

IDENTIFICAÇÃO DE DEFORMIDADES EM GRÃOS DE CHIPS DE RESINA PET COM O USO DE INTELIGÊNCIA ARTIFICIAL

IDENTIFICATION OF DEFORMITIES IN GRAIN OF PET RESIN CHIPS USING ARTIFICIAL INTELLIGENCE

Gleidson Santos Lins

gsl9@discente.ifpe.edu.br

Luciano de Souza Cabral

luciano.cabral@jaboatao.ifpe.edu.br

RESUMO

Este artigo aborda o uso do aprendizado de máquina na detecção de anomalias visuais em chips de resina PET (polietileno tereftalato), que podem ser causados por problemas de fabricação, armazenamento ou transporte. Possui explicações sobre o que é aprendizado de máquina, resina PET e anomalias visuais. Em seguida, discute como o aprendizado de máquina é usado na indústria e quais são as técnicas mais comuns, como regressão linear, regressão logística, árvores de decisão, redes neurais e algoritmos de agrupamento. O artigo então apresenta uma metodologia para o uso do aprendizado de máquina na detecção de anomalias visuais em chips de resina PET, que envolve a criação de um modelo de aprendizado de máquina treinado em imagens de chips normais e anormais apresentando uma acurácia de 97,53%. O modelo pode então ser usado para escanear imagens de chips em tempo real e alertar os operadores para investigação adicional, melhorando a qualidade do processo de fabricação e reduzindo o número de chips com defeito produzidos.

Palavras-chave: Aprendizado de máquina, Redes neurais, Resina PET, Inspeção visual, Anomalias visuais.

ABSTRACT

This article addresses the use of machine learning to detect visual anomalies in PET (polyethylene terephthalate) resin chips, which may be caused by manufacturing, storage, or transportation issues. It has explanations about what machine learning is, PET resin and visual anomalies. It then discusses how machine learning is used in industry and what the most common techniques are, such as linear regression, logistic regression, decision trees, neural networks, and clustering algorithms. The article then presents a methodology for using machine learning to detect visual anomalies in PET resin chips, which involves creating a machine learning model trained on images of normal and abnormal chips with an accuracy of 97.53 %. The model can then be used to scan chip images in real time and alert operators for further investigation, improving the quality of the manufacturing process and reducing the number of defective chips produced.

Keywords: Machine learning, Neural Network, PET resin, Visual Inspection, Visual anomalies.

1. INTRODUÇÃO

O aprendizado de máquina (*machine learning*) é um campo da Inteligência Artificial que permite que sistemas computacionais adquiram a capacidade de aprender e melhorar seu desempenho com base em dados, sem a necessidade de programação explícita para cada tarefa. Conforme destacado por Rai e colegas (2021), o aprendizado de máquina envolve o desenvolvimento de algoritmos que conseguem acessar grandes volumes de dados, identificar padrões complexos e, assim, tomar decisões com o mínimo de intervenção humana. A crescente aplicação dessas tecnologias na indústria tem gerado avanços significativos em diversos setores, como saúde, finanças e manufatura.

No setor de embalagens, um material amplamente utilizado é o polietileno tereftalato (PET), uma resina termoplástica da família dos poliésteres, que se destaca por sua versatilidade e resistência. Segundo a ALPEK POLYESTER (2023), o PET é comumente utilizado na fabricação de garrafas e outros recipientes para produtos como bebidas, alimentos, cosméticos e medicamentos. A demanda por esse material exige processos de fabricação rigorosos, uma vez que qualquer defeito pode comprometer a qualidade e a segurança dos produtos embalados.

Anomalias visuais, como deformidades e falhas estruturais em chips de resina PET, são exemplos de defeitos que podem surgir ao longo da produção. Essas anomalias podem ocorrer devido a falhas no processo de fabricação, condições inadequadas de armazenamento ou problemas no transporte (CERATTO, 2016). A inspeção visual tradicionalmente utilizada para identificar esses defeitos pode ser lenta, propensa a erros humanos e prejudicial à saúde dos trabalhadores, devido à demanda física repetitiva e à necessidade de atenção constante.

Neste contexto, o uso de inteligência artificial e aprendizado de máquina para a inspeção automatizada de chips de resina PET surge como uma solução promissora. Métodos avançados de reconhecimento de imagens e visão computacional permitem detectar anomalias de maneira rápida, precisa e não-destrutiva, aliviando os operadores humanos das tarefas repetitivas e melhorando o controle de qualidade.

Nas próximas seções, apresentam-se os trabalhos relacionados ao artigo, detalhando estudos anteriores que investigaram diversos aspectos do desempenho da automação da inspeção visual com Inteligência Artificial. Em seguida, apresenta-se a Metodologia utilizada, na qual compõe a aquisição, pre-processamento e análise exploratória dos dados, Modelagem do problema e Métricas de Avaliação, na seção 4, apresentam-se resultados e discute-se como o presente estudo se diferencia ao focar especificamente nos fatores que influenciam a identificação de falhas em resinas PET, além da criação do dataset para este fim. Por fim, registram-se as contribuições finais, limitações e as referências utilizadas neste estudo.

2. TRABALHOS RELACIONADOS

A aplicação de aprendizado de máquina para detecção de anomalias visuais tem sido amplamente explorada em diversas áreas industriais. Uma busca na base Google Scholar utilizando os termos "*classification, visual, deep learning, PET (polyethylene terephthalate), resin chips*" retornou 3.790 estudos. No entanto, não foi encontrado nenhum trabalho que siga os mesmos parâmetros e particularidades deste estudo, que envolve a classificação de deformidades em grãos de resina PET. Isso destaca o caráter inédito e a relevância da contribuição deste trabalho.

Dentre os estudos analisados, destacamos alguns que abordam temas semelhantes, embora em espectros diferentes. Por exemplo, o estudo de Choi et al. (2023) utiliza algoritmos de aprendizado profundo, como o modelo YOLO, em conjunto com sensores de imagem para classificar diferentes tipos de resíduos plásticos, incluindo variações de PET e PET-G, alcançando uma precisão superior a 91,7% (mAP). O artigo discute métodos mais eficientes e sustentáveis de reciclagem, ressaltando a importância da separação precisa de plásticos com composições químicas semelhantes. Em síntese, a identificação do tipo de plástico, como no caso de um grupo de garrafas plásticas, permite agrupar materiais de mesma composição química, facilitando processos de reciclagem mais eficazes.

Na mesma linha de raciocínio, tem-se o trabalho de Xiong (2019) que aborda a criação de uma solução para melhorar a reciclagem de plásticos, considerando que 87% dos plásticos acabam em aterros ou no ambiente, apenas 9% são reciclados, e apenas três dos sete tipos de plástico são recicláveis. A solução proposta tem duas partes: 1) projetar um dispositivo barato de infravermelho próximo para classificar os sete tipos de plástico; 2) usar aprendizado de máquina para diferenciá-los. Um controle remoto de TV foi modificado com emissores de infravermelho e uma câmera Raspberry Pi adaptada para captar a luz refletida e absorvida pelos plásticos. Foram coletadas mais de 50 garrafas de plástico dos tipos 1, 2, 4 e 5, e as imagens capturadas foram classificadas. Com o uso de aprendizado de máquina, o dispositivo conseguiu identificar os tipos de plástico com uma precisão entre 90% e 99%.

Outro trabalho na mesma linha de Martinez-Hernandez et al. (2024) que apresenta uma abordagem para o reconhecimento de plásticos utilizando um módulo de sensor espectroscópico de baixo custo, aliado a um conjunto de métodos de aprendizado de máquina. O sensor é um módulo multiespectral capaz de medir 18 comprimentos de onda, desde o visível até o infravermelho próximo. Foram aplicados dez métodos de aprendizado de máquina (Random Forest, Support Vector Machines, Multi-Layer Perceptron, Convolutional Neural Networks, Decision Trees, Regressão Logística, Naive Bayes, k-Nearest Neighbour, AdaBoost, Análise Discriminante Linear) para processar e analisar os dados coletados de seis tipos de plástico, incluindo PET, HDPE, PVC, LDPE, PP e PS, provenientes de resíduos domésticos. O pipeline computacional implementado validou a abordagem, com resultados que mostraram que as Redes Neurais Convolucionais e o Perceptron Multicamadas reconheceram plásticos com uma acurácia média de 72,50% e 70,25%, respectivamente, atingindo 83,5% para plásticos PS e 66% para plásticos PET.

Como é possível observar, a detecção de anomalias em chips de resina PET, entretanto, ainda é um campo em desenvolvimento, e a combinação de técnicas como CNNs e aprendizado supervisionado pode oferecer novas oportunidades para otimização do processo de fabricação. Este artigo propõe a explorar essa abordagem, contribuindo com uma metodologia prática e eficiente para a inspeção automatizada de chips de resina PET, com foco na melhoria da qualidade do produto final e na redução de custos operacionais.

3. METODOLOGIA

O uso de aprendizado de máquina para detectar anomalias visuais em chips de resina PET envolve a criação e treinamento de um modelo capaz de reconhecer padrões anômalos em imagens desses chips. O processo começa com a coleta de um conjunto de dados contendo imagens rotuladas de chips normais e com defeitos, que serão usadas para treinar o modelo a identificar irregularidades visuais. Após o treinamento, o modelo pode ser aplicado em novas imagens, permitindo a detecção automática de anomalias em tempo real, conforme SOUZA (2020).

3.1. Técnicas de Aprendizado de Máquina

Diversas técnicas de aprendizado de máquina podem ser aplicadas na detecção de anomalias, cada uma com suas próprias vantagens e aplicações em diferentes contextos industriais:

- *Regressão Linear*: Utilizada para prever valores contínuos com base em variáveis independentes. Na indústria, é aplicada para estimar demandas de recursos, otimizar consumo energético e prever custos operacionais. Por exemplo, pode ser usada na previsão de vendas considerando tendências históricas e fatores sazonais (Montgomery et al., 2012).
- *Regressão Logística*: Uma técnica de classificação binária utilizada para prever a ocorrência ou não de eventos. É amplamente usada para prever riscos, como a probabilidade de cancelamento de serviço (churn) ou inadimplência de empréstimos (Hosmer et al., 2013).

- *Árvores de Decisão*: Modelos baseados em regras derivadas dos dados, comumente utilizados em cenários onde a interpretabilidade é importante. São amplamente usados na indústria para diagnósticos médicos automatizados e decisões complexas (Breiman et al., 1984).
- *Redes Neurais*: Modelos de aprendizado profundo capazes de identificar padrões complexos em grandes volumes de dados. São particularmente eficazes em tarefas de reconhecimento de imagens e são amplamente aplicadas na detecção de defeitos em produtos manufaturados (Goodfellow et al., 2016).
- *Algoritmos de Agrupamento*: Técnicas de aprendizado não supervisionado que agrupam dados semelhantes sem a necessidade de rótulos pré-definidos. Esses algoritmos são usados em aplicações como segmentação de clientes para campanhas de marketing (Jain et al., 1999).

Diante do exposto, no contexto do problema que este artigo se propõe a resolver, a escolha mais adequada recai sobre as redes neurais. Essas redes são particularmente eficazes na identificação de padrões complexos em grandes volumes de dados. Como o problema em questão envolve inspeção visual — utilizando imagens — essa técnica se revela a mais apropriada entre as abordadas neste estudo.

3.2. Aplicação de Redes Neurais Convolucionais (CNNs)

A detecção de anomalias visuais em chips de resina PET é particularmente adequada para o uso de redes neurais convolucionais (CNNs), uma técnica de aprendizado profundo que tem se mostrado eficaz na análise de imagens. As CNNs são capazes de identificar padrões complexos e sutis em imagens digitais, sendo amplamente utilizadas para detectar defeitos em produtos manufaturados (Microsoft, 2023).

Para implementar um sistema de detecção de anomalias visuais, são necessárias as seguintes etapas:

- *Coleta de Dados:* Imagens de chips de resina PET com e sem anomalias são capturadas e rotuladas para criação de um conjunto de dados robusto. Essas imagens devem representar uma ampla variedade de defeitos possíveis, como rachaduras, deformações e impurezas.
- *Pré-processamento de Imagens:* As imagens coletadas são pré-processadas para garantir a uniformidade nos dados de entrada, ajustando aspectos como resolução, escala e remoção de ruídos.
- *Treinamento do Modelo:* O conjunto de dados rotulado é usado para treinar um modelo de CNN, que aprende a distinguir entre chips normais e defeituosos. O modelo é otimizado para maximizar sua precisão na identificação de padrões visuais anômalos.
- *Validação e Testes:* O modelo é validado utilizando um conjunto de imagens que não foi utilizado durante o treinamento. A precisão do modelo é avaliada com base na sua capacidade de detectar anomalias de forma consistente e eficaz.
- *Implementação em Tempo Real:* Uma vez treinado, o modelo pode ser integrado ao processo de fabricação para realizar a inspeção de chips em tempo real. As imagens dos chips são capturadas por câmeras industriais e processadas pelo modelo de CNN, que identifica automaticamente defeitos e alerta os operadores para investigação adicional.

3.3. Benefícios da Automação

O sistema de detecção automatizada de anomalias proporciona melhorias significativas na qualidade do processo de fabricação. A detecção em tempo real reduz a dependência da inspeção manual, que é propensa a erros humanos e pode ser fisicamente desgastante. Além disso, a automação permite uma detecção mais rápida e precisa, minimizando o número de chips defeituosos e os custos associados ao retrabalho e desperdício de material (BL SISTEMAS, 2023).

4. EXPERIMENTOS, RESULTADOS E DISCUSSÃO

Nos experimentos realizados, em cada conjunto de testes, realizou-se uma avaliação minuciosa dos resultados, com o objetivo de analisar o desempenho do software desenvolvido e identificar oportunidades para aprimorar sua estrutura.

O foco central dos testes foi a acurácia, buscando alcançar o mais alto nível de confiança na classificação das imagens.

Como mostrado na Figura 1, os experimentos de classificação foram realizados utilizando imagens capturadas em um ambiente controlado de laboratório químico, envolvendo três diferentes classificações de chips de resina PET.

Figura 1 – Bancada de análises para visualização de deformidades em resina PET.



Fonte: Autoria própria.

4.1 Perfil da Amostra

A amostra consiste em grãos de resina PET, com um total de 100g coletadas em intervalos de tempo ao longo do lote de produção. O processo de visualização das amostras, conforme o procedimento interno do laboratório químico, é ilustrado na Figura 2.

Figura 2 – Grãos de resina PET para avaliação visual de deformidades.



Fonte: Autoria própria.

4.2 Aplicação de Inteligência Artificial

A criação do algoritmo de aprendizado de máquina, projetado para reconhecer deformidades nos chips de resina PET por meio de um processo de aprendizado supervisionado, envolve as seguintes etapas:

- **Obtenção de Dados:** A primeira etapa consistiu na coleta de dados relevantes, que incluiu amostras de chips de resina PET com diferentes tipos de deformidades. Essas amostras foram cuidadosamente identificadas, separadas e fotografadas, gerando um banco de dados abrangente com imagens de chips de PET apresentando várias anomalias de produção.
- **Etiquetamento dos Dados:** As imagens coletadas foram rotuladas manualmente, com cada uma marcada de acordo com a deformidade específica apresentada (por exemplo, chips com sobressalências, chips fundidos, etc.). Esse processo de etiquetamento é crucial, pois permite que os algoritmos aprendam a associar as características visuais das deformidades às suas respectivas classes.
- **Pré-processamento das Imagens:** As imagens passaram por um pré-processamento para garantir que estivessem em um formato adequado para o treinamento dos algoritmos. Essa etapa inclui operações como limpeza de imagem, normalização, redimensionamento e outras transformações que melhoraram a qualidade dos dados de entrada.
- **Seleção de Algoritmos:** Optou-se por utilizar frameworks de deep learning, como *TensorFlow/Keras*, para treinar um modelo de rede neural com os dados fornecidos. Para problemas de reconhecimento de imagens, foram empregadas redes neurais convolucionais (CNNs), que são especialmente eficazes em tarefas de visão computacional.
- **Treinamento dos Algoritmos:** Os algoritmos foram treinados utilizando as imagens pré-processadas e rotuladas. Durante essa fase, o algoritmo ajustou seus parâmetros internos para minimizar a diferença entre as saídas previstas

e as saídas esperadas (rotuladas). O treinamento foi um processo iterativo, permitindo ao algoritmo aprender gradualmente a reconhecer padrões e classificar as deformidades com maior precisão.

- **Validação e Ajuste de Parâmetros:** Após o treinamento, os algoritmos foram validados com um conjunto de dados separado (conjunto de teste) para avaliar a precisão e a capacidade de generalização do modelo. Foram realizados ajustes adicionais para otimizar o desempenho.

4.3. Avaliando o Treinamento do Modelo

O comando `model.fit()`, conforme mostrado na figura 3, é uma função usada em frameworks de deep learning como TensorFlow/Keras para treinar um modelo de rede neural com os dados fornecidos.

Figura 3 – Linha de código que treina o modelo utilizado.

```
model.fit(x_train, y_train, batch_size=32, epochs=5,  
         validation_data=(x_test, y_test), callbacks=callbacks)
```

Fonte: Autoria própria.

4.3.1 Componentes do `model.fit()`

1. `x_train` e `y_train`:

- *x_train*: Este é o conjunto de dados de entrada (features) utilizado para treinar o modelo. Pode consistir em uma matriz de imagens, dados numéricos ou qualquer outra forma de dados que o modelo possa processar como entrada. Neste caso, foi utilizada uma matriz de imagens.
- *y_train*: Este é o conjunto de rótulos (labels) correspondente ao `x_train`, representando as saídas desejadas que o modelo deve aprender a prever.

2. `batch_size=32`:

- Este parâmetro define o número de amostras que o modelo processa antes de atualizar seus parâmetros internos. Um *batch_size* de 32 significa que o modelo calcula a perda e ajusta os pesos após processar 32 exemplos do conjunto de treinamento.

3. `epochs=5`:

- Este parâmetro define o número de vezes que o modelo passará por todo o conjunto de treinamento, ou seja, as matrizes *x_train* e *y_train*. Cada passagem completa pelos dados é chamada de "época". Com *epochs=5*, o modelo será treinado por 5 épocas.

4. `validation_data=(x_test, y_test)`:

- Este argumento é utilizado para avaliar o desempenho do modelo em um conjunto de dados de validação (neste caso, x_{test} e y_{test}) após cada época. Isso ajuda a monitorar a performance do modelo em dados que ele não viu durante o treinamento, o que é essencial para detectar o *overfitting*.


5. `callbacks=callbacks`:

- Os callbacks são funções opcionais que podem ser passadas para o `model.fit()` para personalizar o treinamento. Exemplos de callbacks incluem *EarlyStopping*, que interrompe o treinamento quando a performance não melhora, e *ModelCheckpoint*, que salva o modelo após cada época.

4.4. Rotulando Dados

A implementação em *Python* utiliza a biblioteca *Matplotlib* para visualizar algumas amostras do conjunto de dados de treinamento (x_{train}) e seus respectivos rótulos (y_{train}). O objetivo principal é exibir as primeiras 16 imagens do conjunto, acompanhadas de seus rótulos, permitindo uma melhor compreensão do conteúdo visual e a verificação da correção das imagens e rótulos. O código gera uma grade de gráficos 4x4, totalizando 16 subplots em uma única figura, conforme ilustrado na Figura 4. Cada subplot apresenta uma imagem do conjunto de treinamento.

Figura 4 – Estrutura do gráfico 4 x 4.



Fonte: Autoria própria.

- **Iteração:** O loop for percorre as primeiras 16 imagens ($x_{train}[i]$) e seus rótulos ($y_{train}[i]$) para exibi-las.

- **category_dict:** Este dicionário é utilizado para mapear os valores dos rótulos (0, 1, 2) para suas respectivas categorias textuais ('normal', 'geminado', 'palito'). Essa abordagem facilita a interpretação dos rótulos, exibindo o nome da categoria em vez de apenas um número.
- **Facilidade de Interpretação:** Ao utilizar rótulos textuais (por exemplo, 'normal', 'geminado', 'palito'), o código se torna mais intuitivo para interpretar os resultados, especialmente na compreensão do que cada rótulo representa.
- **Usabilidade:** Seguir a prática recomendada de visualizar os dados antes de treinar um modelo é essencial para garantir que o conjunto de dados esteja corretamente formatado e que as amostras sejam representativas das classes que o modelo deve aprender a distinguir.

4.5 Avaliando o Desempenho do Modelo

O registro do treinamento do modelo apresenta os resultados ao longo de 5 épocas. A Tabela 1 ilustra o desempenho do modelo em todas as épocas, complementada pela representação gráfica na Figura 04, que facilita a avaliação dos resultados.

Tabela 01 – Desempenho do modelo durante as 5 épocas.

Época	Loss (Treinamento)	Acurácia (Treinamento)	Val Loss (Validação)	Val Acurácia (Validação)	Learning Rate
1	1.1735	36.42%	0.9428	77.78%	1.0000e-04
2	0.9258	58.33%	0.7203	96.30%	1.0000e-04
3	0.6765	80.56%	0.4760	97.53%	1.0000e-04
4	0.4009	95.06%	0.2587	97.53%	1.0000e-04
5	0.1923	98.77%	0.1156	97.53%	1.0000e-04

Fonte: Autoria própria.

Na primeira época, a loss é relativamente alta e a precisão inicial do modelo é baixa (36.42%), o que é esperado. No entanto, a validação apresenta uma precisão superior (77.78%), sugerindo que o modelo está começando a aprender.


Na próxima, o modelo demonstra uma melhoria na precisão de treinamento, atingindo 58.33%. A precisão de validação também melhora significativamente, alcançando 96.30%, enquanto a *loss* de validação diminui, o que é um sinal positivo.

Na época seguinte, o modelo continua a apresentar melhorias, com a precisão de treinamento agora em 80.56% e uma excelente precisão de validação de 97.53%. A perda continua a diminuir, indicando um bom ajuste.

Na penúltima época, a precisão de treinamento atinge 95.06%, enquanto a precisão de validação se mantém alta. A perda de validação continua a diminuir, sugerindo que o modelo está se ajustando bem aos dados.

Na última época, a precisão de treinamento atingiu 98.77%, refletindo um desempenho excepcional. A precisão de validação permanece estável, indicando que o modelo conseguiu aprender efetivamente a partir dos dados de treinamento.

Figura 5 – Gráfico comparativo do teste e treinamento da rede neural.



Fonte: Autoria própria.

O modelo alcança uma precisão de treinamento muito alta, de 98.77%, enquanto mantém uma boa precisão de validação, de 97.53%. A perda de validação é baixa, o que sugere um bom ajuste.

Observações gerais indicam que houve uma melhoria contínua ao longo das épocas, com um aumento na precisão do modelo e uma diminuição da perda, tanto no conjunto de treinamento quanto no de validação. A precisão de validação permanece consistentemente alta após a segunda época, o que é um bom sinal de que o modelo está generalizando bem e não apresenta *overfitting*.

Além disso, o modelo é salvo após a primeira época, uma vez que a perda apresentou uma melhoria significativa. Nas épocas subsequentes, embora a perda de treinamento continue a diminuir, o *callback* não considera essas melhorias como suficientes para salvar o modelo novamente.

4.6. Métricas de Desempenho Adicionais

A avaliação apresentada na Figura 05 sugere que o modelo de aprendizado de máquina está se comportando de forma muito eficaz, apresentando altos valores de precisão, recall, F1-score e outras métricas, o que indica um excelente desempenho na tarefa de classificação.

Figura 5 – Desempenho das métricas médias do modelo

```
3/3 [-----] - 2s 455ms/step
Métricas médias
      precision    recall  f1-score   support

0         0.96      1.00      0.98         27
1         0.96      1.00      0.98         27
2         1.00      0.93      0.96         27

 accuracy                   0.98         81
 macro avg                   0.98         81
weighted avg                   0.98         81

Acurácia: 0.9753
Precisão: 0.9762
Cobertura(recall): 0.9753
F1(weighted): 0.9751
PRF support: (array([0.96428571, 0.96428571, 1.
Cohen Kappa: 0.9630
Acurácia: 0.9753
Sensitividade: 1.0000
Especificidade: 1.0000
```

Fonte: Autoria própria.

A acurácia de 0,9753 (ou 97,53%) indica que o modelo classificou corretamente 97,53% dos exemplos no conjunto de teste, o que é um sinal positivo, especialmente em cenários onde há uma distribuição balanceada entre as classes.

A precisão média de 0,9762 (ou 97,62%) sugere que, entre as instâncias classificadas como positivas, 97,62% realmente pertencem à classe correta. Alta precisão é essencial em contextos onde os falsos positivos precisam ser minimizados.

O recall de 0,9753 (ou 97,53%) indica que o modelo conseguiu identificar corretamente 97,53% das instâncias que pertencem a cada classe.

Por fim, o F1-score médio ponderado de 0,9751 reflete o equilíbrio entre precisão e recall, sugerindo que o modelo apresenta um bom desempenho geral, mesmo que haja uma leve variação entre as classes.

4.6.1 Análise por Classe

As três classes (0, 1 e 2) apresentam valores de precisão, recall e F1-score bastante próximos. No entanto, a classe 2 demonstra um recall ligeiramente inferior (0,93), indicando que o modelo teve um pouco mais de dificuldade em identificar corretamente todas as instâncias dessa classe. Apesar disso, os valores permanecem elevados, sugerindo que o modelo se sai bem ao lidar com todas as classes.


4.6.2 Métricas Complementares

O coeficiente Kappa de Cohen, com um valor de 0,9630, indica um forte acordo entre as previsões do modelo e as classificações reais, superando o que seria esperado por acaso. Um valor tão alto é um sinal positivo de que o modelo está generalizando bem. Quanto à sensibilidade e especificidade, ambos os valores são 1,0000, o que indica que o modelo é perfeitamente capaz de identificar a presença (sensibilidade) e a ausência (especificidade) das características das classes, sem erros de classificação.

4.6.3 Matriz de Confusão

A Figura 6 apresenta uma matriz de confusão do modelo, que é uma ferramenta fundamental para a avaliação do desempenho de um modelo de classificação.

Figura 6 – Matriz de confusão do modelo



Fonte: Autoria própria.

A matriz de confusão contém três classes (Palito = 0, Normal = 1 e Geminado = 2), com os valores nas células indicando a quantidade de previsões corretas e incorretas realizadas pelo modelo. Na avaliação de cada classe, observou-se que, para a Classe 0, 27 amostras foram corretamente classificadas como tal, e não houve

amostras incorretamente classificadas como classe 1 ou 2. Para a Classe 1, o desempenho foi semelhante: 27 amostras foram corretamente classificadas, sem erros de classificação para as classes 0 ou 2. Na Classe 2, 25 amostras foram corretamente identificadas, mas houve duas previsões incorretas: uma amostra foi classificada erroneamente como classe 0 e outra como classe 1.

Essa análise indica uma precisão alta nas Classes 0 e 1, onde o modelo demonstrou desempenho impecável, sem erros de classificação. No entanto, a classe 2 apresentou uma ligeira confusão, com duas amostras classificadas incorretamente. Isso sugere que o modelo teve um pouco mais de dificuldade em separar claramente as instâncias da classe 2, possivelmente devido a similaridades com as classes 0 e 1.

5. CONSIDERAÇÕES FINAIS, LIMITAÇÕES E TRABALHOS FUTUROS

O presente trabalho teve como objetivo principal utilizar Inteligência Artificial para reconhecer deformidades em chips de resina PET a partir de imagens desses componentes. Para isso, foi implementado um software que utiliza uma rede neural, desenvolvida com a biblioteca Keras (um invólucro da plataforma TensorFlow), permitindo que o modelo adquirisse conhecimento por meio de aprendizagem supervisionada. Os resultados demonstraram a eficácia do software, evidenciando a capacidade de identificar deformidades nos chips de resina PET com base nas imagens analisadas.

O modelo apresentou um bom desempenho, com alta precisão tanto no treinamento quanto na validação. A queda constante na loss indica que o ajuste aos dados está ocorrendo de maneira satisfatória, e a elevada precisão de validação sugere que o modelo está generalizando bem. Caso a melhoria continue sem indícios de overfitting, o modelo se posiciona favoravelmente para aplicação em ambientes de produção.

As métricas obtidas revelam que o modelo é robusto, executando a tarefa de classificação com alta eficiência. A excelente precisão e a capacidade de generalização sugerem que o modelo é confiável para uso prático em seu contexto de aplicação. Contudo, a pequena variação no recall da classe 2 merece investigação adicional para entender melhor se existem características inerentes a essa classe que poderiam ser melhor capturadas.

A matriz de confusão confirma o desempenho geral do modelo, apresentando uma precisão quase perfeita nas classes 0 e 1, e uma leve margem de erro na classe 2. Esses resultados refletem a alta acurácia do modelo (97,53%) e a necessidade potencial de ajustes finos para aprimorar a classificação da classe 2. A análise visual complementa as métricas numéricas, reforçando a confiabilidade do modelo, ao mesmo tempo em que sugere melhorias na distinção entre as classes, especialmente no que diz respeito à classe 2.

Embora os resultados sejam promissores, algumas limitações devem ser reconhecidas. A variação no desempenho da classe 2 indica que o modelo pode não ter sido suficientemente treinado com um conjunto diversificado de amostras. Futuros trabalhos podem se concentrar na ampliação do conjunto de dados, incluindo mais

exemplos da classe 2, bem como na implementação de técnicas de aumento de dados (data augmentation) para melhorar a robustez do modelo. Além disso, a exploração de arquiteturas de rede mais avançadas e ajustes nos hiperparâmetros podem contribuir para otimizar ainda mais a capacidade do modelo em classificar corretamente todas as classes.

O código fonte e o dataset utilizado podem ser disponibilizados mediante contato com o autor.

REFERÊNCIAS

- ALPEK POLYESTER. *Resina PET*. 2023. Disponível em: <<https://alpekpolyester.com.br/produtos/resina-pet/>> . Acesso em: 29 ago. 2023.
- BL SISTEMAS. *Aplicação de aprendizado de máquina na indústria*. Disponível em: <<http://www.blsistemas.com.br/aplicacao-de-aprendizado-de-maquina-na-industria/>>. Acesso em: 9 out. 2024.
- BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE, C. J. *Classification and Regression Trees*. Boca Raton: CRC Press, 1984.
- CERATTO, Renan. *Inspeção visual: entenda como analisar os riscos*. 2016. Disponível em: <<https://onsafety.com.br/inspecao-visual-entenda-como-analisar-os-riscos/>> Acesso em: 9 Out 2024.
- CHOI, J.; LIM, B.; YOO, Y. *Advancing Plastic Waste Classification and Recycling Efficiency: Integrating Image Sensors and Deep Learning Algorithms*. Appl. Sci. 2023, 13 (18), 10224. Disponível em: <<https://doi.org/10.3390/app131810224>>. Acesso em: 10 out. 2024.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge: MIT Press, 2016.
- HOSMER, D. W.; LEMESHOW, S.; STURDIVANT, R. X. *Applied Logistic Regression*. 3. ed. New York: John Wiley & Sons, 2013.
- JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. *Data Clustering: A Review*. ACM Computing Surveys, v. 31, n. 3, p. 264-323, 1999.
- MARTINEZ-HERNANDEZ, U.; WEST, G.; ASSAF, T. *Low-Cost Recognition of Plastic Waste Using Deep Learning and a Multi-Spectral Near-Infrared Sensor*. Sensors 2024, 24 (9), 2821. <https://doi.org/10.3390/s24092821>
- MICROSOFT. *Anomaly Detector Overview*. 20/09/2024. Disponível em: <<https://learn.microsoft.com/pt-br/azure/ai-services/anomaly-detector/overview/>>. Acesso em: 9 out. 2024.
- MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. *Introduction to Linear Regression Analysis*. 5. ed. New York: John Wiley & Sons, 2012.
- RAI, R., TIWARI, M., IVANOV, D., & DOLGUI, A. (2021). *Machine learning in manufacturing and industry 4.0 applications*. International Journal of Production

Research, 59, 4773 - 4778. Disponível em:
<<https://doi.org/10.1080/00207543.2021.1956675>>. Acesso em: 10 out. 2024.

SOUZA, Marco Antonio Alves de. *Deposição de materiais metálicos em pó a laser baseado em controle por visão computacional e aprendizagem de máquina*. 2020. Dissertação (Mestrado em Física Aplicada) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2020. doi:10.11606/D.76.2020.tde-15052020-105711. Disponível em:
<<https://www.teses.usp.br/teses/disponiveis/76/76132/tde-15052020-105711/>>. Acesso em: 9 out. 2024.

XIONG, Edward. *Autonomous Sorting of Plastic Resin Using Near-Infrared and Machine Learning*. 2019. THE CANADIAN SCIENCE FAIR JOURNAL ARTICLE. v. 3 (4). Ontario, 2019. Disponível em:
<https://static1.squarespace.com/static/5a63b41dd74cff19f40ee749/t/60773802f673a2006a4d4c82/1725023468522/Xiong_Proof.pdf>. Acesso em: 10 out. 2024.