



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS SOBRAL
CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO
TRABALHO DE CONCLUSÃO DE CURSO

FRANCISCO IGOR FELÍCIO LINHARES

**SERVIÇO WEB PARA DIAGNÓSTICO DE RETINOPATIA DIABÉTICA ATRAVÉS
DE IMAGENS UTILIZANDO REDES NEURAS CONVOLUCIONAIS**

SOBRAL

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

F349s Felício Linhares, Francisco Igor.
SERVIÇO WEB PARA DIAGNÓSTICO DE RETINOPATIA DIABÉTICA ATRAVÉS DE IMAGENS
UTILIZANDO REDES NEURAIAS CONVOLUCIONAIS / Francisco Igor Felício Linhares. – 2023.
36 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Sobral,
Curso de Engenharia da Computação, Sobral, 2023.
Orientação: Prof. Dr. Wendley Souza da Silva.

1. Diabetes. 2. Retinopatia Diabética. 3. Inteligência Artificial. 4. Visão Computacional. 5. Redes
Neurais Convolucionais. I. Título.

CDD 621.39

FRANCISCO IGOR FELÍCIO LINHARES

SERVIÇO WEB PARA DIAGNÓSTICO DE RETINOPATIA DIABÉTICA ATRAVÉS DE
IMAGENS UTILIZANDO REDES NEURAIAS CONVOLUCIONAIS

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do Campus Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Wendley Souza da Silva

SOBRAL

2022

FRANCISCO IGOR FELÍCIO LINHARES

SERVIÇO WEB PARA DIAGNÓSTICO DE RETINOPATIA DIABÉTICA ATRAVÉS DE
IMAGENS UTILIZANDO REDES NEURASIS CONVOLUCIONAIS

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do Campus Sobral da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Aprovada em: 20 de Dezembro de 2022

BANCA EXAMINADORA

Prof. Dr. Wendley Souza da Silva (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Iális Cavalcante de Paula Júnior
Universidade Federal do Ceará (UFC)

Prof. Dr. David Nascimento Coelho
Universidade Federal do Ceará (UFC)

À minha família, por sua capacidade de acreditar e investir em mim. Mãe, seu cuidado e dedicação foi que deram, em alguns momentos, a esperança para seguir. Pai, sua presença significou segurança e certeza de que não estou sozinho nessa caminhada.

AGRADECIMENTOS

Em primeiro lugar, agradeço a minha mãe, Maria Denis Felício Linhares, por sua força em propiciar tudo que foi necessário para minha formação.

Ao meu pai, Lourival Honorato Linhares, e minha avó, Maria de Lourdes Felício Sousa, que apesar de não estarem mais entre nós, foram essenciais para a minha formação enquanto cidadão, e sei que onde quer que estejam estão torcendo pelo meu sucesso.

Aos meus irmãos, José Renato Felício Linhares e Antônio Márcio Felício Linhares, e minhas irmãs, Geane Felício Linhares e Vanderlene Felício Linhares, por terem sido os maiores incentivadores à minha formação.

Ao meu orientador Wendley Souza da Silva, por sua paciência, orientação e ensinamentos que pude adquirir não apenas sob orientação deste trabalho, mas como também durante toda a graduação e projetos em que participamos em conjunto.

Aos meus amigos Afonso Henrique Daltro Damasceno, Cícero Gabriel Rocha Albuquerque, Lucenilson Rodrigues do Nascimento e Pedro Davi Lima de Sousa, Pedro Ivo Caetano Abreu e José Wilson Otaviano do Nascimento Filho por sempre se fazerem presentes desde o momento em que mudei de cidade constituindo minha segunda família em Sobral-CE.

À todos os meus amigos e colegas da universidade, que são muito para enumerar, que fizeram com que eu conseguisse passar por todas as dificuldades da graduação de forma leve.

E por fim, à todos os meus companheiros da minha equipe de voleibol Tutano Vôlei, que me proporcionaram e proporcionam momentos que sempre levarei comigo.

RESUMO

O diabetes é uma das doenças que mais cresce nas últimas décadas. O número de adultos que vivem com esta doença mais que triplicou nos últimos 20 anos, e as estimativas indicam que este número só aumentará. O maior problema para pessoas com diabéticas são as consequências provocadas pelos altos níveis de glicose no sangue, variando de doenças cardiovasculares a amputação de membros. Uma consequência comum em pessoas com diabetes é o desenvolvimento de retinopatia diabética, uma condição que causa inchaço e vazamentos nos vasos sanguíneos da retina, que pode até levar à perda total da visão. A retinopatia diabética é a principal causa evitável de cegueira, e isso se deve principalmente ao diagnóstico tardio e falta de tratamento adequado para reverter a condição do paciente. Com base nesse cenário, o presente trabalho foi desenvolvido com a finalidade de utilizar a Inteligência Artificial para auxiliar no diagnóstico desta patologia, para isso foram testadas 4 arquiteturas diferentes de Redes Neurais Convolucionais para realizar o diagnóstico sendo elas a Lenet-5, Alexnet, Googlenet e Vgg-19, esta última atingindo aproximadamente 78% de acurácia com sensibilidade acima de 98%. Os modelos treinados podem ser utilizados para auxiliar o diagnóstico desta condição e assim fazendo com que pessoas diabéticas com retinopatia façam o tratamento precoce, evitando o desenvolvimento da doença até sua forma mais agressiva.

Keywords: Diabetes. Retinopatia Diabética. Inteligência Artificial. Visão Computacional. Redes Neurais Convolucionais.

ABSTRACT

Diabetes is one of the fastest growing diseases in recent decades. The number of adults living with this disease has more than tripled in the last 20 years, and estimates indicate that this number will only increase. The biggest problem for people with diabetes are the consequences brought about by high levels of glucose in the blood, ranging from cardiovascular diseases to amputation of limbs. A common consequence in people with diabetes is the development of diabetic retinopathy, a condition that causes swelling and leaks in the blood vessels of the retina, which can even lead to complete loss of vision. Diabetic retinopathy is the main preventable cause of blindness, and this is mainly due to late diagnosis and lack of adequate treatment to reverse the patient's condition. Based on this scenario, the present work was developed with In order to use Artificial Intelligence to aid in the diagnosis of this pathology, 4 different architectures of Convolutional Neural Networks were tested to perform the diagnosis, namely Lenet-5, Alexnet, Googlenet and Vgg-19, the latter reaching approximately 78% accuracy with sensitivity above 98%. The trained models can be used to assist the diagnosis of this condition and thus making diabetic people with retinopathy undergo early treatment, preventing the development of the disease to its most aggressive form.

Keywords: Diabetes. Diabetic retinopathy. Artificial Intelligence. Computer Vision. Convolutional Neural Networks.

LISTA DE ILUSTRAÇÕES

Figura 1 – Aumento real <i>Diabetes Mellitus</i> no Mundo e projeções.	13
Figura 2 – Ilustração de olho saudável e com Retinopatia Diabética	16
Figura 3 – Camadas básicas de uma RNC	18
Figura 4 – Ilustração da operação de convolução	19
Figura 5 – Ilustração de camada <i>max-pooling</i>	19
Figura 6 – Arquitetura LENET	20
Figura 7 – Arquitetura <i>AlexNet</i>	21
Figura 8 – Exemplo imagens de Retina da base de dados EyePACS.	25
Figura 9 – Pré-processamento das amostras.	26
Figura 10 – Matriz de Confusão	28
Figura 11 – Matrizes de Confusão.	30
Figura 12 – Página inicial da interface de documentação do <i>Swagger</i>	31
Figura 13 – Fazendo o <i>upload</i> de imagem.	32
Figura 14 – Retorno da API.	33

LISTA DE TABELAS

Tabela 1 – Resumo de métricas	31
---	----

LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizagem de Máquina
API	<i>Application Programming Interface</i>
AUC	<i>Area Under Curve</i>
DM	<i>Diabetes Mellitus</i>
IA	Inteligência Artificial
IDF	<i>International Diabetes Federation</i>
ILSVRC	<i>ImageNet Large-Scale Visual Recognition Challenge</i>
NIPS	<i>Neural Information Processing Systems</i>
OS	Open Science
PaaS	<i>Platform as a Service</i>
RD	Retinopatia Diabética
RDNP	Retinopatia Diabética Não-Proliferativa
RDP	Retinopatia Diabética Proliferativa
RNA	Rede Neural Artificial
RNC	Rede Neural Convolutacional

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Motivação	12
1.2	Objetivo geral	13
1.3	Objetivos específicos	14
2	FUNDAMENTAÇÃO TEÓRICA	15
2.1	Diabetes Mellitus	15
2.2	Retinopatia Diabética	16
2.3	Redes Neurais Convolucionais	17
2.4	Principais Arquiteturas de RNC	20
3	TRABALHOS RELACIONADOS	22
4	METODOLOGIA	23
4.1	Ferramentas utilizadas	23
4.1.1	<i>Google Drive e Colaboratory</i>	23
4.1.2	<i>Python e Bibliotecas</i>	23
4.1.3	<i>Heroku</i>	24
4.2	Base de Dados	24
4.3	Pré-processamento	25
4.4	Treinamento de modelos e avaliação de modelos	26
4.5	Desenvolvimento de API	27
4.6	Métricas de avaliação de resultados	28
5	RESULTADOS	30
5.1	Modelos treinados	30
5.2	Serviço web	31
6	CONCLUSÃO	34
6.1	Considerações Finais	34
6.2	Limitações	34
6.3	Trabalhos Futuros	34
	REFERÊNCIAS	35

1 INTRODUÇÃO

A utilização de Inteligência Artificial (IA) tem revolucionado diversas áreas, sendo utilizada para auxiliar tomadas de decisões em bancos, comércios, transporte, gestão de recursos, atendimento a usuários dentre outros. Na medicina, a utilização de IA é bastante abrangente sendo aplicada para monitoramento de risco a partir de dados obtidos de *wearable-devices*; apoio à decisão clínica baseada em sintomas apresentados pelo paciente; diagnóstico a partir de imagens (radiologia, dermatologia, oftalmologia, etc.); aplicações de telemedicina.

Tratando-se especificamente de imagens é bastante comum a utilização de IA em problemas de visão computacional, ciência a qual se utiliza de dados, em sua maioria imagens, para realização de processos computacionais que simulem a visão humana e utilizando os respectivos resultados para auxiliar nas tomadas de decisões. O uso de IA para visão computacional é uma abordagem razoavelmente recente, com seus primeiros trabalhos datados por volta da década de 70, mas sem grandes avanços significativos devido principalmente aos limitados recursos computacionais na época.

Aplicações de visão computacional normalmente são voltadas para resolução de problemas bastante específicos para as mais distintas finalidades. Apesar da grande gama de possibilidade de aplicações, existem alguns estágios que se repetem no processo de desenvolvimento da maioria das aplicações de visão computacional, como a aquisição de imagens, pré-processamento, extração de características, detecção e segmentação, e processamento de alto nível (MILANO; HONORATO, 2014).

O *Diabetes Mellitus* (DM), popularmente conhecido apenas como diabetes, é uma condição que ocorre quando alguém possui elevados níveis de glicose no sangue porque o corpo produz pouca ou nenhuma insulina, hormônio que permite que as células do corpo absorvam a glicose da corrente sanguínea a converta em energia ou a armazene, ou por algum motivo o corpo não consegue utilizar a insulina produzida. O DM a longo prazo pode causar várias complicações à saúde como doenças cardiovasculares, neuropatia, nefropatia, amputação de membros inferiores e doenças oculares, atingindo principalmente a retina. Uma das complicações oftalmológicas mais comuns causadas pelo DM é a Retinopatia Diabética (RD).

A RD é uma patologia que acomete pessoas com DM, em que os altos níveis de açúcar no sangue podem causar inchaços e vazamentos nos vasos sanguíneos da retina. É possível também que os vasos sanguíneos sejam obstruídos impedindo a circulação do sangue, fazendo com que novos vasos sanguíneos anormais surjam. Todas essas circunstâncias podem

levar à perda de visão (BOYD, 2020).

Tendo em vista as consequências trazidas pela RD, é muito importante que seu diagnóstico seja feito de forma hábil, possibilitando com o que o paciente receba o tratamento adequado o mais rápido possível, evitando maiores consequências.

Neste caso específico, a IA pode contribuir com a automatização do diagnóstico da patologia, através da utilização de alguma arquitetura de Rede Neural Convolucional (RNC) nas imagens de fundo olho para detectar padrões presentes nas imagens como microaneurismas e neovascularização.

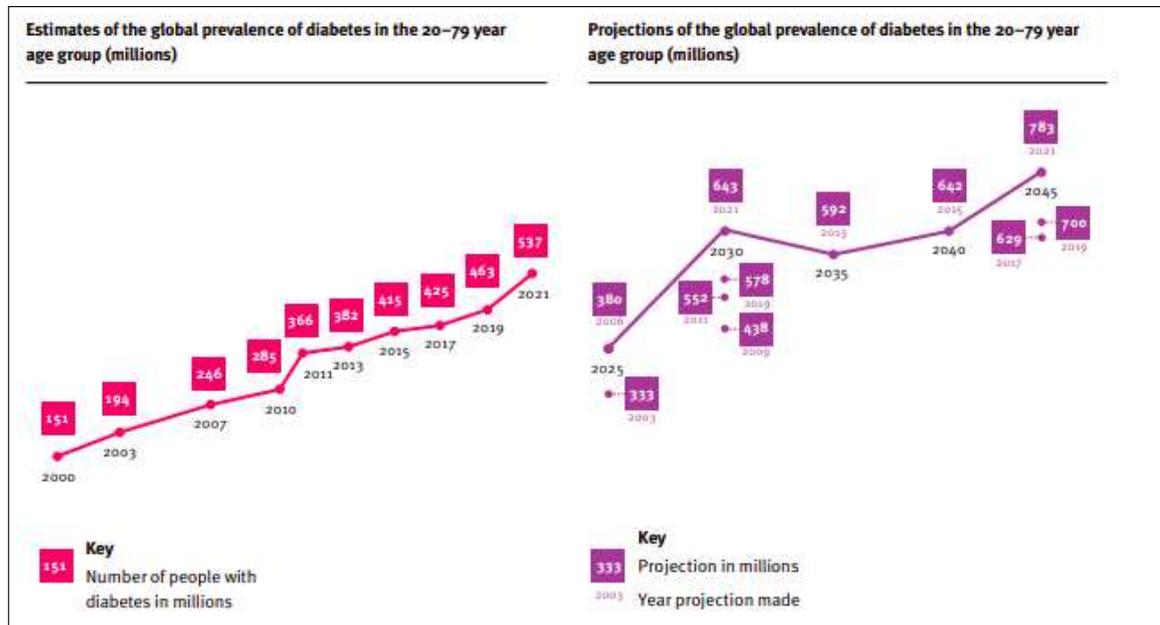
Além disso, também é importante que a solução esteja acessível à comunidade, seguindo os princípios do Open Science (OS) que consiste na disseminação livre e aberta dos resultados de pesquisas científicas de forma compreensível, acessível e aproveitável, e que permita a reprodutibilidade (MARTINS, 2019). Para isso, é de suma importância que os artefatos resultantes sejam disponibilizados à comunidade de forma que seja possibilitada a sua utilização, podendo ser disponibilizada através de serviços WEB como APIs, bibliotecas ou até mesmo *softwares* livres.

1.1 Motivação

Segundo a *International Diabetes Federation* (IDF), o DM acomete uma em cada 10 pessoas adultas no mundo, com mais de meio bilhão de pessoas diabéticas em 2021 com projeção para que esse número aumente para 643 milhões até 2030, outro dado alarmante é a grande quantidade de pessoas diabéticas não-diagnosticadas, cerca de 45%, sendo assim uma das emergências de saúde global com maior crescimento do século 21 (FEDERATION, 2021).

Na Figura 1, divulgada pela IDF, são mostrados 2 gráficos, no gráfico à esquerda é ilustrado o crescimento do número de pessoas portadoras de diabetes com o passar dos anos, número que passou de 151 milhões em 2000 para 537 milhões em 2021. Enquanto no gráfico à direita, é mostrada a evolução das projeções para o número de diabéticos no mundo, onde é possível observar que as projeções só aumentam com o passar dos anos. A projeção feita em 2009 para o ano de 2030, por exemplo, era de 438 milhões de diabéticos no mundo, número já superado em 2019, enquanto a projeção mais recente feita prevê que esse número seja de 643 milhões.

Figura 1 – Aumento real *Diabetes Mellitus* no Mundo e projeções.



Fonte – (FEDERATION, 2021)

A RD é a principal causa de cegueira de pessoas na faixa etária de 20 a 70 anos, sendo responsável por cerca de 12% dos novos casos de cegueira legal - diminuição da acuidade visual que impede o exercício de atividades laborais. No Brasil, alguns estudos realizados em diferentes regiões do país mostram uma prevalência de RD entre 24% a 39%, atingindo principalmente pessoas residentes em regiões não metropolitanas, estimando-se que cerca de 2 milhões de brasileiros tenham algum grau de RD (DIABETES, 2015).

Considerando a rápida progressão dos casos de RD, o pronto diagnóstico é essencial para que o paciente não perca a visão. Para isso, uma ferramenta capaz de auxiliar no diagnóstico automático pode agilizar o início de tratamento, e assim evitando que consequências mais graves causadas pela evolução da doença.

1.2 Objetivo geral

Este trabalho tem por objetivo o desenvolvimento de um serviço web para diagnosticar casos de RD a partir de imagens de fundo de olho com a utilização de métodos de aprendizagem de máquina profunda, mais especificamente RNC para determinar a presença ou não de RD.

1.3 Objetivos específicos

- Coletar e padronizar as bases de dados públicas de imagens de fundo de olho;
- Desenvolver métodos de pré-processamento de imagens;
- Desenvolver o algoritmo de aprendizagem de máquina baseado em RNC para realizar classificação binária das imagens em presença ou ausência de RD;
- Desenvolver serviço web utilizando a rede neural treinada de forma que fique disponível para uso de terceiros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Diabetes Mellitus

O DM é uma doença crônica não transmissível caracterizada por um conjunto de distúrbios metabólicos causados pela hiperglicemia resultante de defeitos na ação e/ou na secreção de insulina, podendo ser classificado em quatro classes clínicas: DM tipo 1 (DMT1), DM tipo 2 (DMT2), DM gestacional (DMG) e outros tipos específicos de DM.

O DMT1, normalmente diagnosticado durante a infância, pode ser dividido em 2 categorias: 1A, em que o organismo não consegue produzir insulina, e no 1B que não tem causa definida e corresponde aos casos onde não há presença de marcadores imunes. Em pacientes com o DMT2, o organismo produz insulina, porém as células não conseguem utilizá-las devido à diminuição da sua ação. O DMG é caracterizado pela alteração dos níveis de glicose de gestantes. Por fim, existem alguns tipos específicos menos comuns de DM, como situações de defeitos genéticos, infecções, dentre outros (BERTONHI, 2018).

A característica progressiva do DM faz com que portadores da doença tenham sua saúde deteriorada com o passar do tempo, em que complicação derivadas do mau controle glicêmico costumam surgir trazendo impactos negativos tanto físico quanto emocional (LIMA *et al.*, 2018).

No último levantamento feito pela IDF em 2021 estima-se que cerca de 537 milhões de pessoas entre 20 e 79 anos são portadoras de DM, com previsão que esse número chegue a 643 milhões de pessoas até 2030. Além disso, cerca de 240 milhões de pessoas são diabéticas mas nunca receberam o diagnóstico. O Brasil é o 6º país com o maior número de diabéticos com cerca mais de 15 milhões de pessoas convivendo com essa patologia.

O tratamento do DM tem objetivo principal o controle glicêmico e metabólico do paciente para evitar complicações causadas por esta condição. Para isso, pode ser seguido uma abordagem medicamentosa podendo ser através de medicamentos antidiabéticos orais com a finalidade de diminuir a glicemia plasmática e a mantendo em níveis normais, ou através da insulinoterapia, que consiste na aplicação de insulina exógena para manutenção dos índices glicêmicos.

Entretanto há casos em que a intervenção medicamentosa não é necessária e pode ser recomendado apenas a adoção de hábitos saudáveis como a prática de atividades físicas regulares e o seguimento de dieta específica. A dietoterapia em indivíduos com DM tem como principais

objetivos o fornecimento de energia através de nutrientes, a manutenção da glicemia, prevenção e tratamento de complicações agudas e crônicas, redução de risco de comorbidades dentre outros (BERTONHI, 2018).

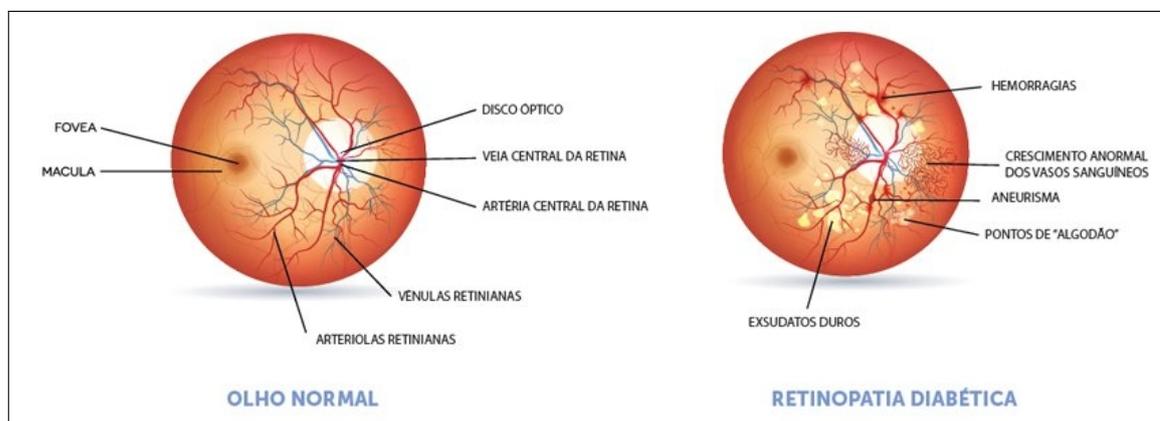
2.2 Retinopatia Diabética

A RD é a doença vascular mais comum a atingir a retina, em que 3 a cada 4 pessoas com DM são atingidas. O seu desenvolvimento é diretamente ligado à DM prolongada e hipertensão. A patologia pode ser caracterizada por condições clínicas diversas como microaneurismas, hemorragia, manchas algodonosas, neovascularização e até a perda completa da visão (FILHO *et al.*, 2022).

O diagnóstico é feito pela detecção e análise de anomalias vasculares na retina conforme ilustrado na Figura 2, podendo ser dividida em dois estágios clínicos principais:

- **Retinopatia Diabética Não-Proliferativa (RDNP):** é o estágio inicial da RD. Neste estágio é observado principalmente o aumento da permeabilidade vascular e oclusão de capilares. Patologias como microaneurismas, hemorragias e exsudatos podem ser detectados pela imagem do fundo do olho. Este estágio pode ser categorizado em leve, moderado ou severo.
- **Retinopatia Diabética Proliferativa (RDP):** é o estágio mais avançado da RD e tem como principal característica a neovascularização. Neste estágio o paciente pode sofrer complicações sérias causadas pelo sangramento dos vasos sanguíneos anormais dentro do vítreo ou pelo deslocamento da retina.

Figura 2 – Ilustração de olho saudável e com Retinopatia Diabética



Fonte – (FRANCO, 2017)

Na Figura 2 são ilustrados dois exemplos de retinas. Na retina do lado esquerdo é possível visualizar um olho saudável, enquanto na retina do lado direito é possível identificar características de olho com RD, como hemorragias, aneurismas, neovascularização e a presença de exsudatos duros.

Normalmente alterações diabéticas não manifestam muitos sintomas até a perda visual, fazendo com o que o diagnóstico e tratamento precoce sejam fundamentais para que a doença não se desenvolva a ponto de causar a cegueira do paciente. É recomendado que pacientes iniciem acompanhamento oftalmológico regular após a puberdade ou após 5 anos de doença e que pacientes diabéticos tipo 2 iniciem no momento do diagnóstico, e que os intervalos entre as revisões não sejam maiores que um ano, já em gestantes recomenda-se que as avaliações sejam feitas trimestralmente, pois há maior risco de progressão da doença.

O tratamento da RD pode ser feito de 2 formas distintas. Na sua forma proliferativa o tratamento já é iniciado utilizando a fotocoagulação a laser, com o intuito de cauterizar os microaneurismas. Já na sua forma proliferativa além da fotocoagulação a laser, é possível a utilização de medicamentos anti-VGEF, mas apenas em casos em que não há edema macular, esta abordagem consiste na aplicação intravítreo de anticorpos que com intuito de inibir o processo de neovascularização (SILVEIRA *et al.*, 2018).

2.3 Redes Neurais Convolucionais

A utilização de Rede Neural Artificial (RNA) é bastante abrangente, podendo ser utilizada para resolução de problemas de aprendizagem supervisionados e não-supervisionados, aplicando-se a dados estruturados, como tabelas, ou não-estruturados, como imagens, áudios e textos. Existem diversos tipos e arquiteturas de RNA, cada uma sendo mais adequada para cada tipo de dado e se tratando especificamente de imagens um tipo de RNA bastante utilizado são as RNC.

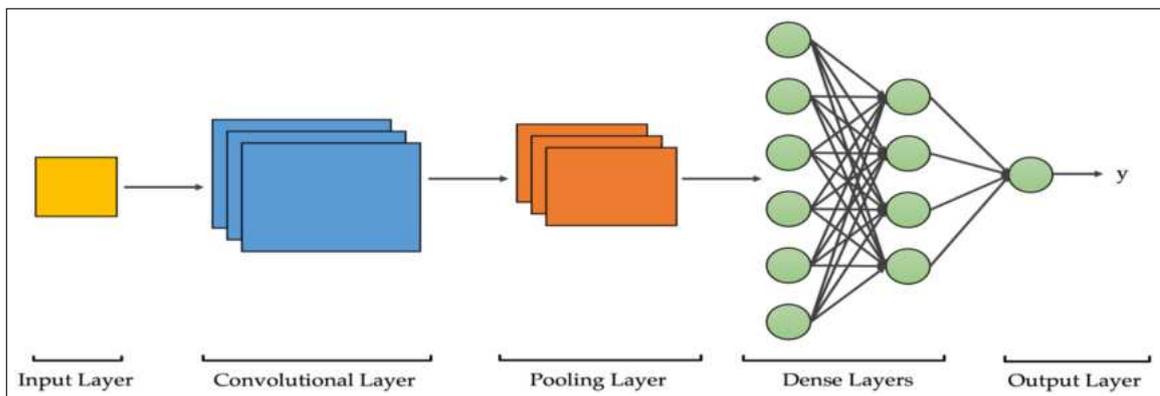
Antes da popularização das RNC, uma abordagem comum para classificação de imagens era realizar a extração de características, e a partir disso utilizar algum outro método de Aprendizagem de Máquina (AM) para realizar a inferência, podendo ser necessária a ajuda de especialistas sobre o tema abordado para entender quais atributos seriam mais adequados para a resolução do problema. As RNC contornam esta problemática, pois elas recebem os *pixels* brutos das imagens e conseguem encontrar um conjunto de características relevantes para classificar os dados corretamente.

Outro problema ao utilizar outros tipos de redes neurais para classificar imagens é a grande quantidade de pesos a serem estimados, pois cada canal de cada pixel representaria uma entrada da rede e cada neurônio adicionado aumentaria muito o custo computacional para cálculo dos pesos da rede.

Ao analisar imagens, normalmente assume-se alta correlação entre os *pixels* vizinhos, logo quanto maior a distância entre os *pixels* menor a correlação entre eles. Desta forma, os neurônios de uma RNC recebem apenas *pixels* correlacionados espacialmente, utilizando a operação de convolução (GAD, 2018).

As RNC são compostas geralmente por 3 tipos de camadas: camadas de convolução, camadas de *pooling* e camadas totalmente conectadas, a Figura 3 mostra uma arquitetura simples contendo as camadas básicas.

Figura 3 – Camadas básicas de uma RNC

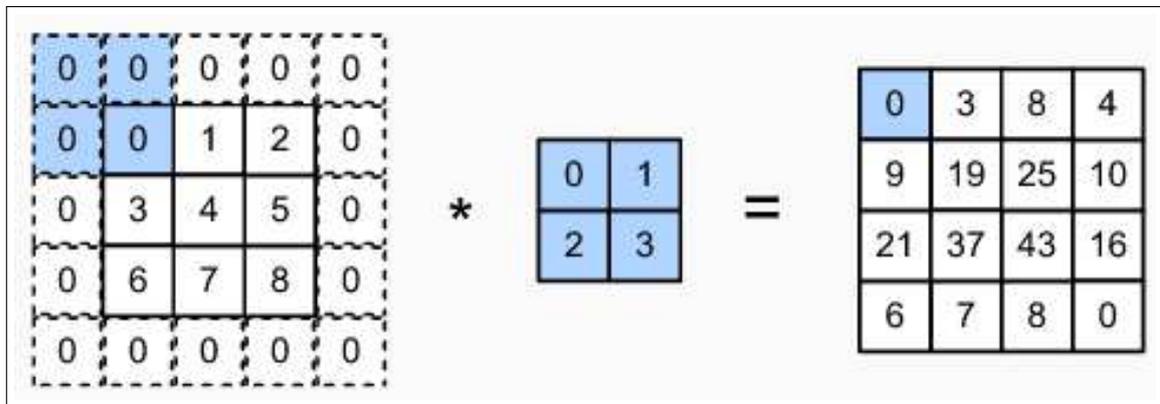


Fonte – C, 2020

A camada de convolução consiste basicamente em um conjunto de filtros convolucionais, também chamados de *kernels*, em que a imagem de entrada é convoluída com esses filtros para gerar os mapas de atributos. Os *kernels* são uma matriz quadrada de números discretos inicializados aleatoriamente, e cada número é chamado de peso e estes pesos são atualizados durante o treinamento com o intuito de extrair características importantes das imagens.

Na operação de convolução é feito o produto interno entre os *kernels* e a respectiva região da imagem, resultando em um valor escalar que representa aquela região. Após isso, o *kernel* desliza uma quantidade de *pixels* vertical ou horizontalmente, para calcular a convolução da região adjacente até que o *kernel* deslize por toda a imagem. A quantidade de pixels deslizada pelo *kernel* em cada passo é chamada de *stride*. O processo é ilustrado na Figura 4:

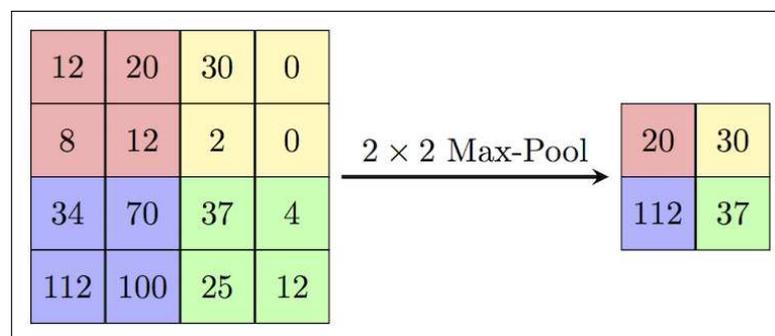
Figura 4 – Ilustração da operação de convolução



Fonte – Zhang *et al.*, 2021

A operação de convolução naturalmente reduzirá as dimensões da imagem de entrada, o que pode resultar na perda de informação das bordas, uma solução para isso é o chamado *padding*, que consiste na adição de uma borda ao redor da imagem para que resultado da operação de convolução possua as mesmas dimensões da imagem de entrada (ALZUBAIDI *et al.*, 2021).

A camada de *pooling* é responsável por reduzir a dimensionalidade da saída de um neurônio, assim reduzindo a quantidade de parâmetros a serem estimados na camada seguinte e consequentemente a complexidade computacional da rede. Normalmente, são utilizadas camadas de *max-pooling* com *kernels* 2x2 com *stride* de 2 nas dimensões espaciais, conforme o ilustrado na Figura 5. Existem também outros tipos de camada de *pooling* que são menos utilizadas que realizam vários tipos de operações básicas, como *min-pooling* e *average-pooling* (O'SHEA; NASH, 2015).

Figura 5 – Ilustração de camada *max-pooling*

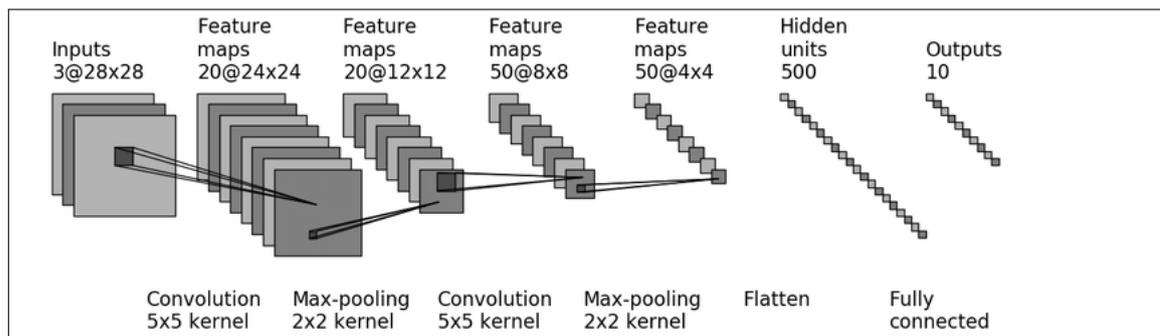
Fonte – Wiki, 2018

2.4 Principais Arquiteturas de RNC

Com o passar dos anos, os computadores foram se tornando cada vez mais potentes possibilitando a evolução de diversos estudos em RNA. No âmbito das RNC diversas novas arquiteturas foram desenvolvidas. A *LENET* e *AlexNet* são exemplos de arquiteturas precursoras de diversas outras, como a *GoogleNet* e *VGG-19* e serão abordadas em mais detalhes a seguir.

A *LENET*, ou também chamada de *LENET5*, foi uma das primeiras arquiteturas de RNC desenvolvidas. Esta arquitetura foi idealizada pelo Prof. Yann Lecun's para classificação de dígitos utilizando a base de dados MNIST, que era composta por imagens em escala de cinza de canal único de dimensão 28x28. Esta arquitetura é composta por 2 camadas de convolução e uma camada totalmente conectada.

Figura 6 – Arquitetura LENET



Fonte – Zhou *et al.*, 2017

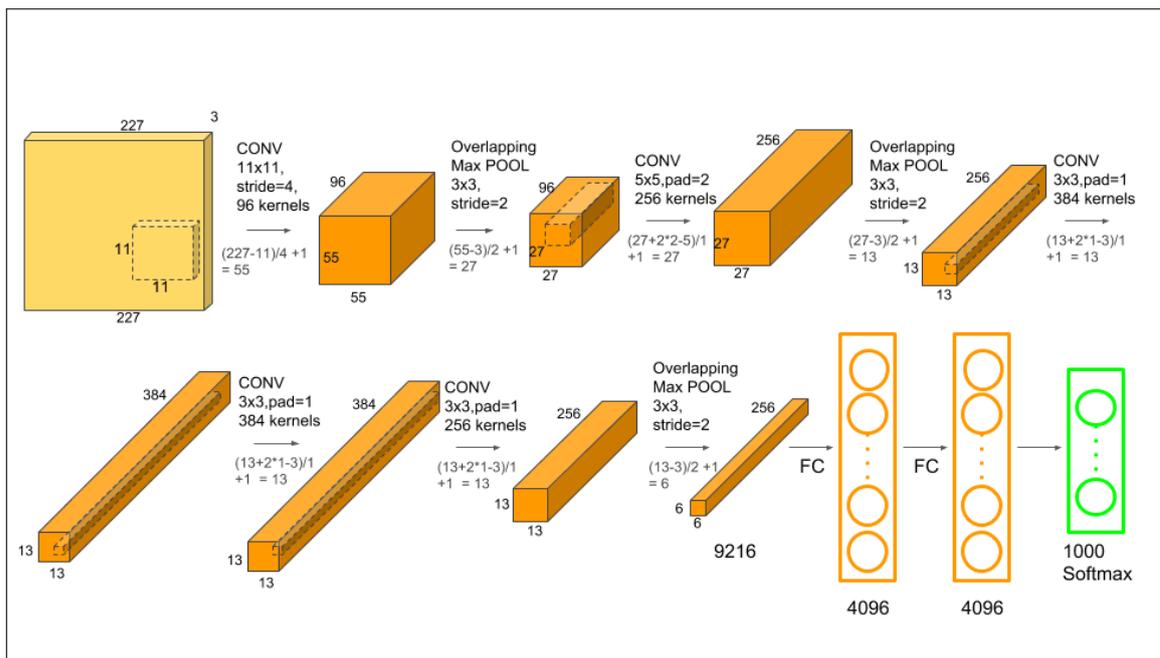
A primeira camada convolucional possuía 20 filtros de dimensões 5x5, gerando um volume de saída de 24x24x20. Em seguida o volume tem sua dimensão de saída reduzida pela metade após passar por uma camada de *pooling*, resultando em um volume de 12x12x20. A camada seguinte possui 50 filtros de 5x5, gerando um volume de saída de 8x8x50, que novamente tem suas dimensões reduzidas pela metade pela camada de *pooling*, resultando em um volume de 4x4x50 que passa pela operação de *flatten* para se tornar um vetor de 800 valores. Em seguida, o vetor passa por uma camada totalmente conectada de 500 neurônios e por uma camada *softmax* de 10 nós, um para cada dígito a ser reconhecido.

A arquitetura de RNC *AlexNet* foi introduzida por Krizhevsky na *Neural Information Processing Systems (NIPS) conference* de 2012, e assim como a *LENET*, foi influenciada pelo dataset MNIST, a *AlexNet* foi desenvolvida para a base de dados ImageNet, que na época era composto por mais de 15 milhões de imagens divididas em mais de 22 mil categorias. A

arquitetura foi treinada para a competição *ImageNet Large-Scale Visual Recognition Challenge* (ILSVRC) utilizando 1000 categorias da base total.

A *AlexNet* é basicamente uma *LENET* com mais camadas, ao todo ela possui 5 camadas de convolução seguidas por 2 camadas totalmente conectadas e uma camada *softmax* com 1000 nós conforme mostrado na Figura 7. Apesar da semelhança na arquitetura, a quantidade de pesos e consequentemente a complexidade da rede pode causar *overfitting*.

Figura 7 – Arquitetura *AlexNet*



Fonte – Hassan, 2018

Para contornar a grande complexidade computacional da *AlexNet*, algumas adaptações da arquitetura original foram feitas. Uma das mais significativas foi a utilização de ReLU como função de ativação ao invés de das funções tanh ou sigmóide, pois diferentemente das outras a ReLU não satura em valores próximos à 1, acelerando a aprendizagem. Outras contribuições da *AlexNet* foram a utilização de múltiplas GPUs para treinamento e a utilização de *dropout*, que é um método utilizado para evitar a co-adaptação de mapas de características onde a saída de um neurônio é forçada à zero com uma probabilidade aleatória (VENKATESAN; LI, 2017).

3 TRABALHOS RELACIONADOS

Com a criação de competições de aprendizagem de máquina e com a disponibilização de bases de dados públicas, diversos trabalhos científicos com foco no desenvolvimento de modelos de AM para diagnóstico de RD foram publicados.

No estudo desenvolvido por Gargeya e Leng (2017) utilizou a base de dados EYE-PACS composta por mais de 75 mil imagens para treinamento de um modelo de AM para diagnóstico de RD. Antes do treinamento do modelo as imagens tiveram o tamanho reduzido à 512x512 cortando o círculo retinal interno e preenchendo-as num quadrado; os *pixels* normalizados entre 0 e 1; brilho e contraste ajustados aleatoriamente; e foi utilizada a técnica de *data augmentation*, em que amostras foram aleatoriamente rotacionadas, para reforçar previsões em possíveis imagens rotacionadas.

Para o modelo de AM, uma arquitetura de RNC personalizada foi desenvolvida para extração de características que seriam utilizadas para treinar um modelo secundário baseado em *gradient-boosting* para realizar o diagnóstico final. O modelo alcançou 93% de sensibilidade, 87% de especificidade e *Area Under Curve* (AUC) de 0.94 na base de dados de validação MESSIDOR, e na base de dados E-OPHTHA atingiu 90% de sensibilidade, 94% de especificidade e AUC de 0.95, ressaltando que nenhuma imagem das bases de dados de validação foi utilizada para treinamento (GARGEYA; LENG, 2017).

Em outro estudo, desenvolvido por Wan *et al.* (2018), foi utilizada parte da base de dados EYEPACS que passou por algumas etapas de pré-processamento como *data augmentation*, remoção de ruídos e normalização dos dados. Após serem pré-processadas, as imagens foram utilizadas para o treinamento de 4 arquiteturas diferentes de RNC (AlexNet, VggNet, GoogleNet and ResNet) para classificação multi-classe.

Dentre as arquiteturas treinadas a VggNet foi a que obteve os melhores resultados, seguida pela GoogleNet. Na arquitetura VggNet foram treinadas 3 variantes: VggNet-s, VggNet-16 e a VggNet-19. A VggNet-s, a melhor arquitetura entre as variantes, chegou à uma acurácia de 95.68% e AUC de 0.9786 (WAN *et al.*, 2018).

4 METODOLOGIA

4.1 Ferramentas utilizadas

Para execução deste projeto foram utilizadas diversas ferramentas, com destaques para as ferramentas em nuvem do *Google Drive* e *Google Colaboratory*, a linguagem de programação *Python* juntamente com suas bibliotecas com destaque especial para os *frameworks TensorFlow* e *OpenCV*, além do provedor de nuvem *heroku*.

4.1.1 *Google Drive e Colaboratory*

O *Google Drive* é o serviço de armazenamento e sincronização de arquivos em nuvem do *Google*. O serviço é disponibilizado gratuitamente para todos os usuários do *Google*, porém com certas limitações pois cada usuário possui o limite máximo de 15 GB para armazenamento de arquivos, podendo ser expandido mediante assinatura. A ferramenta também dispõe de integrações com demais serviços, como o *Google Docs*, *Google Sheets* e o *Google Colaboratory*, ferramenta essencial para o desenvolvimento deste projeto.

O *Google Colaboratory* permite que usuário execute blocos de código *python* em nuvem através do navegador, fazendo com que o usuário não precise instalar todos os pacotes manualmente em seu computador. A ferramenta disponibiliza uma máquina em nuvem com 12 GB de RAM gratuitamente, além de dar a opção do usuário executar os códigos utilizando CPU, GPU ou TPU dadas as devidas limitações de gratuidade. O *Google Colaboratory* também possui a vantagem de ter integração com os arquivos armazenados no *Google Drive*, facilitando o processo de importação e exportação de dados.

4.1.2 *Python e Bibliotecas*

Para o desenvolvimento deste trabalho foi utilizada a linguagem *python* em sua versão 3.8.15¹, juntamente com algumas bibliotecas específicas que auxiliaram desde o pré-processamento dos dados até ao desenvolvimento do serviço *web*.

Para o pré-processamento dos dados foram utilizadas as bibliotecas *pandas*, para processamento de dados tabulares na versão 1.3.5² e *numpy* para operações matemáticas em

¹ <https://www.python.org/downloads/release/python-3815/>

² <https://pandas.pydata.org/pandas-docs/dev/whatsnew/v1.3.5.html>

vetores na versão 1.21.6³. Para a visualização de resultados através de gráficos foi utilizada a biblioteca *seaborn* na versão 0.11.2⁴. Para realizar o pré-processamento das imagens, como cortar e redimensionar, foi utilizada a biblioteca *OpenCV* na sua versão 4.6.0⁵. Para o treinamento das RNC, foi utilizado o *framework TensorFlow* na versão 2.9.2⁶.

Para o desenvolvimento da *Application Programming Interface* (API) foi utilizada a biblioteca *Flask* na versão 2.2.2⁷, biblioteca *python* utilizada para o desenvolvimento de aplicações web.

4.1.3 Heroku

O *heroku* é uma poderosa *Platform as a Service* (PaaS) em nuvem com suporte para diversas linguagens de programação. Através dele é possível fazer *deploy* gerenciar aplicações em nuvem de forma prática, sem a necessidade de maiores preocupações com infraestrutura, certificados dentre outros. Atualmente o *heroku*, não dispõe mais de serviço de hospedagem gratuito e para poder hospedar a solução foi necessário uma licença paga.

4.2 Base de Dados

Para o desenvolvimento deste trabalho foram utilizadas imagens de uma base de dados pública disponibilizada pela *California Healthcare Foundation* em uma competição realizada no *kaggle*⁸, site de competição voltado para ciência de dados, disponibilizando uma base de dados com mais de 80 GB de imagens coletadas e fornecidas pelo EyePACS.

As imagens disponibilizadas são divididas em bases de treino e teste, para a realização deste trabalho foram utilizadas apenas as imagens destinadas para treino sendo composta por mais de 35 mil imagens contendo imagens de retina diagnosticadas com diversos níveis de RD, resultando em cerca de 30 GB em arquivos.

A base conta com 25810 imagens de olhos saudáveis e 9316 imagens de olhos com algum nível de RD. Todas as imagens possuem o diagnóstico com o respectivo nível de RD.

A Figura 8 apresenta exemplos de imagens da base de dados do EyePACS, sendo possível observar a diferença entre um olho saudável, mostrado na imagem (a), enquanto na

³ <https://numpy.org/devdocs/release/1.21.6-notes.html>

⁴ <https://seaborn.pydata.org/archive/0.11/whatsnew.html#v0-11-2-august-2021>

⁵ <https://opencv.org/opencv-4-6-0/>

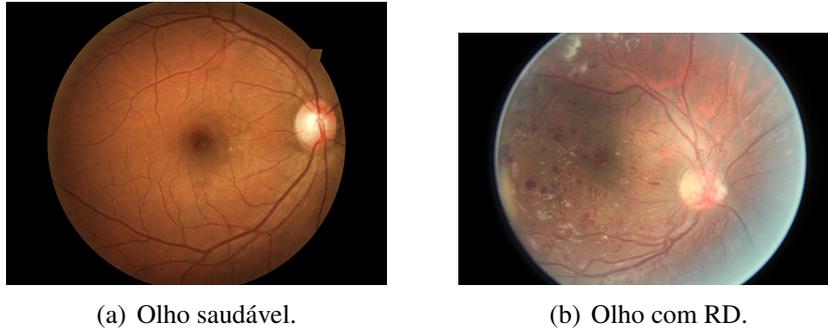
⁶ <https://github.com/tensorflow/tensorflow/releases/tag/v2.9.0>

⁷ <https://flask.palletsprojects.com/en/2.2.x/changes/>

⁸ <https://www.kaggle.com>

imagem (b) é possível identificar a presença de microaneurismas e de regiões com hemorragia, características comumente observadas em pacientes portadores de RD.

Figura 8 – Exemplo imagens de Retina da base de dados EyePACS.



Fonte – EyePACS, 2015

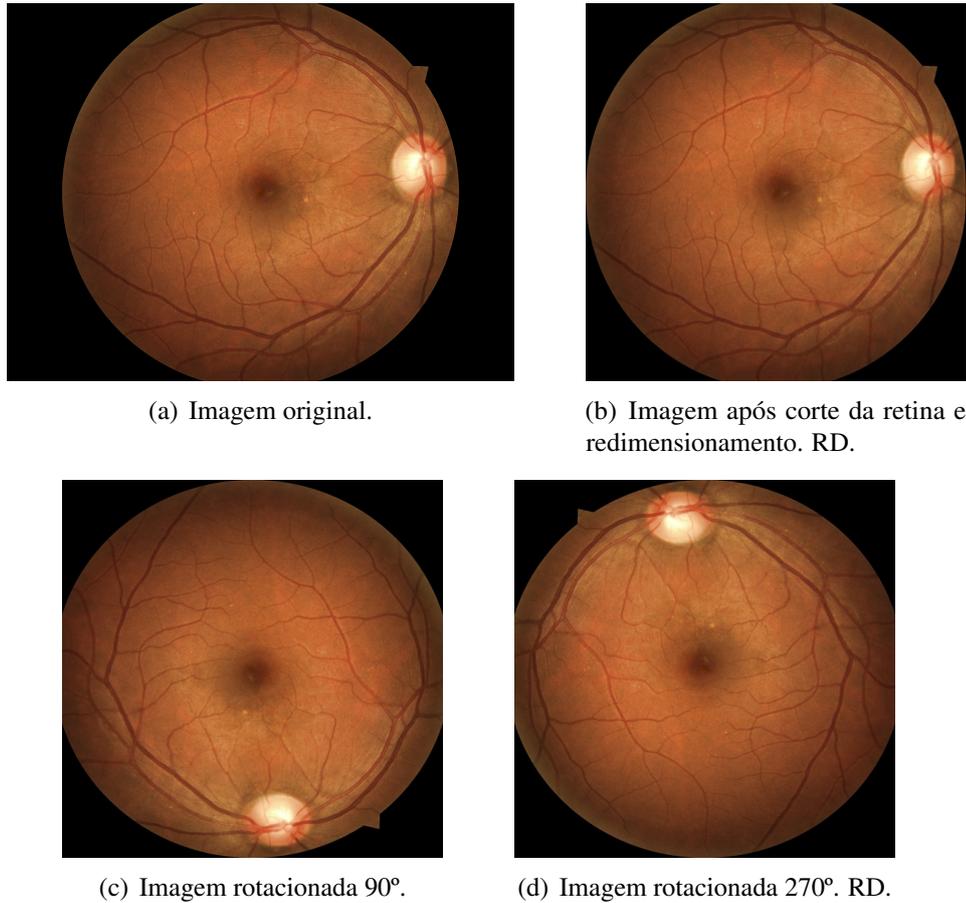
4.3 Pré-processamento

Antes de realizar o treinamento das RNC propriamente dito, foi necessário realizar a padronização das imagens, tendo em vista que elas possuíam alta resolução além de dimensões e proporções diferentes não seria possível realizar o treinamento com as imagens brutas.

Primeiramente, a retina foi detectada em todas as imagens e recortada, fazendo com que as informações vazias na parte externa à retina não impactassem negativamente na criação do modelo. Após isso, todas as imagens foram redimensionadas para a resolução padrão de 256x256.

Após essa padronização das imagens, foram geradas novas amostras a partir das imagens já existentes rotacionando-as em 90°, 180° e 270°, assim, assegurando que os modelos treinados fossem robustos o suficiente para lidar com a variabilidade das imagens. A Figura 9, mostra o resultado destas transformações.

Figura 9 – Pré-processamento das amostras.



Fonte – EyePACS, 2015

Após o pré-processamento das amostras, um total de 140.504 contendo com as novas imagens geradas, e descartando imagens que consideradas inválidas por estarem corrompidas. Após isso, as classes também foram alteradas de forma que imagem fosse classificada de forma binária: presença ou ausência de RD, onde inicialmente os diagnósticos eram multi-classe contendo o respectivo nível.

Após as transformações, o conjunto de dados final a ser utilizado para treinamento e avaliação das RNC, continha 140504 amostras divididas em 2 classes: 103240 imagens de retinas saudáveis e 37264 retinas com algum nível de RD.

4.4 Treinamento de modelos e avaliação de modelos

Antes de treinar os modelos, é importante notar que a base de dados final após o pré-processamento está desbalanceada, pois o número de amostras contendo imagens de retinas saudáveis é quase 4 vezes maior do que o número de retinas com indícios de RD, sendo

necessário balancear a base de dados, de forma que essa diferença na quantidade de amostras de cada classe não impacte negativamente no desempenho dos modelos que serão treinados.

Existem algumas abordagens para lidar com bases de dados desbalanceadas, as 2 principais e mais simples são o *oversampling*, que consiste no aumento da quantidade de amostras da classe de menor quantidade até que a base de dados esteja balanceada e o *undersampling*, que consiste na redução do número de amostras da classe com a maior quantidade até que as quantidades nas classes estejam iguais.

Como a base de dados a ser utilizada para o treinamento das RNC, tem uma quantidade razoável, optei pela utilização do método de *undersampling*, reduzindo assim a quantidade total de amostras para 74528 igualmente divididas entre as duas classes.

Para o treinamento dos modelos foi utilizado a linguagem *python* em conjunto com o *framework tensorflow*. Foram testadas 4 arquiteturas de RNC diferentes: Lenet-5, Alexnet, GoogleNet e a Vgg-19 e os métodos implementados para cada uma estão disponibilizados em um repositório do *Github*⁹.

4.5 Desenvolvimento de API

Com o intuito de disponibilizar ao público os modelos treinados, uma API foi desenvolvida utilizando a biblioteca *python flask* e hospedada no serviço de nuvem *heroku*¹⁰, que fornece algumas opções gratuitas para manter serviços em nuvem funcionando com algumas limitações de tráfego. Desta forma, os usuários conseguem enviar imagens através de requisições HTTP e obter como retorno o diagnóstico da imagem enviada, facilitando assim a utilização do modelo em aplicações de terceiros.

A API conta com apenas um único *endpoint*, em que através de uma requisição *POST* o usuário consegue enviar uma imagem para ser processada e os modelos realizarem a predição do diagnóstico e retornar um valor entre 0 e 1 correspondente à probabilidade do diagnóstico ser positivo e quanto mais próximo 1 o valor retornado, maior a probabilidade da imagem ser de um caso de uma retina com algum nível de RD.

⁹ <https://github.com/Igorlinharesb/RD-Detection>

¹⁰ <https://www.heroku.com>

4.6 Métricas de avaliação de resultados

Para a avaliação das RNC desenvolvidas existem algumas métricas que são comumente utilizadas. Para este trabalho em específico serão utilizadas a Acurácia, Sensibilidade e a Especificidade, descritas respectivamente nas equações 4.1, 4.2 e 4.3. Essas métricas são obtidas através da matriz de confusão, ilustrada na imagem. Na matriz de confusão é possível visualizar como estão distribuídas as predições feitas pelo modelo desenvolvido, nela é possível identificar a quantidade de Verdadeiros Positivos(VP), Verdadeiros Negativos(VN), Falsos Positivos(FP) e Falsos Negativos(FN). A Figura 10 mostra um exemplo de matriz de confusão para classificação binária.

Figura 10 – Matriz de Confusão

		Valor Predito	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Fonte – Nogare, 2020

A acurácia é bastante utilizada como principal parâmetro de avaliação de classificadores na inteligência artificial, principalmente por ser eficiente e conceitualmente simples. É calculada pela razão entre o número de predições corretas e o número total de predições, a partir da matriz de confusão, a acurácia pode ser definida como na equação 4.1.

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

A sensibilidade é normalmente utilizada em situações em que a quantidade de falsos negativos são potencialmente mais preocupantes que a quantidade de falsos positivos. Ela vai medir a taxa de verdadeiros positivos que o modelo consegue prever, possibilitando a análise da capacidade do classificador em identificar os falsos negativos, a partir da matriz de confusão, a sensibilidade pode ser definida como na equação 4.2..

$$\text{Sensibilidade} = \frac{TP}{TP + FN} \quad (4.2)$$

Diferentemente da sensibilidade, a especificidade a taxa de verdadeiros negativos, e é dada pela razão entre a quantidade de verdadeiros negativos e o total de negativos, a partir da matriz de confusão, a especificidade pode ser definida como na equação 4.1 (JUNIOR *et al.*, 2022).

$$\text{Especificidade} = \frac{TN}{TN + FP} \quad (4.3)$$

Para esse caso específico, as métricas citadas são opções viáveis para a avaliação dos modelos gerados, com destaque para a sensibilidade, considerando a importância de não deixar que um paciente com RD, não seja diagnosticado corretamente.

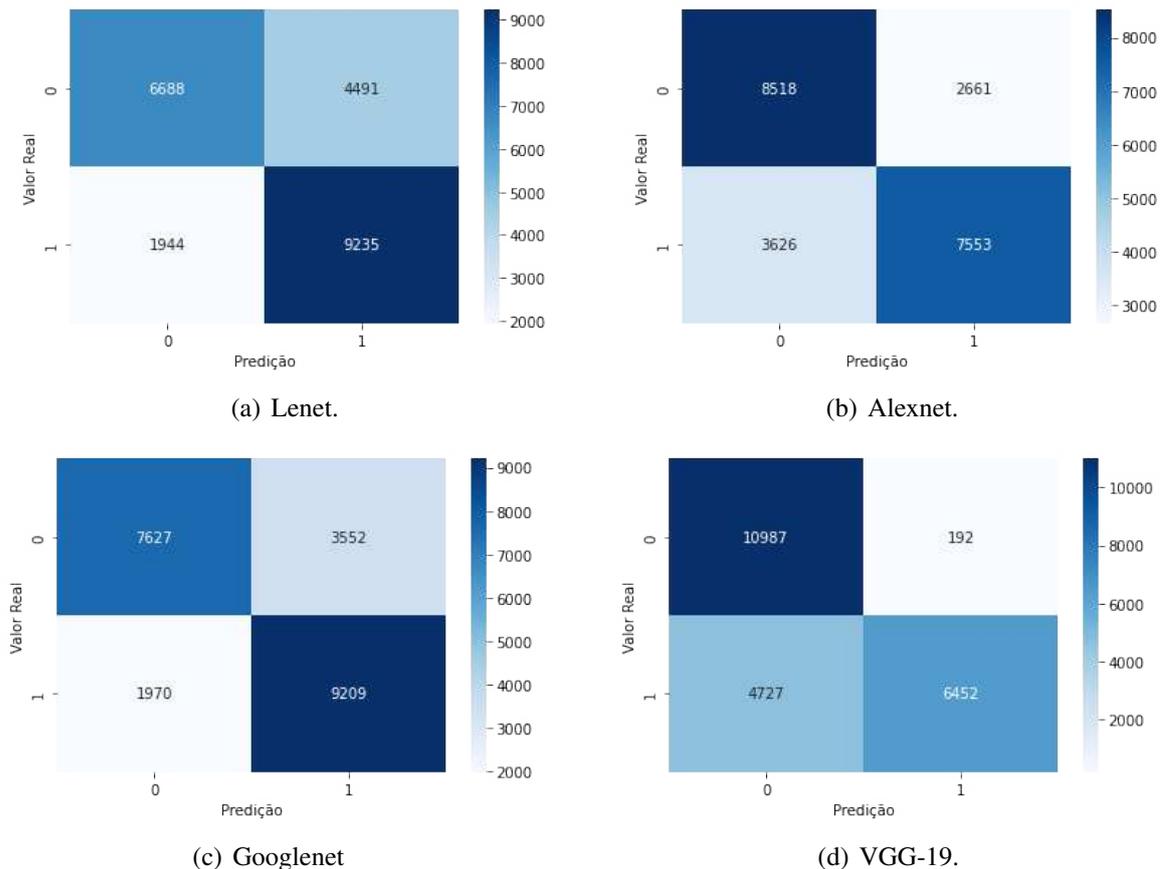
5 RESULTADOS

5.1 Modelos treinados

Nesta seção serão mostrados os resultados obtidos a partir deste trabalho. Os modelos treinados se mostraram eficientes para a realização da detecção da RD, com destaque para a arquitetura Vgg-19, que conforme mostrado na Figura 11, obteve a maior quantidade de verdadeiros positivos e a menos de falsos negativos, logo, o modelo se mostra muito robusto na identificação de potenciais casos de RD.

As bases finais de dados finais utilizadas para o treinamento assim como os modelos treinados estão disponíveis para download em uma pasta do *Google Drive* ¹.

Figura 11 – Matrizes de Confusão.



Fonte – Elaborado pelo autor.

Na Tabela 1 é mostrado o resumo das métricas obtidas de cada rede a partir das respectivas matrizes de confusão. As arquiteturas Googlenet e Vgg-19 foram as que obtiveram

¹ https://drive.google.com/drive/folders/1iK5IEVf67g2OCY_bhyqpH4egHZ3G6wFI

melhor desempenho, e apesar de possuírem acurácias próximas, a Vgg-19 apresenta uma sensibilidade muito maior, tornando a melhor opção dentre os modelos treinados.

Tabela 1 – Resumo de métricas

Modelo	Acurácia	Sensibilidade	Especificidade
Lenet-5	0,71218	0,59826	0,82610
Alexnet	0,71880	0,76196	0,67564
Googlenet	0,75302	0,68226	0,82378
Vgg-19	0,77999	0,98282	0,57715

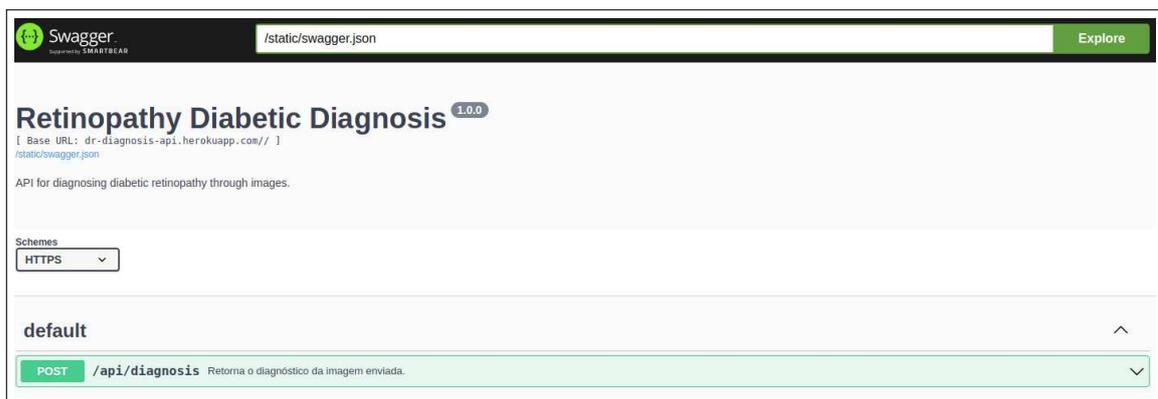
Fonte – Elaborado pelo autor.

5.2 Serviço web

A API contendo os modelos foi hospedada em um servidor do *heroku*². A API conta apenas com um *endpoint* o *'/api/diagnosis'*, que recebe uma requisição através do método POST. Para testar o funcionamento do serviço foi utilizado o software de código aberto *Isomnia* para fazer as requisições.

Para facilitar o teste da API a solução também contém com uma interface de documentação³ feita com o *swagger*⁴, que reúne um conjunto de ferramentas que auxiliam na documentação de APIs. A Figura 12 mostra a página da documentação da aplicação.

Figura 12 – Página inicial da interface de documentação do *Swagger*.



Fonte – Elaborado pelo autor.

Para testar o serviço, o usuário precisa expandir o *endpoint* mostrado na interface de

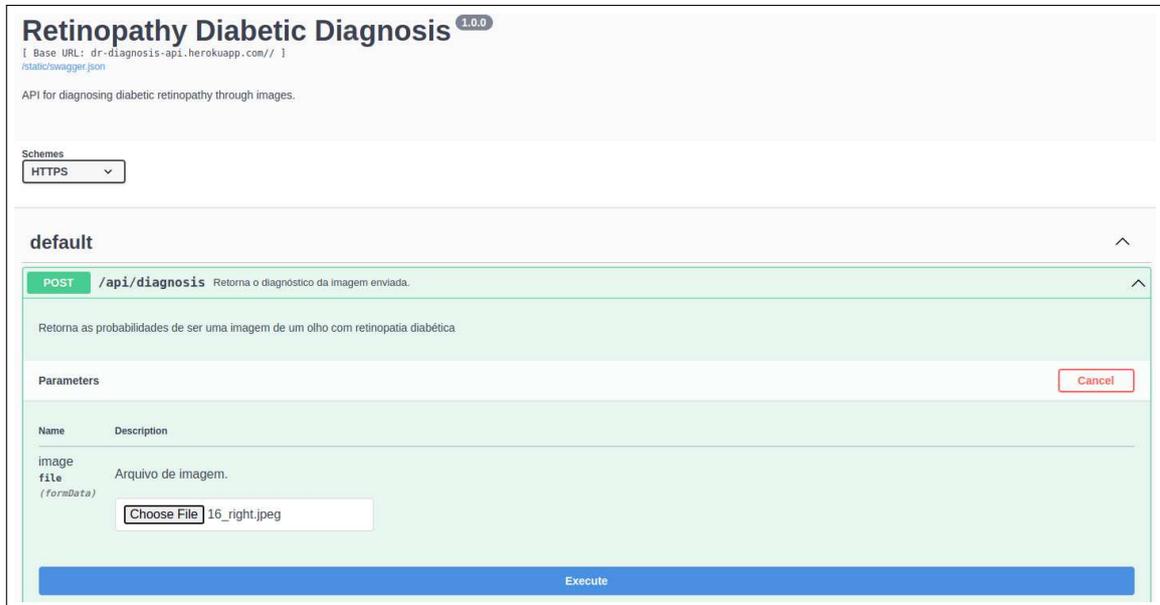
² <https://dr-diagnosis-api.herokuapp.com>

³ https://dr-diagnosis-api.herokuapp.com/swagger/#/default/post_api_diagnosis

⁴ <https://swagger.io/>

documentação, ao expandir terá a opção *"Try it out"* e ao clicar nesta opção o usuário poderá fazer o *upload* de sua imagem para testar o diagnóstico, conforme mostrado na Figura 13.

Figura 13 – Fazendo o *upload* de imagem.



Fonte – Elaborado pelo autor.

Então o usuário poderá fazer a requisição através da própria interface e ver o diagnóstico vindo dos modelos clicando no botão *"Execute"*, e logo abaixo a resposta da requisição é mostrada com o respectivo status HTTP, conforme ilustrado na Figura 14.

Figura 14 – Retorno da API.

The screenshot displays the 'Responses' tab in a web browser's developer tools. The 'Response content type' is set to 'application/json'. The 'Curl' section shows the command used to make the request. The 'Request URL' is 'https://dr-diagnosis-api.herokuapp.com/api/diagnosis'. The 'Server response' section shows a '200' status code. The 'Response body' is a JSON object with the following structure:

```

{
  "predictions": [
    {
      "alexnet": 0.78865,
      "googlenet": 0.80845,
      "lenet": 0.77615,
      "vgg-19": 0.81765
    }
  ]
}

```

The 'Response headers' section shows the following headers:

```

access-control-allow-origin: *
connection: keep-alive
content-length: 91
content-type: application/json
date: Thu, 08 Dec 2022 17:34:20 GMT
server: gunicorn
via: 1.1 vegur

```

The 'Responses' table at the bottom shows a single entry with a '200' status code and a description of 'OK'.

Fonte – Elaborado pelo autor.

Neste caso é possível inferir que há uma boa probabilidade de que a imagem utilizada no teste seja de um olho com RD, pois os 4 modelos retornaram probabilidades acima de 70% para o diagnóstico positivo.

A API é projetada para profissionais de saúde que desejam obter resultados precisos e rápidos na detecção de RD. O público-alvo da API inclui oftalmologistas, endocrinologistas, clínicos gerais e outros profissionais de saúde que trabalham com pacientes diabéticos, além de poder ser utilizada por desenvolvedores, podendo ser integrada à sistemas de gerenciamento de saúde existentes. Desta forma esses profissionais podem agilizar o processo de diagnóstico, reduzir o tempo de espera do paciente e melhorar a eficácia do tratamento.

6 CONCLUSÃO

6.1 Considerações Finais

Neste trabalho foi mostrado o desenvolvimento de uma solução *web* para diagnóstico de retinopatia diabética utilizando inteligência artificial. O intuito é que com a disponibilização dessa solução o diagnóstico automatizado possa auxiliar em sua detecção precoce fazendo com que danos maiores causados por essa patologia sejam evitados e que os pacientes possam iniciar o tratamento o mais rápido possível. Os modelos de RNC treinados neste trabalho para realizar o diagnóstico se mostraram razoavelmente eficazes, atingindo bons valores de acurácia e sensibilidade. Além disso, a API torna os modelos treinados acessíveis ao público geral.

6.2 Limitações

Trabalhar com imagens é sempre desafiador principalmente pela alta demanda computacional que o treinamento de RNC requiere, isso se tornou um fator limitante devido a impossibilidade de utilizar a base dados completa no treinamento das redes neurais, além do processo de treino, teste e validação das arquiteturas ser bastante demorado devido aos escassos recursos computacionais disponíveis para o desenvolvimento dos experimentos.

6.3 Trabalhos Futuros

Em trabalhos futuros, os modelos podem ser retreinados utilizando uma quantidade maior de imagens, assim como com mais combinações de hiperparâmetros de cada uma das arquiteturas com o intuito de treinar um modelo ideal para o diagnóstico.

Além disso, a solução desenvolvida pode ser ampliada de forma que conte com uma interface gráfica a ser utilizada diretamente por usuários não-técnicos.

REFERÊNCIAS

- ALZUBAIDI, L.; ZHANG, J.; HUMAIDI, A. J.; AL-DUJAILI, A.; DUAN, Y.; AL-SHAMMA, O.; SANTAMARÍA, J.; FADHEL, M. A.; AL-AMIDIE, M.; FARHAN, L. Review of deep learning: concepts, cnn architectures, challenges, applications, future directions. **Journal of big Data**, Springer, v. 8, n. 1, p. 1–74, 2021.
- BERTONHI, L. G. Diabetes mellitus tipo 2: aspectos clínicos, tratamento e conduta dietoterápica. 2018.
- BOYD, K. **What Is Diabetic Retinopathy?** 2020. Acesso em 03/03/2021. Disponível em: <<https://www.aaopt.org/eye-health/diseases/what-is-diabetic-retinopathy>>.
- C, A. **An Overview on Convolutional Neural Networks.** 2020. Disponível em: <<https://medium.com/swlh/an-overview-on-convolutional-neural-networks-ea48e76fb186>>.
- DIABETES, S. B. de. **Diretrizes da Sociedade Brasileira de Diabetes: 2014-2015/Sociedade Brasileira de Diabetes.** [S.l.: s.n.], 2015.
- EYEPACS. **Diabetic Retinopathy Detection.** 2015. Disponível em: <<https://www.kaggle.com/c/diabetic-retinopathy-detection>>.
- FEDERATION, I. D. Idf diabetes atlas, 10th edn. **Dunia: IDF**, 2021.
- FILHO, G. C. A.; AMARAL, C. R. do; JÚNIOR, E. A. da S.; MALAQUIAS, J. C. B.; CASSIMIRO, L. M. A. de A.; BENTO, M. A. da S. Retinopatia diabética: aspectos clínicos e manejo terapêutico diabetic retinopathy: clinical aspects and therapeutic management. **Brazilian Journal of Development**, v. 8, n. 7, p. 52594–52608, 2022.
- FRANCO, L. **Retinopatia Diabética.** 2017. Disponível em: <<http://drleiserfranco.com.br/retinopatia-diabetica/>>.
- GAD, A. F. **Practical Computer Vision Applications Using Deep Learning with CNNs.** [S.l.: s.n.], 2018.
- GARGEYA, R.; LENG, T. Automated identification of diabetic retinopathy using deep learning. **Ophthalmology**, Elsevier, v. 124, n. 7, p. 962–969, 2017.
- HASSAN, M. ul. **AlexNet – ImageNet Classification with Deep Convolutional Neural Networks.** 2018. Disponível em: <<https://neurohive.io/en/popular-networks/alexnet-imagenet-classification-with-deep-convolutional-neural-networks/>>.
- JUNIOR, G. d. B. V.; LIMA, B. N.; PEREIRA, A. A.; RODRIGUES, M. F.; OLIVEIRA, J. R. L. de; SILIO, L. F.; CARVALHO, A. dos S.; FERREIRA, H. R.; PASSOS, R. P. Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes. **Revista CPAQV-Centro de Pesquisas Avançadas em Qualidade de Vida-CPAQV Journal**, v. 14, n. 2, 2022.
- LIMA, L. R. d.; FUNGHETTO, S. S.; VOLPE, C. R. G.; SANTOS, W. S.; FUNEZ, M. I.; STIVAL, M. M. Qualidade de vida e o tempo do diagnóstico do diabetes mellitus em idosos. **Revista Brasileira de Geriatria e Gerontologia**, SciELO Brasil, v. 21, p. 176–185, 2018.
- MARTINS, H. C. **A importância da ciência aberta (open science) na pesquisa em Administração.** [S.l.]: SciELO Brasil, 2019. 01–02 p.

MILANO, D. de; HONORATO, L. B. **Visao computacional**. 2014.

NOGARE, D. **File:ConfusionMatrix.png**. 2020. Disponível em: <<https://diegonogare.net/2020/04/performance-de-machine-learning-matriz-de-confusao/>>.

O'SHEA, K.; NASH, R. An introduction to convolutional neural networks. **arXiv preprint arXiv:1511.08458**, 2015.

SILVEIRA, V.; MALFATTI, G.; GARBIN, J.; ROMANI, F.; VARGAS, J. Atualizações no manejo de retinopatia diabética: revisão de literatura. **Acta Méd Ligas Acad.(Porto Alegre)**, v. 39, n. 1, p. 293–306, 2018.

VENKATESAN, R.; LI, B. **Convolutional neural networks in visual computing: a concise guide**. [S.l.]: CRC Press, 2017.

WAN, S.; LIANG, Y.; ZHANG, Y. Deep convolutional neural networks for diabetic retinopathy detection by image classification. **Computers & Electrical Engineering**, Elsevier, v. 72, p. 274–282, 2018.

WIKI, C. S. **File:MaxpoolSample2.png**. 2018. Disponível em: <<https://computersciencewiki.org/index.php/File:MaxpoolSample2.png>>.

ZHANG, A.; LIPTON, Z. C.; LI, M.; SMOLA, A. J. Dive into deep learning. **arXiv preprint arXiv:2106.11342**, 2021.

ZHOU, Y.; SONG, S.; CHEUNG, N.-M. On classification of distorted images with deep convolutional neural networks. In: IEEE. **2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. [S.l.], 2017. p. 1213–1217.