



UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO DE TUCURUÍ
FACULDADE DE ENGENHARIA DE COMPUTAÇÃO

GABRIEL VENTURA GIORDANO

**Uso de Sistemas Generalistas de Reconhecimento de Imagem na Diferenciação de Lesões
de Pele**

TUCURUÍ
2025

GABRIEL VENTURA GIORDANO

Uso de Sistemas Generalistas de Reconhecimento de Imagem na Diferenciação de Lesões de Pele

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia de Computação, do Campus Universitário de Tucuruí, da Universidade Federal do Pará, como requisito parcial para obtenção do título de Bacharel em Engenharia de Computação.

Orientador(a): Dr. Daniel da Conceição Pinheiro

TUCURUÍ
2025

AGRADECIMENTOS

Agradeço primeiramente a Deus e minha família que com muito amor me trouxeram a esse mundo cheio de arte e alegrias. Tenho muita sorte por ter vocês e amo cada momento que estamos juntos.

Agradeço imensamente meus amigos, que me ajudam na árdua caminhada de ser um humano digno. Se eu não tivesse encontrado vocês eu teria que inventá-los.

Agradeço a Universidade Federal do Pará e seus professores por me permitir estudar e aprender sobre o mundo direto do interior do Pará, lugar onde eu cresci e que carrego comigo onde quer que eu vá.

Por último eu agradeço a toda comunidade de software livre, que dedica seu tempo a criar um mundo melhor e mais democrático.

RESUMO

O presente trabalho trata do uso de ferramentas de processamento e classificação de imagem na distinção entre dois diferentes tipos de lesão de pele (nevus e melanoma). Primeiramente, os subconjuntos de dados foram rotulados, um modelo de classificação de imagens foi treinado utilizando os dados rotulados, e por fim, a validação do modelo foi feita usando o conjunto completo de dados. As imagens utilizadas vieram de um banco de imagens médicas disponibilizadas publicamente, que foram processadas usando o YOLO11, uma ferramenta de treinamento de modelos para reconhecimento de imagem. O modelo chegou a alcançar uma taxa de acerto de 67% no conjunto de melanoma e 87% no conjunto de nevus na classificação dessas lesões.

Palavras-chave: Visão computacional; Classificação de imagens; Melanoma; Nevus; YOLO.

ABSTRACT

This paper deals with the use of image processing and classification tools to distinguish between two different types of skin lesion (nevi and melanoma). First, the data subsets were labeled, an image classification model was trained using the labeled data, and finally, the model was validated using the complete data set. The images used came from a bank of publicly available medical images, which were processed using YOLO11, a model training tool for image recognition. The model achieved a hit rate of 67% on the melanoma set and 87% on the nevus set when classifying these lesions.

Keywords: *Computer vision; Image classification; Melanoma; Nevus, YOLO.*

LISTA DE FIGURAS

Figura 1 – Comparação entre os diferentes modelos YOLO...	17
Figura 2 – Exemplo de imagens descartadas...	21
Figura 3 – Exemplo de imagens de melanomas utilizadas...	22
Figura 4 – Exemplo de imagens de nevos melanocíticos utilizados...	22
Figura 5 – Métricas geradas ao treinar o modelo...	24
Figura 6 – Gráfico da Curva de Precisão pela Confiança...	26
Figura 7 – Gráfico da Curva de Sensibilidade pela Confiança...	27
Figura 8 – Gráfico da Curva de Sensibilidade pela Confiança...	28
Figura 9 – Gráfico da Assertividade do Modelo...	30
Figura 10 – Matriz de confusão do modelo...	30
Figura 11 – Exemplo de detecções no conjunto de imagens de Nevos...	31
Figura 12 – Exemplo de detecções no conjunto de imagens de Melanoma...	32

LISTA DE TABELAS

Tabela 1 – Comparação entre categorias de modelos...	18
Tabela 2 – Distribuição de imagens por uso no modelo...	22
Tabela 3 – Principais Parâmetros de treino...	24
Tabela 4 – Parâmetros usados na predição...	28

LISTA DE SIGLAS

GPU	<i>Graphics Processing Unit</i> (Unidade de Processamento Gráfico)
RAM	<i>Random Access Memory</i> (Memória de Acesso Aleatório)
YOLO	<i>You Only Look Once</i> (Você Só Olha Uma Vez)
COCO	<i>Common Objects in Context</i> (Objetos Comuns em Contexto)
mAPval	<i>Multiple Average Precision Valor</i> (Valor de Média de Múltipla Precisão)
WRC	<i>Weighted-Residual-Connections</i> (Conexões Residuais Ponderadas)
CSP	<i>Cross-Stage-Partial-connections</i> (Conexões Parciais entre Estágios)
CmBN	<i>Cross mini-Batch Normalization</i> (Normalização de mini-lotes Cruzados)
GELAN	<i>Generalized Efficient Layer Aggregation Network</i> (Rede de Agregação de Camadas Eficiente Generalizada)
PGI	<i>Programmable Gradient Information</i> (Informações de Gradiente Programável)
NMS	<i>Non-Maximum Suppression</i> (Supressão Não Máxima)

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Contextualização do problema	11
1.2	Justificativa	11
1.3	Objetivos	12
1.3.1	Objetivo geral	12
1.3.2	Objetivos específicos.....	12
1.4	Estrutura do trabalho	12
2	REFERENCIAL TEÓRICO E TRABALHOS RELACIONADOS	13
2.1	Referencial teórico	13
2.1.1	Melanoma	13
2.1.2	Nevos Melanocíticos	13
2.1.3	Dermatoscopia.....	14
2.1.4	Visão Computacional	14
2.1.5	Redes Neurais Convolucionais.....	14
2.1.6	YOLO (<i>You Only Look Once</i>)	15
2.1.7	YOLO11 (<i>You Only Look Once 11</i>).....	17
2.2	Trabalhos relacionados	18
3	METODOLOGIA	20
3.1	Conjuntos de dados	20
3.1.1	<i>The International Skin Imaging Collaboration (ISIC)</i>	20
3.1.2	Dados Utilizados para a Criação do Modelo de Classificação.....	20
3.2	Ambiente e Modo de Treinamento do Modelo	23
3.2.1	Hiperparâmetros de treino.....	23
4	RESULTADOS E DISCUSSÕES	26
4.1	Métricas do Modelo Gerado	26
4.2	Parametrização para análise dos conjuntos de dados	28
4.3	Desempenho geral	29
5	CONCLUSÃO E TRABALHOS FUTUROS	33
	REFERÊNCIAS	34

1 INTRODUÇÃO

O presente trabalho tratará sobre o uso de sistemas de reconhecimento de imagens para diferenciação dos seguintes tipos de lesão de pele: Melanoma e Nevos. A criação de ferramentas que auxiliem nas análises dermatoscópicas pode acelerar o processo de diagnóstico em caso de lesões malignas. Ferramentas desse tipo também podem ser usadas em casos onde o paciente se encontre em localidade remota, ou em caso de isolamento provocado por doenças contagiosas e podem auxiliar a atuação dos profissionais da saúde e até protegê-los de situações de risco.

1.1 Contextualização do problema

O diagnóstico de um melanoma é um processo que envolve uma análise visual e biópsia da lesão. A análise visual deve seguir os critérios clínicos ABCDE (SBDRS, 2025), que descrevem as características específicas que indicam como diferenciar uma lesão benigna, como por exemplo o nevo melanocítico, de um melanoma. Entretanto esse exame visual é complexo e leva em consideração múltiplos fatores que podem minimizar a confiança do diagnóstico de uma lesão qualquer.

Diante dessa complexidade, a precisão do diagnóstico pode ser comprometida, impactando diretamente a sobrevivência do paciente. Como o sucesso no tratamento de um melanoma está diretamente ligado ao diagnóstico precoce, tendo uma taxa de sobrevivência de 5 anos em 99,6% quando diagnosticado no estágio I, reduzindo drasticamente para apenas 35,1% quando diagnosticado nos estágios mais avançados (Saida *et al*, 2025), desenvolver ferramentas que auxiliem esse ponto do diagnóstico, aumentando sua confiança pode impactar positivamente na redução do tempo de início do tratamento.

1.2 Justificativa

O YOLO11, ferramenta usada para o treino do modelo de reconhecimento de imagens, é a última versão da biblioteca que vem sendo desenvolvida desde 2015, tendo passado por avanços significativos nas métricas de acerto, velocidade e eficiência, sendo utilizado em diversos setores (Ultralytics, 2025).

Os dados utilizados para treinar o modelo estão disponibilizados no site ISIC, *The International Skin Imaging Collaboration*, fruto de uma parceria acadêmica e de setores médicos projetada para usar imagens digitais da pele para ajudar a reduzir a mortalidade por

câncer de pele (ISIC, 2025).

A importância do desenvolvimento desse estudo para o reconhecimento de imagens se dá porque durante os estágios iniciais do desenvolvimento de um melanoma ele apresenta características muito semelhantes ao nevo (Waseh *et al*, 2023), um tipo de lesão benigna, o que pode atrasar seu diagnóstico.

1.3 Objetivos

1.3.1 Objetivo geral

O principal objetivo desse trabalho é demonstrar a possibilidade de desenvolver ferramentas que auxiliem no diagnóstico de lesões dermatológicas malignas, com os recursos disponíveis, como software e conjuntos de imagens livres.

1.3.2 Objetivos específicos

- Rotular um conjunto de imagens para o desenvolvimento de um modelo de reconhecimento de imagens;
- Treinar o YOLO11x com o conjunto de dados de treinamento;
- Analisar o desempenho geral do modelo verificando sua eficácia com os conjuntos de dados de imagens;

1.4 Estrutura do trabalho

Este trabalho está dividido em cinco capítulos, nos quais são apresentados os aspectos que fundamentam seu desenvolvimento. O primeiro capítulo descreve o problema abordado, a justificativa e os objetos gerais e específicos. Em seguida no segundo capítulo está o referencial teórico que foi utilizado como base de conhecimento para o desenvolvimento deste trabalho.

No terceiro capítulo estão expostos os materiais e metodologias utilizadas para treinar o modelo de detecção, e em seguida no quarto capítulo estão apresentados os resultados e discussões relacionadas. Por último, no quinto capítulo está a conclusão e as referências utilizadas durante o texto deste trabalho.

2 REFERENCIAL TEÓRICO E TRABALHOS RELACIONADOS

Neste capítulo, serão abordados os conceitos teóricos fundamentais relacionados a este trabalho, além da apresentação de artigos correlatos que contribuem para a compreensão do tema.

2.1 Referencial teórico

A seguir estão expostos concisamente alguns dos temas da área de saúde que foram objetos da análise deste trabalho, além das redes neurais convolucionais e a biblioteca YOLO11 que foram tecnologias envolvidas no processamento das imagens.

2.1.1 Melanoma

Segundo o INCA o melanoma é o tipo de câncer de pele mais agressivo e frequente no Brasil, correspondendo a cerca de 30% de todos os tumores malignos registrados no país. Apesar disso, o prognóstico desse câncer é positivo quando detectado precocemente (INCA, 2022).

O processo de detecção e diagnóstico do melanoma ocorre em duas etapas, o exame visual e a biópsia. O exame visual é guiado pelos critérios clínicos ABCDE que auxiliam na avaliação das lesões, conceito descrito por Azulay em 2021 (CDPA, 2025):

A = Assimetria, quando uma metade da lesão não é igual à outra metade;
B = Bordas irregulares ou mal definidas;
C = Coloração variada nas diversas áreas
D = Diâmetro dos melanomas geralmente é maior que 6 mm
E = Evolução, quando um sinal fica diferente dos outros da própria pessoa (tamanho, formato, coloração)

A presença de uma ou mais dessas características indica que a lesão pode ser um melanoma.

2.1.2 Nevos Melanocítico

O nevo melanocítico é uma lesão cutânea benigna que surge devido a proliferação de melanócitos, as células responsáveis pela produção da melanina, o pigmento que dá cor a pele. Em geral esse tipo de lesão é simétrico, tem bordas regulares, o mesmo tom de cor em sua extensão e geralmente um diâmetro inferior a 6 mm (Hospital Albert Einstein, 2023).

Os nevos melanocíticos podem ser congênitos, quando presentes desde o nascimento, ou adquiridos ao longo da vida. A maioria dos nevos adquiridos surge na infância e

adolescência, estabilizando-se na idade adulta. Algumas variantes, como os nevos displásicos, apresentam características atípicas, podendo gerar dúvidas no diagnóstico diferencial com o melanoma.

2.1.3 Dermatoscopia

A dermatoscopia é uma técnica diagnóstica não invasiva utilizada na identificação de lesões pigmentadas da pele (Frange et al., 2009). Como nem todas as lesões cutâneas pigmentadas podem ser identificadas corretamente apenas pelo aspecto clínico, utiliza-se o dermatoscópio, que permite uma ampliação de, no mínimo, 10 vezes (Rezze et al., 2006).

Segundo Bafounta, a dermatoscopia apresenta todas as qualidades essenciais para um teste diagnóstico eficaz: precisão, ausência de efeitos adversos, identificação de doenças potencialmente graves se não diagnosticadas precocemente e possibilidade de tratamento eficaz quando a doença é detectada em estágio inicial (Bafounta et al., 2001).

2.1.4 Visão Computacional

A visão computacional é um campo da Inteligência Artificial, composta por conjuntos de técnicas que permitem ao computador extrair informações de imagens digitais, utilizando-se de técnicas de processamento de imagem e inteligência artificial para esse fim.

Segundo Holm *et al* (2020) a visão computacional é o campo da ciência que se concentra na quantificação do conteúdo de informação visual de imagens digitais. Essa área teve um crescimento significativo de aplicações ativas; sensoriamento remoto, diagnóstico técnico, orientação de veículos autônomos e imagens biomédicas nas últimas décadas (Sonka *et al*, 2014, p. 27).

2.1.5 Redes Neurais Convolucionais

As redes neurais convolucionais são modelos computacionais projetados para processar imagens que utilizam multicamadas complexas e profundas, sendo capazes de reconhecer elementos em imagens (Santos *et al*, 2017). Elas são capazes de fazer isso através de um processo de aprendizado onde são atribuídos valores de importância através de pesos e vieses em suas camadas a vários aspectos ou objetos de cada imagem durante o treinamento.

As redes neurais convolucionais diferem das redes neurais tradicionais por não relacionarem cada neurônio de uma camada com todos os neurônios da próxima camada. Isso

é feito para evitar que pixels que estão distantes na imagem sejam diretamente relacionados durante o treinamento. Nas redes neurais convolucionais é levado em consideração a composição espacial da imagem. Essas características aceleram o treinamento de modelos desse tipo e permitem que redes com mais camadas sejam treinadas (*Deep Learning Book*, 2025).

2.1.6 YOLO (*You Only Look Once*)

Em 2015 Joseph Redmon e Ali Farhadi da Universidade de Washington lançaram o YOLOv1, um modelo de detecção de objetos cuja arquitetura combinava a predição de caixas limitadoras e estimativa de probabilidade de classe em uma única passagem pela rede neural. Essa característica permitiu o seu uso em aplicações de processamento em tempo real (Labelvisor, 2024) o que abriu a possibilidade de uso em diferentes áreas.

A arquitetura interna da rede consistia em 24 camadas convolucionais e duas camadas totalmente conectadas, o que permitia um processamento eficiente de até 45 quadros por segundo (Redmon *et al*, 2016). Sua capacidade de realizar predições em tempo real sem perda de precisão tornou o YOLO uma das ferramentas de referência na área visão computacional.

As próximas versões do YOLO foram desenvolvidas incrementando recursos, realizando refinamentos e por vezes alterando a estrutura da rede neural utilizada. A segunda versão, além de melhorias como o uso de caixas de ancoragem que melhoraram a detecção de objetos de diferentes tamanhos, também passou a usar a arquitetura Darknet-19, uma rede neural convolucional que possui 19 camadas, que melhorou a capacidade de extração de características de imagens do modelo. A terceira versão do YOLO alterou novamente a arquitetura interna da rede para a Darknet-53 com mais camadas convolucionais, o que impulsionou ainda mais suas capacidades de aprendizado. Essa versão também conta com avanços em detecção de objetos de diferentes tamanhos, por ter sido implementada a capacidade de predição multi-escalar. Outro ponto importante foram melhorias sensíveis no tempo de processamento de até 3.8 vezes mais rápido em comparação com as versões anteriores (Redmon *et al*, 2018).

Em 2020 Joseph Redmon, o arquiteto original do projeto, deixou a área e a comunidade passou a ter um papel central no desenvolvimento da aplicação como um todo (Labelvisor, 2024), o que expandiu as possibilidades de implementação de melhorias e aumentou a velocidade de desenvolvimento, com as duas próximas versões sendo lançadas com um intervalo de menos de dois meses entre elas.

O YOLOv4, lançado em abril de 2020, contou a implementação de diversos recursos, incluindo: *Weighted-Residual-Connections* (WRC), *Cross-Stage-Partial-connections* (CSP) e *Cross mini-Batch Normalization* (CmBN), fazendo dele o sistema mais avançado de detecção de objetos até o momento (Bochkovskiy *et al*, 2020).

A quinta versão do YOLO foi a primeira a ser lançada pela Ultralytics, uma organização criada com o propósito de tornar o desenvolvimento de modelos de detecção de objetos mais acessível e eficiente (Ultralytics, 2020). Suas melhorias incluem a otimização de hiperparâmetros, acompanhamento de treino e integrações com formatos populares.

O YOLOv6 foi desenvolvido e lançado de forma *open source* pela Meituan, uma empresa chinesa de varejo da área de tecnologia, em 2022, especificamente para ser usado em robôs de entrega autônomos.

A versão seguinte, YOLOv7, fez a parametrização do modelo, melhorando o gradiente de propagação, passou a trabalhar com rotulação dinâmica, melhorando a precisão e também reduziu a quantidade de parâmetros em 40%, tornando-o mais eficiente (Ultralytics, 2022). Essas melhorias geraram ganhos expressivos em velocidade de inferência em relação aos modelos anteriores de até 150% (Wang *et al*, 2023).


A versão YOLOv8 foi desenvolvida pela Ultralytics, lançada em janeiro de 2023, e incluiu uma nova arquitetura, otimizações de equilíbrio entre precisão e velocidade e vários modelos já treinados. Essas melhorias tornaram o modelo mais acessível ao público geral, além de mais eficiente e rápido (Ultralytics, 2023).

Desenvolvido por uma equipe independente (Wang *et al*, 2024), o YOLOv9 conseguiu desenvolver modelos com melhoria de média de precisão de 1,7% em relação a geração anterior utilizando 15% menos parâmetros. Essas melhorias vêm da implementação de técnicas como *Generalized Efficient Layer Aggregation Network* (GELAN) e *Programmable Gradient Information* (PGI).

A décima versão do YOLO foi criada por pesquisadores da Universidade de Tsinghua, na China, e conta com mais melhorias na sua arquitetura que aumentam sua capacidade de extração de características, precisão de objetos em diferentes escalas, além de múltiplas detecções por objeto durante o treino para aumentar a precisão. Outro recurso importante foi a eliminação de *non-maximum suppression* (NMS) que acelerou o tempo de inferência dos modelos.

No gráfico a seguir é possível ver como todas esses progressos impactaram na performance dos modelos YOLO. O eixo vertical do gráfico representa a precisão do modelo quando treinado no conjunto de dados COCO, enquanto o eixo horizontal representa o tempo de inferência do modelo em milissegundos por imagem. No gráfico é possível ver que o modelo com as melhores métricas é o YOLO11, que será discutido a seguir.

Figura 1 – Comparação entre os diferentes modelos YOLO



a detecção, mas em contrapartida mais preciso ele é.

Na tabela a seguir é possível realizar essa comparação das diferentes categorias de modelo quando treinadas no conjunto de imagens COCO (*Common Objects in Context*), esse conjunto de imagens é mantido pela Microsoft e é comumente usado para avaliar a performance de diferentes modelos de visão computacional (Ultralytics, 2025). As principais características a serem avaliadas na tabela são as colunas de mAPval, que é a média de precisão das múltiplas classes as quais esses modelos diferenciam, e Velocidade CPU, que é uma métrica de tempo de uma detecção utilizando o modelo especificado.

Tabela 1 – Comparação entre categorias de modelos

Modelo	tamanho (pixéis)	mAPval 50-95	Velocidade CPU ONNX (ms)	Velocidade T ₄ TensorRT10 (ms)	params (M)	FLOPs (B)
YOLO11n	640	39.5	56.1 ± 0.8	1.5 ± 0.0	2.6	6.5
YOLO11s	640	47.0	90.0 ± 1.2	2.5 ± 0.0	9.4	21.5
YOLO11m	640	51.5	183.2 ± 2.0	4.7 ± 0.1	20.1	68.0
YOLO11l	640	53.4	238.6 ± 1.4	6.2 ± 0.1	25.3	86.9
YOLO11x	640	54.7	462.8 ± 6.7	11.3 ± 0.2	56.9	194.9

Fonte: Ultralytics (2025)

2.2 Trabalhos relacionados

Para desenvolver a pesquisa sobre o uso de sistemas generalistas de reconhecimento de lesões de pele foram utilizados artigos científicos, capazes de embasar as áreas que esse trabalho engloba, sendo elas: Criação de ferramenta que utilizar a visão computacional e a arquitetura de Redes Neurais Convolucionais para auxiliar no diagnóstico de doenças de pele.

Deniz *et al*, (2024). O trabalho: *Skin Cancer Detection Based on YOLOv8 Through A Mobile Application*, avalia o desempenho do YOLOv8 para detecção de câncer de pele usando um conjunto de dados HAM100000. A eficácia do método proposto foi de 92,80%. Esse estudo sugere que o YOLO pode ser utilizado para detectar câncer de pele em estágio inicial e que tal ferramenta pode ser considerada para futuras pesquisas.

Hosen *et al*, (2023). O artigo: *Analyze Skin Disease using Xception Deep Learning Technique*, apresenta uma forma de utilizar a visão computacional e a arquitetura de Redes Neurais Convolucionais para auxiliar no diagnóstico de doenças de pele. Para construir esse sistema especializado foi utilizado o modelo Xception. No desenvolvimento deste trabalho foi utilizado um conjunto de imagens clínicas de doenças de pele, o repositório contou com 19.500

fotos faciais de 23 categorias diferentes. O modelo obteve uma precisão de classificação de 73,46%.

Zhipan *et al*, (2023). O trabalho acadêmico: *A Real-Time Skin Disease Recognition System Based on YOLOv5 Algorithm* discorre sobre a utilização de ferramentas como *You Only Look Once* (YOLO v5), EfficientDet, M2det e *Single Shot Multi-Box Detector* (SSD), para o desenvolvimento de um sistema de reconhecimento de doenças de pele comuns como acne e dermatite. Na construção da pesquisa é verificada a superioridade de precisão da utilização do YOLOv5 em comparação com as demais. O valor médio de mAP (múltipla precision média) do YOLOv5 é de aproximadamente 8,3 e 3,1.

Pareddy *et al*, (2025). A publicação: *A Skin Disease Detection using various methods of Deep Learning – a Comprehensive Approach*, expõe a necessidade de criação de um sistema automatizado de design auxiliado por computador (CAD) para auxiliar na identificação e classificação de anomalias na pele a partir de fotografias. A pesquisa propôs como estratégia para alcançar o objetivo geral o uso da visão computacional (*deep learning*), utilizando-se, para tanto, das ferramentas Inception V3, Inception ResNET V2 e MobileNet.

Yasir *et al*, (2014). O artigo: *Dermatological Disease Detection using Image Processing and Artificial Neural Network* propõe a utilização de métodos com utilização de técnicas baseadas em visão computacional. Para o desenvolvimento do trabalho foram utilizados diferentes algoritmos de processamento de imagem para extração de características, sendo a rede neural artificial do tipo *feedforward* para treinamento. O sistema proposto funciona em duas fases: primeiro pré-processa as imagens e depois identifica as doenças. Esse sistema obteve 90% de precisão na detecção de nove tipos de doenças dermatológicas.

Juthi *et al*. (2024). A publicação: *Dermatological Disease Detection Using Image Processing and Deep Learning*, busca propor um método de facilitar a detecção e identificação de doenças de pele, utilizando arquitetura de redes neurais convolucionais: U-Net, VGG19 e MobileNetV2 para identificar o modelo mais adequado. Nesse contexto, o U-Net foi considerado mais eficaz, alcançando uma precisão de 93% no conjunto de testes.

3 METODOLOGIA

O presente capítulo descreve o desenvolvimento metodológico utilizado para a realização deste trabalho. Esta é uma pesquisa aplicada exploratória, que tem por objetivo investigar a possibilidade de se utilizar recursos publicamente disponíveis e ferramentas de visão computacional para gerar dados úteis para a diferenciação entre lesões de pele benignas e malignas, especificamente entre nevos melanocítico e melanomas.

A abordagem da pesquisa é quantitativa, com o foco em desenvolver um modelo classificador de imagens específico que gere dados concretos pelas análises diretas dos conjuntos de dados selecionados para o estudo. A métrica central de análise utilizada é a média de acertos do modelo criado em relação aos dois diferentes conjuntos de dados, que permite inferir padrões de comportamento do modelo entre as diferentes classes, que por sua vez indica possíveis melhorias a serem realizadas neste processo.

3.1 Conjuntos de dados

Esta seção descreve a origem e as características dos conjuntos de dados utilizados no trabalho para treinar e validar o modelo classificador de imagens.

3.1.1 *The International Skin Imaging Collaboration (ISIC)*

O site ISIC tem por objetivo apoiar esforços para reduzir a taxa de mortalidade ligada a melanomas, através de propostas de padronização dos registros de imagem de lesões e do engajamento com a comunidade científica e com desenvolvedores para aumentar a precisão dos diagnósticos com a ajuda de inteligência artificial (ISIC *Mission*, 2025).

A plataforma disponibiliza uma biblioteca *open source* (ISIC *Archive*, 2025) com diversos conjuntos de imagens representativos de diferentes tipos de lesões dermatológicas para serem usados para o fim de pesquisa na área de visão computacional aplicada a diagnósticos. Essas imagens são majoritariamente obtidas por dermatoscopia ou fotografias de enquadramento fechado.

3.1.2 Dados Utilizados para a Criação do Modelo de Classificação

Foram utilizados dois conjuntos de imagens, um que contém apenas imagens de nevos melanocítico e o outro de melanomas. Detalhando o conjunto de nevos temos que ele se

encontra na categoria *BENIGN MELANOCYTIC PROLIFERATIONS*. Esse conjunto contém atualmente 38.500 imagens. Destas apenas 28.437 foram de fato utilizadas neste trabalho por dois motivos, o primeiro foi conseguir alcançar tempos de processamento razoáveis, tanto de treinamento de modelo quanto dos testes de detecção, evitando que a detecção levasse mais de 12 horas, e o segundo motivo foi que algumas imagens não tinham a lesão de pele como foco da imagem, onde seria extremamente difícil o modelo discernir qualquer característica relevante sobre a lesão em questão.

O conjunto de imagens de melanomas se encontra na categoria *MALIGNANT MELANOCYTIC PROLIFERATIONS* e contém 9.974 imagens. Destas apenas 9045 foram utilizadas depois de remover do conjunto de dados as imagens que não tinham a lesão como foco da imagem.

Figura 1 – Exemplo de imagens descartadas



Fonte: ISIC (2025)

Essa seleção de imagens foi feita com o intuito de homogeneizar os dois conjuntos de dados a fim de facilitar o processo de extração de características das lesões. Nas figuras a seguir estão alguns exemplos de imagens que foram utilizadas neste trabalho.


Dentre o conjunto total de 37.482 imagens utilizadas neste trabalho foram utilizadas 4.416 imagens para a criação do modelo que realiza a detecção e classificação das imagens.

Para a rotulação dessas imagens foi utilizado o software LabelImg, uma ferramenta *open source* para anotação de imagens, que fica armazenada em um arquivo secundário com o mesmo nome da imagem no formato txt. Essa anotação é que indica para o YOLO onde na imagem está o objeto para as características serem extraídas (LabelImg, 2024).

A partir das imagens rotuladas é necessário dividir esse conjunto em 3 subconjuntos: um de treino, um de validação e um de teste. O conjunto de treino é de onde serão extraídas as características que comporão o modelo de classificação, o conjunto de validação é utilizado

durante o treinamento do modelo para validar a performance do modelo durante o treinamento. Esse processo de validação é importante tanto para os ajustes dos hiperparâmetros de treinamento quando para garantir a capacidade do modelo de generalizar sua capacidade de classificação evitando *overfitting*. Por último o conjunto de teste é usado após finalizar o treinamento para mensurar a performance do modelo classificador.

Figura 2 – Exemplo de imagens de melanomas utilizadas



Fonte: ISIC (2025)

Figura 3 – Exemplo de imagens de nevos melanocítico utilizadas



Fonte: ISIC (2025)

Na tabela a seguir estão descritas em detalhe as quantidades e proporções de imagens utilizadas. As proporções definidas destes conjuntos são usualmente utilizadas para treinamento de modelos de aplicações semelhantes.

Tabela 2 – Distribuição de imagens por uso no modelo

	Quantidade (nevos + melanoma)	Porcentagem total (%)
Treinamento	1524 + 1569	70,04%
Validação	435 + 448	19,99%
Teste	217 + 223	9,96%

Fonte: Elaborado pelo autor (2025)

3.2 Ambiente e Modo de Treinamento do Modelo

O processo de treinamento de modelos de classificação demanda um alto nível de recurso computacional, por esse motivo foi escolhido utilizar a plataforma online de desenvolvimento Kaggle, que disponibiliza gratuitamente ambientes de execução de códigos com GPUs Tesla P100 e até 29 Gbs de RAM em sessões de até 12 horas contínuas para desenvolvimento de aplicações voltadas para Inteligência Artificial e Aprendizado de Máquina (Kaggle, 2025).

Considerando a necessidade de ambientes com essas características para treinar os modelos de detecção de objetos as limitações do ambiente foram consideradas para escolher o tamanho do conjunto de dados de treinamento e também a quantidade de épocas treinadas, parâmetros que impacta diretamente no tempo de duração do treinamento. Essas limitações também servem para limitar os recursos energéticos que foram utilizados durante o desenvolvimento deste trabalho.

3.2.1 Hiperparâmetros de treino

Os parâmetros utilizados durante o treinamento do modelo YOLO11, também chamados de hiperparâmetros, influenciam a performance, velocidade e precisão do modelo a ser gerado. Esses parâmetros incluem *batch size*, que indica o número de imagens de treinamento utilizados em cada iteração, *learning rate* e *weight decay*, que influenciam a forma como os pesos são ajustados durante o treinamento, entre outros.

Há também parâmetros que aumentam a robustez do modelo introduzindo variabilidade no conjunto de treinamento, o que ajuda o modelo a ser capaz de generalizar melhor as características quando ele avalia um conjunto de dados novo. Alguns exemplos de parâmetros desse tipo são: *degrees*, que rotaciona imagens do conjunto de treinamento em um ângulo aleatório dentro do parâmetro especificado, *scale*, que redimensiona a imagem para simular objetos em diferentes distâncias da câmera, além de parâmetros que modificam atributos de coloração e iluminação das imagens, como *hsv_h*, *hsv_s* e *hsv_v* que

respectivamente ajustam os valores de coloração, saturação e luminosidade da imagem.

Além disso ainda há a questão de qual categoria de modelo treinar. Visto que o objetivo da aplicação não está relacionado a processamento de imagens em tempo real ou execução do modelo em ambientes com recursos limitados, foi selecionado a categoria de modelo yolo11x.pt que é esperado que tenha a maior precisão.

Na tabela a seguir estão apresentados os principais valores de parâmetros utilizados durante o treinamento do modelo YOLO11.

Tabela 3 – Principais Parâmetros de treino


Hiperparâmetro	Valor
Modelo	yolo11x.pt
epochs	115
hsv_h	0.3
hsv_s	0.7

Fonte: Elaborado pelo autor (2025)

O parâmetro de épocas foi escolhido para que o tempo de processamento não excedesse o limite de 12 horas do ambiente de execução. Os parâmetros seguintes, hsv_h e hsv_s, foram definidos dessa forma para incluir variabilidade no conjunto de imagens em sua coloração e saturação visto que essas são características definidoras das lesões presentes nas imagens de treino, desta forma uma imagem de lesão no conjunto de treinamento é utilizada mais de uma vez com diferentes colorações o que ajuda o modelo a extrair características que independam da coloração da lesão, visto que a coloração das lesões pode variar.

O principal motivo para utilizar esses parâmetros e aumentar a variabilidade do conjunto de treinamento é aumentar a capacidade de generalização do modelo e evitar o overfitting, isto é, impedir que o modelo se adapte ao conjunto de treinamento, tendo bons resultados durante um teste fechado, mas tenha um desempenho ruim em aplicações reais.

Figura 5 – Métricas geradas ao treinar o modelo



Fonte: Elaborado pelo autor (2025)

Após o término do treinamento do modelo, o YOLO11 gera gráficos de desempenho, que ilustram as métricas internas dos conjuntos de dados de teste e validação. Esses gráficos permitem acompanhar o desempenho do modelo a cada época, possibilitando uma análise detalhada da evolução das métricas, como precisão, sensibilidade e média de precisão múltipla, onde quanto maior o valor do índice registrado melhor é o desempenho do modelo em seu respectivo índice.

No gráfico da Figura 5 é possível verificar que os indicadores de precisão (*precision*), sensibilidade (*recall*) e as métricas de média de precisão múltipla para valores de precisão até 50% (*mAP50*) e entre 50% e 95% (*mAP50-95*) alcançam platôs quando a quantidade de épocas utilizadas para o treinamento se aproxima de 100. Isso indica que para esse conjunto de dados com essa parametrização os ganhos de performance seriam mínimos caso a quantidade de épocas fosse incrementada, reforçando a escolha de 115 épocas de treinamento.


4 RESULTADOS E DISCUSSÕES

Este capítulo aborda a análise do desempenho do modelo YOLO11x treinado, tanto as métricas criadas durante sua criação quanto as métricas geradas através de análises dos conjuntos de dados utilizados no estudo.

4.1 Métricas do Modelo Gerado

Durante o treinamento do modelo o YOLO11x gera gráficos das métricas de desempenho em relação aos seus conjuntos de treino, teste e validação. A partir desses gráficos é possível entender o comportamento do modelo quanto utilizadas diferentes parametrizações de detecção.


Figura 6 – Gráfico da Curva de Precisão pela Confiança



Fonte: Elaborado pelo autor (2025)

Esse gráfico mostra a relação entre Precisão, que é a métrica de acertos do modelo, e Confiança, que é a taxa de confiança do modelo na detecção feita, podendo ser usada para definir quais são os parâmetros de confiança a serem usados durante a predição de imagens.

Figura 7 – Gráfico da Curva de Sensibilidade pela Confiança




Fonte: Elaborado pelo autor (2025)

O gráfico acima mostra a relação entre a sensibilidade do modelo, que é a capacidade de detectar os objetos, em relação a confiança do modelo em classificar o objeto. Demonstrando que quanto maior é a capacidade do modelo de realizar detecções, menor é a confiança.

O gráfico a seguir retrata a Pontuação-F1 que equilibra as métricas de precisão e sensibilidade, indicando pontos de maior eficiência de desempenho do modelo, onde detecções sejam feitas sem um risco elevado de falsos positivos.

Figura 8 – Gráfico da Curva de Sensibilidade pela Confiança



Fonte: Elaborado pelo autor (2025)

Levando em consideração essas métricas é possível definir parâmetros de uso do modelo conforme a necessidade específica de análise dos conjuntos de dados de imagens em questão.

4.2 Parametrização para análise dos conjuntos de dados

A parametrização utilizada para a análise dos conjuntos de dados leva em consideração que os conjuntos são especializados, onde objetiva-se que cada imagem tenha apenas uma lesão. Com isso o modelo detecta apenas um tipo de lesão por imagem, predizendo qual é a classe baseada em qual apresenta um maior índice de confiança. Na tabela a seguir estão dispostos os parâmetros utilizados na execução das predições:

Tabela 4 - Parâmetros usados na predição

Parâmetro	Valor
conf (Confidence Threshold)	0.0
max_det (Maximum number of detections)	1

Fonte: Elaborado pelo autor (2025)

O parâmetro de limiar de confiança (conf) com o valor de 0.0 garante que qualquer detecção que tenha sido feita seja levada em consideração. Dessa forma o modelo deve ser capaz de realizar ao menos uma predição para o objeto de interesse da imagem, independente do grau de confiança que o modelo tenha.

O parâmetro seguinte, max_det, limita a quantidade de detecções que o modelo registrará em cada imagem. O valor foi definido para uma detecção por imagem visto que raramente as imagens registram mais de uma lesão. Utilizando esse parâmetro o modelo YOLO11x ordena as detecções realizadas e registra apenas a de maior valor de confiança.

A utilização desses parâmetros garante que o modelo YOLO11x atue de forma esperada nos conjuntos de dados a serem analisado.

4.3 Desempenho geral

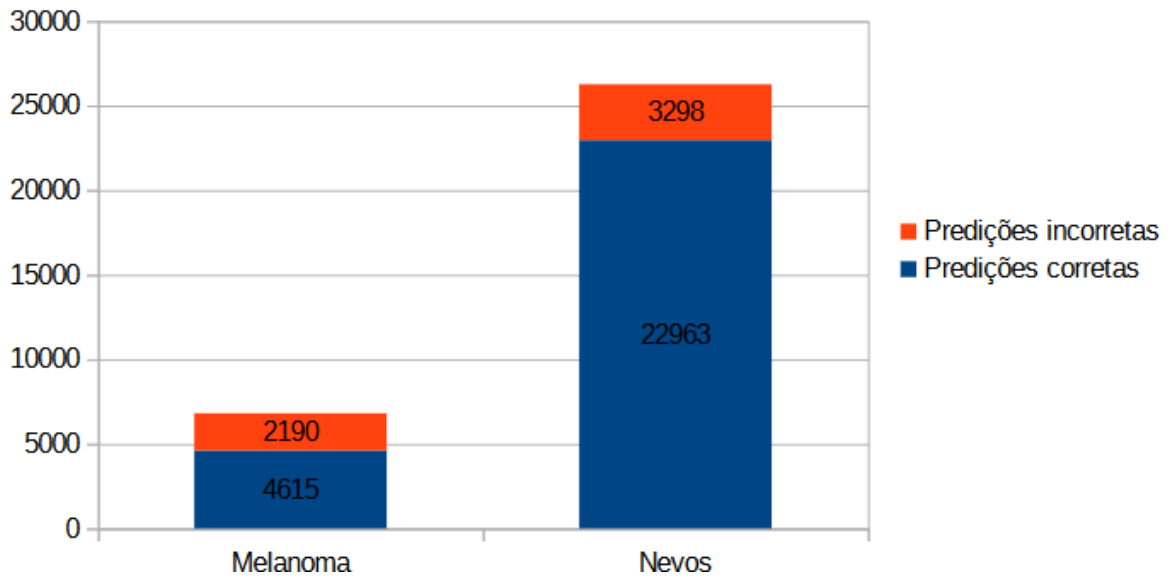
O desempenho do modelo YOLO11x foi mensurado analisando dois conjuntos de dados, um apenas com imagens de lesões do tipo Melanoma e o outro apenas com imagens de lesões do tipo Nevos.

Quando analisado o conjunto de dados de imagens de Nevos o resultado foi 22.963 predições corretas (87,44%), 3.298 predições incorretas (12,55%), com uma média de precisão de 61,83% quando o modelo prediz corretamente e de 50,19% quando o modelo prediz incorretamente.

Realizando a mesma análise no conjunto de dados de imagens de Melanoma o resultado foi 4.615 predições corretas (67,81%), 2.190 predições incorretas (32,18%), com uma média de precisão de 61,83% quando o modelo acerta a predição e 50,19% quando o modelo erra a predição.

Figura 9 – Gráfico da Assertividade do Modelo


Análises dos Conjuntos de Imagens Usando o Modelo gerado



Fonte: Elaborado pelo autor (2025)

Esses dados estão consistentes com a matriz de confusão gerada durante o treino do modelo que mostra uma porcentagem significativa de falsos positivos.

Figura 10 – Matriz de confusão do modelo




Fonte: Elaborado pelo autor (2025)

O motivo do modelo encontrar uma maior assertividade no conjunto de dados de nevos em relação ao conjunto de imagens de melanoma possivelmente se deve ao fato de que as lesões do tipo nevos são lesões bastante consistentes em suas características aparentes, enquanto o melanoma tem uma série de características que podem ou não estar presentes em uma lesão qualquer, com diferentes graus de intensidade. Essa variedade de padrões gera lesões que apesar de possuírem o mesmo diagnóstico possuem aspectos vastamente diferentes.

Além disso, os dois tipos de lesões, nevos e melanoma, compartilham características entre si, dificultando o ato de classificar imagens nessas duas classes, conforme demonstram as imagens a seguir.


Figura 11 – Exemplo de detecções no conjunto de imagens de Nevos



Fonte: Elaborado pelo autor (2025)

Na análise das imagens das Figuras 11 e 12 é possível constatar um exemplo de onde ocorre uma classificação incorreta feita pelo modelo YOLO11x. A motivação para isso é, principalmente, a semelhança entre as lesões dermatológicas. De forma mais detalhada, verifica-se que a quarta imagem do conjunto de nevos se assemelha a primeira imagem do conjunto de Melanoma e a terceira imagem do grupo de melanoma se assemelha a terceira imagem do conjunto de nevos.

Figura 12 – Exemplo de detecções no conjunto de imagens de Melanoma



Fonte: Elaborado pelo autor (2025)

Apesar disso, ainda existem características comuns suficientes entre as imagens de melanoma para o modelo conseguir diferenciar entre as lesões com pelo menos 67,81% de precisão, o que indica que é possível melhorar esse índice aumentando a diversidade e quantidade de imagens usadas no treinamento do modelo, permitindo que o modelo seja capaz de abstrair mais características que venham a ser usadas na classificação.

Outro possível ponto de otimização seria estender o trabalho de otimização de hiperparâmetros durante o treinamento do modelo, principalmente a quantidade de épocas que foram usadas. Isso pode levar a um aumento da precisão, mas que em contrapartida demandaria muito mais recursos durante a criação do modelo. Além do parâmetro de épocas, é possível realizar ajustes nos parâmetros que foram utilizados de pré-processamento das imagens que introduzem variabilidade no conjunto de treinamento.

Esses resultados demonstram que é possível utilizar o YOLO11x como uma ferramenta para o desenvolvimento de aplicações que realizem a diferenciação de lesões de pele.

5 CONCLUSÃO E TRABALHOS FUTUROS

O objetivo deste trabalho foi demonstrar a possibilidade de desenvolver um sistema de detecção e diferenciação entre lesões benignas comuns de pele lesões malignas, utilizando dados e recursos disponíveis em plataformas abertas ou *open source*.

Durante o desenvolvimento do trabalho, conjuntos de imagens foram selecionados e rotulados, modelos de detecção de objetos foram treinados e suas performances foram avaliadas e os resultados obtidos foram promissores, de modo a mostrar a viabilidade do trabalho.

Mesmo assim é possível compreender que existem pontos de melhorias técnicas no futuro, como por exemplo, estender o conjunto de imagens utilizado na construção do modelo, o que o tornaria mais robusto, além de refinar a definição de parâmetros utilizados, que poderia melhorar sua precisão. Outro ponto de interesse que poderia ser explorado seria a inclusão de mais lesões a serem diferenciadas, visto que as imagens estão disponíveis no banco de dados do ISIC, entretanto essa abordagem demandaria mais recursos, tanto humano, para rotular imagens, quanto computacionais para treinar modelos maiores.

REFERÊNCIAS

7 dúvidas sobre nevo melanocítico, as manchas benignas da pele. Vida Saudável o blog do Einstein, 2023. Disponível em: <https://vidasaudavel.einstein.br/7-duvidas-sobre-nevo-melanocitico-as-manchas-benignas-da-pele/> . Acesso em 14 de fev. de 2025.

Autoexame do ABCDE ajuda no diagnóstico de câncer de pele melanoma. Sociedade Brasileira de Dermatologia Seccão RS, 2025. Disponível em: <https://sbdrs.org.br/autoexame-do-abcde-ajuda-no-diagnostico-de-cancer-de-pele-melanoma/> . Acesso em 14 de fev. de 2025.

BAFOUNTA, Marie-Lise *et al.* *Is dermoscopy (epiluminescence microscopy) useful for the diagnosis of melanoma?: Results of a meta-analysis using techniques adapted to the evaluation of diagnostic tests.* *Archives of dermatology*, v. 137, n. 10, p. 1343-1350, 2001.

BOCHKOVSKIY, Alexey; WANG, Chien-Yao; LIAO, Hong-Yuan Mark. *Yolov4: Optimal speed and accuracy of object detection.* *arXiv preprint arXiv:2004.10934*, 2020.

Câncer de pele melanoma. INCA, 2022. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/pele-melanoma#:~:text=O%20c%C3%A2ncer%20de%20pele%20melanoma,de%20manchas%2C%20pintas%20ou%20sinais> . Acesso em 14 de fev. de 2025.

Capítulo 40 – Introdução às Redes Neurais Convolucionais. Deep Learning Book, 2025. Disponível em: [https://www.deeplearningbook.com.br/introducao-as-redes-neurais-convolucionais/#:~:text=Uma%20Rede%20Neural%20Convolucional%20\(ConvNet,de%20diferenciar%20um%20do%20outro](https://www.deeplearningbook.com.br/introducao-as-redes-neurais-convolucionais/#:~:text=Uma%20Rede%20Neural%20Convolucional%20(ConvNet,de%20diferenciar%20um%20do%20outro) . Acesso em 14 de fev. de 2025.

COCO Dataset. Ultralytics, 2025. Disponível em: <https://docs.ultralytics.com/pt/datasets/detect/coco/#sample-images-and-annotations> . Acesso em 14 de fev. de 2025.

DENIZ, Numan; TASTIMUR, Canan. *Skin Cancer Detection Based on YOLOv8 Through A Mobile Application.* In: *2024 8th International Artificial Intelligence and Data Processing Symposium (IDAP).* IEEE, 2024. p. 1-5.

Explore Ultralytics YOLOv8. Ultralytics, 2023. Disponível em: <https://docs.ultralytics.com/models/yolov8/#overview> . Acesso em 14 de fev. de 2025.

FRANGE, Viviane Maciel Nassar; ARRUDA, Lúcia Helena Favaro; DALDON, Patrícia Érica Christofolletti. Dermatoscopia: importância para a prática clínica. *Revista de Ciências Médicas*, v. 18, n. 4, 2009.

History of YOLO: From YOLOv1 to YOLOv10. Labelvisor, 2024. <https://www.labelvisor.com/history-of-yolo-from-yolov1-to-yolov10/> . Acesso em 14 de fev. de 2025.

HOLM, Elizabeth A.; *et al.* *Overview: Computer Vision and Machine Learning for Microstructural Characterization and Analysis.* *Metallurgical And Materials Transactions A*, 2020. DOI: 10.1007/s11661-020-06008-4.

HOSEN, Md Delwar; MOAZZAM, Md Golam. *Analyze Skin Disease using Xception Deep Learning Technique.* In: *2023 26th International Conference on Computer and Information Technology (ICCIT).* IEEE, 2023. p. 1-5.

How to Use Kaggle. Kaggle, 2025. Disponível em: <https://www.kaggle.com/docs/notebooks> . Acesso em 14 de fev. de 2025.

JUTHI, Nafisha Nower *et al.* *Dermatological Disease Detection Using Image Processing and Deep Learning*. In: *2024 IEEE International Conference on Computing, Applications and Systems (COMPAS)*. IEEE, 2024. p. 1-5.

LabelImg. Github, 2024. Disponível em: <https://github.com/HumanSignal/labelImg> . Acesso em 14 de fev. de 2025.

PAREDDY, Sudha V. *et al.* *A Skin Disease Detection using various methods of Deep Learning-a Comprehensive Approach*. In: *2023 Second International Conference On Smart Technologies For Smart Nation (SmartTechCon)*. IEEE, 2023. p. 848-853.

REDMON, Joseph *et al.* *You only look once: Unified, real-time object detection*. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016. p. 779-788.

REDMON, Joseph; FARHADI, Ali. *Yolov3: An incremental improvement*. *arXiv preprint arXiv:1804.02767*, 2018.

REZZE GG, Soares de Sá BC, Neves RI. *Dermatoscopia: o método de análise de padrões*. *An Bras Dermatol*. 2006;81(3):261-8

SAIDA, Toshiaki; KOGA, Hiroshi; UHARA, Hisashi. *Key points in dermoscopic differentiation between early acral melanoma and acral nevus*. *The Journal of dermatology*, v. 38, n. 1, p. 25-34, 2011.

SANTOS, Alan *et al.* *Uma abordagem de classificação de imagens dermatoscópicas utilizando aprendizado profundo com redes neurais convolucionais*. In: *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*. SBC, 2017.

SONKA, Milan; HLAVÁČ, Vaclav; BOYLE, Roger. *Image Processing, Analysis, and Machine Vision*. 4. ed. Stamford, USA: Cengage Learning, 2014.

The International Skin Imaging Collaboration. ISIC, 2025. Disponível em: <https://www.isic-archive.com/> . Acesso em 14 de fev. de 2025.

The International Skin Imaging Collaboration. *ISIC Archive*, 2025. Disponível em: <https://gallery.isic-archive.com/> . Acesso em 14 de fev. de 2025.

The International Skin Imaging Collaboration. *ISIC Mission*, 2025. Disponível em: <https://www.isic-archive.com/mission> . Acesso em 14 de fev. de 2025.

This is Ultralytics. *Ultralytics*, 2025. Disponível em: <https://www.ultralytics.com/about> . Acesso em 14 de fev. de 2025.

Tudo sobre melanoma. Centro Dermatológico Prof. Azulay, 2025. Disponível em: <https://www.cdpa.com.br/novidade/1417/tudo-sobre-melanoma> . Acesso em 14 de fev. de 2025.

Ultralytics YOLO Docs. *Ultralytics*, 2025. Disponível em: <https://docs.ultralytics.com/models/yolo11/> . Acesso em 14 de fev. de 2025.

Ultralytics YOLO11. *Ultralytics*, 2025. Disponível em:

<https://docs.ultralytics.com/models/yolo11/#overview> . Acesso em 1 de mar. de 2025.

WANG, Chien-Yao; BOCHKOVSKIY, Alexey; LIAO, Hong-Yuan Mark. *YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors*. In: *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2023. p. 7464-7475.

WANG, Chien-Yao; YEH, I.-Hau; MARK LIAO, Hong-Yuan. *Yolov9: Learning what you want to learn using programmable gradient information*. In: *European conference on computer vision*. Cham: Springer Nature Switzerland, 2024. p. 1-21.

WANG, Ao et al. *Yolov10: Real-time end-to-end object detection*. *Advances in Neural Information Processing Systems*, v. 37, p. 107984-108011, 2024.

WASEH, Shayan; LEE, Jason B. *Advances in melanoma: epidemiology, diagnosis, and prognosis*. *Frontiers in Medicine*, v. 10, p. 1268479, 2023.

WU, Zhipan et al. *A Real-Time Skin Disease Recognition System Based on YOLOv5 Algorithm*. In: *2023 IEEE 6th International Conference on Electronic Information and Communication Technology (ICEICT)*. IEEE, 2023. p. 290-293.

YASIR, Rahat; RAHMAN, Md Ashiqur; AHMED, Nova. *Dermatological disease detection using image processing and artificial neural network*. In: *8th international conference on electrical and computer engineering*. IEEE, 2014. p. 687-690.

YOLO: Algorithm for Object Detection Explained. V7labs, 2025. Disponível em: <https://www.v7labs.com/blog/yolo-object-detection> . Acesso em 14 de fev. de 2025.

YOLOv6. Meituan, 2022. Disponível em: <https://github.com/meituan/YOLOv6> . Acesso em 14 de fev. de 2025.

YOLOv7: Trainable Bag-of-Freebies. Ultralytics, 2022. <https://docs.ultralytics.com/models/yolov7/#comparison-of-sota-object-detectors> . Acesso em 14 de fev. de 2025.