tabela 1 pode-se observar as precisões dos métodos testados. A rede neural convolucional (RNC) estágio 1 seria a rede após as primeiras 5 épocas, e a RNC estágio 2 a rede após as últimas 5 épocas que modificaram as matrizes de convolução. O método CAMDC e FDANN são referentes aos resultados obtidos pelo trabalho [3]. Em termos de performance, ambas as RNC consumiram 26.5 ms para classificar uma imagem, enquanto o método CAMDC consumiu 38.09 ms.

Tabela 1: Precisão dos métodos, adaptado de [3].

Método	Precisão
RNC estágio 2	100%
CAMDC	98.13%
FDANN	93.10%
RNC estágio 1	91.5%

## Conclusões

Percebe-se que a implementação utilizando a rede neural convolucional obteve um resultado melhor para o conjunto de dados selecionado. Apesar disso, a rede só foi capaz de chegar a um nível de acerto superior ao método tradicional quando apenas o rebite estava em destaque, não sendo capaz de classificar a mesma imagem de entrada utilizada pelos métodos CAMDC e FDANN. Esse detalhe faz com que a rede neural precise de um processamento similar ao utilizado na abordagem com os métodos de processamento de imagem tradicionais, tornando-a mais lenta. Apesar de não ser o caso ideal, como a esteira que carrega as tampas tem uma variação de 4 a 8 tampas por segundo, consumir mais 38 ms para detectar o rebite não seria proibitivo para a utilização da RNC. Para trabalhos futuros fica a aquisição de novas imagens para tentar eliminar a necessidade da segmentação do rebite na rede neural, e outra possibilidade, seria treinar outra rede para identificar a posição do rebite.

## Referências

- [1] T. Chen, Y. Wang, C. Xiao, and Q. J. Wu. A machine vision apparatus and method for can-end inspection. *IEEE transactions on instrumentation and measurement*, 65(9):2055–2066, 2016.
- [2] J. Howard et al. *fastai*. <https://github.com/fastai/fastai>, 2018.
- [3] M. E. Stivanello and K. J. Marcellino. A machine vision system for online metal can-end rivet inspection. In *Journal of Physics: Conference Series*, volume 1335, page 012002. IOP Publishing, 2019.
- [4] C. Tzia and T. Varzakas. *Handbook of food processing: Food preservation*. 2015.