

AUTOMAÇÃO NA DETECÇÃO DE DESVIOS EM CARIMBOS DE CARTONAGENS PARA GARANTIA DA INTEGRIDADE E SEGURANÇA DO PRODUTO

Claudio Honorio da Silva Junior
 Docente Faculdade Biopark
 Toledo, Brasil
 claudiohonorio.ac@gmail.com

Mateus Heck Soares
 Docente Faculdade Biopark
 Toledo, Brasil
 m_heck@outlook.com

Leonardo Garcia Tampelini
 Docente Faculdade Biopark
 Cascavel, Brasil
 leonardo.tampelini@bpkedu.com.br

Jhoni Eldor Schulz
 Docente Faculdade Biopark
 Marechal Cândido Rondon, Brasil
 jhoni.schulz@bpkedu.com.br

Abstract — This paper investigates an approach to enhance quality control in the pharmaceutical industry by leveraging optical character recognition (OCR) techniques for automated batch identification on drug packaging. The current manual inspection process is susceptible to human errors and delays, jeopardizing the accuracy and safety of drug production. To address these concerns, this study explores the application of artificial neural networks (RNAs) to automate the verification process.

Keywords — Optical Character Recognition (OCR); Machine Learning; Artificial Neural Networks (RNAs); Image Preprocessing.

Resumo — Este artigo investiga uma abordagem para melhorar o controle de qualidade na indústria farmacêutica, aproveitando técnicas de reconhecimento óptico de caracteres (OCR) para identificação automatizada de lotes em embalagens de medicamentos. O processo de inspeção manual atual é suscetível a erros humanos e atrasos, prejudicando a precisão e a segurança da produção de medicamentos. Para solucionar essas preocupações, este estudo explora a aplicação de redes neurais artificiais (RNAs) para automatizar o processo de verificação.

Palavras-chave — Reconhecimento óptico de Caracteres (OCR); Machine Learning; Redes Neurais Artificiais (RNAs); Pré-processamento de Imagens.

I. INTRODUÇÃO

No setor farmacêutico, o processo de embalagem é fundamental para garantir a qualidade e integridade dos medicamentos. Após as fases iniciais de preparo e compressão, os medicamentos são cuidadosamente acondicionados em embalagens primárias, que podem variar entre frascos, blisters e bisnagas, com o objetivo de assegurar sua proteção e preservação.

Após o fechamento das cartonagens, uma etapa crucial na linha de produção é a impressão das informações importantes, como data de fabricação, número do lote e data de validade, utilizando uma impressora, como mostra a Figura 1, especializada que através de um jato de tinta

preciso e de alta velocidade marca as cartonagens com tais informações como exemplificado na Figura 2.

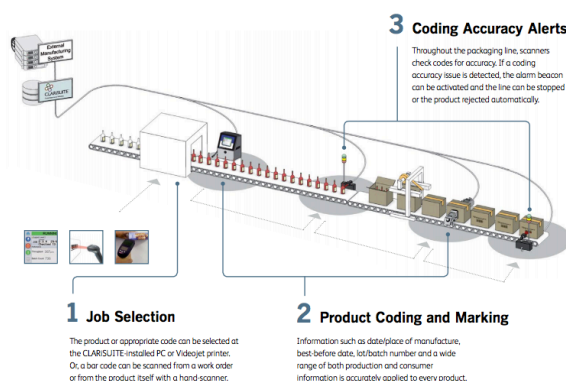


Fig. 1. Processo de impressão com verificação de código QR.



Fig. 2. Exemplo de carimbo ideal.

Entretanto, a complexidade desse procedimento impõe desafios, incluindo a possibilidade de desvios de posicionamento, falhas na impressão e borrões nos carimbos. Essas questões representam potenciais ameaças à

integridade das informações e, por consequência, a segurança do produto final.



Fig. 3. Exemplo de carimbo com problemas de impressão (desvio).

Se não detectadas e corrigidas durante a produção, essas imperfeições podem resultar em produtos farmacêuticos com informações incorretas ou ilegíveis, aumentando o risco de erros na administração dos medicamentos pelos consumidores e comprometendo sua saúde e segurança. Quando esses problemas ocorrem, há uma alta probabilidade de que farmácias e distribuidores registrem reclamações, o que pode levar à devolução completa do lote.

Atualmente, a verificação é realizada manualmente por operadores humanos no final da linha de produção, que examinam algumas das cartonagens do lote. Para mitigar esses riscos, é crucial implementar um processo de verificação automatizado.

Segundo Clark e Turner (2015), o objetivo do pré-processamento de imagens digitais é melhorar a qualidade da imagem. Nesse contexto, a automação e a utilização de algoritmos classificadores podem representar um avanço significativo. Tais algoritmos podem analisar imagens dos carimbos para identificar rapidamente desvios, falhas ou borrões, aumentando a precisão e a eficiência do processo. Entretanto, esse processo apresenta alguns desafios, entre eles a alta velocidade de operação da máquina, que, em velocidade máxima requer cerca de 250 a 300 classificações por minuto, pois é capaz de imprimir em objetos em velocidades de até 300m/min, resultando em pouco mais de 200 milissegundos para cada decisão.

O presente estudo tem como objetivo desenvolver uma solução baseada em visão computacional para aperfeiçoar a agilidade e eficácia na validação de impressões de cartonagens de medicamentos.

II. REFERENCIAL TEÓRICO

Para possibilitar a solução proposta foram estudadas abordagens utilizando técnicas de inteligência artificial com foco em visão computacional.

A visão computacional é uma área que estuda a extração de informações provindas de imagens ou frames de um vídeo e suas aplicações mais conhecidas são detecção de objetos e reconhecimento dos mesmos, como explica Jan Erik Solem (2012).

Uma ferramenta exemplar para a utilização desses conceitos na prática é a linguagem Python, que traz uma gama de bibliotecas já implementadas e de fácil utilização por conta da quantidade de usuários e informação

disponível, além de compatibilidade com quaisquer sistemas operacionais, caso seja necessária a embarcação da aplicação.

Para detectar e reconhecer objetos em uma imagem, é necessário passar pela fase de pré-processamento, que envolve a preparação da imagem para retirar interferências, como distorções e ruídos. Esse tratamento é crucial para melhorar a qualidade da imagem e aumentar a eficiência dos algoritmos de detecção. Uma biblioteca reconhecida para esse tratamento é a OpenCV [1], que possui uma infinidade de módulos para a redução desses ruídos, recortes de imagem e edição da proporção das mesmas, visto que os algoritmos ganham tempo de processamento quando a imagem é propriamente tratada.

Já no reconhecimento de objetos, podem ser utilizadas técnicas de Reconhecimento Óptico de Caracteres (OCR), que foram criadas para identificar textos escritos à mão mas que hoje é extremamente eficaz para identificação de quaisquer tipos de texto. A biblioteca utilizada para esse artigo que se utiliza desta tecnologia é a Easy OCR desenvolvida pela Jaded IA [2] e que é *open source* construída com base no Pytorch [3] que é uma biblioteca de aprendizado profundo usando processamento de unidades de processamento gráfico (GPUs) e unidade central de processamento (CPUs).

Utilizar a tecnologia OCR tem grande potencial para automatizar a leitura de informações em diversos campos, como leitores de tela, que auxiliam pessoas com deficiência visual a acessar informações digitais, além de aplicações industriais. Cathy Tschida argumenta em "Designing for Accessibility" [4], que a utilização de modelos de OCR é crucial para que pessoas com deficiência visual possam ter acesso à informação. No contexto da indústria farmacêutica, a precisão e a eficácia do OCR para leitura de lotes em embalagens garantem a segurança e o acesso à informação crucial para o paciente.

No entanto, o uso de OCR em ambientes industriais apresenta desafios específicos relacionados à qualidade da impressão, à presença de ruído e à robustez dos algoritmos.

- 1) *Impressão de Lotes*: Equipamentos de última geração, como a Videojet 1880, alcançam velocidades impressionantes [2]. Embora esses sistemas incorporem mecanismos de detecção de falhas na impressão, como a identificação de erros comuns, eles ainda apresentam limitações. A detecção automática baseada em visão computacional pode interpretar letras de forma errônea ou validar como aceitáveis caracteres que seriam difíceis de entender por alguém com visão comprometida.




Fig. 4. Exemplo de carimbo com pontos extras no caractere 5 respectivo ao horário assemelhando-se a um 6.

Um desafio crucial está na configuração dos pré-filtros. O ajuste excessivo da imagem pode resultar em modificações que tornam um texto ilegível como legível pelo modelo, como mostra a Figura 5. Em outras palavras, o pré-processamento pode remover características importantes do texto, levando a falsos positivos e prejudicando a precisão da leitura.




Fig. 5. Exemplo de carimbo onde o pré-filtro poderia ajustar uma inclinação indesejada.

III. METODOLOGIA

A metodologia deste estudo consiste na implementação e avaliação de um sistema automatizado para verificação de carimbos em embalagens de medicamentos, utilizando OCR e técnicas de *machine learning*, com ênfase em redes neurais artificiais (RNAs). O desenvolvimento e a validação do sistema foram conduzidos em quatro etapas principais: coleta de dados, pré-processamento de imagens, desenvolvimento do modelo de classificação e validação do sistema.

A. Coleta dos dados e pré-processamento

A primeira etapa consistiu na captura e digitalização de imagens das cartonagens que os pesquisadores coletaram. A captura foi feita manualmente utilizando uma câmera de 50 megapixels. Durante a captura, enfrentamos desafios relacionados às condições de iluminação e variações nas superfícies das embalagens, como reflexos indesejados ou diferenças de cor e textura, que poderiam influenciar negativamente o desempenho do OCR. A fim de garantir a qualidade da imagem e melhorar a precisão do modelo, foi necessário aplicar uma série de técnicas de pré-processamento.

Essa etapa é crítica para o sucesso do processo de reconhecimento, ela padroniza a imagem e torna a aplicação do modelo algo mais simples. Os métodos de processamento mais comuns são:

- Ajuste de contraste: ajusta o nível de brilho e contraste para destacar as áreas de interesse, nesse caso os caracteres impressos.
- Eliminação de Ruído: é utilizado para remover ruídos que possam interferir na leitura do OCR.
- Realce e Normalização: uniformiza a imagem e aplica filtros de realce para acentuar os contornos dos caracteres.

B. Segmentação de imagem

Ao fim do pré-processamento, as imagens passam por um processo de segmentação para dividi-las em regiões de

interesse e separar os caracteres do fundo. De acordo com Martin e Davis (2016), a segmentação é um passo importante, pois a precisão na delimitação das áreas de interesse afeta diretamente o desempenho final do reconhecimento de padrões.




Fig. 6. Carimbo com as marcações das áreas de interesse.

A segmentação deve ser realizada para garantir que cada área esteja suficientemente separada para análise posterior para evitar possíveis problemas.

C. Reconhecimento e classificação de padrões

Após a segmentação da imagem, e considerando as limitações na quantidade de casos reais, foi decidido combinar uma rede neural pré-treinada e de código aberto (*EasyOCR*) com técnicas estatísticas, fornecendo uma solução confiável, flexível para ajustes e adaptável às variações nas linhas de produção. As técnicas estatísticas, como cálculo de intervalos de confiança e análise de variância, foram aplicadas para medir o grau de certeza do modelo em cada área de interesse, permitindo não apenas identificar a presença do texto, mas também avaliar a precisão da leitura com base em padrões de posicionamento e frequência de caracteres.

D. Categorização, validação e Testes

Após a conclusão do processo de reconhecimento, categorizamos os resultados da escrita como "legível" ou "ilegível" com base na confiança do modelo em suas predições. Observamos que quando houve erro de impressão, o modelo mensurou sua previsão com baixa confiança, enquanto em casos comuns o modelo apresentou alta confiança.

Por fim, para garantir a eficácia do sistema desenvolvido, o algoritmo é validado com imagens de cartonagens reais, coletadas ao longo de diferentes lotes de produção. A precisão na detecção de erros foi medida, e os resultados foram comparados com a inspeção manual para verificar a acurácia e a confiabilidade do sistema automatizado.

IV. RESULTADOS PRELIMINARES

A metodologia aplicada apresentou resultados promissores para a classificação das cartonagens. Podemos visualizar os resultados conforme indica no gráfico de matriz de confusão Figura 7, na Tabela 1 de métricas (precisão, recall e score F1). O modelo *EasyOCR* consegue classificar satisfatoriamente as caixas de medicamento que possuem lote e datas de validade válidas.

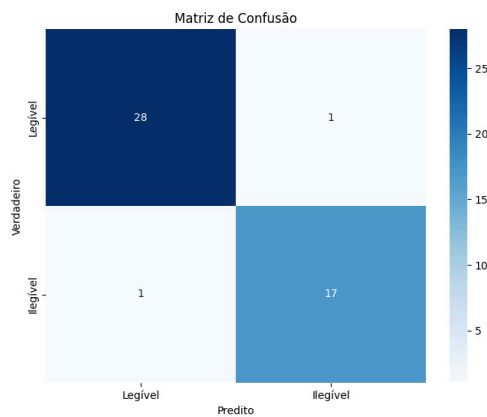


Fig. 7. Matriz de confusão dos resultados.

TABELA I
Resultados

Métrica	Valor
Acurácia	95,91%
Precisão	97,91%
Recall	97,91%
F1 Score	97,91%

No entanto, ao implementar o modelo em um Raspberry Pi 4, observamos um desempenho insatisfatório. O tempo de processamento foi de 342,12 segundos para 47 imagens, excedendo em 3538,3% o tempo limite de processo por cartongem, que é de 200 milissegundos. As possíveis causas desse desempenho insatisfatório incluem as limitações de processamento do hardware embarcado e a complexidade do modelo utilizado. Para melhorar o desempenho, consideramos explorar técnicas de compressão de modelo, como poda e quantização, ou o uso de hardware adicional com maior capacidade de processamento.

V. PRÓXIMAS ETAPAS

A. Base de dados

Mesmo que os resultados sejam positivos para a base de imagens atual, é importante notar que ela hoje não é suficiente para uma que o modelo consiga treinar e realizar os testes de forma com que preveja com exatidão comprovada nos diferentes modelos de cartongem a variação de fontes.

A solução ideal seria adquirir mais imagens posicionando uma câmera para captura de imagens logo após a impressão na linha de produção de alguma indústria. Infelizmente essa opção requer uma parceria com farmacêuticas locais além de possíveis complicações como a não interferência no controle de qualidade e a segurança do equipamento.

B. Sistema embarcado

Um dos principais desafios da abordagem atual é embarcar o modelo. Embora tenha demonstrado um desempenho satisfatório nas máquinas dos pesquisadores, o tempo de processamento no Raspberry Pi está demasiadamente acima do limite de 200 milissegundos por validação.

Para resolver esse problema, estão sendo feitos ajustes significativos no modelo, como a simplificação e a aplicação de técnicas de compressão. Essas otimizações serão essenciais para que o modelo possa atender ao requisito de tempo estabelecido e ser implementado de forma eficiente no ambiente embarcado.

AGRADECIMENTOS

Agradecemos à Faculdade Biopark pelo apoio financeiro concedido por meio da bolsa de iniciação científica, que foi fundamental para o desenvolvimento deste projeto. Esse incentivo tem sido crucial para a formação acadêmica e profissional dos alunos envolvidos, proporcionando oportunidades valiosas de aprendizado e inovação.

REFERÊNCIAS

- [1] Jan Erik Solem (2012). Programming Computer Vision with Python.
- [2] Jaided AI. Easy OCR documentation <<https://www.jaided.ai/easyocr/>>
- [3] Pytorch. Pytorch documentation <<https://pytorch.org/docs/stable/index.html>>
- [4] Tschida, C. (2019). Designing for Accessibility: A Complete Guide to Creating Inclusive User Experiences.
- [5] Videojet. (2023). Videojet 1880HR. Videojet Brasil. <<https://www.videojet.br.com/br/homepage/products/continuous-inkjet-printers/specialty-cij-printers/videojet-1880hr.html>>
- [6] Li, M., Lv, T., Chen, J., Cui, L., Lu, Y., Florencio, D., Zhang C., Li Z., Wei, F. (2022). TrOCR: Transformer-based Optical Character Recognition with Pre-trained Models. arXiv preprint arXiv:2109.10282.
- [7] TURNER, T. Pattern Recognition in Image Analysis. Cambridge: Cambridge University Press, 2017.
- [8] MARTIN, M. Image Segmentation Techniques. Oxford: Oxford University Press, 2016.