



ARTIGOS TECNOLÓGICOS

RELATO DE EXPERIÊNCIA: DETECÇÃO DE FERIMENTOS CUTÂNEOS A PARTIR DE IMAGENS COM O AUXÍLIO DE INTELIGÊNCIA ARTIFICIAL



INSTITUTO FEDERAL
Baiano

RELATO DE EXPERIÊNCIA: DETECÇÃO DE FERIMENTOS CUTÂNEOS A PARTIR DE IMAGENS COM O AUXÍLIO DE INTELIGÊNCIA ARTIFICIAL

André Luiz Andrade Rezende, Anizio Moreira dos Santos Filho, Romero Mendes Freire
de Moura Júnior

Resumo: Este trabalho surge no contexto do projeto Cicatribio, iniciado em 2018, que investiga o uso do látex da mangabeira (*Hancornia speciosa*) no tratamento de ferimentos. Propõe-se uma solução automatizada para a detecção de ferimentos em imagens obtidas a partir de um aplicativo para dispositivos móveis. Imagens de ferimentos foram coletadas e anotadas para criar um conjunto de dados de treinamento que teve sua quantidade de imagens aumentada pelo uso da técnica de data augmentation. Foi utilizado o algoritmo de aprendizado de máquina YOLO para treinar o modelo de detecção de objetos, utilizado para identificar a presença dos ferimentos a fim de proporcionar o bom funcionamento do processo de estimativa do tamanho da ferida presente no aplicativo. Os resultados mostram que o modelo foi capaz de obter valores acima de 99% nas métricas de precisão, *recall* e mAP50, demonstrando consistência e coerência na detecção da presença dos ferimentos em imagens.

Palavras-chave: Inteligência Artificial; Detecção de ferimentos; Dispositivos Móveis; Planimetria Digital; Cicatrização de Pele.

1. Introdução

Em 2020, a participação no Edital 05/2020, de Apoio ao Empreendedorismo Inovador do Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo (IFES), possibilitou a criação de um gel-creme¹ regenerativo a partir do látex da mangaba ou Mangabeira (*Hancornia speciosa*), associado a um aplicativo para dispositivos móveis operado por Inteligência Artificial (IA), com o intuito de acompanhar o processo de cicatrização de lesões cutâneas em animais.

Inicialmente, a primeira versão do aplicativo era direcionado para o tratamento de animais e contava apenas com a possibilidade de organizar os registros dos ferimentos cutâneos por paciente, em um perfil que pudesse ser alimentado pelo usuário e acompanhado pelos veterinários. Atualmente, já estão disponíveis as versões de aplicativos para animais e humanos².

2. Contexto do problema

Uma etapa essencial para o acompanhamento do processo de cicatrização de ferimentos é a medição do seu tamanho. No entanto, os métodos tradicionais ainda apresentam diversas limitações. Um dos procedimentos mais comuns é a técnica de “desenho da ferida”, que consiste em utilizar uma folha de papel de acetato sobre a ferida para delinear seu contorno. Este método apresenta dois problemas principais: riscos ao manuseio do ferimento e a possibilidade de inconsistências nas medições devido ao processo manual, suscetível a erros humanos, além do desconforto e o risco de infecções para os pacientes.

3. Diagnóstico do problema ou da oportunidade

A necessidade de contato direto com o paciente para efetuar os procedimentos tradicionais é a principal causa de problemas no processo de medição de feridas. Dessa forma conseguir desenvolver um método capaz de efetuar essa tarefa sem necessidade de contato com o paciente e de forma automática trará mais agilidade para o processo além de bem-estar e conforto para o paciente que passa pelo procedimento.

¹ Utilizada pela “sabedoria popular” no tratamento de úlceras gástricas, hematomas e ferimentos cutâneos. A partir dessa observação foram realizados testes *in vitro* e *in vivo* que comprovaram a eficácia cicatrizante de seu látex. Esses estudos resultaram em dois pedidos de patente no INPI, um em 2020 (n.º BR1020200143875) e outro em 2021 n.º BR1020210054719).

² O gel-creme para uso humano está em desenvolvimento, atualmente em fase de estudos clínicos, com previsão de registro junto à ANVISA e comercialização no segundo semestre de 2025.

4. Proposta da solução do problema

O principal uso da inteligência artificial na medicina é oferecer suporte aos profissionais da saúde, em tomadas de decisões, diagnóstico, prognósticos e em tarefas que exigem manipulação de dados, além de automatizar atividades de administração médica (RAMESH, 2004; CROSSNOHERE, 2022). A título de exemplificação, podemos citar o uso da detecção de objetos para auxiliar no diagnóstico de cáries dentárias (DHANAK, 2024), a adoção de *chatbot* para recomendação de especialistas médicos para pacientes (LEE, 2021), o uso de aprendizado profundo para prever o avanço da retinopatia diabética (ARCADU, 2019) ou até mesmo determinar o nível de preparo intestinal para colonoscopia com base na análise das fezes dos pacientes (ZHU, 2023). Observou-se este mesmo comportamento na utilização da inteligência artificial em conjunto com *smartphones* em trabalhos que desenvolvem a temática de ferimentos, seja para detectar úlceras de pé de diabéticos (CASSIDY, 2023), para auxiliar na avaliação de ferida por pressão (LAU, 2022), ou até mesmo na detecção automatizada de feridas (ADNAN, 2023).

Tendo como base o objetivo e os trabalhos citados acima, o uso da Inteligência Artificial (IA) é primordial para o desenvolvimento das atividades. O primeiro estágio propõe desenvolver o módulo de detecção de ferimentos que será responsável pela seleção das imagens obtidas através dos aplicativos, que subsequentemente serão encaminhadas para o módulo de cálculo das dimensões dos ferimentos.

5. Plano de ações da mudança

No desenvolvimento do módulo de detecção foi utilizado o método PDCA (*Plan-Do-Check-Act*), concebido em 1950, por W. Edwards Deming. O PDCA é um modelo de gestão de qualidade utilizado na indústria (ISNIAH, 2020; NGUYEN, 2020), que busca identificar e solucionar problemas de gestão da qualidade (HONG, 2020), sendo dividido em quatro etapas: planejar, fazer, verificar e agir.

O planejamento (*Plan*) é a etapa onde são definidos os objetivos a serem alcançados e a construção de um planejamento. No fazer (*Do*), operacionalizam-se as ações alinhadas ao planejamento. A verificação (*Check*) é a etapa de análise dos resultados das implementações. Por fim, temos o agir (*Act*) que confirma se as implementações alcançaram os objetivos e/ou se será necessário elaborar novos planos para aperfeiçoar o processo. Ao finalizar a esta etapa, o ciclo se reinicia, permitindo que novas avaliações e

ações sejam continuamente aplicadas para promover a evolução constante do processo (ZAILANI, 2023).

As atividades desenvolvidas neste projeto foram inseridas nas etapas do ciclo do PDCA, permitindo identificar pontos de melhoria, promovendo ajustes contínuos no processo. O Quadro 1 apresenta uma visão geral das atividades desenvolvidas em cada fase por ciclo.

Quadro 1- Distribuição das atividades por etapa do Ciclo PDCA.

	Ciclo 1	Ciclo 2
Planejar	Construir um conjunto de dados com total próximo a 10 mil imagens de ferimentos.	Ampliar o conjunto de dados para no mínimo 50 mil imagens de ferimentos.
	Os valores das variáveis de desempenho do modelo devem ser iguais ou superiores a 80%.	Os valores das variáveis de desempenho do modelo devem ser iguais ou superiores a 80%.
Fazer	Buscar por repositórios públicos de imagens de ferimentos.	Ampliar o conjunto de dados para no mínimo 50 mil imagens de ferimentos.
	Buscar por ambientes de treinamento que atendessem aos critérios pré-estabelecidos	Os valores das variáveis de desempenho do modelo devem ser iguais ou superiores a 80%.
	Configurar o ambiente de treinamento.	
	Treinar o modelo.	
Verificar	Validar as implementações realizadas.	
Agir	O conjunto de dados com total próximo a 10 mil imagens de ferimentos foi construído?	O conjunto de dados foi ampliado para no mínimo 50 mil imagens de ferimentos?
	Os valores das variáveis de desempenho do modelo foram iguais ou superiores a 80%?	

Fonte: Elaborado pelo autor.

6. Conclusões e contribuições

Os resultados apresentados abaixo referem-se à evolução do modelo, onde são exibidas as métricas em cada um dos cenários de treinamento. Em cada ambiente de treinamento foram realizados uma série de treinos, porém apenas três cenários de cada foram destacados, esses seis *checkpoints* têm o objetivo de mostrar resumidamente a progressão de desempenho das variáveis do modelo conforme o trabalho se aperfeiçoava. No Quadro 2 é possível observar a configuração dos cenários.

Quadro 2- Configuração dos cenários.

Cenário	Ambiente	N.º de imagens	N.º de épocas
I	<i>Google Colab</i>	7.344	005
II		7.344	050
III		7.344	100
IV	Ògún	66.090	005
V		66.090	050
VI		66.090	100

Fonte: Elaborado pelo autor.

No Quadro 3, temos as métricas obtidas após realizar o treinamento do modelo de detecção de feridas nos cenários I, II, III, IV, V e VI.

Quadro 3- Métricas e resultados dos cenários I, II, III, IV, V e VI.

Métricas e resultados do treinamento						
	Nº de imagens	Nº de épocas	Precisão	Recall	MAP50	MAP50-95
Cenário I	7344	5	0,594	0,513	0,516	0,188
Cenário II		50	0,706	0,623	0,624	0,255
Cenário III		100	0,739	0,637	0,659	0,290
Cenário IV	66090	5	0,809	0,719	0,815	0,515
Cenário V		50	0,990	0,985	0,994	0,818
Cenário VI		100	0,995	0,997	0,995	0,877

Fonte: Elaborado pelo autor.

Ao analisar os resultados, é importante destacar três aspectos. O primeiro, tem relação com o desempenho apresentado entre o modelo do cenário IV e o cenário III. Este último, mesmo tendo noventa e cinco épocas a mais para se desenvolver, não superou as métricas do cenário IV, ou seja, a quantidade de imagens para o treinamento influenciou diretamente na melhora dos índices.

O segundo ponto, refere-se à evolução ao aumentar o número de épocas para 50, conforme o cenário V. A Precisão, o *Recall* e o MAP50 ultrapassam a marca dos 98%, indicando que o modelo apresentou um comportamento próximo da excelência na identificação da presença de feridas.

Por fim, tem-se no cenário VI o comportamento semelhante ao que aconteceu no cenário III. Houve um avanço menor das métricas entre o cenário V e VI, confirmado pelos valores de 0,5%, 1,2%, 0,1% e 5,9% na Precisão, *Recall*, MAP50 e MAP50-95 respectivamente.

Cabe destacar, que não existe espaço para uma melhora acentuada, pois o cenário V exhibe valores próximos a 100%, conforme o Quadro 3. Com precisão de 99,5% no cenário VI, observou-se que os falsos positivos regrediram de 26,1%, cenário III, para 0,5%. Essa mesma situação foi identificada em relação aos falsos negativos, que caíram de 36,6% para 0,3%, indicando que apenas 0,3% das feridas não são detectadas pelo modelo.

Em consonância ao percurso metodológico, além da avaliação por meio de métricas, também foram utilizados métodos da avaliação visual denominados testes manuais. Esse teste envolve o envio de imagens aos modelos, que devem delinear quadriláteros ao redor dos ferimentos identificados por cada um.


Figura 1- Imagens utilizadas nos testes manuais do cenário III.



Fonte: https://universe.roboflow.com/detectulcer/detect_ulcer/dataset/2.

Os testes manuais possibilitaram observar que o modelo do cenário III detectou corretamente o posicionamento das feridas, que estão delimitadas por quadriláteros vermelhos. Porém em alguns casos (ferimento 3 e 4) o modelo se apresenta incapaz de detectar a presença das feridas, reforçando a necessidade de melhora de desempenho. Essa melhora é refletida nos testes manuais executados no modelo VI, conforme apresentado na figura 2.

Figura 2- Representação da melhora de desempenho do cenário VI.



Fonte: https://universe.roboflow.com/detectulcer/detect_ulcer/dataset/2.

No cenário VI o modelo detectou a presença de feridas que antes não foram identificadas, bem como localizou o posicionamento delas, conforme apresentado na figura 2. Foi possível constatar a evolução entre os modelos no decorrer do processo de treinamento. Além do progresso no número de acertos e na diminuição dos erros, tem-se a assertividade quanto ao posicionamento da ferida, principalmente quando se observam as métricas do cenário VI do Quadro 3, que atingiram valores acima de 87%.

Apesar das adversidades encontradas, o modelo atendeu à necessidade acerca da detecção automática de ferimentos. Ao incorporá-lo aos aplicativos foi possível atender totalmente a demanda de selecionar imagens qualificadas para o cálculo das dimensões do ferimento. Ao atingir uma taxa de precisão acima de 90% na detecção dos ferimentos, um possível encaminhamento futuro em busca de melhorar os índices de desempenho e até mesmo adicionar novas funcionalidades no sistema vem a ser a reformulação do conjunto de dados. Com esta mudança, além de trazer novos dados para o aprendizado do modelo, poderia ser possível treiná-lo para além de identificar presença do ferimento também conseguir classificá-lo quanto ao tipo.

Referências

ADNAN, M. et al. **An Automatic Wound Detection System Empowered by Deep Learning**. Journal of Physics: Conference Series. **Anais...**Institute of Physics, 2023. DOI: 10.1088/1742-6596/2547/1/012005. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/2547/1/012005>. Acesso em: 01 out. 2024.

ARCADU, F. et al. Deep learning algorithm predicts diabetic retinopathy progression in individual patients. **npj Digital Medicine**, v. 2, n. 1, 1 dez. 2019. DOI: 10.1038/s41746-019-0172-3. Disponível em: <https://www.nature.com/articles/s41746-019-0172-3>. Acesso em: 05 set. 2024.

CASSIDY, B. et al. Artificial intelligence for automated detection of diabetic foot ulcers: A real-world proof-of-concept clinical evaluation. **Diabetes Research and Clinical Practice**, v. 205, 1 nov. 2023. DOI: 10.1016/j.diabres.2023.110951. Disponível em: [https://www.diabetesresearchclinicalpractice.com/article/S0168-8227\(23\)00714-3/fulltext](https://www.diabetesresearchclinicalpractice.com/article/S0168-8227(23)00714-3/fulltext). Acesso em: 24 set. 2024.

CROSSNOHERE, N. L. et al. **Guidelines for Artificial Intelligence in Medicine: Literature Review and Content Analysis of Frameworks**. **Journal of Medical Internet Research** JMIR Publications Inc., , 1 ago. 2022. DOI: 10.2196/36823. Disponível em: <https://www.jmir.org/2022/8/e36823>. Acesso em: 11 set. 2024.

DHANAK, N. et al. Artificial intelligence enabled smart phone app for real-time caries detection on bitewing radiographs. **Bioinformation**, v. 20, n. 3, p. 243–247, 31 mar. 2024. DOI: 10.6026/973206300200243. Disponível em: <https://www.bioinformation.net/020/973206300200243.htm>. Acesso em: 01 out. 2024.

HONG, Y. et al. Continuous improvement on the rationality of prophylactic injectable PPIs usage by a clinical pharmacist-led guidance team at a Chinese tertiary teaching hospital. **Journal of International Medical Research**, v. 48, n. 10, 2020. DOI: 10.1177/0300060520954729. Disponível em: <https://journals.sagepub.com/doi/10.1177/0300060520954729>. Acesso em: 15 set. 2024.

ISNIAH, S.; HARDI PURBA, H.; DEBORA, F. Plan do check action (PDCA) method: literature review and research issues. **Jurnal Sistem dan Manajemen Industri**, v. 4, n. 1, p. 72–81, 31 jul. 2020. DOI: 10.30656/jsmi.v4i1.2186. Disponível em: <https://ejournal.lppmunsera.org/index.php/JSMI/article/view/2186>. Acesso em: 20 ago. 2024.

LAU, C. H. et al. An artificial intelligence-enabled smartphone app for real-time pressure injury assessment. **Frontiers in Medical Technology**, v. 4, 2022. DOI: 10.3389/fmedt.2022.905074. Disponível em: <https://www.frontiersin.org/journals/medical-technology/articles/10.3389/fmedt.2022.905074/full>. Acesso em: 09 out. 2024.

LEE, H.; KANG, J.; YEO, J. Medical specialty recommendations by an artificial intelligence chatbot on a smartphone: Development and deployment. **Journal of Medical Internet Research**, v. 23, n. 5, 1 maio 2021. DOI: 10.2196/27460

. Disponível em: <https://www.jmir.org/2021/5/e27460>. Acesso em: 13 set. 2024.

NGUYEN, V. et al. Practical application of plan-do-check-act cycle for quality improvement of sustainable packaging: A case study. **Applied Sciences (Switzerland)**, v. 10, n. 18, 1 set. 2020. DOI: **10.3390/app10186332**. Disponível em: <https://www.mdpi.com/2076-3417/10/18/6332>. Acesso em: 09 set. 2024.

RAMESH, A. N. et al. **Artificial intelligence in medicine. Annals of the Royal College of Surgeons of England**, set. 2004. DOI: 10.1308/147870804290. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1964229/pdf/15333167.pdf>. Acesso em: 13 set. 2024.

ROSSNOHERE, N. L. et al. **Guidelines for Artificial Intelligence in Medicine: Literature Review and Content Analysis of Frameworks. Journal of Medical Internet Research** JMIR Publications Inc., , 1 ago. 2022. DOI: 10.2196/36823. Disponível em: <https://www.jmir.org/2022/8/e36823>. Acesso em: 11 set. 2024.

ZAILANI, Q. N. N. et al. PLAN-DO-CHECK-ACT CYCLE: A METHOD TO IMPROVE CUSTOMER SATISFACTION AT A MUNICIPAL COUNCIL IN MALAYSIA. **International Journal of Professional Business Review**, v. 8, n. 4, 2023. DOI: 10.26668/businessreview/2023.v8i4.931. Disponível em: <https://openaccessijs.com/JBReview/article/view/931/645>. Acesso em: 01 out. 2024.

ZHU, Y. et al. Improving bowel preparation for colonoscopy with a smartphone application driven by artificial intelligence. **npj Digital Medicine**, v. 6, n. 1, 1 dez. 2023. DOI: 10.1038/s41746-023-00786-y
. Disponível em: <https://www.nature.com/articles/s41746-023-00786-y>. Acesso em: 13 set. 2024.