

# CLASSIFICAÇÃO E IDENTIFICAÇÃO DE FALHAS DE PRODUTOS EM LINHA PRODUTIVA COM REDES NEURAIS

1<sup>st</sup> Luan Willig Silveira

Engenharia Elétrica

Universidade Federal de Santa Maria

Cachoeira do Sul, Brasil

luan.w.silveira@gmail.com

2<sup>nd</sup> Paulo César Vargas Luz

Engenharia Elétrica

Universidade Federal de Santa Maria

Cachoeira do Sul, Brasil

paulo.c.luz@ufsm.br

3<sup>rd</sup> Laura Lisiane Callai dos Santos

Engenharia Elétrica

Universidade Federal de Santa Maria

Cachoeira do Sul, Brasil

laura.santos@ufsm.br

4<sup>th</sup> Nelson Knak Neto

Engenharia Elétrica

Universidade Federal de Santa Maria

Cachoeira do Sul, Brasil

nelson.knak@ufsm.br

**Resumo**—A crescente demanda por aplicações de Inteligência Artificial na engenharia está em crescimento constante, viabilizando a resolução de problemas complexos e a execução de tarefas antes consideradas inimagináveis. Nesse contexto, este trabalho apresenta uma metodologia para reconhecimento de imagem baseada em redes neurais para identificação automatizada de objetos danificados em processos industriais, além de classificação pelas categorias quadrado, triângulo ou círculo. O modelo de inteligência artificial alcançou uma acurácia de 95,59%, superando a estimativa para o desempenho humano na tarefa de classificação de imagens, e demonstrando resultados comparáveis ou superiores a trabalhos similares. A utilização de técnicas de pré-processamento e a geração automática de figuras danificadas foram cruciais para aprimorar esse desempenho. Esses resultados enfatizam o potencial do Deep Learning como uma ferramenta poderosa para aprimorar a automação industrial e a qualidade dos produtos.

**Palavras-chave**—inteligência artificial, redes neurais, automação industrial, engenharia elétrica

## I. INTRODUÇÃO

A inteligência artificial é aplicada em diversas áreas, como reconhecimento de objetos em imagens, simulação de conversações humanas e carros autônomos. A evolução da inteligência artificial também contribui para a indústria 5.0, em que máquinas trabalham em conjunto com humanos, trazendo inteligência à automação e eficiência da indústria 4.0 [1] [2]. A demanda por aplicações de Inteligência Artificial (IA) na engenharia está em constante crescimento, possibilitando a resolução de problemas complexos e tarefas anteriormente inimagináveis, como detecção de perdas não técnicas, previsão de geração de energia renovável e segurança cibernética [3] [4].

O Deep Learning, um dos ramos da IA, está entre temas mais destacados na atualidade devido aos resultados excepcionais alcançados em diversas aplicações, tais como visão computacional, reconhecimento de fala e compreensão de linguagem natural [5]. Nesse contexto, este trabalho desenvolve uma metodologia baseada em redes neurais para identificar falhas em objetos em uma linha de produção industrial,

avaliando seu desempenho diante de variações paramétricas e estruturais.

## II. REVISÃO BIBLIOGRÁFICA

Visando compreender o funcionamento da IA para explorar seu potencial, serão abordados a seguir conceitos fundamentais sobre Deep Learning, incluindo o modelo de um neurônio artificial, a função de custo, os tipos de redes neurais e os otimizadores utilizados.

### A. Conceitos sobre redes neurais

Uma rede neural artificial é formada por inúmeros neurônios para funcionar corretamente, mas para compreender o funcionamento de uma rede neural, deve-se definir o modelo de um único neurônio artificial. Esse modelo é apresentado na Fig. 1.




Fig. 1. Modelo de neurônio artificial.

Desta forma, a definição de uma rede neural envolve vários graus de liberdade, que precisam ser definidos pelo projetista, sendo um deles a escolha da função de ativação, considerando suas diferentes características e aplicações. Por exemplo, a função Softmax apresentada através da Fig. 2 é utilizada na última camada da rede neural para problemas de classificação multiclasse, pois é capaz de acentuar o maior valor e transformar as saídas da rede neural na probabilidade de que o resultado seja cada uma das classes.




Fig. 2. Função de ativação Softmax.

Já a função ReLU apresentada através da Fig. 3 é outra função de ativação amplamente utilizada nas camadas ocultas da rede neural devido às suas vantagens computacionais e aceleração da convergência na descida do gradiente [6].

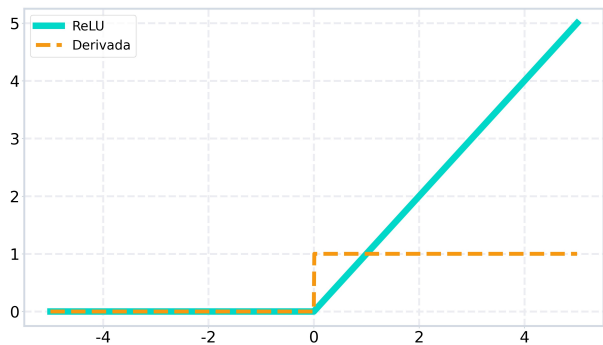


Fig. 3. Função de ativação ReLU.

Além da escolha da função de ativação, também deve ser escolhido um tipo de rede neural. Existem diversos desses tipos de redes neurais, sendo alguns dos mais conhecidos o tipo Perceptron e Convolutacional.

A rede perceptron é uma Feed Forward Network (FFN), sendo o tipo mais básico de rede neural, em que cada neurônio realiza uma operação matemática linear do tipo  $wx + b$ , sendo  $x$  o valor de entrada,  $w$  o peso e  $b$  o bias do neurônio. O resultado passa por uma função de ativação e em seguida é enviado para a próxima camada. As redes neurais do tipo FFN possuem conexões em apenas um único sentido, geralmente limitadas a 5 camadas. Já a rede Perceptron, exemplificada na Fig. 4, é um caso especial FFN, em que todos os neurônios de uma camada são conectados com todos os neurônios da camada seguinte.




Fig. 4. Rede neural do tipo Perceptron.

A rede perceptron, não considera uma relação de vizinhança entre os dados de entrada. Por exemplo, não faria diferença se antes do treinamento a posição de todos os dados de entrada fossem embaralhadas da mesma forma. Por outro lado, a rede neural convolutacional (CNN), apresentada na Fig. 5, é capaz de considerar a relação de vizinhança entre as entradas. Essa relação de vizinhança pode ser muito importante para alguns casos específicos, como no reconhecimento de imagens, reconhecimento de voz, análise grafista do mercado financeiro, etc. No reconhecimento de imagens, por exemplo, grande parte da informação está contida na relação de vizinhança dos pixels como o contraste e a textura [7].




Fig. 5. Rede Neural Convolutacional.

Uma CNN percebe uma imagem como uma caixa retangular cuja largura e altura são medidas pelo número de pixels da imagem e a profundidade é representada por cada uma das três camadas de cores, vermelho, verde e azul referidas como canais. Ao longo das camadas de uma rede CNN, as dimensões da imagem se alteram, pois a medida em que a altura e largura da imagem diminuem, o número de canais aumenta, reduzindo o volume de dados. Esse processo é chamado de pooling, que faz um resumo dos dados através do descarte das saídas menos significativas, mantendo somente às de maior valor. O processo de convolução é realizado arrastando uma janela (kernel) de dimensão menor pela imagem original, sendo essa janela uma

rede FFN. Por exemplo, se uma imagem 5x5 pixels passar pelo processo da convolução e supondo uma janela de 3x3 com passo 1 (stride), primeiramente os 3x3 pixels do canto superior esquerdo da imagem original passarão por uma FFN. Em seguida, essa janela é arrastada 1 pixel (tamanho do passo) para a direita e o processo se repete até ao final da imagem [8].

Além da escolha das funções de ativação e do tipo de rede neural, outro aspecto importante são as funções de custo (também chamadas de erro ou funções de perda). Essas funções são um dos aspectos mais importantes das redes neurais, por serem responsáveis por ajustar o modelo aos dados de treinamento fornecidos juntamente com as funções de otimização. Elas medem a acurácia do modelo e retornam o quão distantes estão os resultados de saída comparados aos resultados esperados. Logo, o objetivo é minimizar a função de custo, pois ao se aproximar do custo zero, a rede neural se aproxima da precisão máxima.

Existem dois tipos principais de função de custo no aprendizado supervisionado relacionados aos dois principais tipos de redes neurais: funções de regressão e classificação. As funções de custo de regressão são usadas em modelos de regressão, em que a rede neural prevê um valor numérico como saída ao invés de rótulos. Já as funções de custo de classificação, são usadas em modelos de classificação, em que a rede neural prevê a probabilidade da entrada pertencer a cada uma das categorias, permitindo que seja selecionada a categoria de maior probabilidade [6].

Visando minimizar a função de custo e conseqüentemente maximizar a assertividade da rede neural, empregam-se os otimizadores, os quais são algoritmos que permitem ajustar os parâmetros de um modelo de aprendizado de máquina para minimizar a função de custo. Existem diversos tipos de otimizadores, que funcionam de maneiras específicas e se aplicam a diferentes problemas. Alguns dos principais tipos de otimizadores são o Gradient Descent, Stochastic Gradient Descent, Adagrad, Adadelta, RMSprop e Adam levine.

### *B. Trabalhos relacionados*

Tendo em vista os conceitos abordados sobre Deep Learning, esta seção apresenta uma análise de três trabalhos relevantes relacionados a classificação de imagens. Cada estudo aborda aspectos específicos da aplicação de inteligência artificial em diferentes contextos: segurança industrial, análise de imagens médicas e vigilância por vídeo.

Um estudo apresentado em [9], fez o desenvolvimento de um sistema de segurança de baixo custo para uma célula de trabalho robótica sem cercas. O sistema emprega câmeras 2D e inteligência artificial, combinando três modelos de aprendizado profundo (ResNet-152, AlexNet e SqueezeNet) e três módulos de aprendizado de máquina (máquina de vetores de suporte, random forest e árvore de decisão) para a classificação de objetos estranhos que adentram a zona de alarme.

Os modelos foram treinados com imagens de dez objetos estranhos, simulando cenários reais de produção industrial, incluindo variações disruptivas, como vibrações da câmera,

sombras, reflexos e mudanças na iluminação. O modelo SqueezeNet apresentou a melhor precisão de 95% sem superajuste, enquanto os modelos de aprendizado de máquina demonstraram tempos de predição aproximadamente 100 vezes mais rápidos que os modelos de aprendizado profundo. Os resultados destacam a viabilidade de um sistema de segurança flexível e eficiente para células de trabalho robóticas sem a necessidade de cercas físicas.

Outro estudo focou na avaliação de seis plataformas de code free deep learning (CFDL) em relação ao desempenho e usabilidade na criação de modelos de aprendizado de máquina para análise de radiografias de tórax [10]. Classificadores foram treinados para identificar condições patológicas torácicas usando conjuntos de dados específicos, e a avaliação foi realizada por meio do F1-score.

Os resultados revelaram que as plataformas de CFDL apresentaram desempenho e usabilidade limitados. Embora os modelos de classificação de pneumonia tenham demonstrado boa performance interna, o mesmo não se verificou externamente. Além disso, os classificadores multirrotulo tiveram desempenho fraco tanto internamente quanto externamente, e a usabilidade das plataformas foi considerada restrita, requerendo soluções codificadas.

Em [11] é feita uma abordagem do desafiador problema de classificação de objetos abandonados/retirados em sistemas de vigilância por vídeo, estendendo a análise para incluir a classificação de objetos em movimento. As técnicas existentes de classificação de regiões de objetos abandonados/retirados foram avaliadas, revelando limitações na correta classificação de movimentos localizados, como abandono ou remoção.

O estudo propôs uma nova abordagem que alcançou uma taxa de classificação correta de 90% para objetos movidos, além de realizar a classificação adequada de objetos abandonados e removidos. Essa técnica inovadora pode ter aplicação relevante em sistemas de vigilância por vídeo, proporcionando maior precisão na identificação de eventos significativos e reduzindo falsos positivos.

Os trabalhos apresentados proporcionam uma visão abrangente sobre o uso de técnicas avançadas de inteligência artificial e aprendizado profundo em diversos cenários, como segurança industrial, análise de imagens médicas e vigilância por vídeo. Cada estudo oferece percepções valiosas sobre a eficácia, desempenho e desafios associados à aplicação dessas tecnologias em seus respectivos domínios. Este trabalho, assim como os estudos anteriores, emprega técnicas de Machine Learning para a classificação de imagens. No entanto, a aplicação se destina à automação industrial, especificamente no processo de identificação e descarte de peças danificadas.

### III. METODOLOGIA

O presente trabalho propõe uma abordagem para enfrentar um desafio significativo na escala de processos industriais: a identificação de produtos danificados. Por meio de uma identificação automatizada de objetos danificados, busca-se eliminar a incerteza e subjetividade inerentes à avaliação

humana, ao mesmo tempo em que se aumenta a eficiência e a precisão no processo produtivo.

A estratégia proposta, que consiste nas etapas apresentadas no fluxograma da Fig. 6, envolve a implementação de uma rede neural aplicada a um sistema de automação composto por uma esteira transportadora de objetos.

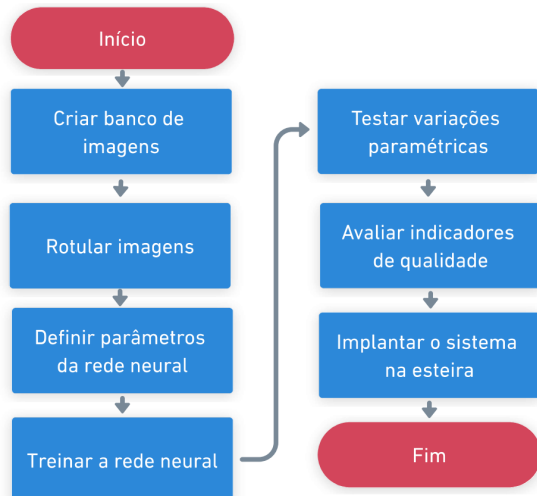


Fig. 6. Fluxograma da metodologia.

Por meio do uso de imagens capturadas por uma câmera, a rede neural visa identificar objetos danificados e classificar seus tipos. A criação de um banco de imagens equilibrado é um passo crucial, contendo quantidades semelhantes de objetos danificados e adequados, evitando que o algoritmo seja influenciado. Para isso, formas geométricas nas formas de quadrados, triângulos e círculos, elaboradas manualmente com Etileno Acetato de Vinila, são utilizadas. A variação das condições de iluminação e ângulo da câmera durante o registro das imagens garante a robustez do conjunto de dados, evitando o overfitting (ajuste excessivo de um modelo aos dados de treinamento, comprometendo sua habilidade de generalizar para novos dados não observados). Uma amostra das 480 fotografias totais é apresentada através da Fig. 7.




Fig. 7. Amostras do dataset gerado a partir de fotografias.

Na etapa de criação do banco de imagens, foi desenvolvido um pré-processamento, conforme mostrado na Fig. 8, para simplificar o banco de imagens, minimizando a quantidade de informações desnecessárias na imagem para classificar as figuras.

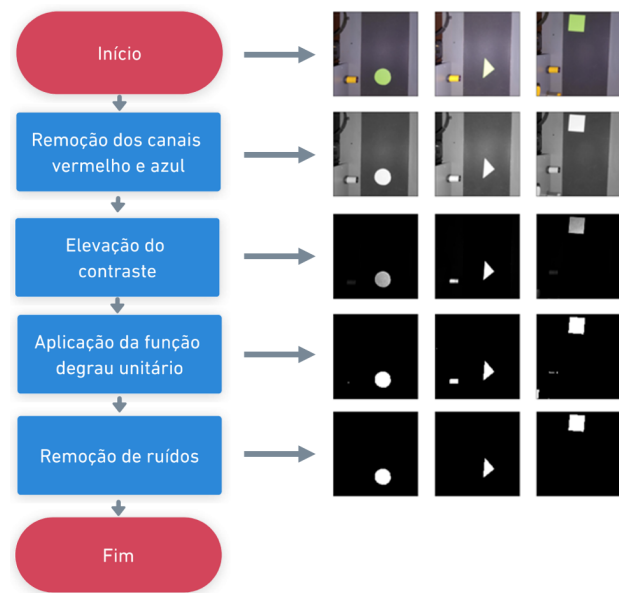


Fig. 8. Fluxograma do pré-processamento.

O pré-processamento das imagens é realizado em várias etapas para destacar a figura de interesse. Inicialmente, são removidos os canais vermelho e azul, mantendo apenas o canal verde, devido ao seu maior contraste com o plano de fundo. Em seguida, o contraste é aumentado para realçar ainda mais a figura. A imagem é então convertida em preto e branco por meio de uma função degrau unitário, eliminando a escala de cinza. Por fim, técnicas de remoção de ruídos são aplicadas para melhorar a qualidade. O resultado é uma imagem simplificada, contendo o mínimo de informação necessária para a classificação.

Ainda na etapa da criação do banco de imagens, visando alcançar acurácias satisfatórias, torna-se necessário um conjunto de dados extenso e equilibrado. Para isso, foi elaborado um método para criação automática de defeitos nas figuras, possibilitando a economia de tempo ao evitar a criação manual de defeitos, além da ampliação do conjunto de dados disponível. O método de criação automática de defeitos consiste em duas etapas principais sobre a imagem pré-processada. Inicialmente, são desenhados polígonos de forma aleatória na imagem para simular cortes ou imperfeições, acompanhados de 50% de probabilidade de aplicação de ruído. No entanto, há o risco de que os polígonos aleatórios causem o desaparecimento completo da figura na imagem. Nesse caso, os polígonos são descartados, e apenas o ruído é aplicado à imagem original.

O próximo passo da metodologia da Fig. 6 é a rotulação das imagens criadas anteriormente, onde as saídas desejadas da rede neural para cada entrada (imagens de objetos) são adicionadas ao dataset. Os objetos são categorizados com uma das seguintes classes: square (quadrado adequado), triangle (triângulo adequado), circle (círculo adequado), failed-square (quadrado danificado), failed-triangle (triângulo danificado), failed-circle (círculo danificado).

A seguir, é conduzido um processo de experimentação para criar diferentes configurações de redes perceptrons e redes convolucionais, variando a quantidade de parâmetros. A implementação das redes neurais é realizada em Python, com o suporte da biblioteca de código aberto TensorFlow. Esses experimentos visam analisar o desempenho e a eficácia das arquiteturas de redes neurais utilizadas, mostradas na Tabela I, Tabela II, Tabela III e Tabela IV.

Tabela I  
P1

Camada	Formato da saída	Ativação
InputLayer	512 x 512 x 1	-
Flatten	262144	-
Dense	128	ReLU
Dense	64	ReLU
Dense	32	ReLU
Dense	3	Softmax

Tabela II  
P2

Camada	Formato da saída	Ativação
InputLayer	512 x 512 x 1	-
Flatten	262144	-
Dense	64	ReLU
Dense	32	ReLU
Dense	3	Softmax

Tabela III  
CNN1

Camada	Formato da saída	Ativação
InputLayer	512 x 512 x 1	-
Conv2D	510 x 510 x 32	ReLU
MaxPooling2D	127 x 127 x 32	-
Conv2D	125 x 125 x 32	ReLU
MaxPooling2D	31 x 31 x 32	-
Flatten	30752	-
Dense	8	ReLU
Dense	3	Softmax

Tabela IV  
CNN2

Camada	Formato da saída	Ativação
InputLayer	512 x 512 x 1	-
Conv2D	510 x 510 x 32	ReLU
MaxPooling2D	127 x 127 x 32	-
Conv2D	125 x 125 x 64	ReLU
MaxPooling2D	31 x 31 x 64	-
Flatten	61504	-
Dense	8	ReLU
Dense	3	Softmax

As tabelas apresentam as estruturas redes neurais, em que cada linha representa uma de suas camadas com a seguinte legenda:

- InputLayer: camada de entrada;

- Flatten: camada que converte os dados multidimensionais em uma única dimensão (estica os dados);
- Dense: camada de neurônios;
- Conv2D: camada convolucional de duas dimensões;
- MaxPooling2D: camada de pooling de duas dimensões.

A avaliação do desempenho da rede neural é conduzida com base em indicadores de qualidade, tais como acurácia, precisão, sensibilidade e F1-score. A matriz de confusão é utilizada para fornecer uma visão geral do desempenho do modelo, permitindo a análise das previsões corretas e incorretas para cada classe de objetos.

Por fim, a solução de reconhecimento de imagem é implantada em uma esteira transportadora, e o controle é estabelecido por um microcontrolador ESP32, que manipula a angulação de servo motores conectados a atuadores. Esse controle permite separar os objetos por tipo e descartar aqueles identificados como danificados. Um servidor web é utilizado para realizar a categorização através das redes neurais e fornecer os resultados ao ESP32 pela internet, possibilitando a configuração adequada para os atuadores presentes na esteira.

Em síntese, o trabalho abrange uma abordagem estruturada para lidar com o desafio da identificação de objetos danificados em processos industriais. A metodologia proposta combina a criação de um banco de imagens equilibrado, a rotulação dos dados, o desenvolvimento e a avaliação de redes neurais, bem como a implementação prática em um sistema de automação industrial, oferecendo potencial para melhorar a qualidade do produto final e aumentar a eficiência da produção.

#### IV. RESULTADOS E DISCUSSÕES

Aplicando o procedimento abordado na metodologia, é realizado o treinamento dos modelos de redes neurais definidos na Tabela I, Tabela II, Tabela III e Tabela IV, alcançando as acurácias apresentadas na Tabela V, em que pode-se perceber que o modelo mais eficiente foi o da rede CNN1 com 95,59% de acurácia.

Tabela V  
ACURÁCIAS POR MODELO

Modelo	Acurácia
P1	88,3%
P2	87,4%
CNN1	95,59%
CNN2	95,53%

A acurácia obtida neste trabalho foi comparada com a acurácia dos trabalhos relacionados abordados no referencial teórico. A comparação é apresentada na Tabela VI.

Tabela VI  
COMPARAÇÃO DE ACURÁCIAS

Trabalho	Acurácia
Sistema de segurança baseado em câmera 2D [9]	95%
Classificação de doenças [10]	94,6%
Classificação de objetos abandonados [11]	90%
Este trabalho	95,59%

Percebe-se através da Tabela VI que o modelo mais eficiente desenvolvido neste trabalho obteve uma acurácia satisfatória e condizente com o esperado para a aplicação específica. Além disso, um estudo estima o erro humano no processo de categorização de imagens em 5,1% [12], ou seja, pode-se estimar a acurácia humana em 94,9%, corroborando a eficácia do modelo para classificação de figuras geométricas.

Além da acurácia, foram avaliados outros indicadores de desempenho do modelo CNN1, tais como a precisão de 95,6%, sensibilidade de 95,59% e F1-score de 95,58%. Os valores alcançados para cada um dos indicadores foram extremamente próximos, sugerindo não haver um padrão de erros do modelo. No entanto, ao analisar a matriz de confusão apresentada na Fig. 9, percebe-se uma tendência do modelo confundir triângulos adequados com danificados e vice-versa. Essa tendência pode ser explicada pelo tamanho reduzido dos triângulos em comparação com as outras figuras, o que pode fornecer menos informações para a rede neural processar.

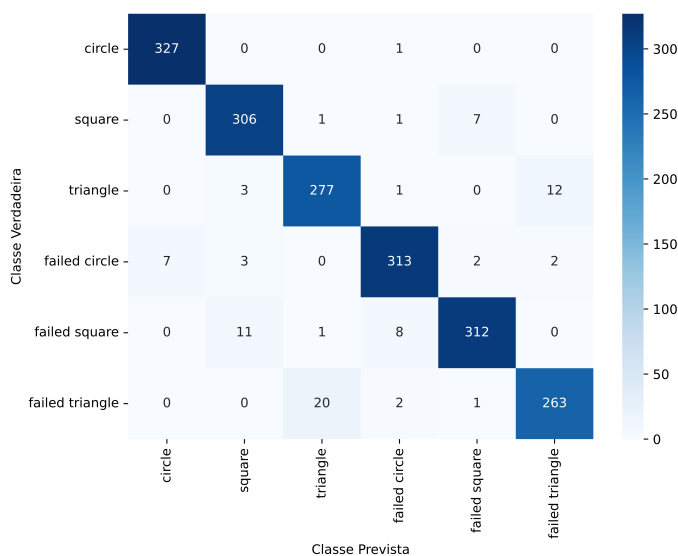


Fig. 9. Matriz de confusão.

Após a avaliação do modelo, este foi utilizado para a implementação de uma esteira transportadora automatizada, em que um aplicativo mobile desenvolvido realiza a captura das imagens dos objetos, enviando-as para o servidor com a rede neural. O servidor retorna a classificação da figura e a distância das bordas da imagem. As predições são registradas e a classificação final é determinada pela frequência das classificações durante o tempo em que a figura permanece na margem de enquadramento. O aplicativo mapeia a condição da esteira e se comunica com um ESP32 para permitir a separação adequada dos objetos com base em suas características geométricas. A Fig. 10 mostra a esteira transportadora utilizada juntamente com a interface do aplicativo mobile desenvolvido. O resultado está disponível no vídeo em <https://youtu.be/fukCSafNtTA>. Já os códigos utilizados para o desenvolvimento desse trabalho estão disponíveis em <https://github.com/luanws/TCC>.



Fig. 10. Esteira transportadora e aplicativo mobile.

## V. CONCLUSÃO

Este trabalho apresentou o desenvolvimento de um sistema baseado em uma metodologia de reconhecimento de imagens mediante redes neurais artificiais para identificação automatizada de objetos danificados em processos industriais. Os objetivos foram atingidos, e os resultados obtidos mostraram uma acurácia de 95,59%, comparável àquela alcançada pelo ser humano (94,9%) e outros estudos similares. No entanto, destaca-se que a eficácia da rede neural depende significativamente da qualidade do conjunto de dados e do pré-processamento aplicado. A geração automática de figuras com defeitos se mostrou fundamental para ampliar o conjunto de dados de treinamento e melhorar o desempenho do modelo.

Sugere-se, para trabalhos futuros, a implementação de redes neurais treinadas com combinação de dados de figuras danificadas criadas manual e automaticamente, além do uso de recursos computacionais de alto nível para obter resultados ainda mais aprimorados, explorando o potencial da união dessas duas fontes de dados e melhorando a detecção de defeitos em processos industriais.

## REFERÊNCIAS

- [1] ABHISHEK, K. Introduction to artificial intelligence. Red gate, 2022.
- [2] KLEININGS, H. Industry 5.0: Leadership in the Era of AI. levity, 2022.
- [3] MARR, B. How Is Artificial Intelligence And Machine Learning Used In Engineering? forbes, 2020.
- [4] GONÇALVES, F. 8 Aplicações de Inteligência Artificial no Setor de Energia. venturus, 2020.
- [5] LECON. Quais as Diferenças entre Machine Learning e Deep Learning? Lecon, 2022.
- [6] CECCON, D. Funções de ativação: definição, características, e quando usar cada uma. iaexpert, 2020.
- [7] AS 10 Principais Arquiteturas de Redes Neurais. Deep Learning Book, 2022.
- [8] SAHA, S. A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way. towardsdatascience, 2018.
- [9] Ozkahraman, Merdan, and Haydar Livatyali. "Artificial Intelligence in Foreign Object Classification in Fenceless Robotic Work Cells Using 2-D Safety Cameras."Tehnički Vjesnik 29.5 (2022): 1491-498. Web.
- [10] Santomartino, Samantha M, Nima Hafezi-Nejad, Vishwa S Parekh, and Paul H Yi. "Performance and Usability of Code-Free Deep Learning for Chest Radiograph Classification, Object Detection, and Segmentation."Radiology. Artificial Intelligence 5.2 (2023): E220062. Web.
- [11] Fitzsimons, Jack, and Kenneth Dawson-Howe. "Abandoned, Removed and Moved Object Classification."International Journal of Pattern Recognition and Artificial Intelligence 30.1 (2016): 1655002. Web.
- [12] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, et al. Imagenet large scale visual recognition challenge. arXiv:1409.0575, 2014