

# MODELOS DE APRENDIZADO PROFUNDO APLICADOS À ANÁLISE DE IMAGENS DE ÚLCERAS DERMATOLÓGICAS

Isadora de Souza Lima Gomes<sup>1</sup>, Mirela Teixeira Cazzolato<sup>2</sup>, Harlei Miguel de Arruda Leite<sup>3</sup>.

<sup>1</sup>Escola de Engenharia de Lorena-USP, <sup>2</sup>Instituto de Ciências Matemáticas e de Computação- USP, <sup>3</sup>Instituto Tecnológico de Aeronáutica

**Resumo:** Pacientes acamados ou com predisposição a doenças como diabetes podem desenvolver úlceras de pressão, que comprometem a qualidade de vida e exigem monitoramento contínuo por profissionais de saúde, geralmente por meio de fotografias utilizadas para acompanhar a evolução clínica e identificar mudanças visuais como presença de fibrina, granulação, necrose e calosidade. A medição manual dessas lesões, realizada com sobreposição de tecidos e marcadores, é imprecisa e desconfortável, o que motiva o desenvolvimento de métodos automatizados mais confiáveis. Trabalhos na literatura, como o framework UTrack (Cazzolato et al., 2021), avançaram na segmentação e classificação de tecidos a partir de imagens, mas ainda existem limitações na segmentação das bordas e na medição baseada em objetos de referência. Nesse cenário, avanços recentes em aprendizado profundo, especialmente em modelos baseados em Transformers, oferecem oportunidades promissoras para a classificação e segmentação automáticas, podendo reduzir erros comuns dos métodos manuais em até 70% (Little; Lindsay; Singer, 2009). Este projeto propõe investigar modelos de deep learning aplicados a imagens reais de úlceras, com apoio de uma fisioterapeuta especialista, e validar os resultados a partir da precisão obtida em comparação com métodos tradicionais, destacando o potencial de aplicação em contextos de Defesa, nos quais diagnósticos rápidos, precisos e de baixo custo são essenciais para o cuidado de militares em campo ou em regiões de difícil acesso.

## I. INTRODUÇÃO

- Úlceras dermatológicas precisam de monitoramento contínuo.
- Métodos manuais são invasivos e imprecisos.
- Aprendizado profundo com Transformers permite segmentação automática.
- Técnicas distinguem tecidos e medem a área da lesão com alta precisão.
- Reduzem erros em até 70% comparado aos métodos tradicionais.
- Projeto busca aplicar essas tecnologias para melhorar diagnóstico e acompanhamento clínico.

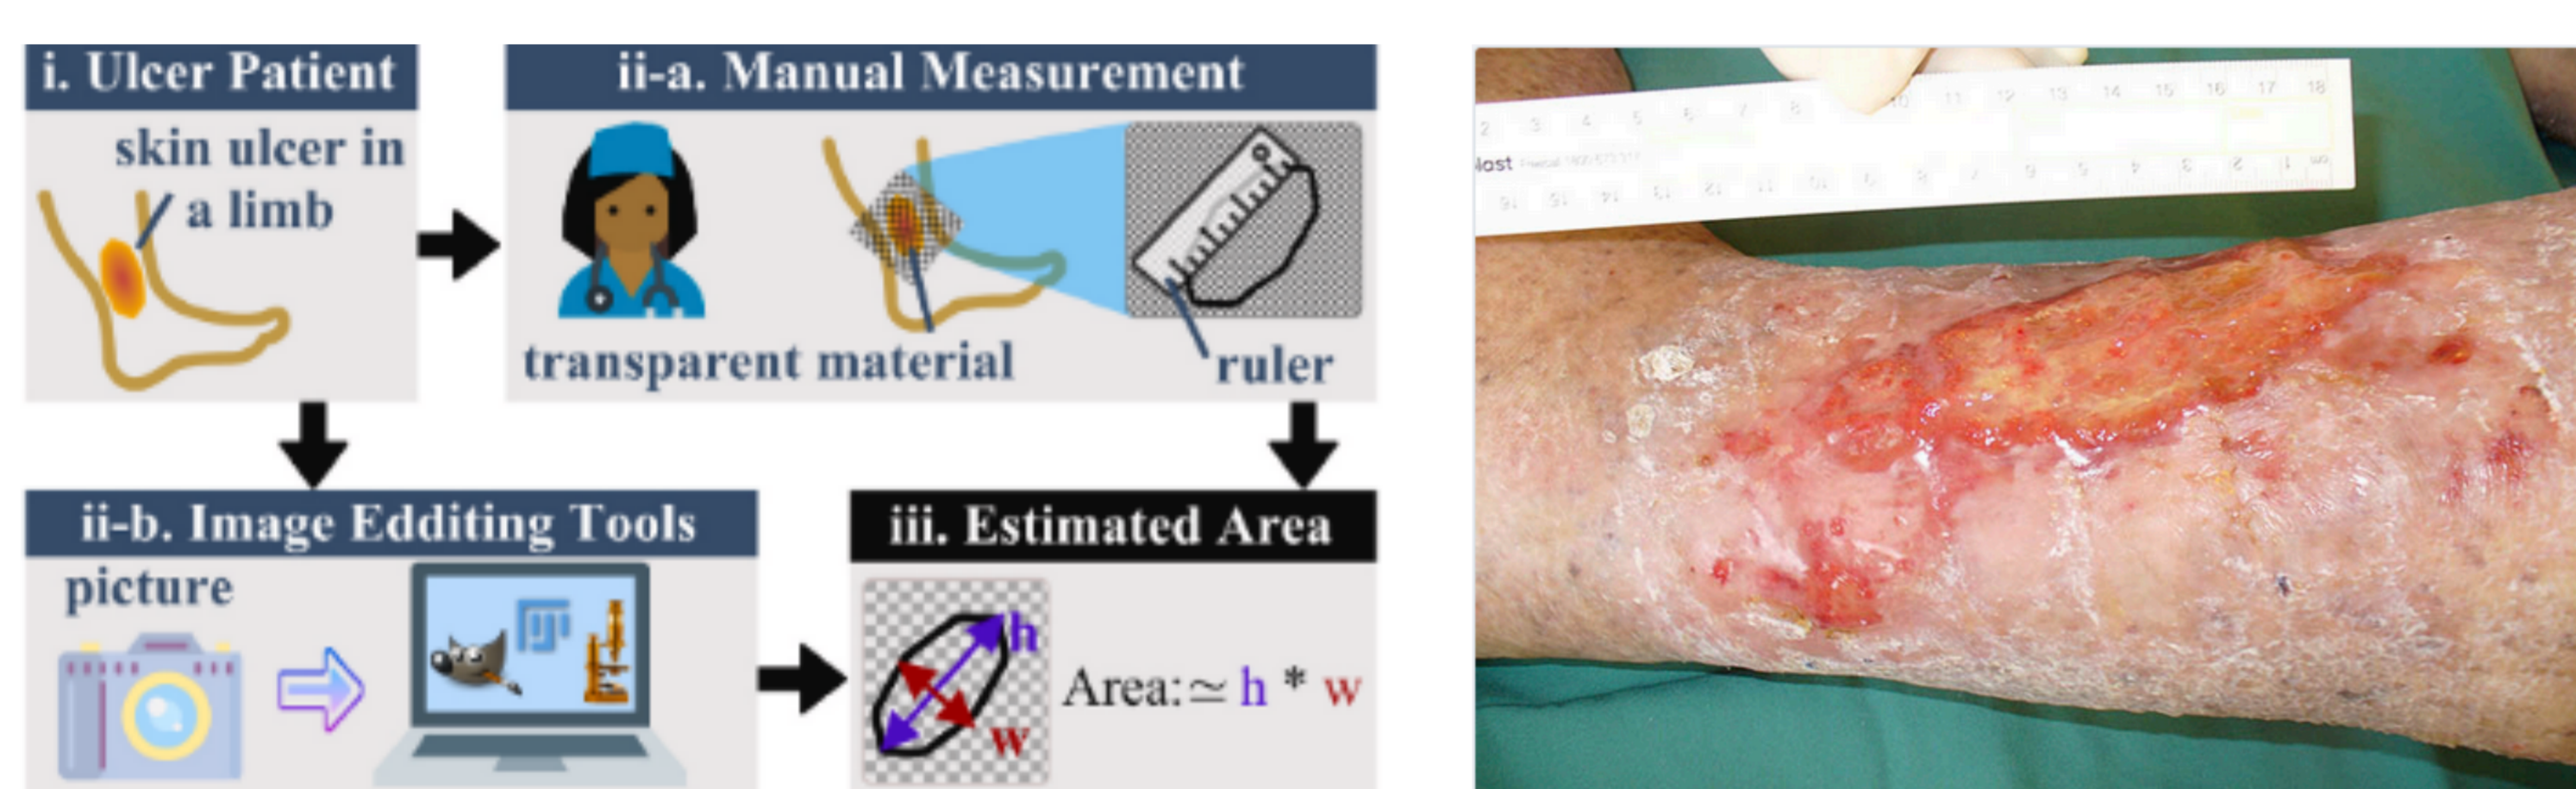


Figura a): Diagrama do processo de medição das úlceras. b): Processo real de medição das úlceras

## II. METODOLOGIA

### 1. Análise Crítica de Protocolo Oficial

- Estudo aprofundado do *Manual de Condutas para Úlceras Neurotróficas e Traumáticas* (Ministério da Saúde, 2002).

### 2. Revisão Bibliográfica em Inteligência Artificial

- Levantamento e análise de publicações sobre o uso de IA na segmentação automática de úlceras dermatológicas.

### 3. Avaliação de Arquiteturas de Segmentação

- **ASURA** (Chino et al., 2020) (**Automatic Skin Ulcer Region Assessment**) – Combinação de U-Net com detecção de régua para estimativa de escala.
- **QTDU** (Blanco et al., 2020) (**Superpixel-driven deep learning approach for the analysis not dermatological wounds**) – Método híbrido com superpixels e redes convolucionais (CNN).
- **Transformers** (ex.: **TinyViT** (Brehmer et al., 2025) (**Tiny Vision Transformer**)) – Avaliação de arquiteturas modernas com atenção visual para segmentação precisa.

### 4. Estudo de Técnicas de Explicabilidade

- Aplicação de métodos como **Grad-CAM** (**Gradient-weighted Class Activation Mapping**) e **LIME** (**Local Interpretable Model-Agnostic Explanations**) para interpretar e validar os resultados das redes neurais.

## III. RESULTADOS

Comparação de Métodos de Medição de Úlceras  
Escala de 1 (pior) a 10 (melhor)

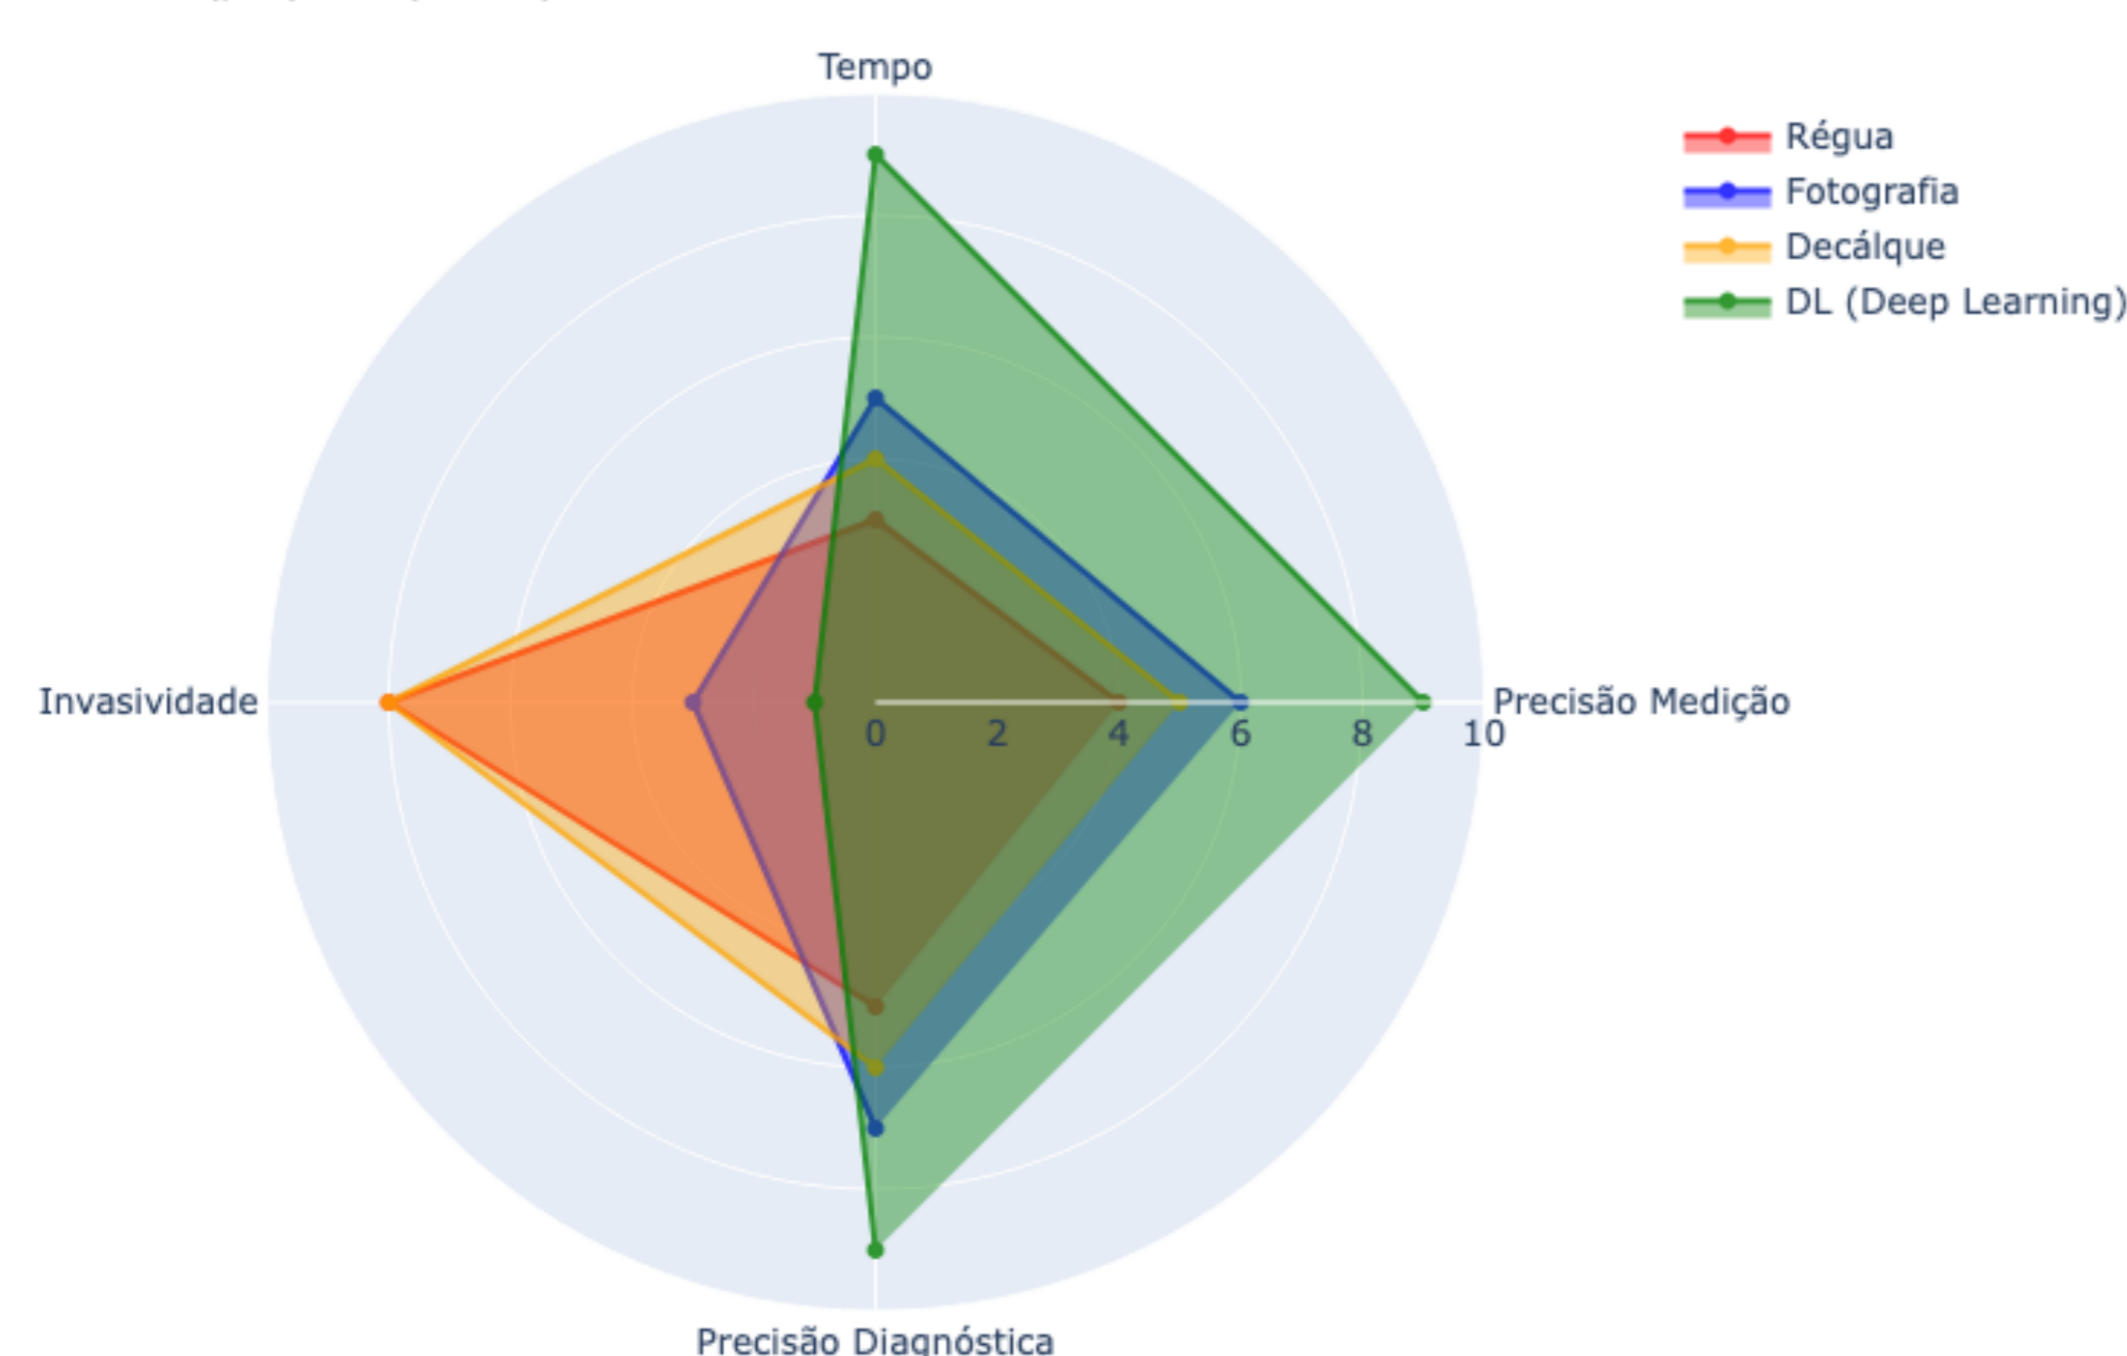


Figura 2: Diagrama comparativo dos métodos de medição de úlceras

Modelo	Tarefa	F1 (%)	AUROC	Unidades
ASURA	Segmentação + área real	—	—	cm <sup>2</sup>
QTDU	Classificação tecidual	97,0	0,986	pixels
TinyViT (JMIR)	PU vs IAD (binária)	93,2	0,985	imagem + clínico
Fast R-CNN	Doenças de pele (23 classes)	90,0	—	caixa delimitadora
TinyViT-21M	Pré-treino geral (ImageNet)	84,8	—	transf. aprend.

Tabela 1: Comparativo entre principais modelos revisados

Modelos compactos como o **TinyViT** demonstram alta eficiência, alcançando desempenho comparável ou superior a modelos maiores, com menor custo computacional.

A abordagem **QTDU**, que combina *superpixels* com *CNNs*, oferece alta acurácia na segmentação e quantificação de tecidos ulcerados, sendo eficaz mesmo com bases de dados reduzidas.

O modelo **ASURA** se destaca pela conversão da área da ferida em unidades físicas (cm<sup>2</sup>), agregando valor clínico direto à segmentação.

A classificação multimodal com **TinyViT** supera especialistas humanos na distinção entre úlceras de pressão e dermatite associada à incontinência, validando o uso clínico de modelos baseados em *Transformer*.

O uso de **Fast R-CNN** (Dwivedi et al., 2021) (**Faster Region-Convolutional Neural Network**) em imagens dermatológicas diversificadas mostra que redes convolucionais profundas são aplicáveis para triagem automática em larga escala.

Estratégias como **transfer learning**, **data augmentation** e **destilação de conhecimento** são essenciais para viabilizar o uso de IA em contextos médicos com dados limitados

## IV. CONCLUSÃO

- **Modelos compactos:** TinyViT garante alta precisão em dispositivos leves.
- **Segmentação precisa:** QTDU classifica tecidos com baixo erro de área.
- **Medição física:** ASURA converte imagens em cm<sup>2</sup> para uso clínico.
- **IA superior a especialistas:** TinyViT multimodal supera equipes de enfermagem.
- **Aplicação em escala:** Fast R-CNN detecta 23 doenças de pele com 90% de acurácia.
- **Estratégias técnicas:** Transfer learning e destilação mantêm desempenho com poucos dados.
- **Aplicações em Defesa:** Diagnóstico rápido de feridas em campo militar.
- **Impacto estratégico:** Apoio médico ágil e menor custo logístico em operações.

## REFERÊNCIAS

- CHINO, D. Y. T. et al. Segmenting skin ulcers and measuring the wound area using deep convolutional networks. *Computer Methods and Programs in Biomedicine*, v. 191, p. 105376, 2020. Disponível em: <https://doi.org/10.1016/j.cmpb.2020.105376>.
- BLANCO, G. et al. A superpixel-driven deep learning approach for the analysis of dermatological wounds. *Computer Methods and Programs in Biomedicine*, v. 183, p. 105079, 2020. Disponível em: <https://doi.org/10.1016/j.cmpb.2019.105079>.
- DWIVEDI, P. et al. A deep learning based approach for automated skin disease detection using Fast R-CNN. In: *INTERNATIONAL CONFERENCE ON IMAGE INFORMATION PROCESSING (ICIIP)*, 6., 2021. Proceedings [...]. IEEE, 2021. p. 116–121. DOI: 10.1109/ICIIP53038.2021.9702567.
- BREHMER, A. et al. Fine-Grained Classification of Pressure Ulcers and Incontinence-Associated Dermatitis Using Multimodal Deep Learning: Algorithm Development and Validation Study. *JMIR AI*, v. 4, n. 1, e67356, 2025. Disponível em: <https://doi.org/10.2196/67356>.
- BRASIL. Ministério da Saúde. Manual de condutas para úlceras neurotróficas e traumáticas. Brasília, DF: Ministério da Saúde, 2002. 56 p. (Série J. Cadernos de Reabilitação em Hanseníase; n. 2). ISBN 85-334-0562-6
- CAZZOLATO, M. T. et al. The UTrack framework for segmenting and measuring dermatological ulcers through telemedicine. *Computers in Biology and Medicine*, v. 134, p. 104489, 2021.