

IDENTIFICAÇÃO DE REBITES FRATURADOS EM LATAS

GRUPO 09 - AMABYLE RABECHE HECK E GUILHERME PIVETI FILHO

INTRODUÇÃO

Há ampla utilização de latas metálicas na indústria alimentícia pela sua capacidade de garantir a conservação e segurança dos produtos que armazenam. No entanto, um rebite (parte que une a alavanca de abertura à tampa) defeituoso pode ocasionar a contaminação de alimentos. O objetivo deste trabalho era implementar soluções que fizessem a identificação de rebites fraturados com base em imagens de tampas de latas. Para isso, utilizaram-se técnicas clássicas de visão computacional e abordagem por *deep learning*, com redes neurais convolucionais, e fez-se a comparação entre os resultados obtidos em ambas as soluções.

MÉTODOS

ABORDAGEM CLÁSSICA

O primeiro método usado foi baseado em visão computacional clássica, o que significa que os passos para processamento e extração de informação das imagens foram desenvolvidos manualmente. A sequência de passos envolvida neste algoritmo está no esquema da Figura 1, e a Figura 2 apresenta imagens em cada etapa do algoritmo para um dos rebites.

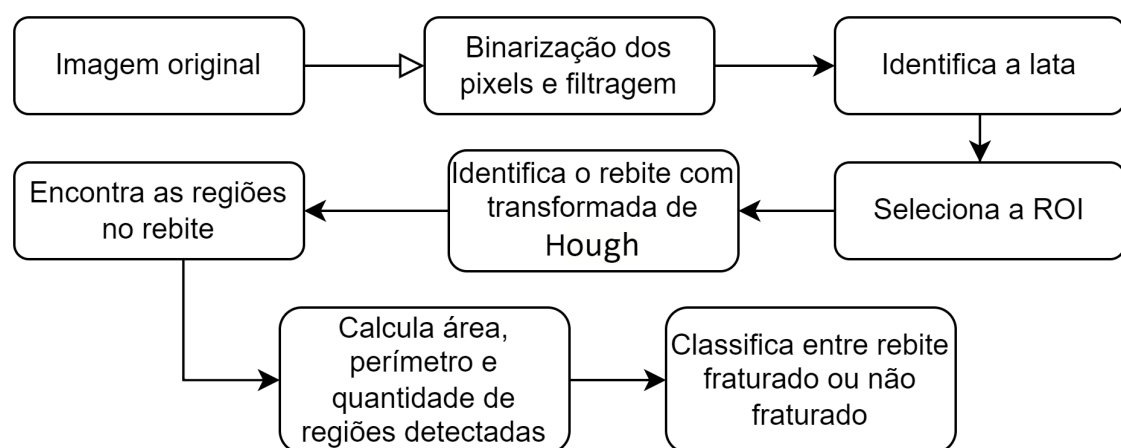


Figura 1: Algoritmo da abordagem clássica

A partir da imagem original das latas foi executada a binarização da imagem utilizando como parâmetro do limiar o valor do histograma de cores que melhor divide os pixels em dois grupos. Após um processo de filtragem através da erosão da imagem, realiza-se a identificação da lata com o uso da transformada de Hough buscando circunferências de raios próximos ao esperado. Com base no centro da circunferência encontrada, cria-se uma região de interesse (Region of Interest - ROI) onde se aplica novamente a transformada de Hough em busca de circunferências do tamanho esperado de um rebite.

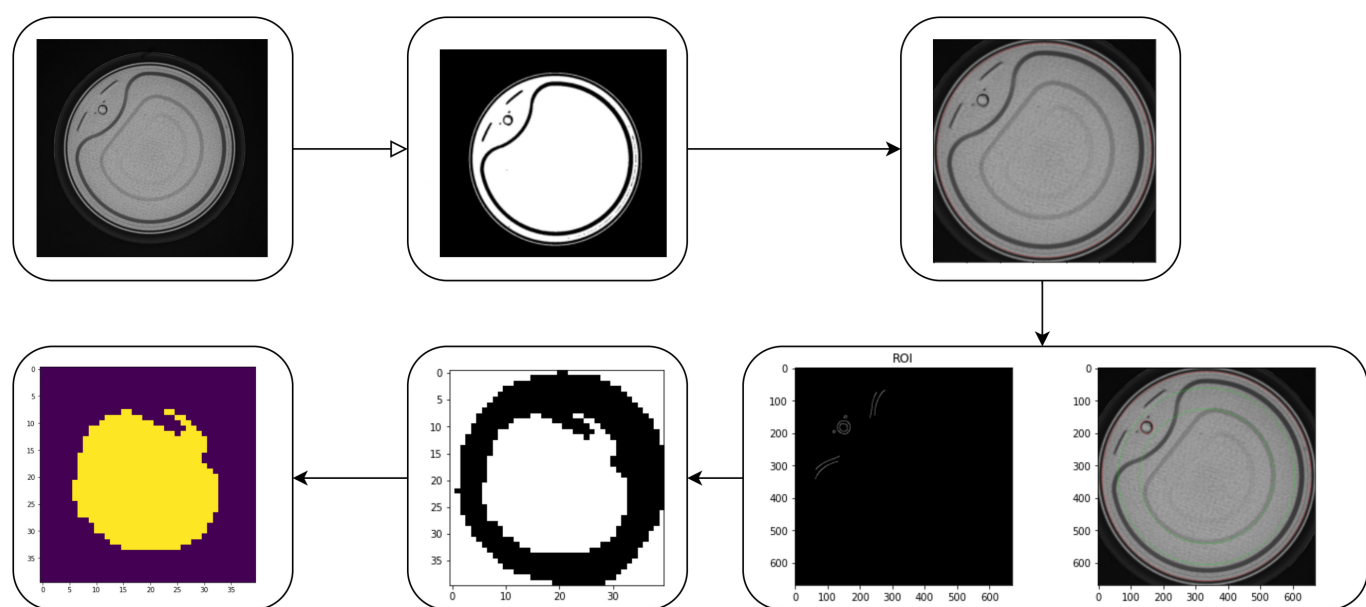


Figura 2: Exemplo de rebite a cada etapa do algoritmo

Com a nova ROI contendo somente a região do rebite, identifica-se os contornos das regiões presentes, e após eliminar as regiões fronteiriças (que pertencem à lata, e não os rebite) extrai-se os parâmetros dessa região (área, perímetro e quantidade de regiões presentes nas imagens, como no algoritmo de [1]).

Executando o processo conforme descrito em 80% do *dataset* disponível (37 imagens de rebites fraturados e 88 rebites não fraturados) foi definida a árvore de decisão quanto a classificação dos rebites apresentada na Figura 3.

Finalmente, este algoritmo foi aplicado nas imagens restantes (20%) a fim de classificá-las.

ABORDAGEM POR DEEP LEARNING

Para a abordagem em *deep learning*, optou-se por implementar o modelo de rede YOLOv5. Por se tratar de uma rede de detecção de objetos, as imagens do

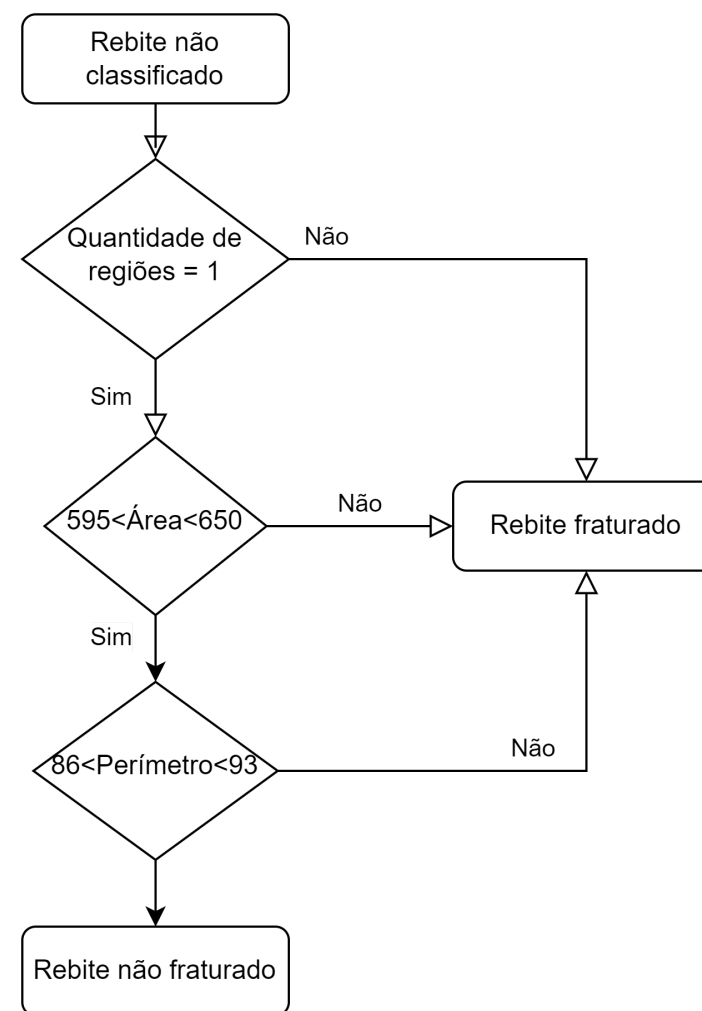


Figura 3: Árvore de decisão

dataset foram rotuladas de forma a indicar o localização dos rebites e indicar se são rebites fraturados ou não. Para isso, foi utilizado o *framework* RoboFlow. Como as duas classes de rebites originalmente eram muito desbalanceadas, foi necessário passar por processos de *data augmentation* separadamente a fim de igualar as amostras de cada classe.

Assim, após o processo de treinamento, a rede aprende a detectar os rebites e a classificá-los, conforme o exemplo na Figura 5.



Figura 4: Detecção e classificação do rebite

RESULTADOS

A precisão de classificação obtida através do método clássico foi de 97,4% (100% para rebites não fraturados e 90% para fraturados) com a matriz confusão apresentada da Tabela 1.

		Predito	
		Fraturado	Não fraturado
Real	Fraturado	9	1
	Não fraturado	0	23

Tabela 1: Matriz confusão do método clássico

A abordagem por *deep learning* apresentou facilidade em localizar os rebites, sem errar nenhuma vez a sua localização. Quanto à classificação, seu desempenho foi aquém do método clássico. A rede apresentou uma precisão de 84,4% (91% para rebites não fraturados e 70% para fraturados) com a matriz confusão apresentada na Tabela 2.

		Predito	
		Fraturado	Não fraturado
Real	Fraturado	7	3
	Não fraturado	2	20

Tabela 2: Matriz confusão do método por *deep learning*

CONCLUSÕES

Com a execução deste trabalho, observamos um bom funcionamento do método clássico, enquanto a abordagem utilizando *deep learning* não alcançou um resultado melhor. Acreditamos que a ineficiência do segundo método se deu graças ao fato de o *dataset* possuir poucas imagens originais de rebites fraturados (47 imagens). Como cada rebite fraturado tem características muito diferentes dos demais, mesmo após o processo de *data augmentation* a rede não foi capaz de aprender as diversas formas como um rebite fraturado pode se apresentar. Para trabalhos futuros seria interessante obter um *dataset* com maior quantidade e maior variedade de rebites fraturados.

REFERÊNCIA

[1] Stivanello, M.E. & Marcellino, Kleber. (2019). A Machine Vision System for Online Metal Can-End Rivet Inspection. Journal of Physics: Conference Series. 1335. 012002. 10.1088/1742-6596/1335/1/012002.

GIT: https://github.com/guipiveti/rivet_dataset

APRESENTAÇÃO: <https://www.youtube.com/watch?v=s0onHR5sB00>