

IMPLEMENTAÇÃO DE UM MODELO DE DEEP LEARNING PARA DETECÇÃO DE RETINOPATIA DIABÉTICA APLICADO EM UMA BASE DE IMAGENS DE RETINA

Iago Amorim Avelino – caflo.2023114tads0011@aluno.ifpi.edu.br

Graduando em Tecnólogo em Análise e Desenvolvimento de Sistema – Instituto Federal do Piauí

Willamys Rangel Nunes de Sousa – rangelnunes@ifpi.edu.br

Doutor em Geologia – Instituto Federal do Piauí

Rafael Angelo dos Santos Leite – rafaelangelo@ifpi.edu.br

Doutor em Ciência da Propriedade Intelectual – Instituto Federal do Piauí

José Joaquim de Moura Ramos – joaquim.demoura@udc.es

Doutor em Ciência da Computação – University of A Coruña

RESUMO—O seguinte estudo baseia-se no desenvolvimento de técnicas automatizadas que sejam capazes de identificar a presença de retinopatia diabética em imagens de retina. Para isso foi utilizado de técnicas de aprendizado profundo, um subcampo de estudo da área de inteligência artificial, onde foram treinados 5 (cinco) modelos utilizando a arquitetura de rede neural convolucional *ResNet18*. Desses cinco modelos, apenas um focava em detectar olhos doentes em qualquer estágio da doença, enquanto os outros quatro foram treinados para identificar em cada estágio da doença. Ao final do treinamento dos modelos que detectaram a doença por estágio foi montado uma *pipeline*, com os quatro modelos que detectasse por estágio, para que pudesse identificar se a imagem de retina apresentava ou não sinais da doença. Todos os modelos apresentaram uma acurácia acima de 90%, entretanto, o modelo que comparava olhos de controle com olhos com o estágio inicial da doença, a especificidade desse modelo foi inferior aos outros, indicando poucas presenças de características da doença na imagem. Para trabalhos futuros fica-se a sugestão de aumento do conjunto de dados e treinar modelos com outras arquiteturas no mesmo conjunto.

Palavras-chave—Retinopatia diabética; redes neurais convolucionais; aprendizado profundo; diabetes mellitus.

ABSTRACT—The following study is based on the development of automated techniques that are capable of identifying the presence of diabetic retinopathy in retinal images. For this, deep learning was used, a subfield of study in the area of artificial intelligence, where 5 (five) models were trained using the *ResNet18* convolutional neural network architecture. Of these five models, only one focused on detecting diseased eyes at any stage of the disease, while the other four were trained to identify at each stage of the disease. At the end of training the models that detected the disease by stage, a pipeline was set up, with the four models that detected by stage, so that it could identify whether or not the retinal image showed signs of the disease. All models showed an accuracy above 90%, however, the model that compared control eyes with eyes in the initial stage of the disease, the specificity of this model was lower than the others, indicating few presence of disease characteristics in the image. For future work, we suggest increasing the data set and training models with other architectures on the same set.

Keywords—Diabetic retinopathy; convolutional neural networks; deep learning; diabetes mellitus.

1 INTRODUÇÃO

Segundo a Organização Mundial de Saúde (OMS), em 2018, existiam mais de 422 milhões de pessoas com a diabetes mellitus (Casarin *et al.*, 2022). O Brasil ocupa o 6º lugar entre os países do mundo com mais

peessoas diabéticas, sendo que uma em cada três pessoas que possuem diabetes, não sabem que têm diabetes (Sociedade Brasileira de Diabetes, 2024).

Uma das consequências da diabetes mellitus é a retinopatia diabética, uma das principais causas de comorbidade em pacientes com a doença, e, uma das maiores causas de perda de visão no mundo, afetando um em cada três diabéticos (Bortoli *et al.*, 2022; Franco *et al.*, 2022). Por a diabetes ser uma doença sem cura, as suas consequências podem acontecer em qualquer momento da vida.

Portanto, o diagnóstico precoce da retinopatia diabética é fundamental para evitar seu desenvolvimento ou, caso ocorra, para controlá-la e minimizar os danos (Casarin *et al.*, 2022). Estudos prévios já aplicaram métodos automáticos para a detecção de retinopatia diabética utilizando aprendizado profundo (Wan, Liang, Zhang, 2018). Sendo comprovado que a utilização de diversos métodos de aprendizado profundo para a detecção da retinopatia em imagens de fundo de olhos tem uma boa eficácia (Tsiknakis *et al.*, 2021).

Com base nisso, este estudo tem como objetivo facilitar o diagnóstico da retinopatia diabética em imagens de fundo de olho dos pacientes, através da implementação de um modelo de aprendizado profundo que reconheça padrões característicos da doença. Permitindo, assim, ajudar os oftalmologistas no seu dia a dia a terem um melhor diagnóstico nos exames realizados.

2 REFERENCIAL TEÓRICO

2.1 DIABETES MELLITUS

De acordo com o Ministério da Saúde (2020), a *diabetes mellitus* (DM), ou só diabetes, é uma doença causada pela produção insuficiente ou má absorção de insulina, hormônio responsável pela quebra das moléculas de glicose presentes no sangue, transformando-as em energia para o organismo.

Devido a essa disfunção, a pessoa portadora da doença passa a apresentar um aumento nas taxas de glicemia, que em altas taxas pode causar complicações para outros órgãos, como coração, olhos e rins, e em casos mais extremos, a diabetes pode levar à morte (Casarin *et al.*, 2022).

A retinopatia diabética (RD) é uma microangiopatia que afeta os vasos da retina, os quais são vulneráveis aos elevados níveis glicêmicos (Bastos *et al.*, 2022). Ela pode levar à alterações na visão, desde manchas ou pontos cegos até à cegueira total, sendo que ela é uma das principais causas de cegueira em todo o mundo (Melo *et al.*, 2019).

No Brasil, a incidência da RD é de 24% a 39% da população diabética, sendo estimado que tenha uma prevalência de 2 milhões de casos. Após 20 anos de doença, estima-se que 90% dos diabéticos de tipo 1 (DM1) e 60% dos do tipo 2 (DM2) terão algum grau de RD (Ministério da Saúde, 2021).

A RD é classificada clinicamente em dois tipos de estágios principais, o não-proliferativo (RDNP) e o proliferativo (RDP), sendo diferenciadas essencialmente pela presença ou não do surgimento de neovaso (Melo *et al.*, 2019; Bortoli *et al.*, 2022). Na RDNP a causa da perda da capacidade visual é resultado apenas



dos edemas e isquemias maculares, caracterizada por acontecer somente na retina e não ir além da membrana limitante interna.

A RD é detectada pela presença de microaneurismas, exsudatos duros e suaves, e hemorragias. Microaneurismas aparecem como pequenos pontos ($< 125 \mu\text{m}$) vermelhos arredondados, devido às fraquezas dos vasos. Os exsudatos duros aparecem como manchas amarelas brilhantes na retina causadas por vazamento de plasma, e, os exsudatos suaves aparecem como manchas brancas ovais ou arredondadas na retina causada pelo inchaço da fibra nervosa. As hemorragias aparecem como grandes manchas na retina ($> 125 \mu\text{m}$), sendo bem maiores que os microaneurismas, e sem um formato específico (Alyoubi *et al.*, 2020).

A triagem da RD vem se provando muito útil para o controle da doença em países com programas ativos para o rastreamento dela. Com a utilização da retinografia proporcionou-se um grande aumento na quantidade de pacientes atendidos, reduzindo assim a superlotação em centro ambulatoriais e grandes filas de espera, permitindo portanto uma redução no número de pessoas cegas por RD (Bortoli *et al.*, 2022).

Além disso, com o avanço das tecnologias houve um crescente aumento no número de métodos de análises automatizadas. As pesquisas de técnicas de aprendizado de máquina nos campos da medicina tiveram um crescimento exponencial nas últimas décadas (Paixão *et al.*, 2022). Os métodos automatizados de diagnósticos de RD poupam tempo e dinheiro, além de serem menos propensos a erros e não necessitarem de muitos esforços comparado com a utilização de análises manuais (Alyoubi *et al.*, 2020).

2.2 APRENDIZADO DE MÁQUINA E APRENDIZADO PROFUNDO

Aprendizado de Máquina (do inglês *Machine Learning* - ML) é um ramo do estudo de Inteligências Artificiais (IA) e que por meio de técnicas computacionais de algoritmos e aprendizado automatizado, a máquina seja capaz de aprender por conta própria através dos dados (Monard, Baranauskas, 2003; Mitchell, 1997).

O principal ponto do ML é o reconhecimento e aprendizado de padrões em conjunto de dados. Com esse aprendizado de padrões, a máquina consegue se ajustar aos dados que está recebendo. Diferente de programas de computadores ou algoritmos normais, que possuem uma hierarquia de tomada de decisões e tarefas completamente pré-definidas e imutáveis, os algoritmos de ML conseguem, com base nos padrões extraídos dos dados, ajustar os seus parâmetros para otimizar a performance de decisões (Alpaydin, 2021).

Dentro do aprendizado de máquina há o modelo matemático de Redes Neurais Artificiais (RNAs), que foram criadas baseando-se nas estruturas neurais humanas. As redes neurais são o centro do Aprendizado Profundo, ou *Deep Learning*, que é um subcampo de estudo dentro do estudo de ML, onde busca-se o desenvolvimento de redes neurais profundas, ou seja, com grandes quantidades de camadas ocultas (Géron, 2019).

As RNAs são um conjunto de camadas interligadas compostas por neurônios artificiais, onde um neurônio de uma camada é ligado a outro neurônio de outra camada. Cada conexão entre neurônios é ponderada por valores reais que são chamados de pesos (Bezerra, 2016). O processamento das informações é feito nos neurônios, que recebem as informações de neurônios de camadas anteriores e envia o resultado do processamento para os neurônios das próximas camadas (Géron, 2019).

As redes neurais tradicionais têm uma grande luta com a complexidade computacional necessária para o processamento de imagens. Dentro do DL, há arquiteturas de redes focadas no recebimento de imagens na entrada de dados, como as Redes Neurais Convolucionais (RNCs), principalmente utilizadas na área de reconhecimento de padrões de imagens (O'Shea, 2015)

As RNCs são arquiteturas de RNAs capazes de aprenderem e identificarem padrões independente do tamanho, escala, translação, rotação e transformações nas imagens (O'Shea, 2015), sendo muito utilizadas e mais eficientes que outros métodos de reconhecimento de imagens na medicina (Alyoubi, *et al.*, 2020).

2.3 TRABALHOS RELACIONADOS

Wan (2018), em seu trabalho "*Deep convolutional neural networks for diabetic retinopathy detection by image classification*", afirma que a detecção automática de diabetes tem trazido muitos benefícios, incluindo poder realizar um diagnóstico precoce da doença.

Ademais, Khalifa *et al.* (2019) reforça a eficiência de arquiteturas de redes neurais como *ResNet*, *AlexNet* e *VggNet*, apresentando modelos com uma alta acurácia e sensibilidade utilizando destas arquiteturas e da base de dados *Kaggle APTOS 2019*. Mohanty *et al* (2023) também apresenta uma alta acurácia ao utilizar a arquitetura *DenseNet-121*, na mesma base de dados, em conjunto com técnicas de pré-processamento, como o desfoque gaussiano.

3 METODOLOGIA

Este estudo possui uma metodologia experimental quantitativa, pois visa manipular variáveis como o tamanho dos dados para treinamentos, pré-processamento de imagens e ajustes no modelo, a fim de levantar informações que serão posteriormente analisadas com métodos estatísticos. Assim, o processo metodológico proposto nesta pesquisa será constituído de 3 (três) etapas: pré-treinamento, treinamento e pós treinamento.

Na primeira etapa da metodologia, foi realizada a escolha das bases de dados desta pesquisa. O conjunto de imagens escolhido para o treinamento do modelo foi o conjunto de dados públicos *Kaggle APTOS 2019 Blindness Detection*.

O *Kaggle APTOS 2019 Blindness Detection* é uma base de dados feita pelo hospital indiano *Aravind Eye Hospital* com imagens de fundo de olho de pessoas de áreas rurais. O conjunto possui 5590 imagens,

entretanto utilizou-se apenas 3662 imagens, pois estavam devidamente classificadas em 5 classes diferentes, utilizando como base a Escala de Gravidade da Doença Retinopatia Diabética (Ministério da Saúde, 2021).

Cada imagem é rotulada com um número de 0 a 4, com suas quantidades separadas de acordo com a tabela 1. Cada número representa uma das classes, tendo 0 como uma imagem que não tem retinopatia diabética, 1 como retinopatia diabética não proliferativa leve, 2 como retinopatia diabética não proliferativa moderada, 3 como retinopatia diabética não proliferativa severa e 4 como retinopatia diabética proliferativa.

Tabela 1 - Quantidade de imagens para cada etapa

Classes	Quantidade de imagens para treinamento	Quantidade de imagens para validação	Quantidade de imagens para testes
Classe 0	1011	433	361
Classe 1	208	88	74
Classe 2	560	239	200
Classe 3	108	46	39
Classe 4	166	70	59
Total	2053	876	733

Fonte: Elaborada pelo autor (2025)

Após a escolha e divisão da base de dados, ocorreu a etapa de treinamento do modelo. Nesta etapa executou-se o treinamento de 5 modelos diferentes. O primeiro modelo consistiu em um classificador binário entre olho de controle e olho doente, utilizando todas as imagens que apresentavam alguma classificação de doença contra as de olhos sem doença.

Os outros 4 treinamentos basearam-se em treinar um classificador binário que comparasse um olho de controle com cada estágio da doença, ou seja, um modelo para distinguir olhos sem RD de olhos com estágio 1, outro para estágio 2, outro para estágio 3 e outro para estágio 4 da doença.

Todos os modelos foram treinados com a arquitetura de RNC *resnet-18*, pré-treinada com os pesos do conjunto de dados *imagenet*; posteriormente, realizou-se a etapa de pós-treinamento, ou, avaliação do modelo. Nela foi feito o teste de cada modelo com as imagens restantes das suas respectivas classes e posteriormente a avaliação de cada modelo. As métricas que foram utilizadas são: acurácia, sensibilidade e especificidade (Wan, Liang, Zhang, 2018; Monard, Baranauskas, 2003).

$$Acurácia = \frac{TN + TP}{(TN + TP + FN + FP)} \quad (1)$$

$$\text{Sensibilidade} = \frac{TP}{(TP + FN)} \quad (2)$$

$$\text{Especificidade} = \frac{TN}{(TN + FP)} \quad (3)$$

A acurácia identifica a taxa de acertos do modelo, verificando quantas das imagens totais o modelo classificou corretamente. As métricas de sensibilidade e especificidade examinam, respectivamente, a quantidade de imagens positivas que foram classificadas como positivas e a quantidade de imagens negativas que foram classificadas como negativas.

4 RESULTADOS

Nesta subseção são abordados os resultados dos 5 (cinco) modelos treinados, e, posteriormente, executados no conjunto de dados de testes separados previamente.

4.1 OLHO DE CONTROLE VS OLHO DOENTE

Durante o treinamento do modelo de olho de controle vs olho doente, obteve-se uma acurácia de treinamento crescente nas épocas iniciais, enquanto a acurácia de validação não acompanha essa crescente, se mantendo sempre num intervalo de 92% a 94%. Nas épocas iniciais foi possível identificar um sinal de sobreajuste do modelo, pois a perda de validação se mantém com valores próximos a 0.2, apresentando algumas flutuações, e, a perda de treinamento continua a diminuir, ficando próxima a zero.

A função de *Early Stopping* salva o modelo na época 20, mas já com sinais de sobreajuste. O modelo salvo ao ser colocado para executar as imagens de testes obteve uma acurácia de 95.4%, sensibilidade de 95.7% e especificidade de 95.2%. Classificando apenas 16, das 372, imagens com olhos doentes do conjunto de teste como olhos sem RD.

4.2 OLHO DE CONTROLE VS CADA ESTÁGIO DA DOENÇA

Todos os modelos, por volta da terceira à quinta época conseguiram convergir em uma alta acurácia, atingindo um platô, enquanto a perda continua a decair. Os modelos de classificação do estágio severo e proliferativo conseguem ter uma diferença entre a perda de validação e treinamento melhor do que os treinamentos dos estágios leve e moderado.

Esta diferença de desempenho se dá pelo fato de olhos com os estados mais avançados da doença apresentarem mais características da mesma. Entretanto, a partir da 20ª época os modelos começam a apresentar oscilações nas perdas e uma pequena queda na acurácia de validação.

A especificidade dos modelos no conjunto de testes apresentam resultados semelhantes ou superiores a sensibilidade, ou seja, o modelo consegue prever melhor olhos de controle do que olhos doentes. Esta

superioridade para detecção de olhos de controle se dá principalmente pela quantidade de amostras no treinamento.

Tabela 2 - Acurácia, sensibilidade e especificidade para cada modelo no conjunto de teste

Modelo	Acurácia	Sensibilidade	Especificidade
Olho de Controle vs Olho Doente Leve	93.3%	79.7%	96.1%
Olho de Controle vs Olho Doente Moderado	97.1%	97.5%	97.0%
Olho de Controle vs Olho Doente Severo	98.2%	92.3%	98.8%
Olho de Controle vs Olho Doente Proliferativo	98.5%	92.3%	99.2%

Fonte: Elaborada pelo autor (2025)

Modelos que tiveram menos amostras de olhos doentes tiveram uma sensibilidade menor. Entretanto, mesmo os conjuntos de olhos doentes leve terem uma maior quantidade de imagens em relação ao estágio severo e proliferativo, os olhos doentes apresentam poucas características da doença, sendo mais difícil diferenciar de olhos de controle.

Ao final desses testes, foi criada uma *pipeline* de execução que avaliou todas as imagens do conjunto de testes do classificador de olho de controle vs. olho doente. Nesta *pipeline*, cada imagem foi processada por todos os modelos, cada um correspondendo a um estágio da doença. Nesta abordagem, uma imagem era classificada como doente se ao menos um dos modelos a detectasse como tal. Essa metodologia resultou em uma acurácia de 95,2%, uma sensibilidade de 94,6% e uma especificidade de 95,8%.

5 CONSIDERAÇÕES FINAIS

Os modelos desenvolvidos neste estudo apresentaram ótimos resultados em cada uma das métricas selecionadas. Contudo, no treinamento do classificador binário de olho doente foi possível identificar, em poucas épocas, um sobreajuste precoce do modelo, sendo isso algo que não é visível tão cedo no treinamento dos 4 outros modelos.



A união de 4 modelos que identificam cada estágio da doença em uma *pipeline* ajuda a mitigar o sobreajuste presente no treinamento do modelo binário que identifica se há ou não sinais da doença. Pois, cada modelo aprende características de um único estágio da doença; e, para a *pipeline* classificar uma imagem com doente, basta que apenas um dos modelos detecte a doença.

Este sobreajuste nos modelos provavelmente foi causado pelo tamanho do conjunto de dados utilizados para treinar os modelos, tal fato sendo a principal limitação deste trabalho. Portanto, em futuras pesquisas sugere-se aumentar a base de dados utilizada, com técnicas de aumento de dados ou com a adição de imagens de outros conjuntos.

AGRADECIMENTO

Artigo apoiado pelo “Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq” via Chamada CNPq/MCTI/FNDCT Nº 22/2024 - Termo outorga: 444625/2024-0 (CNPq).

REFERÊNCIAS

ALPAYDIN, Ethem. **Machine Learning**: revised and updated edition. Cambridge: The MIT Press, 2021.

ALYOUBI, Wejdan L.; SHALASH, Wafaa M.; ABULKHAIR, Maysoon F. **Diabetic retinopathy detection through deep learning techniques: A review**. *Informatics in Medicine Unlocked*, v. 20, p. 100377, 2020. DOI: 10.1016/j.imu.2020.100377. Acesso em: 27 nov. 2024.

BASTOS, Thaís Marino de Azeredo; OLIVEIRA, Ítalo Pena de; JORGE, Rodrigo. **Manifestações oculares de doenças sistêmicas II: retinopatia diabética e retinopatia hipertensiva**. *Medicina (Ribeirão Preto)*, Ribeirão Preto, Brasil, v. 55, n. 2, p. e-178543, 2022. DOI: 10.11606/issn.2176-7262.rmrp.2022.178543. Acesso em: 18 out. 2024.

BEZERRA, Eduardo. **Introdução à Aprendizagem Profunda**. Berlim: ResearchGate, 2016. Disponível em: https://www.researchgate.net/publication/309321510_Introducao_a_Aprendizagem_Profunda. Acesso em: 2 dez. 2024.

BORTOLI, Julia Quadri; SILBER, Paulo Caldas; PICETTI, Egídio; SILVA, Cássio Freitas da Silva; Pakter, Helena Messinger. **Retinografia como forma de rastreamento de retinopatia diabética em hospital terciário do Sistema Único de Saúde**. *Revista Brasileira de Oftalmologia*, v. 81, p. e0057, 2022. DOI: 10.37039/1982.8551.20220057. Acesso em: 19 out. 2024

CASARIN, Daniele Escudeiro; DONADEL, Guilherme; DALMAGRO, Mariana; OLIVEIRA, Priscila Cogo de; CERANTO, Daniela de Cássia Faglion Boleta; ZARDETO, Giuliana. **Diabetes mellitus: causas, tratamento e prevenção**. *Brazilian Journal of Development*, v. 8, n. 2, p. 10062-10075, 2022. DOI: 10.34117/bjdv8n2-107. Acesso em: 21 out. 2024.

DATA SCIENCE ACADEMY. **Deep Learning Book**, 2022. Disponível em: <https://www.deeplearningbook.com.br/>. Acesso em: 15 nov. 2024.

FRANCO, Elisa Marques; SILVA, Leonardo Neves; ROCHA, Leonardo Dias Flor; BATISTA, Marina Andrade Aguiar; SATHLER, Yasmin Gomes; PAIVA, Lovily Duarte Toledo; FRANCO, Cláudia Marques Andrade; DURANTE, Brenda Castanha. **Revisão bibliográfica: retinopatia diabética**. *Brazilian Journal of Development*, [S. l.], v. 8, n. 5, p. 35257–35264, 2022. DOI: 10.34117/bjdv8n5-168. Acesso em: 19 out. 2024.

GÉRON, Aurelien. **Mãos à Obra Aprendizado de Máquina com Scikit-Learn & TensorFlow**. Sebastopol: O'Reilly, 2019.



KANADANI, Tereza Cristina Moreira; BRAGA, Carolina Serpa; IBRAHIM, Larissa Fouad; SILVA, Senice Alvarenga Rodrigues; KANADANI, Fábio Nishimura. **Comparação da eficácia da retinografia colorida e da angiografia fluorescente no diagnóstico da retinopatia diabética.** Revista Brasileira de Oftalmologia, v. 80, n. 6, p. 48, 2021. DOI: 10.37039/1982.8551.20210048. Acesso em: 21 out. 2024.

KHALIFA, Nour Eldeen M.; LOEY, Mohamed; TAHA, Hamed N.; MOHAMED, Hamed Nasr Eldin T. **Deep Transfer Learning Models for Medical Diabetic Retinopathy Detection.** Acta Informatica Medica, v. 27, n. 12, p. 327. DOI: 10.5455/aim.2019.27.327-332. Acesso em: 30 jun. 2025

MELO, Laura Gomes Nunes. **Prevalência da retinopatia diabética e seus fatores de risco em pacientes com diabetes tipo 1 no Brasil.** 2019. 102 f. Tese (Doutorado em Fisiopatologia Clínica e Experimental) - Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2019. Disponível em: <https://www.bdtd.uerj.br:8443/handle/1/12589>. Acesso em: 22 out. 2024.

MINISTÉRIO DA SAÚDE. **Portaria Conjunta nº 17, de 01 de outubro de 2021.** Aprova o Protocolo Clínico e Diretrizes Terapêuticas da Retinopatia Diabética. Brasília, DF: Ministério da Saúde, 2021. Disponível em: https://www.gov.br/conitec/pt-br/midias/relatorios/portaria/2021/20211217_portaria_conjunta_17.pdf/view. Acesso em: 18 out. 2024.

MINISTÉRIO DA SAÚDE. **Saúde de A a Z.** 2024. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/d/diabetes>. Acesso em: 3 dez. 2024.

MITCHELL, Tom. **Machine learning.** Vol. 1. No. 9. New York: McGraw-hill, 1997.

MOHANTY, Cheena; MAHAPATRA, Sakuntala; ACHARYA, Biswaranjan; KOKKORAS, Fotios; GEROGIANNIS, Vassilis; KARAMITSOS, Ioannis; KANAVOS, Andreas. **Using Deep Learning Architectures for Detection and Classification of Diabetic Retinopathy.** Sensors, v. 23, n. 12, p. 5726, 2023. DOI: 10.3390/s23125726. Acesso em: 6 jul. 2025.

MONARD, Maria Carolina; Baranauskas, José Augusto. **Conceitos Sobre Aprendizado de Máquina,** Sistemas Inteligentes, Fundamentos e Aplicações, v. 1, n. 1. São Paulo: Manole Ltda, 2003.

O'SHEA, Keiron; NASH, Ryan. **An Introduction to Convolutional Neural Networks.** New York: Cornell University, 2015. Disponível em: <https://arxiv.org/abs/1511.08458>. Acesso em: 17 nov. 2024

PAIXÃO, Gabriela Miana de Mattos; SANTOS, Bruno Campos; ARAUJO, Rodrigo Martins de; RIBEIRO, Manoel Horta; MORAES, Jermana Lopes de; RIBEIRO, Antonio L. **Machine Learning na Medicina: Revisão e Aplicabilidade.** Arquivos Brasileiros de Cardiologia, v. 118, n. 1, p. 95-102, jan. 2022

SOCIEDADE BRASILEIRA DE DIABETES (SBD). **Brasil já tem cerca de 20 milhões de pessoas com diabetes.** 2024. Disponível em: <https://diabetes.org.br/brasil-ja-tem-cerca-de-20-milhoes-de-pessoas-com-diabetes/>. Acesso em: 18 out. 2024.

TSIKNAKIS, Nikos; THEODOROPOULOS, Dimitris; MANIKIS, Georgios; KTISTAKIS, Emmanouil; BOUTSORA, Ourania; BERTO, Alexa; SCARPA, Fabio; SCARPA, Alberto; FOTIADIS, Dimitrios I.; MARIAS, Kostas. **Deep learning for diabetic retinopathy detection and classification based on fundus images: A review.** *Computers in Biology and Medicine*, v. 135, p. 104599, 2021. DOI: 10.1016/j.compbiomed.2021.104599. Acesso em: 18 out. 2024.

WAN, Shaohua; LIANG, Yan; ZHANG, Yin. **Deep convolutional neural networks for diabetic retinopathy detection by image classification.** *Computers & Electrical Engineering*, v. 72, p. 274-282, 2018. DOI: 10.1016/j.compeleceng.2018.07.042. Acesso em: 25 out. 2024.

ZHOU, Zhi-Hua. **Machine learning.** Berlim: Springer nature, 2021.