

Francisco Nathanael da Silva Rêgo  
Orientador: Leonardo Pereira de Sousa

**Revisão Sistemática das Técnicas mais  
utilizadas na identificação da Retinopatia  
Diabética**

Picos - PI  
16 de março de 2023

Francisco Nathanael da Silva Rêgo  
Orientador: Leonardo Pereira de Sousa

## **Revisão Sistemática das Técnicas mais utilizadas na identificação da Retinopatia Diabética**

Monografia submetida ao Curso de Bacharelado em Sistemas de Informação como requisito parcial para obtenção de grau de Bacharel em Sistemas de Informação.

Universidade Federal do Piauí  
Campus Senador Heuvídio Nunes de Barros  
Bacharelado em Sistemas de Informação

Picos - PI  
16 de março de 2023

**FICHA CATALOGRÁFICA**  
**Serviço de Processamento Técnico da Universidade Federal do Piauí**  
**Biblioteca José Albano de Macêdo**

**R725r** Rêgo, Francisco Nathanael da Silva

Revisão sistemática das técnicas mais utilizadas na identificação da Retinopatia Diabética [recurso eletrônico] / Francisco Nathanael da Silva Rêgo – 2023.

34 f.

1 Arquivo em PDF

Indexado no catálogo *online* da biblioteca José Albano de Macêdo-CSHNB  
Aberto a pesquisadores, com restrições da Biblioteca

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Bacharelado em Sistemas de Informação, Picos, 2023.

“Orientador: Me. Leonardo Pereira de Sousa”

1. Retinopatia diabética. 2. Processamento de imagem. 3. Diagnóstico – doenças visuais. 4. CNN. I. Sousa, Leonardo Pereira de. II. Título.

**CDD 616**

**Emanuele Alves Araújo CRB 3/1290**

REVISÃO SISTEMÁTICA DAS TÉCNICAS MAIS UTILIZADAS NA IDENTIFICAÇÃO  
DA RETINOPATIA DIABÉTICA

FRANCISCO NATHANAEL DA SILVA RÊGO

Monografia **APROVADA** como exigência parcial para obtenção do grau de Bacharel em  
Sistemas de Informação.

Data de Aprovação

Picos – PI, 16 de março de 2023



---

Prof. Leonardo Pereira de Sousa



---

Prof. Francisco das Chagas Imperes Filho



---

Prof. Ismael de Holanda Leal

# Agradecimentos

Quero agradecer primeiramente a Deus que acima de tudo sempre esteve ao meu lado e nunca me deixou desistir. A minha mãe Rita de Cassia da Silva Rêgo que sempre me apoiou e cuidou de mim e acima de tudo é meu apoio na vida, ao meu pai Gilberto de Sousa Rêgo que sempre me orgulhou e é em quem me inspiro sempre, a minha Irmã Cassia da Silva Rêgo que cuida de mim igual uma mãe e sempre esteve comigo. A minha namorada e futura esposa Maria Catarina de Sousa que sempre pegou na minha mão, me ajudou e foi meu pilar para sempre ter forças. Também quero agradecer aos meus amigos que estiverem comigo nessa jornada: Silverio que sempre me tira boas risadas e sempre posso contar com ele, Marcos Vinicius que me acompanha desde os primeiros meses e sempre me ajudou quando precisei, Maike que era um pouco doido, mas era isso que fazia dele um cara legal e sempre nos divertíamos, Vinicius Loyola que é simplesmente uma pessoa sensacional e um irmão pra mim, Junior que assistiu a minha apresentação de TCC 1 e mesmo eu achando que estava ruim ele me apoiou.

*As pessoas costumam dizer que a motivação não dura sempre. Bem, nem o efeito do banho, por isso recomenda-se diariamente.*

*Zig Ziglar*

# Resumo

As doenças visuais têm afetado a população mundial há tempos. Segundo a Organização Mundial da Saúde (OMS) em 2020, aproximadamente 285 milhões de pessoas no mundo sofrem com deficiências visuais, um número expressivo em relação à população global. Diante disso, têm sido buscadas técnicas e estratégias que utilizam a tecnologia para melhorar e diminuir esses números. Com o avanço tecnológico é possível realizar diagnósticos mais fáceis e rápidos, além de serem propostas cada vez mais soluções e técnicas para a detecção de doenças visuais. Analisar os métodos e ferramentas a serem utilizados em um trabalho é um aspecto crucial quando se trata de pesquisas e análises. É importante selecionar a abordagem que melhor se adequa ao seu contexto e também escolher as métricas apropriadas para avaliar e obter os melhores resultados. Além disso, é fundamental revisar trabalhos relacionados na mesma área de pesquisa para identificar quais são os mais relevantes e como eles podem contribuir para a sua pesquisa. No estudo de processamento de imagens, especialmente na detecção de retinopatia diabética, é essencial obter uma boa base para treinar o modelo de análise e tornar melhor para classificar uma nova imagem. A escolha da base de dados apropriada pode afetar significativamente os resultados da pesquisa e a extração dos dados necessários para avaliar a eficácia do método utilizado. Assim, o objetivo deste trabalho é analisar algumas das principais bases de imagens e abordagens utilizadas na detecção de retinopatia diabética, visando identificar as vantagens e limitações de cada uma delas e contribuir para o avanço da pesquisa na área de classificação e identificação de patologias na área médica.

**Palavras-chaves:** retinopatia diabética, CNN, processamento de imagem, diagnóstico.

# Abstract

Visual diseases have affected the world's population for a long time. According to the World Health Organization (WHO) in 2020, approximately 285 million people worldwide suffer from visual impairments, a significant number relative to the global population. Therefore, techniques and strategies that use technology to improve and reduce these numbers have been sought. With technological advancement, it is possible to perform easier and faster diagnoses, and increasingly more solutions and techniques for detecting visual diseases are being proposed. Analyzing the methods and tools to be used in a study is a crucial aspect when it comes to research and analysis. It is essential to select the approach that best suits your context and also choose the appropriate metrics to evaluate and obtain the best results. Additionally, it is essential to review related work in the same research area to identify the most relevant ones and how they can contribute to your research. In image processing studies, especially in diabetic retinopathy detection, it is essential to obtain a good base to train the analysis model and make it better at classifying a new image. The choice of an appropriate database can significantly affect the research results and the extraction of the necessary data to evaluate the effectiveness of the method used. Therefore, the objective of this study is to analyze some of the main image databases and approaches used in the detection of diabetic retinopathy, aiming to identify the advantages and limitations of each of them and contribute to the advancement of research in the field of classification and identification of pathologies in the medical area.

# Lista de ilustrações

Figura 1 – Retinopatia diabética.	
Fonte: (Instituto de Retina de Campinas, 2023) . . . . .	17
Figura 2 – Aprendizagem de maquina.	
Fonte: (ALURA, 2019) . . . . .	19
Figura 3 – Imagens retiradas do Kaggle EyePACS.	
Fonte: (KAGGLE, 2015) . . . . .	29

# Lista de tabelas

Tabela 1 – Comparação entre trabalhos relacionados. . . . .	25
Tabela 2 – Resultados de pesquisas de trabalhos que utilizam essas bases de imagens.	31

# Lista de abreviaturas e siglas

CNN	Convolutional Neural Network
OMS	Organização Mundial da Saúde
DMRI	Degeneração Macular Relacionada à Idade
ACC	Acurácia
SENS	Sensibilidade
ACM	Association for Computing Machinery
GBD	Global Burden of Disease
DM	Diabetes Mellitus
PNS	Pesquisa Nacional de Saúde
DCNT	Doenças Crônicas Não Transmissíveis
RDNP	Non-Proliferative Diabetic Retinopathy
RDP	Proliferative Diabetic Retinopathy
DR	Diabetic Retinopathy
RD	Retinopatia Diabética
AM	Aprendizagem de Máquina
BNN	Binary Neural Networks
DNN	Deep Neural Networks
IDRiD	Indian Diabetic Retinopathy Image Dataset
PAAO	Pan-American Society of Ophthalmology
IA	Inteligência Artificial
QWK	Quadratic Weighted Kappa
DCNN	Deep Convolutional Neural Network

# Sumário

<b>1</b>	<b>Introdução</b>	<b>12</b>
1.1	Objetivos	12
1.2	Organização do Trabalho	13
1.3	Justificativa	13
<b>2</b>	<b>Referencial Teórico</b>	<b>15</b>
2.1	Diabetes	15
2.2	Retinopatia Diabética	16
2.3	Inteligencia Artificial	18
2.3.1	Aprendizagem de Máquina	18
2.3.2	Processamento de Imagem	19
2.3.3	Deep learning	20
2.4	Bases de imagens	20
<b>3</b>	<b>Trabalhos Relacionados</b>	<b>22</b>
<b>4</b>	<b>Desenvolvimento</b>	<b>27</b>
4.1	Strings de buscas	27
4.2	Bases de dados	27
4.3	Repositórios de imagens	28
4.3.1	IDRiD (Indian Diabetic Retinopathy Image Dataset)	28
4.3.2	APTOS 2019	28
4.3.3	Messidor	29
4.3.4	Kaggle EyePACS	29
4.3.5	e-ophtha	30
4.3.6	Relação Entre Base e Métodos	30
<b>5</b>	<b>Conclusão</b>	<b>32</b>
	<b>Referências</b>	<b>33</b>

# 1 Introdução

A retinopatia diabética é uma das principais causas de perda de visão em pessoas com diabetes, afetando indivíduos de todas as idades, mas com maior incidência em pessoas entre 20 e 75 anos. No Brasil, estima-se que entre 24% e 39% da população com diabetes seja afetada pela doença, sendo que 90% das pessoas com diabetes tipo 1 e 60% das pessoas com diabetes tipo 2 desenvolverão algum grau de retinopatia diabética ao longo da vida. A doença afeta aproximadamente 1 em cada 3 pessoas com diabetes, comprometendo a retina, que é a região central do globo ocular. Quando a retinopatia diabética é identificada em seus estágios iniciais, o risco de cegueira diminui para menos de 5%. O tratamento correto da doença e as precauções adequadas podem evitar a cegueira total. No entanto, se o diagnóstico for tardio, estima-se que a diabetes proliferada possa causar cegueira em até 50% dos casos em apenas cinco anos ([CONITEC, 2021](#)).

Vários métodos de detecção da retinopatia diabética estão disponíveis, sendo a detecção por imagem um dos principais. Atualmente, há um aumento do interesse no uso de técnicas de aprendizado de máquina para auxiliar na detecção e reconhecimento dessa doença. Assim, diversos estudos têm se concentrado na detecção por imagem, seja em relação à utilização de novas técnicas de imagem, seja em relação ao desenvolvimento de novos modelos de aprendizado de máquina para melhorar a precisão do exame.

Atualmente, o diagnóstico da retinopatia diabética é realizado por meio da análise de imagens da retina, capturadas por câmeras de alta qualidade projetadas especificamente para essa finalidade. No entanto, pequenas ou grandes manchas na retina podem passar despercebidas aos olhos humanos, o que pode levar a falhas na análise. A doença apresenta dois tipos: a Retinopatia Diabética não proliferativa, que é mais difícil de detectar por especialistas com pouco treinamento, e a Retinopatia Diabética Proliferativa, que é o estágio mais avançado da doença e pode causar cegueira. Por isso, é essencial identificar a doença precocemente e garantir um tratamento adequado, evitando seu crescimento e agravamento.

## 1.1 Objetivos

Este trabalho tem como objetivo realizar uma revisão sistemática das bases de dados e técnicas mais utilizadas no campo do diagnóstico por imagem da retinopatia diabética.

O presente trabalho traçou alguns objetivos específicos, para alcançar o objetivo principal:

- Identificar e revisar estudos anteriores publicados na ACM, IEEE e ScienceDirect para pesquisa em retinopatia diabética;

- Analisar os estudos revisados para determinar quais ferramentas e bases de imagens foram mais efetivas na obtenção de resultados;
- Sintetizar as principais descobertas dos estudos revisados e fornecer recomendações para a melhor escolha de técnicas e métodos para detecção de retinopatia diabética;

## 1.2 Organização do Trabalho

O trabalho está organizado em cinco seções: introdução, referencial teórico, trabalhos relacionados, desenvolvimento e conclusão.

A seção de introdução apresenta o contexto do trabalho e os objetivos que serão abordados. Em seguida, a seção de referencial teórico discute os conceitos fundamentais relacionados aos temas centrais do trabalho: diabetes, retinopatia diabética e inteligência artificial. Também são apresentadas as bases teóricas que sustentam a metodologia utilizada.

Na seção de trabalhos relacionados, são apresentados os trabalhos que já foram desenvolvidos na área e que têm relação com o trabalho em questão. Esta seção é importante para posicionar o trabalho em relação aos demais trabalhos que já foram realizados na área e destacar a contribuição que este trabalho trará.

A seção de desenvolvimento apresenta a metodologia utilizada para alcançar os objetivos propostos. São apresentados os detalhes das bases de dados e repositórios de imagens utilizados, assim como a relação entre eles e os métodos aplicados.

Finalmente, a seção de conclusão apresenta as principais conclusões alcançadas e destaca a contribuição do trabalho para a área de pesquisa em questão. As referências bibliográficas utilizadas ao longo do trabalho são apresentadas no final do documento.

## 1.3 Justificativa

O aprendizado de máquina é uma área que vem se destacando cada vez mais por suas contribuições em diversas áreas, inclusive na saúde, onde tem auxiliado na solução de problemas e no diagnóstico de doenças, o que tem resultado em diagnósticos mais precisos e menor taxa de erro em comparação aos métodos tradicionais. Esse fato se deve, em grande parte, à capacidade da inteligência artificial em analisar grandes quantidades de dados com precisão e identificar padrões que poderiam passar despercebidos para um ser humano.

No entanto, a detecção precoce de doenças é crucial para garantir uma maior chance de sucesso no tratamento e, nesse sentido, a retinopatia diabética é uma doença que pode levar à cegueira irreversível se não for detectada e tratada precocemente. Por essa razão, o desenvolvimento de ferramentas de análise por imagem que possam ajudar na identificação da doença em estágios iniciais tem se tornado cada vez mais importante.

Neste contexto, a presente monografia ilustra uma revisão sistemática das bases de imagens e ferramentas mais utilizadas no campo da detecção da retinopatia diabética, visando identificar a melhor combinação possível entre elas, com base em outros trabalhos já realizados na área. Para atingir esse objetivo, serão coletados trabalhos que utilizam diferentes bases de imagens e ferramentas de exame por imagem, a fim de avaliar quais combinações apresentaram os melhores resultados.

Com isso, espera-se que os resultados desta pesquisa contribuam para o desenvolvimento de projetos futuros na área de diagnóstico por imagem da retinopatia diabética, a partir da identificação das melhores ferramentas e bases de imagens para serem utilizadas em conjunto. Isso pode resultar em um diagnóstico mais preciso e precoce da doença, o que pode aumentar as chances de sucesso no tratamento e reduzir o risco de cegueira em pacientes com retinopatia diabética.

## 2 Referencial Teórico

Este capítulo descreve conceitos fundamentais que compõem a base deste projeto. Para isto, as seções incluem abordagens sobre processamento de imagens, bases de imagens, retinopatia diabética, técnicas de processamento de imagem e diabetes.

### 2.1 Diabetes

Com o crescimento populacional, diversas doenças vem afetando a população mundial, porém, uma vem ganhando destaque mesmo sendo bem conhecida, que é a Diabetes. Com seu grande crescimento no decorrer do tempo, vem constantemente afetando grande parte da população, principalmente os de idade mais avançada, que às vezes não possuem nenhuma informação sobre a doença e acabam não sabendo lidar com ela da forma correta para seu tratamento, fazendo assim com que ela avance e piore o estado médico da pessoa resultando assim até mesmo na morte ou em outras doenças que afetam os órgãos do corpo.

A diabetes é uma doença não transmissível relacionada com o aumento dos níveis de glicose no sangue. É uma doença que necessita de um trabalho conjunto do especialista com diversas áreas como fisioterapia, nutricionista. Aproximadamente 422 milhões de pessoas no mundo possuem diabetes e 1,6 milhões de mortes anuais são atribuídas a ela ([ORGANIZATION, 2013](#)). Ela também traz consigo diversas outras complicações para o corpo humano, prejudicando também, por exemplo, os olhos.

Segundo dados do Global Burden of Disease (GBD), em 2019, o DM foi responsável por 2,74% do total de mortes no mundo e por 2,8% de anos de vida perdidos por morte ou incapacidade. Análise de dados laboratoriais da Pesquisa Nacional de Saúde (PNS) de 2013 identificou que a prevalência de DM pode variar entre 6,6% e 9,4%, segundo diferentes critérios. Ademais, demonstrou que a prevalência de DM foi superior para pessoas do sexo feminino, idade acima de 30 anos, baixa escolaridade, sobrepeso e obesidade ([MALTA et al., 2022](#)).

As Doenças Crônicas Não Transmissíveis (DCNT) são a principal causa de mortalidade e incapacidades no Brasil e no mundo, sendo consideradas um dos grandes desafios para a saúde pública, portanto, um sinal de alerta. Neste sentido, o Ministério da Saúde elaborou o Plano de Ações Estratégicas para o Enfrentamento das DCNT, para o período 2011-2022, com definições, ações prioritárias e investimentos necessários para detecção e controle dessas doenças e de seus fatores de risco para a promoção de hábitos de vida saudáveis ([MARQUES et al., 2020](#)).

A diabetes é um fator de risco à saúde e faz com que o sistema nacional de saúde tenha muitos gastos com essa doença por ser crônica. Existe também a pré-diabetes, acontece

quando a glicose não é metabolizada, nem aproveitada o suficiente, de modo a acumular no sangue, existem taxas para comparar e verificar se estão dentro dos padrões limites a serem considerados normais, pré-diabéticos e diabéticos, quanto mais alto a taxa de glicemia, mais altas são suas chances de obter a diabetes.

Existem dois tipos de diabetes, tipo 1 que é a mais agressiva e o tipo 2 que é a que acomete mais pacientes da doença. A diabetes tipo 1 é a mais agressiva dentre as duas, com um foco maior entre as pessoas de até 30 anos, mas também podendo ser adquirida por qualquer idade, causa diversos malefícios à saúde como emagrecimento. Caracteriza-se por deficiência absoluta de produção de insulina no pâncreas. Em indivíduos do tipo 1, o pâncreas não produz insulina, o que causa a diabetes. Sem o hormônio, a glicose não entra nas células e fica acumulada no sangue e começam a aparecer os sintomas, essa glicose acumulada no sangue é basicamente o açúcar, por isso as pessoas que têm diabetes evitam o consumi-lo, por conta da dificuldade do pâncreas na produção de insulina, fazendo assim com que se acumule no sangue.

A diabetes tipo 2 é a que mais afeta a população mundial atualmente, sendo ela mais comum nas pessoas: com mais de 40 anos, obesas, alto ou baixo consumo de açúcar e drogas. O pâncreas libera muita insulina levando as células a se deteriorar, com as células deterioradas a produção de insulina cai drasticamente, fazendo assim com que a pessoa necessite tomar insulina quando necessário, por falta de produção do pâncreas devido a destruição das células (LUCENA, 2007).

A diabetes é uma doença que carrega consigo outras que vão se manifestando com o tempo. De acordo com o Diabetes Federation, mais de 250 milhões de pessoas convivem com a doença e, segundo as projeções, este número pode chegar a 380 milhões no ano de 2025, com o Brasil ocupando a 4ª posição no ranking entre os países com mais diabéticos no mundo (HIRAKAWA et al., 2019). Tendo que se preocupar bastante com isso e o gasto que leva ao sistema único de saúde, uma das melhores formas de lutar contra a doença é fazendo campanhas de informação e prevenção, para que ajude as pessoas a ficarem informadas e saberem lidar com a doença caso ela a acometa.

## 2.2 Retinopatia Diabética

A retinopatia diabética é uma doença que vem acometendo a população há algum tempo, sendo assim uma preocupação ainda maior por ser algo decorrente da diabetes. Segundo o ministério da saúde brasileira, ela está em quarto lugar no ranking das principais doenças oculares, responsáveis pela maior parte dos atendimentos feitos no Brasil pelos oftalmologistas. Ela também é responsável por grande parte da população que obteve a cegueira total.

Assim como a diabetes, é uma doença silenciosa, necessita-se de exames constantes e acompanhamento de especialista quando se tem diabetes, pois a possibilidade de adquirir

a retinopatia é alta. A retinopatia diabética é dividida em duas formas principais: não proliferativa (RDPN) e proliferativa (RDP), nomeada pela ausência ou presença de novos vasos sanguíneos anormais que emanam da retina. A RD pode ser ainda classificada por gravidade (FRANCO et al., 2022).

A não proliferativa é a mais leve das doenças, e também a que mais acomete as pessoas sendo a maior parte dos casos, causa baixa visão, discreta e moderada devido ao edema macular. A proliferativa sendo esse o caso mais grave, usualmente causa baixa de visão acentuada, devido a complicações retino vítreas, principalmente a hemorragia vítrea e o descolamento de retina. Em mulheres grávidas com diabetes a chance dela apresentar a retinopatia não proliferativa é de aproximadamente 10% e a proliferativa é de 4% (NEHEMY, 1998).

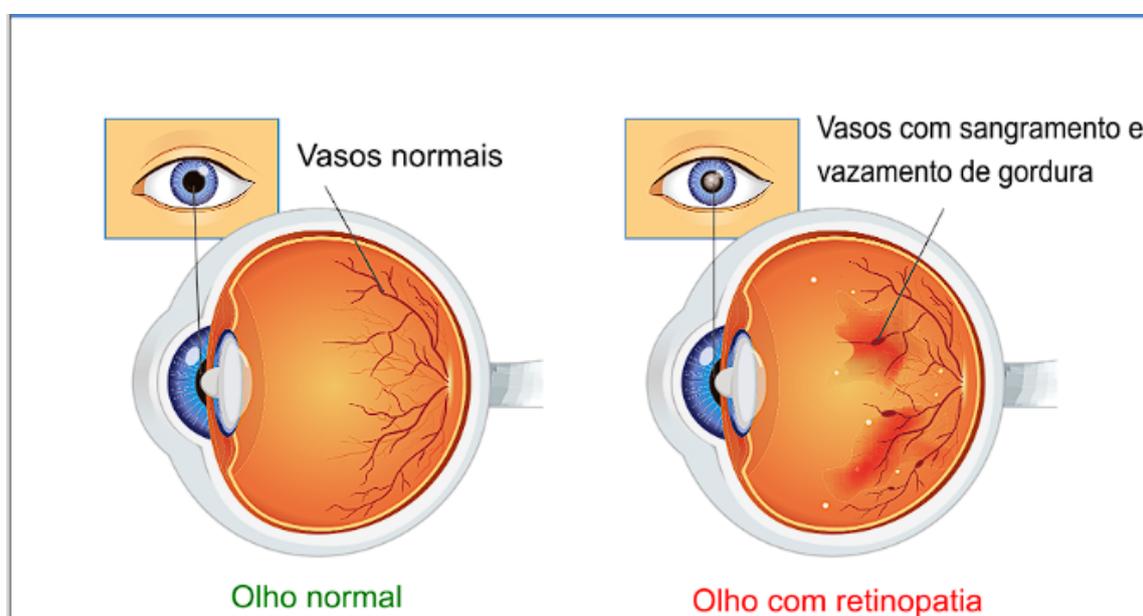


Figura 1 – Retinopatia diabética.  
Fonte: (Instituto de Retina de Campinas, 2023)

A RD são pequenas massas claras (dependendo da imagem) que ficam nos olhos como é possível ver na figura 1 e de acordo com o agravamento da doença elas vão crescendo e deteriorando os vasos sanguíneos nos olhos, fazendo assim que com o tempo venha se perdendo parte da visão até, caso não haja o tratamento correto, perca 100%. Caso haja um diagnóstico precoce da doença, com acompanhamento do especialista, medicações e cuidado, a doença pode ser retardada e não avançar para cegueira total, porém por falta de desinformação muitas pessoas acabam descobrindo a doenças em seu ciclo médio que é entre o período agressivo e não prejudicial.

## 2.3 Inteligencia Artificial

Inteligência Artificial (IA) é um ramo da ciência da computação que busca desenvolver sistemas capazes de simular a inteligência humana. A ideia é criar máquinas que possam aprender, raciocinar, reconhecer padrões e tomar decisões de forma autônoma sem precisar de intervenção humana. A IA abrange diversas técnicas como aprendizado de máquina, processamento de linguagem natural, visão computacional e outras. É uma área em constante evolução e que vem impactando cada vez mais a nossa sociedade.

Com identificação de padrões as IAs são capazes de realizar múltiplas tarefas, das mais simples até as mais complexas. A vantagem da inteligência artificial é sua capacidade de executar tarefas em grande quantidade e menor tempo, algo fora da realidade que um ser humano normal não conseguiria executar sem erros. IAs também podem errar, mas a taxa de erro pode ser melhorada e diminuir com o tempo, fazendo assim que ela se torne melhor a cada aprendizagem (SILVA; MAIRINK, 2019).

### 2.3.1 Aprendizagem de Máquina

Aprendizagem de máquina é uma área da inteligência artificial que consiste em criar algoritmos e modelos estatísticos capazes de aprender a partir de dados e melhorar seu desempenho em uma tarefa específica ao longo do tempo, sem serem explicitamente programados para isso. Em outras palavras, é uma técnica que permite que as máquinas sejam "ensinadas" a resolver problemas ou realizar tarefas complexas como reconhecimento de padrões, classificação de dados, previsão de resultados, entre outras (ALPAYDIN, 2020).

É uma aprendizagem por meios que são delimitados por seu criador, o resultado esperado é a busca de padrões por meios de algoritmos computacionais e estatísticas para alcançar o resultado desejado. Ela utiliza algoritmos com o conceito de IA e é aplicada em determinadas situações em que se busca padrões em um conjunto de variáveis com o intuito de prever um resultado específico de interesse (PAIXÃO et al., 2022).

Existem diversos tipos de aprendizagem de máquina como é possível ver na figura 2. Na aprendizagem supervisionada, o algoritmo é treinado utilizando exemplos rotulados, ou seja, os dados são apresentados ao modelo junto com suas respectivas respostas corretas. Na aprendizagem não supervisionada, o algoritmo busca encontrar padrões nos dados sem ter acesso a rótulos. Já na aprendizagem por reforço, o algoritmo aprende a partir das consequências de suas ações. Há também a aprendizagem semi-supervisionada, que utiliza tanto dados rotulados quanto não rotulados para treinar o modelo. Cada tipo de aprendizagem de máquina é adequado para diferentes tipos de problemas e conjuntos de dados (ALPAYDIN, 2010).

O aprendizado de máquina vem ganhando bastante força na área da saúde, existem diversos trabalhos, pesquisas, artigos e publicações que envolvem o uso dessa técnica para o descobrimento de novos padrões, estudos sobre doenças, processamento de dados, entre



Figura 2 – Aprendizagem de máquina.  
Fonte: (ALURA, 2019)

outros, poupando assim o tempo dos especialistas na área e facilitando seu trabalho. Atualmente, por conta dessa aprendizagem, muitas coisas novas na medicina vem surgindo, como novas abordagens, novos meios de diagnósticos e até cirurgias a distância.

Segundo (HOMEM; UFES, 2020) “A *Aprendizagem de Máquina* (AM) é o campo da ciência que fornece ao computador a habilidade de aprender uma determinada tarefa sem ser explicitamente programada. Uma criança aprende a identificar um brinquedo, por exemplo, uma vez que a mesma é exposta ao objeto várias vezes e, assim, consegue identificar padrões que o caracteriza. Um modelo de aprendizagem, por sua vez, é exposto a um conjunto de dados robusto e utiliza os exemplos ali contidos para identificar padrões relevantes à tarefa que lhe é destinado”.

### 2.3.2 Processamento de Imagem

Uma subárea específica que vem ajudando bastante no descobrimento e diagnósticos de doenças é o processamento de imagem. Baseia-se em imagens já existentes de doenças que têm características e pontos fortes que quando identificadas podem ser diagnosticadas com precisão. O processamento de imagens ajuda nessa identificação por imagem e diminui o fator erro humano que pode acontecer, trazendo assim mais confiabilidade no diagnóstico, claro que existe ainda muito espaço para melhorar essa tecnologia, porém seus avanços são promissores.

No contexto da medicina, o processamento de imagem tem sido amplamente utilizado para auxiliar no diagnóstico de diversas doenças, permitindo a detecção de padrões e anomalias que podem não ser detectáveis a olho nu ou mesmo por meio de exames clínicos tradicionais. Além da retinopatia diabética, essa tecnologia tem sido aplicada no diagnóstico de outras doenças oculares, como o glaucoma e a degeneração macular rela-

cionada à idade, bem como em outras áreas da medicina, como radiologia, dermatologia e neurologia.

Dentre as técnicas de processamento de imagem mais utilizadas em medicina, podemos citar a filtragem, segmentação, reconstrução tridimensional, análise de texturas, aprendizado de máquina e redes neurais artificiais. O uso dessas técnicas pode ajudar a aumentar a precisão dos diagnósticos, reduzir o tempo de análise e melhorar o prognóstico dos pacientes.

### 2.3.3 Deep learning

O deep learning (ou aprendizagem profunda) é um subcampo do aprendizado de máquina que também tem como foco a aprendizagem. O aprendizado de máquina é um conjunto de técnicas e algoritmos que levam dados para conseguir aprender e aplicar o aprendizado na prática, de acordo com a finalidade que foi criada. O deep learning é uma técnica dentro desse campo do aprendizado de máquina que vem beneficiando as pessoas com sua forma de resolver problemas e trazer soluções.

A principal característica do deep learning é o uso de redes neurais artificiais com múltiplas camadas, quanto mais camadas, mais profunda é, e daí surgiu o nome aprendizagem profunda. Essas redes neurais possuem vários nós conectados entre si para conseguir processar uma grande quantidade de dados em pouquíssimo tempo, permitindo assim que ela aprenda e faça previsões a partir desse grande conjunto de dados

Geralmente o treinamento desse tipo de algoritmo é feito com um algoritmo de aprendizagem supervisionada que usa um conjunto de dados rotulados para aprender padrões e prever resultados com precisão. Com o tempo, quanto mais ela aprender, mais ela consegue reconhecer padrões avançado, fazendo assim com que ela consiga fazer tarefas mais complexas

O deep learning é amplamente usado atualmente para diversas áreas, como por exemplo em carros que dirigem sozinhos, ele vai conseguir identificar cores de sinais, distinguir pessoas de objetos, sinalização e limite de velocidade, também em processamento de linguagem natural, e vários outros. Ele é particularmente útil para tarefas complexas que envolvem grandes conjuntos de dados e que não podem ser facilmente resolvidas usando técnicas tradicionais de programação

## 2.4 Bases de imagens

As bases de imagens são coleções de imagens e/ou dados relacionados a imagens que são usados como fonte de dados para tarefas de processamento de imagem e aprendizado de máquina (BISHOP, 2006; GOODFELLOW; BENGIO; COURVILLE, 2016; SHALEV-SHWARTZ; BEN-DAVID, 2014). Essas podem ser compostas por imagens em bruto, imagens com anotações, imagens com informações de segmentação, entre outras. Além disso,

são muito úteis em várias áreas de aplicação, incluindo visão computacional, robótica, medicina, ciência de dados, reconhecimento de padrões, entre outras.

A construção dessas bases é um processo trabalhoso que envolve a coleta, processamento e organização de grandes quantidades de dados. Alguns exemplos de bases de imagens incluem a ImageNet ([DENG et al., 2009](#)), uma base de dados com mais de 14 milhões de imagens categorizadas em 20 mil classes, a MNIST ([LECUN; CORTES; BURGESS, 1998](#)), uma base de dados com 70.000 imagens de dígitos manuscritos, e a COCO ([LIN et al., 2014](#)), uma base de dados com mais de 330.000 imagens anotadas de objetos em diferentes cenários.

As bases de imagens desempenham um papel fundamental no treinamento e validação de modelos de aprendizado de máquina e processamento de imagem. Os modelos são alimentados com dados dessas bases para aprender a reconhecer padrões, segmentar objetos, classificar imagens e outras tarefas. Além disso, são amplamente utilizadas para avaliar a qualidade e desempenho dos modelos, através de métricas como precisão, recall, F1-score e outras. ([ALPAYDIN, 2010](#)).

### 3 Trabalhos Relacionados

O pré-processamento é uma etapa crucial na classificação de imagens e sua importância foi destacada por (DUTTA et al., 2018) em um estudo sobre classificação de imagens de retina. Nesse estudo, três métodos de rede neural, incluindo BNN (Binary Neural Networks), DNN (Deep Neural Networks) e CNN (Convolutional Neural Networks) foram utilizados para melhorar a precisão da classificação de imagens. O pré-processamento foi usado para filtrar as características relevantes da imagem e permitir a extração de informações mais precisas em imagens de alta resolução. O dataset utilizado no estudo contém mais de 35.000 imagens para treinamento e 15.000 para teste, com uma resolução variável e presença de ruído. Para este estudo, foram selecionadas 2.000 imagens, com uma proporção de treinamento e teste de 7:3. Os resultados obtidos foram uma acurácia de 62,7% para BNN, 89,6% para DNN e 76,4% para CNN (VGGNET) no conjunto de treinamento, enquanto no conjunto de teste as acurácias foram 42%, 86,3% e 78,3%, respectivamente.

(WANG et al., 2018) utilizou três arquiteturas diferentes de redes neurais convolucionais (CNNs): AlexNet, VGG16 e InceptionNet V3, para processar imagens. O conjunto de imagens utilizado foi da Kaggle com mais de trinta e cinco mil. Essas imagens foram filtradas e selecionadas por oftalmologistas, totalizando 166 imagens de alta qualidade que foram utilizadas para treinar os modelos de classificação de retinopatia diabética. As arquiteturas AlexNet e VGG16 possuem 8 camadas de aprendizado profundo, sendo as primeiras 5 convolucionais e as últimas 3 totalmente conectadas, enquanto a InceptionNet V3 é uma evolução das arquiteturas Inception e InceptionV2, projetadas para melhorar o desempenho e a eficiência computacional. A precisão média de AlexNet, VGG16 e InceptionNet V3 é de 37,43%, 50,03% e 63,23%, respectivamente

O artigo (PATRA; SINGH, 2022) apresenta um método de classificação de retinopatia diabética em quatro níveis de gravidade utilizando imagens fundoscópicas. O método consiste em três etapas: pré-processamento das imagens, extração de vetores de características usando as CNNs ResNet50 e Inception V3, e classificação das imagens. Foram utilizados diferentes conjuntos de dados, incluindo o IDRiD e o Disha Eye Hospital, Kolkata. Os resultados mostram que o ResNet50 com QWK obteve uma precisão de 80,63% e perda de 52,13% para o conjunto de dados IDRiD, enquanto o Inception V3 obteve uma precisão de 82,95% e perda de 70,14% para o conjunto de dados Aravind Eye Hospital ZZ. O conjunto de dados do Disha Eye Hospital, Kolkata teve resultados ligeiramente piores, com o ResNet50 atingindo uma precisão de 81,34% e perda de 51,13%, e o Inception V3 uma precisão de 83,79% e perda de 60,14%.

(ELSWAH; ELNAKIB; MOUSTAFA, 2020) propõe framework de aprendizado profundo para a classificação dos graus de retinopatia diabética a partir de imagens de fundo

de olho por três etapas. Primeiro, a imagem de fundo é pré-processada usando normalização e aumento de intensidade. Em seguida, a imagem pré-processada é inserida em um modelo de rede neural convolucional ResNet para extrair um vetor de características compacto para a classificação. Por fim, é usada uma etapa de classificação para detectar a retinopatia diabética e determinar seu grau (por exemplo, leve, moderado, grave ou retinopatia diabética proliferativa). O framework proposto é treinado usando o conjunto de dados de imagem de retinopatia diabética IDRiD. Para remover o viés de treinamento, os dados são balanceados para garantir que cada grau de retinopatia diabética seja representado com o mesmo número de imagens durante o processo de treinamento. O sistema proposto mostra um desempenho aprimorado em relação às técnicas relacionadas que usam os mesmos dados, evidenciado pela maior precisão geral de classificação de 86,67%.

O método desenvolvido por (NGUYEN et al., 2020) apresenta uma solução eficiente de triagem de retinopatia diabética baseado em CNN utilizando as arquiteturas VGG-16 e VGG-19, juntamente com a base de imagens EyePACS de 2015 disponibilizada pelo Kaggle. A rede neural desenvolvida foi capaz de classificar imagens em 5 categorias distintas, variando de 0 a 4, onde 0 representa a ausência de RD e 4 corresponde à RDP. Os resultados obtidos demonstraram uma sensibilidade de 80%, precisão de 82%, especificidade de 82% e AUC de 90.4%, indicando um desempenho promissor na detecção automática de RD.

O estudo de (LUO et al., 2021) apresenta uma nova metodologia baseada em uma arquitetura de DCNN multi-visualização que utiliza imagens em diferentes perspectivas para a detecção e classificação da Retinopatia Diabética. A base de dados utilizada foi obtida em um hospital na China no qual o nome não foi citado, contendo mais de 15 mil imagens, e os resultados mostraram que a abordagem é viável e pode melhorar o desempenho do modelo. Foram avaliados três modelos diferentes: o MVDRNet original, o MVDRNet com SE-block e o MVDRNet com SK-unit. Os resultados mostraram que o modelo MVDRNet com SK-unit alcançou a maior precisão de detecção, atingindo uma precisão de 77.75%. Esses resultados indicam que a adaptação do tamanho do campo receptivo melhora a capacidade de extração de recursos das redes e contribui para a detecção de objetos com diferentes escalas. A metodologia proposta pode permitir uma análise mais abrangente e precisa da Retinopatia Diabética, contribuindo para o avanço da área.

Proposto em seu estudo, (UMAPATHY et al., 2019) apresenta dois métodos para automatizar a detecção de RD, uma das causas mais comuns de cegueira em adultos. A primeira abordagem envolve a extração de recursos usando processamento de imagem da retina e extração de recursos de textura, e usa um classificador de Árvore de Decisão para prever a presença de RD. A segunda abordagem aplica aprendizado de transferência para detectar RD em imagens de fundo de olho. Os modelos foram treinados em imagens de conjuntos de dados disponíveis publicamente STARE, HRF, Messidor e um novo conjunto

de dados do Instituto de Retina de Karnataka. As precisões obtidas pelas duas abordagens são de 94,4% e 88,8% respectivamente, que são compatíveis com os métodos de automação atuais. O objetivo do trabalho é automatizar a detecção da RD para amenizar a deficiência de oftalmologistas em determinadas regiões onde é feito o rastreamento.

Este artigo apresenta um modelo para detecção automática de RD em imagens de retina capturadas por smartphones, proposto por (HACISOFTAOGLU; KARAKAYA; SALLAM, 2020). O objetivo é fornecer um método preciso e acessível para triagem de RD em ambientes diversos. Foram utilizadas as arquiteturas AlexNet, GoogLeNet e ResNet50 para treinamento com imagens de retina de diferentes conjuntos de dados, a fim de avaliar o efeito da utilização de imagens de conjuntos de dados únicos, cruzados e múltiplos. O modelo proposto, utilizando a abordagem de transferência de aprendizado com a ResNet50, obteve uma alta taxa de acurácia de 98,6%, com uma sensibilidade de 98,2% e especificidade de 99,1%. O estudo também analisou a qualidade das imagens de retina capturadas por smartphones e sua influência na precisão do modelo. Os resultados indicaram que é possível obter altas taxas de acurácia na detecção de RD com um número menor de imagens de treinamento, tornando o método acessível em locais com recursos limitados.

O artigo (TANG et al., 2021) apresenta uma nova rede neural chamada Lesion Guided Network (LGN) para o diagnóstico automático de RD a partir de imagens de fundo de olho. A rede utiliza um modelo de detecção de lesão chamado RetinaNet treinado em um conjunto de dados com anotações grosseiras para detectar regiões de interesse. Um módulo chamado Lesion-Aware Module (LAM) é então proposto para destacar essas regiões e alimentá-las para uma rede neural convolucional (CNN) para a identificação de RD. A eficácia do LGN é avaliada em um conjunto de dados privado contendo 4465 imagens de fundo de olho, demonstrando resultados comparáveis aos de oftalmologistas. O desempenho do LGN é comparado com outras abordagens, incluindo o uso de ResNet50 e ResNet50 com mapa de lesões grosseiras. O LGN obteve uma sensibilidade de 90.79%, especificidade de 0.9463 e acurácia de 92.71%, mostrando resultados superiores em relação aos outros dois métodos avaliados.

Tabela 1 – Comparação entre trabalhos relacionados.

Trabalho	Métodos	Dataset	ACC	Sens
(DUTTA et al., 2018)	DNN, CNN(VGGNET), BNN	Kaggle	BNN 42%, DNN 86.3%, CNN 78.3%	
(ELSWAH; EL-NAKIB; MOUSTAFA, 2020)	CNN(ResNet)	IDRiD	ResNet 86,67%	
(HACISOFTAOGLU; KARAKAYA; SALILAM, 2020)	CNN( AlexNet, GoogLeNet, RestNet50)	EyePACS, Messidor, Messidor-2, IDRiD	AlexNet 95.6%, GoogLeNet 93.6%, RestNet50 96.2	AlexNet92.8%, GoogLeNet 90.7%, RestNet50 93.9%
(LUO et al., 2021)	DCNN( MVDRNet_SE, MVDRNet, MVDRNet_SK)		MVDRNet_SE 76.60%, MVDRNet 75.98%, MVDRNet_SK 77.75%	
(NGUYEN et al., 2020)	CNN(VGG-16,VGG-19)	Kaggle	VGG-16 82%,VGG-19 82%	VGG-16 80%,VGG-19 80%
(PATRA; SINGH, 2022)	CNN(ResNet50, InceptionV3)	IDRiD,Aravind Eye Hospital, DataPort,Dishayey hospital kolka	ResNet50 81,34%, InceptionV3 83,79%	
(TANG et al., 2021)	CNN( ResNet50, LGN)	IDRiD	LGN 94.63%, ResNet50 96,93%	LGN 90.79%, ResNet50 90.79%
(UMAPATHY et al., 2019)	CNN(Inception-v3)	Messidor, HRF, STARE	Inception-v3 90%	
(WANG et al., 2018)	CNN (Inception-Net V3, AlexNet and VGG16)	Kaggle	AlexNet 37.43%, VGG16 50.03%, InceptionNetV3 63.23%	

Na tabela 1 é apresentada uma comparação entre diversos estudos que utilizaram algoritmos de aprendizado de máquina para reconhecimento de doenças oculares. Ela fornece informações sobre os métodos utilizados, os datasets utilizados e as métricas de desempenho alcançadas por cada trabalho. Alguns dos métodos de aprendizado de máquina utilizados incluem Redes Neurais Convolucionais (CNN), Deep Neural Networks (DNN) e Bayesian Neural Networks (BNN).

Os datasets utilizados incluem Kaggle, IDRiD, EyePACS, Messidor, Messidor-2, Aravind Eye Hospital, DataPort, Disha yey hospital kolka, HRF e STARE. As métricas de desempenho variam amplamente entre os diferentes trabalhos, com a acurácia variando de 42% a 96,93% e a sensibilidade variando de 80% a 94,63%. Essas métricas indicam a capacidade do algoritmo em classificar corretamente as amostras em relação às doenças oculares.

É importante destacar que as métricas de desempenho não são as únicas considerações importantes em relação a esses estudos. Outros fatores, como a qualidade do dataset, a diversidade dos casos, o tamanho da amostra e a metodologia utilizada também são importantes. Portanto, a escolha do melhor algoritmo para reconhecimento de doenças oculares depende de uma avaliação cuidadosa de todos esses fatores.

## 4 Desenvolvimento

Neste capítulo, são apresentadas as bases de dados, trabalhos e pesquisas utilizadas como referência na busca por trabalhos que utilizam ferramentas para detecção de retinopatia diabética. Para a inclusão na pesquisa, foram considerados trabalhos que abordam a retinopatia diabética e descrevem a forma ou ferramenta utilizada para a detecção da doença.

### 4.1 Strings de buscas

Foram buscadas publicações referente aos últimos 5 anos (2023 - 2018):

- IEEE Xplore: ("All Metadata": "diabetic retinopathy") AND ("Document Title": "diabetic retinopathy") AND ("All Metadata": identification OR "All Metadata": classification OR "All Metadata": detection);
- ScienceDirect: (diabetic retinopathy AND classification AND Identification) (Title: diabetic retinopathy).
- ACM Digital Library: [All: "diabetic retinopathy"] AND [Title: "diabetic retinopathy"] AND [[All: identification] OR [All: classification] OR [All: detection]];

### 4.2 Bases de dados

As bases de dados IEEE Xplore<sup>1</sup>, ScienceDirect<sup>2</sup> e ACM<sup>3</sup> são amplamente reconhecidas como fontes confiáveis e respeitáveis de informações científicas e técnicas em suas respectivas áreas de cobertura. A IEEE Xplore é uma base de dados que se concentra em publicações nas áreas de engenharia, tecnologia e ciências da computação. A ScienceDirect, por sua vez, abrange uma ampla gama de tópicos, incluindo ciências da saúde, ciências sociais, ciências físicas e ciências da vida. Já a ACM é uma biblioteca digital que se concentra em ciência da computação e tecnologia da informação.

Essas bases de dados são escolhas comuns para pesquisadores, acadêmicos e profissionais em todo o mundo devido à alta qualidade das publicações que elas abrangem e à facilidade de acesso e pesquisa. Além disso, essas bases de dados oferecem opções de pesquisa avançada, permitindo a utilização de recursos como filtros de pesquisa e referências cruzadas para encontrar informações específicas com mais facilidade. Por essas razões, é uma escolha comum para estudantes e pesquisadores de diversas áreas de conhecimento.

<sup>1</sup> <https://ieeexplore.ieee.org/Xplore/home.jsp>

<sup>2</sup> <https://www.elsevier.com/>

<sup>3</sup> <https://dl.acm.org/>

## 4.3 Repositórios de imagens

A escolha dos conjuntos de dados foi com base em sua usabilidade e citações em trabalhos, essas são as bases que mais são citadas e utilizadas para o treinamento de validação de técnicas de algoritmo para identificação de algum padrão, tanto por seu valor e forma de construção, como por sua quantidade de imagens e informações que podem ser encontradas.

### 4.3.1 IDRid (Indian Diabetic Retinopathy Image Dataset)

O IDRid (Indian Diabetic Retinopathy Image Dataset) é uma base de imagens criada com o foco em retinopatia diabética. Criada na Índia para pesquisas com foco nessa doença possui 516 imagens retinianas digitais de 428 pacientes diabéticos.

Todas as imagens foram adquiridas usando uma câmera de alto desempenho para conseguir fotos de qualidade do fundo do olho. Foi utilizado uma Kowa VX-10 alpha com campo de visão de 50 graus (FOV) e todas estão centralizadas perto da mácula. As imagens têm resolução de  $4288 \times 2848$  pixels e são armazenadas em formato de arquivo jpg. O tamanho de cada imagem é de cerca de 800 KB (PORWAL et al., 2019).

Todas as imagens foram classificadas por dois especialistas em oftalmologia e anotadas quanto à presença ou ausência de lesões associadas à retinopatia diabética, como microaneurismas, exsudatos duros e moles, hemorragias intra retinianas e tração vitreomacular. A base de dados também inclui informações demográficas e clínicas dos pacientes, bem como detalhes do equipamento e parâmetros de imagem utilizados na aquisição das imagens.

### 4.3.2 APTOS 2019

A retinopatia diabética é um grande desafio atualmente para ser superado, conta com diversos casos em todo o mundo e com diversos especialistas nisso. Essa base foi criada para estimular e desafiar pesquisadores, estudantes, cientistas e outros a pesquisar e contribuir com suas pesquisas e trabalhos na área, ajudando assim em um futuro próximo outros pesquisadores.

Essa base de imagens foi criada para ajudar a impulsionar a pesquisa em inteligência artificial aplicada à saúde ocular, especificamente na detecção precoce de retinopatia diabética. Os algoritmos desenvolvidos com base nessa base de imagens podem ajudar a detectar a doença em estágios iniciais, o que pode levar a um tratamento mais eficaz e prevenir a perda de visão.

O conjunto de dados do APTOS 2019 Blindness Detection Challenge incluiu mais de 18.590 imagens de fundo de olho, que foram divididas em conjuntos de treinamento e

teste, sendo elas 3662 imagens de treinamento, 1928 de validação e 13000 imagens para teste. (TYMCHENKO; MARCHENKO; SPODARETS, 2020)

### 4.3.3 Messidor

Messidor é uma das bases mais utilizadas para trabalhos Messidor foi um programa de pesquisa financiado pelo Ministério Francês de Pesquisa e Defesa dentro de um programa TECHNO-VISION de 2004. O bancos de imagens é totalmente gratuito para estudos e pesquisa e não permite sua redistribuição ou uso comercial.

A base contém 1200 imagens do fundo dos olhos de diferentes pessoas, usando uma câmera de vídeo 3CCD colorida montada em um retinógrafo não midiático Topcon TRC NW6 com um campo de visão de 45 graus. As imagens foram capturadas usando 8 bits por plano de cores em 1440\*960, 2240\*1488 ou 2304\*1536 pixels. Essas imagens são divididas em 800 que foram adquiridas com dilatação da pupila após uma gota de Tropicamida a 0,5% e 400 sem a dilatação, as outras especificações e instruções podem ser obtidas no site (ABRAMOFF et al., 2016).

### 4.3.4 Kaggle EyePACS

Criada com o mesmo sentido da base anterior, a Kaggle EyePACS também é um desafio para estudantes, cientistas e outros na luta contra a retinopatia diabetica utilizando sua base de imagens. Esta competição é patrocinada pela California Healthcare Foundation.

Sua base de imagens é uma das maiores do mundo com cada uma sendo classificada de 0 a 4 onde o número 0 significa mais leve e 4 significa a mais grave ela tem ao todo 88 mil imagens de fundo de olho rotuladas para retinopatia diabética em mais de 12.000 pacientes. A base foi criada pela Pan-American Society of Ophthalmology (PAAO) e o Ministério da Saúde do Peru em colaboração com o Google. As imagens foram coletadas de hospitais em seis países da América Latina, incluindo Argentina, Brasil, Chile, México, Peru e Estados Unidos (KAGGLE, 2015).

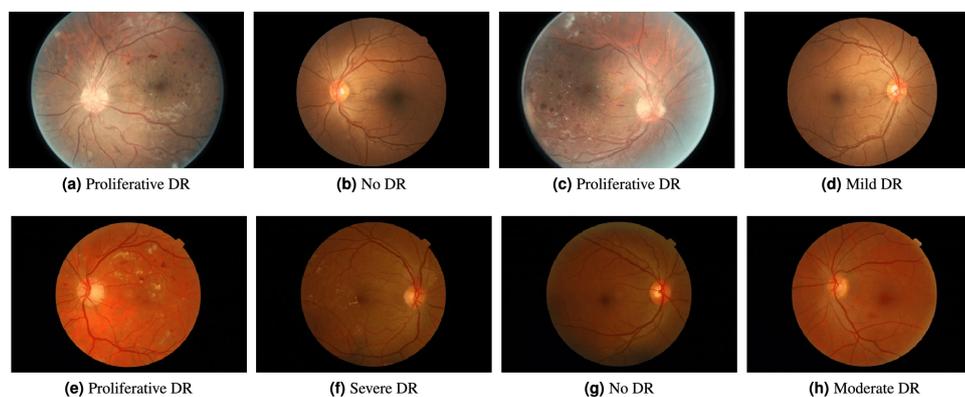


Figura 3 – Imagens retiradas do Kaggle EyePACS.

Fonte: (KAGGLE, 2015)

A base é dividida em 2 conjuntos, um para teste e outro para treino conjunto de treino possui 35.126 e o de teste 53576 imagens. Todas as imagens foram avaliadas e examinadas por oftalmologista experientes e especialista na área e também classificadas para facilitar os estudos dela. Por isso essa base é amplamente usada em desafios que envolvem a classificação de imagens para a identificação e detecção de grau de retinopatia diabética. Infelizmente, não há informações específicas sobre qual equipamento foi utilizado para adquirir as imagens. Na figura 3 temos imagens retiradas da Kaggle-EyePACS com vários ciclos da retinopatia diabética utilizadas para treinamento e validação de modelos de classificação de níveis de gravidade da doença

### 4.3.5 e-optha

Essa base de dados foi feita para a identificação de retinopatia diabética com imagens do fundo dos olhos coloridas e financiado pela Agência Francesa de Pesquisa e gerado a partir da rede OPHDIAT Telemedical. Lançada em 2019 seu objetivo é validar e examinar algoritmos de detecção da doença.

Ela é composta por imagens que contêm diferentes tipos de lesões e foram identificadas por especialistas oftalmológicos. Para adquirir a base basta preencher um formulário no site e enviar e se for aprovado ficará disponível para você o download da base.

A base de dados é dividida entre duas lesões que são exsudatos e microaneurismas, contendo 47 imagens com exsudato e 35 imagens sem lesão e 148 imagens com microaneurismas ou pequenas hemorragias e 233 imagens capturadas com o dispositivo de captura de imagem de retina 3Nethra sem lesão, além disso ela também contém informações clínica e demográficas sobre as imagens para caso seja preciso realizar uma pesquisa mais aprofundada. O 3Nethra é um dispositivo portátil, fácil de usar e não invasivo que é capaz de capturar imagens digitais de alta qualidade do fundo de olho (JIN et al., 2019).

### 4.3.6 Relação Entre Base e Métodos

Os trabalhos relacionados destacam que a escolha da base de imagens e da abordagem utilizada têm uma forte relação com os resultados obtidos. As bases de dados que possuem maior destaque são aquelas que possuem uma grande quantidade de imagens, pois quanto maior a quantidade de imagens, melhor a divisão entre treinamento e teste. As bases de dados Kaggle e IDRiD são as mais utilizadas, juntamente com abordagens de CNN, devido ao grande número de imagens disponíveis.

Nos trabalhos duas métricas são as mais utilizadas: acurácia (ACC) e sensibilidade (Sens). A acurácia é uma medida que indica a porcentagem de previsões corretas em relação ao total de previsões realizadas pelo modelo. Já a sensibilidade é uma medida que indica a porcentagem de casos positivos que foram corretamente identificados pelo modelo em relação ao total de casos positivos.

Dessa forma, a diferença entre essas métricas é que a acurácia mede o desempenho geral do modelo, levando em consideração tanto os casos positivos quanto os negativos, enquanto a sensibilidade mede a capacidade do modelo de identificar corretamente os casos positivos, mesmo que isso possa resultar em um número maior de falsos positivos.

Os métodos utilizados variam desde redes convolucionais simples até modelos mais complexos, como ResNet e InceptionNet. Os conjuntos de dados utilizados também são diversos, incluindo Kaggle, IDRid, EyePACS, Messidor, HRF e STARE. Os resultados de acurácia (ACC) variam entre 37,43% (utilizando o método AlexNet) e 96,93% (utilizando o método ResNet50). Alguns trabalhos também relatam a sensibilidade (Sens), que varia de 72,53% a 90,79%.

Tabela 2 – Resultados de pesquisas de trabalhos que utilizam essas bases de imagens.

<b>Bases de Imagens</b>	<b>IEE Xplore</b>	<b>ScienceDirect</b>	<b>ACM</b>	<b>Total</b>
Messidor	167	50	7	224
IDRid	60	31	13	104
e-ophtha	20	52	1	73
Kaggle EyePACS	10	24	0	34
APTOS 2019	16	8	4	28

A tabela a seguir permite uma análise interessante sobre as bases de imagens mais utilizadas em pesquisas recentes. O número de trabalhos que utilizam cada uma das bases de imagens listadas foi comparado em três plataformas diferentes: IEEE Xplore, ScienceDirect e ACM.

Pode-se notar que na tabela 2 a base de imagens Messidor é a mais utilizada com um total de 224 trabalhos encontrados. A base de imagens IDRid aparece em segundo lugar com um total de 104 trabalhos encontrados. A e-ophtha também apresenta um número significativo de trabalhos com um total de 73. Por outro lado a plataforma ScienceDirect apresenta o menor número de trabalhos que utilizam as bases de imagens listadas.

Esses resultados podem indicar que a base de imagens Messidor é considerada uma fonte confiável e amplamente utilizada na pesquisa em imagens médicas. Além disso o fato de a plataforma ScienceDirect apresentar um menor número de trabalhos que utilizam as bases de imagens listadas pode sugerir que pesquisas em outras áreas fora da oftalmologia podem ser mais comuns nesta plataforma.

## 5 Conclusão

Com base nas informações apresentadas, podemos verificar que existem diversas etapas importantes para se chegar a um bom resultado em um trabalho. A primeira etapa é a escolha cuidadosa da base de dados, que deve ser apropriada e estruturada para garantir a qualidade dos resultados e evitar erros.

A seleção da base de dados é fundamental para qualquer projeto de análise de dados ou desenvolvimento de modelos de aprendizado de máquina, incluindo a identificação da Retinopatia Diabética. Uma base de dados apropriada e bem estruturada permite que as informações sejam organizadas de forma clara e consistente, além de garantir que os resultados do projeto sejam confiáveis.

Já a segunda etapa consiste na escolha dos métodos mais adequados para o objetivo do projeto. No caso da identificação da Retinopatia Diabética, técnicas de análise de imagem e machine learning podem ser utilizadas, por exemplo. A seleção dos métodos corretos é essencial para obter resultados precisos e confiáveis, pois cada método tem suas vantagens e limitações.

Por fim, as métricas selecionadas para avaliar o desempenho do método escolhido também são fundamentais para garantir que os resultados sejam precisos e confiáveis. Algumas das métricas comumente utilizadas na identificação da Retinopatia Diabética incluem sensibilidade, especificidade, acurácia, valor preditivo positivo e valor preditivo negativo.

A sensibilidade é a capacidade do método em identificar casos positivos para a Retinopatia Diabética, enquanto a especificidade indica a capacidade do método em identificar casos negativos. A acurácia é a proporção de casos positivos e negativos corretamente identificados pelo método. O valor preditivo positivo é a proporção de verdadeiros positivos em relação a todos os resultados positivos, enquanto o valor preditivo negativo é a proporção de verdadeiros negativos em relação a todos os resultados negativos.

Em resumo, a escolha cuidadosa da base de dados, dos métodos e das métricas, juntamente com a revisão sistemática adequada, pode levar a um resultado bem-sucedido na identificação da Retinopatia Diabética e em muitos outros projetos de análise de dados. É importante lembrar que cada projeto pode ter suas particularidades e, portanto, é necessário adaptar as etapas e escolhas de acordo com os objetivos e características específicas de cada trabalho.

## Referências

- ABRAMOFF, M. D.; LOU, Y.; ERGINAY, A.; CLARIDA, W.; AMELON, R.; FOLK, J. C.; NIEMEIJER, M. Improved automated detection of diabetic retinopathy on a publicly available dataset through integration of deep learning. *Investigative ophthalmology & visual science*, ARVO, v. 57, n. 13, p. 5200–5206, 2016. Citado na página 29.
- ALPAYDIN, E. *Introduction to machine learning*. [S.l.]: MIT press, 2010. Citado 2 vezes nas páginas 18 e 21.
- ALPAYDIN, E. *Introduction to Machine Learning*. [S.l.]: MIT Press, 2020. Citado na página 18.
- ALURA. *Desmistificando Termos de Machine Learning: Tipos de Aprendizado*. 2019. <https://www.alura.com.br/artigos/desmistificando-termos-machine-learning-tipos-aprendizado>. Citado 2 vezes nas páginas 8 e 19.
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. [S.l.]: Springer, 2006. Citado na página 20.
- CONITEC. *Protocolo Clínico e Diretrizes Terapêuticas da Retinopatia Diabética*. [S.l.], 2021. Disponível em: <[https://www.gov.br/conitec/pt-br/midias/consultas/relatorios/2021/20210219\\_relatorio\\_pcdt\\_retinopatia\\_diabetica\\_cp\\_13.pdf](https://www.gov.br/conitec/pt-br/midias/consultas/relatorios/2021/20210219_relatorio_pcdt_retinopatia_diabetica_cp_13.pdf)>. Citado na página 12.
- DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; FEI-FEI, L. Imagenet: A large-scale hierarchical image database. *IEEE Conference on Computer Vision and Pattern Recognition*, 2009. Citado na página 21.
- DUTTA, S.; MANIDEEP, B.; BASHA, S. M.; CAYTILES, R. D.; IYENGAR, N. Classification of diabetic retinopathy images by using deep learning models. *International Journal of Grid and Distributed Computing*, v. 11, n. 1, p. 89–106, 2018. Citado 2 vezes nas páginas 22 e 25.
- ELSWAH, D. K.; ELNAKIB, A. A.; MOUSTAFA, H. El-din. Automated diabetic retinopathy grading using resnet. In: *2020 37th National Radio Science Conference (NRSC)*. [S.l.: s.n.], 2020. p. 248–254. Citado 2 vezes nas páginas 22 e 25.
- FRANCO, E. M.; SILVA, L. N.; ROCHA, L. D. F.; BATISTA, M. A. A.; SATHLER, Y. G.; PAIVA, L. D. T.; FRANCO, C. M. A. Revisão bibliográfica: retinopatia diabética literature review: diabetic retinopathy. *Brazilian Journal of Development [Internet]*, p. 35257–64, 2022. Citado na página 17.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT press, 2016. Citado na página 20.
- HACISOFTAOGU, R. E.; KARAKAYA, M.; SALLAM, A. B. Deep learning frameworks for diabetic retinopathy detection with smartphone-based retinal imaging systems.

*Pattern Recognition Letters*, v. 135, p. 409–417, 2020. ISSN 0167-8655. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S016786552030129X>>. Citado 2 vezes nas páginas 24 e 25.

HIRAKAWA, T. H.; COSTA, W. d. C.; NAKAHIMA, F.; FERREIRA, A. I. C.; RIBEIRO, L. B.; TICIANELI, J. G.; SEQUEIRA, B. J. Conhecimento dos pacientes diabéticos usuários do sistema único de saúde acerca da retinopatia diabética. *Revista Brasileira de Oftalmologia*, SciELO Brasil, v. 78, p. 107–111, 2019. Citado na página 16.

HOMEM, W. L.; UFES, P. E. M. Apostila de machine learning. *PET Engenharia Mecânica, UFES*, 2020. Citado na página 19.

Instituto de Retina de Campinas. *Retinopatia Diabética*. 2023. <https://www.institutoderetina.com.br/home/retinopatia-diabetica2>. Citado 2 vezes nas páginas 8 e 17.

JIN, C.; CHEN, Q.; LI, X.; LI, L.; LI, Y.; LI, H.; LI, Y.; LU, Z. Automated detection of diabetic retinopathy using deep learning algorithms: a screening tool. *BMJ open diabetes research & care*, BMJ Publishing Group Ltd, v. 7, n. 1, p. e000711, 2019. Citado na página 30.

KAGGLE. Kaggle eyepacs: Diabetic retinopathy detection. In: *Kaggle*. [s.n.], 2015. Disponível em: <<https://www.kaggle.com/c/diabetic-retinopathy-detection/data>>. Citado 2 vezes nas páginas 8 e 29.

LECUN, Y.; CORTES, C.; BURGESS, C. The mnist database of handwritten digits. <http://yann.lecun.com/exdb/mnist/>, 1998. Citado na página 21.

LIN, T.-Y.; MAIRE, M.; BELONGIE, S.; HAYS, J.; PERONA, P.; RAMANAN, D.; DOLLÁR, P.; ZITNICK, C. L. Microsoft coco: Common objects in context. *European Conference on Computer Vision*, 2014. Citado na página 21.

LUCENA, J. Diabetes mellitus tipo 1 e tipo 2. *Monografia*. São Paulo (SP): Centro Universitário das Faculdades Metropolitanas Unidas, 2007. Citado na página 16.

LUO, X.; PU, Z.; XU, Y.; WONG, W. K.; SU, J.; DOU, X.; YE, B.; HU, J.; MOU, L. *Pattern Recognition*, v. 120, p. 108104, 2021. ISSN 0031-3203. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0031320321002910>>. Citado 2 vezes nas páginas 23 e 25.

MALTA, D. C.; RIBEIRO, E. G.; GOMES, C. S.; ALVES, F. T. A.; STOPA, S. R.; SARDINHA, L. M. V.; PEREIRA, C. A.; DUNCAN, B. B.; SCHIMIDT, M. I. Indicadores da linha de cuidado de pessoas com diabetes no brasil: Pesquisa nacional de saúde 2013 e 2019. *Epidemiologia e Serviços de Saúde*, SciELO Brasil, v. 31, 2022. Citado na página 15.

MARQUES, M. V.; SANTOS, S. S. d. A. N.; LIMA, M. V. de; MATOS, M. K. de M.; PEREIRA, S. M.; AMADOR, A. E. Distribuição espacial da mortalidade por diabetes no brasil. *Saúde e Desenvolvimento Humano*, v. 8, n. 3, p. 113–122, 2020. Citado na página 15.

NEHEMY, M. B. Retinopatia diabética. *Arquivos Brasileiros de Oftalmologia*, SciELO Brasil, v. 61, p. 366–370, 1998. Citado na página 17.

- NGUYEN, Q. H.; MUTHURAMAN, R.; SINGH, L.; SEN, G.; TRAN, A. C.; NGUYEN, B. P.; CHUA, M. Diabetic retinopathy detection using deep learning. In: *Proceedings of the 4th International Conference on Machine Learning and Soft Computing*. New York, NY, USA: Association for Computing Machinery, 2020. (ICMLSC 2020), p. 103–107. ISBN 9781450376310. Disponível em: <<https://doi-org-ez17.periodicos.capes.gov.br/10.1145/3380688.3380709>>. Citado 2 vezes nas páginas 23 e 25.
- ORGANIZATION, W. H. *Global action plan for the prevention and control of NCDs 2013-2020*. Geneva: World Health Organization, 2013. ISBN 978-92-4-150623-6. Citado na página 15.
- PAIXÃO, G. M. d. M.; SANTOS, B. C.; ARAUJO, R. M. d.; RIBEIRO, M. H.; MORAES, J. L. d.; RIBEIRO, A. L. Machine learning na medicina: Revisão e aplicabilidade. *Arquivos Brasileiros de Cardiologia*, SciELO Brasil, v. 118, p. 95–102, 2022. Citado na página 18.
- PATRA, P.; SINGH, T. Diabetic retinopathy detection using an improved resnet50-inceptionv3 structure. In: *2022 13th International Conference on Computing Communication and Networking Technologies (ICCCNT)*. [S.l.: s.n.], 2022. p. 1–6. Citado 2 vezes nas páginas 22 e 25.
- PORWAL, N.; PACHADE, D.; JOSHI, A.; MISHRA, A. Idrid: Indian diabetic retinopathy image dataset. *Data in brief*, Elsevier, v. 25, p. 104130, 2019. Citado na página 28.
- SHALEV-SHWARTZ, S.; BEN-DAVID, S. *Understanding machine learning: From theory to algorithms*. [S.l.]: Cambridge University Press, 2014. Citado na página 20.
- SILVA, J. A. S. da; MAIRINK, C. H. P. Inteligência artificial. *LIBERTAS: Revista de Ciências Sociais Aplicadas*, v. 9, n. 2, p. 64–85, 2019. Citado na página 18.
- TANG, X.; HUANG, Y.; LIN, L.; LI, M.; YUAN, J. Automated diabetic retinopathy identification via lesion guided network. In: *The Fourth International Symposium on Image Computing and Digital Medicine*. New York, NY, USA: Association for Computing Machinery, 2021. (ISICDM 2020), p. 141–144. ISBN 9781450389686. Disponível em: <<https://doi-org-ez17.periodicos.capes.gov.br/10.1145/3451421.3451452>>. Citado 2 vezes nas páginas 24 e 25.
- TYMCHENKO, B.; MARCHENKO, P.; SPODARETS, D. Deep learning approach to diabetic retinopathy detection. *arXiv preprint arXiv:2003.02261*, 2020. Citado na página 29.
- UMAPATHY, A.; SREENIVASAN, A.; NAIRY, D. S.; NATARAJAN, S.; RAO, B. N. Image processing, textural feature extraction and transfer learning based detection of diabetic retinopathy. In: *Proceedings of the 2019 9th International Conference on Bioscience, Biochemistry and Bioinformatics*. New York, NY, USA: Association for Computing Machinery, 2019. (ICBBB '19), p. 17–21. ISBN 9781450366540. Disponível em: <<https://doi-org-ez17.periodicos.capes.gov.br/10.1145/3314367.3314376>>. Citado 2 vezes nas páginas 23 e 25.

---

WANG, X.; LU, Y.; WANG, Y.; CHEN, W.-B. Diabetic retinopathy stage classification using convolutional neural networks. In: *2018 IEEE International Conference on Information Reuse and Integration (IRI)*. [S.l.: s.n.], 2018. p. 465–471. Citado 2 vezes nas páginas 22 e 25.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA  
“JOSÉ ALBANO DE MACEDO”**

**Identificação do Tipo de Documento**

- ( ) Tese  
( ) Dissertação  
( X ) Monografia  
( ) Artigo

Eu, **Francisco Nathanael da Silva Rêgo**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação **“Revisão Sistemática das Técnicas Mais Utilizadas na Identificação de Retinopatia Diabética”** de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 25 de Março de 2023.

---

Assinatura

---

Assinatura