

DETECÇÃO PRECOCE DE DOENÇAS A PARTIR DA ANÁLISE DE IMAGENS DE MAPEAMENTO DE RETINA POR INTELIGÊNCIA ARTIFICIAL

FUNDAÇÃO ESCOLA TÉCNICA LIBERATO SALZANO VIEIRA DA CUNHA

Kamily Eduarda da Silva e Lívia Klein Machado
Orientador: Anderson Jean de Farias

JUSTIFICATIVA

Erros de diagnóstico, incluindo diagnósticos tardios ou incorretos, são responsáveis por cerca de 16% dos danos evitáveis nos sistemas de saúde em todo o mundo (Organização Mundial da Saúde, 2024). Esse dado evidencia a necessidade do desenvolvimento de ferramentas de apoio capazes de tornar o processo diagnóstico mais rápido e preciso.

As imagens de retina permitem uma análise não invasiva e acessível das estruturas oculares, possibilitando a observação detalhada de vasos sanguíneos e fibras nervosas. Além disso, estudos recentes indicam que alterações retinianas podem atuar como importantes biomarcadores de diversas doenças, incluindo condições cardiovasculares, metabólicas e degenerativas.

PROBLEMA

Qual é a acurácia que uma ferramenta baseada em Inteligência Artificial é capaz de alcançar na detecção de biomarcadores de doenças degenerativas a partir da análise de imagens de mapeamento de retina?

OBJETIVOS

• Geral:

Desenvolver uma ferramenta de Inteligência Artificial para análise de doenças através de imagens de mapeamento de retina.


• Específico:

Demonstrar sua acurácia na detecção precoce de sinais da doença de glaucoma e retinopatia diabética.

METODOLOGIA

As imagens utilizadas no processo de aprendizado da máquina foram obtidas nas plataformas Kaggle e EyerCloud. O conjunto de dados foi organizado em três classes – Saudável, Glaucoma e Retinopatia. O conjunto total, composto por 6.000 imagens, foi dividido em duas partes: treinamento, que recebeu 80% dos dados, e validação, que recebeu os 20% restantes. Além disso, 300 imagens foram reservadas exclusivamente para testes.

Glaucoma




Fonte: Bergman (2016).

Retinopatia diabética



Fonte: Signorelli (2016).

Saudável




Fonte: Vislisl (2019).

A arquitetura adotada foi uma Rede Neural Convolutacional (CNN), uma classe de redes neurais artificiais projetada especificamente para o processamento e reconhecimento de padrões em imagens. O modelo foi estruturado com cinco camadas convolucionais, responsáveis por extrair progressivamente as características mais relevantes das imagens.

O desenvolvimento foi realizado em Python, utilizando os ambientes Visual Studio Code e JupyterLab. Para a implementação, foram empregadas as bibliotecas TensorFlow e Keras, que fornecem ferramentas para a construção, treinamento e avaliação de redes neurais de forma prática e eficiente.

Estrutura CNN




Fonte: As autoras (2025).

RESULTADOS

Para acompanhar o desempenho do modelo durante o treinamento, geramos dois gráficos:

- Gráfico da acurácia: exibe a acurácia (proporção de acertos) tanto no conjunto de treinamento quanto no de validação, ao longo das épocas.
- Gráfico da função de perda (loss): apresenta a evolução do erro do modelo ao longo do treinamento.


Gráfico de Treinamento



Fonte: As autoras (2025).

A métrica escolhida para avaliar o desempenho do modelo foi a acurácia, definida como a razão entre o número de previsões corretas e o total de previsões realizadas, permitindo mensurar, de forma objetiva, a eficácia do modelo. Para uma análise mais aprofundada da performance do modelo, foi utilizada a Matriz de Confusão, ferramenta que permite visualizar os acertos e erros da classificação em relação aos dados reais.

Matriz de Confusão



Fonte: As autoras (2025).

Valores de acurácia

Métrica	Valor (%)
Acurácia geral	88,80%
Acurácia classe Saudável	96,75%
Acurácia classe Glaucoma	71,40%
Acurácia classe Retinopatia diabética	98,25%

Fonte: As autoras (2025).

CONCLUSÃO

Ao final da pesquisa, concluímos que o modelo desenvolvido se mostrou eficaz na detecção de doenças oculares. Os resultados mostram um desempenho satisfatório, demonstrando que a Inteligência Artificial pode ser uma aliada importante na identificação de biomarcadores de doenças degenerativas, tornando o processo de diagnóstico mais precoce e preciso.

REFERÊNCIAS

- BERGMAN, Olle. Nya samarbeten avlastar ögonsjukvården. Läkartidningen, Estocolmo, v. 113, n. 49/50, dez. 2016. Disponível em: <https://lakartidningen.se/nyheter/nya-samarbeten-avlastar-ogonsjukvarden/>. Acesso em: 14 mai. 2025.
- ORGANIZAÇÃO MUNDIAL DA SAÚDE. World Patient Safety Day 2024. Genebra: WHO, 2024. Disponível em: <https://www.who.int/campaigns/world-patient-safety-day/world-patient-safety-day-2024>. Acesso em: 15 set. 2025.
- SIGNORELLI, Armando. Retinopatia Diabética. Signorelli Oftalmologia, Campinas, nov. 2016. Disponível em: <https://signorellioftalmologia.com.br/retinopatia-diabetica/>. Acesso em: 9 jul. 2025.
- VISLISEL, Jesse. Fundo normal - adulto. In: EyeRounds.org. Iowa City: University of Iowa Health Care, c2019. Disponível em: <https://webeye.ophth.uiowa.edu/eyeforum/atlas/pages/normal-fundus.htm#>. Acesso em: 30 abr. 2025.
- WANG, Jinyuan et al. Artificial intelligence-enhanced retinal imaging as a biomarker for systemic diseases. Theranostics, [S.l.], v. 15, n. 8, p. 3223-3233, fev. 2025. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/40093903/>. Acesso em: 18 jul. 2025.