



Faculdade de Medicina de São José do Rio Preto
Programa de Pós-Graduação em Ciências da Saúde

CAMILA BRANDÃO FANTOZZI

**PROPOSTAS DE ALGORITMOS DE
INTELIGÊNCIA ARTIFICIAL PARA
SCREENING DE EDEMA MACULAR
DIABÉTICO**

São José do Rio Preto

2024

CAMILA BRANDÃO FANTOZZI

**PROPOSTAS DE ALGORITMOS DE
INTELIGÊNCIA ARTIFICIAL PARA
SCREENING DE EDEMA MACULAR
DIABÉTICO**

Tese apresentada à Faculdade de Medicina de São José do Rio Preto para obtenção do Título de Doutora no Curso de Pós-Graduação em Ciências da Saúde. Eixo Temático: Medicina e Ciências Correlatas.

Orientador: Prof. Dr. Rubens Camargo Siqueira

São José do Rio Preto

2024

Fantozzi, Camila Brandão

Propostas de Algoritmos de Inteligência Artificial para *Screening* de Edema Macular Diabético / Camila Brandão Fantozzi. – São José do Rio Preto, 2024.

67 p.

Tese (Doutorado) – Faculdade de Medicina de São José do Rio Preto, FAMERP, 2024.

Eixo Temático: Medicina e Ciências Correlatas.

Orientador: Prof. Dr. Rubens Camargo Siqueira

1. Predição; 2. Inteligência Artificial; 3. Edema de Mácula;
4. Paraconsistent Feature Engineering

Camila Brandão Fantozzi

**PROPOSTAS DE ALGORITMOS DE
INTELIGÊNCIA ARTIFICIAL PARA *SCREENING*
DE EDEMA MACULAR DIABÉTICO**

**BANCA EXAMINADORA
TESE PARA OBTENÇÃO DO GRAU DE DOUTOR**

Presidente e Orientador: Prof. Dr. Rubens Camargo Siqueira

2º Examinador: Prof. Dr. Rodrigo Capobianco Guido

3º Examinador: Prof. Dr. Rafael Cardoso Oliveira

4º Examinador: Prof. Dr. Daniel da Rocha Lucena

5º Examinador: Profa. Dra. Luciene Cavalcanti Rodrigues

Suplente: Prof. Dr. João Paulo Lemos Escola

Suplente: Profa. Dra. Carolina Assis Pereira Vilela

São José do Rio Preto, 16 / 08 / 2024.

SUMÁRIO

Agradecimentos	i
Lista de Figuras	ii
Lista de Tabelas	iii
Resumo	iv
Abstract	v
1 Introdução	1
1.1 Contextualização	1
1.2 Justificativa do Estudo	1
1.3 Objetivos	2
2 Revisão da Literatura	4
3 Material e Método	15
4 Resultados	33
5 Discussão	46
6 Conclusões	50
Referências Bibliográficas	51

Agradecimentos

Primeiramente, agradeço ao meu orientador Prof. Dr. Rubens Siqueira por me acolher e mostrar o melhor caminho.

Ao Prof. Dr. Rodrigo Capobianco Guido por toda orientação, auxílio, colaboração e aprendizado compartilhado durante toda a jornada acadêmica.

Aos meus pais, pelo apoio ao longo de toda a minha vida e cuidados com a minha filha Eloísa.

Ao meu marido e filha cujo amor, cuidado e diversão têm sido fundamentais para meu bem-estar e sucesso nesta jornada acadêmica.

Aos meus amigos Lidiana, Valter, Rafael, ao meu primo Arthur e ao Jogi sou grata a todos pelo incentivo, conversas produtivas e dicas que contribuíram significativamente para o meu desenvolvimento acadêmico.

A minhas tias, Sandra (*in memoriam*) pelo incrível incentivo dado aos meus estudos. E Cinara, seu apoio e confiança foram essenciais.

Por fim, agradeço de coração a todos aqueles que, de forma direta ou indireta, contribuíram nos meus estudos. Todas as colaborações foram fundamentais nesta conquista.

Lista de Figuras

1	O OCT em uso, e imagem-exemplo de um exame sem EMD.	3
2	A sequência de passos para o método proposto, a qual caracteriza o Algoritmo <i>AlgEdema</i>	15
3	Imagem-exemplo de um exame OCT, com EMD.	16
4	Imagens capturadas durante um exame OCT.	16
5	Quadro de Snellen ⁽²⁷⁾ , usado durante os exames da retina.	17
6	O Plano Paraconsistente onde as variáveis G_1 e G_2 estão destacadas. .	22
7	SVM utilizada como técnica <i>knowledge-based</i> de identificação dos padrões.	24
8	Exemplo genérico de regressão logística para um caso de dimensão 2. A curva casa aproximadamente aos pontos em azul, minimizando o erro quadrático médio ⁽³⁴⁾	28
9	Importação de algumas bibliotecas em linguagem Python.	28
10	Preparação e pré-processamento dos dados.	29
11	Transformando a classe-fenótipos.	29
12	Código do treinamento do modelo SVM com as 26 <i>features</i> originais. . .	29
13	Código do treinamento do modelo SVM com quatro <i>features</i> selecionadas pela PFE.	30
14	Dados normativos para espessura da retina em vários subcampos do ETDRS ⁽³⁵⁾	30
15	Um exemplo de ETDRS 9 do olho esquerdo, baseado na Figura 14. . .	31
16	Código de algumas métricas de validação e apresentação dos resultados. .	32
17	Curva ROC-AUC, modelo SVM e KNN com 26 <i>features</i> e dois fenótipos. . .	43
18	Curva ROC-AUC, modelo SVM com quatro <i>features</i> (PFE) e dois fenótipos. .	43
19	Curva ROC-AUC, modelo SVM com 26 <i>features</i> e seis fenótipos.	44
20	Curva ROC-AUC, modelo SVM com quatro <i>features</i> (PFE) e seis fenótipos. .	45

Lista de Tabelas

1	Conjunto de 26 <i>features</i> utilizadas neste trabalho: acrônimos e seus significados	20
2	Conjunto de 26 <i>features</i> utilizadas neste trabalho, com exemplo de dados coletados de acordo com o número de ordem constante na Tabela 1. Com relação aos diagnósticos, isto é, a <i>feature</i> com número de ordem 14, as 8 primeiras linhas correspondem a casos normais, as quatro próximas correspondem a casos normais com anomalias, as quatro seguintes a casos N-MER, as quatro na sequência a casos S, seguidas de quatro casos S-MER e, finalmente, quatro casos S-PERIFOVEAL. . . .	21
3	Acrônimos, Fenótipos e quantidades utilizadas no cenário 1	33
4	Matriz Confusão SVM e KNN para 26 <i>features</i> e dois fenótipos	34
5	Desempenho dos Modelos no Cenário 1: dois fenótipos/classes	35
6	Matriz Confusão SVM para quatro <i>features</i> (PFE) e dois fenótipos	36
7	Matriz Confusão LR para quatro <i>features</i> (PFE) e dois fenótipos	36
8	Métricas estatísticas	37
9	Acrônimos, Fenótipos e quantidades utilizadas no cenário 2	38
10	Matriz Confusão SVM para 26 <i>features</i> e seis fenótipos	38
11	Matriz Confusão LR para quatro <i>features</i> (PFE) e seis fenótipos	39
12	Matriz Confusão SVM para quatro <i>features</i> (PFE) e seis fenótipos	40
13	Métricas estatísticas	40
14	Desempenho dos Modelos no Cenário 2: seis fenótipos/classes	42

Resumo

Introdução: O Edema Macular Diabético (EMD), um inchaço na área central da retina resultante da oclusão vascular, é uma das consequências da retinopatia diabética (RD). No entanto, ferramentas atuais utilizadas para seu diagnóstico, como a Tomografia de Coerência Óptica (OCT), que traz em seu contexto dados para auxiliar no diagnóstico de doenças maculares e glaucoma, requerem experiência médica significativa para a confirmação dos fenótipos. Por isso, ferramentas de Inteligência Artificial (IA) para apoiar a tomada de decisão em tal contexto são naturalmente bem-vindas. **Objetivos:** Desse modo, a intenção da autora deste trabalho é a de descrever uma nova estratégia baseada em Inteligência Artificial (IA) para apoiar a detecção e o pré-diagnóstico de EMD, analisando características oriundas da Tomografia de Coerência Óptica (OCT) utilizando a *Paraconsistent Feature Engineering* (PFE). **Materiais e Métodos:** Foram analisados subconjuntos de 21 características descritas no *OCT setting Macula Map A X-Y*, além da acuidade visual, do parâmetro diagnóstico, da idade, da indicação do olho sob análise e do gênero, totalizando 26 características, num total de 700 exames, divididos em dois cenários, com duas ou seis classes, isto é, fenótipos diferentes. Especificamente, baseado na PFE e na comparação dos classificadores *Support Vector Machine* (SVM), *K-Nearest Neighbourhoods* (KNN), *Decision Trees* (DTREE) e *Logistic Regression* (LR), para formular uma estratégia que visa ajudar os clínicos no pré-diagnóstico do EMD. **Resultados:** A análise baseada em PFE encontrou efetivamente características representativas dominantes que permitiram acurácias de classificação relevantes com base na SVM. **Conclusão:** Os resultados obtidos comprovam a possibilidade do uso da PFE na detecção automática inteligente do EMD, em função da seleção provida nas características pela PFE, provendo uma contribuição ao estado-da-arte na área.

Palavras-chaves: 1. Predição; 2. Inteligência Artificial; 3. Edema de Mácula; 4. *Paraconsistent Feature Engineering*

Abstract

Introduction: Diabetic Macular Edema (EMD), a swelling in the central area of the retina resulting from vascular occlusion, is one of the consequences of diabetic retinopathy (RD). However, current tools used for its diagnosis, such as Optical Coherence Tomography (OCT), which provides data to aid in the diagnosis of macular diseases and glaucoma, require significant medical expertise to confirm phenotypes. Therefore, Artificial Intelligence (IA) tools to support decision-making in such a context are naturally welcome. **Objectives:** Thus, the intention of the author of this work is to describe a new strategy based on Artificial Intelligence (IA) to support the detection and pre-diagnosis of EMD, analyzing features originating from Optical Coherence Tomography (OCT) using *Paraconsistent Feature Engineering* (PFE). **Materials and Methods:** Subsets of 21 features described in the *OCT setting Macula Map A X-Y* were analyzed, in addition to visual acuity, diagnostic parameter, age, indication of the eye under analysis and gender, totaling 26 features, in a total of 700 exams, divided into two scenarios, with two or six classes, that is, different phenotypes. Specifically, based on the EFP and the comparison of the *Support Vector Machine* (SVM), *K-Nearest Neighbourhoods* (KNN), *Decision Trees* (DTREE) and *Logistic Regression* (LR), to formulate a strategy that aims to help clinicians in the pre-diagnosis of EMD. **Results:** The PFE-based analysis effectively found dominant representative features that allowed relevant classification accuracies based on SVM. **Conclusion:** The results obtained prove the possibility of using PFE in the intelligent automatic detection of EMD, due to the selection provided in the features by PFE, providing a contribution to the state-of-the-art in the area.

Keywords: 1. Prediction; 2. Artificial Intelligence; 3. Macula Edema;
4. *Paraconsistent Feature Engineering*

1 Introdução

1.1 Contextualização

O Edema Macular (EM), inchaço na região central da retina devido à oclusão vascular, é uma das complicações da retinopatia diabética (RD). Consequentemente, o Edema Macular Diabético (EMD) é caracterizado por espessamento da retina e acúmulo de líquido intrarretiniano causado por permeabilidade vascular anormal e vazamento na retinopatia diabética e *diabetes mellitus*. É uma das principais causas de cegueira entre adultos em idade ativa. Resultante do excesso prolongado de açúcar no sangue, forçando os vasos sanguíneos oculares a absorver mais líquido, o EMD já afetou milhares de pessoas no mundo todo ⁽¹⁾.

Apesar do número expressivo de indivíduos portadores de EMD, as ferramentas atuais utilizadas para seu diagnóstico, como a Tomografia de Coerência Óptica (OCT) e seu pacote de *software* associado, são capazes de oferecer apenas dados de apoio para o médico estudar e fundamentar uma decisão. Aproveitando da revisão das técnicas de Inteligência Artificial (IA) atualmente disponíveis, realizada por Shahriari et al. ⁽²⁾

O presente trabalho visa detectar o EMD por uma abordagem inovadora.

1.2 Justificativa do Estudo

A possibilidade de utilizar métodos de IA para o pré-diagnóstico do EMD é, claramente, de extrema valia para melhorar a qualidade de vida das pessoas que convivem com a referida condição patológica. Além disso, observa-se que as es-

timativas fornecidas pelos métodos tradicionais, ou seja, os parâmetros oriundos do OCT, colocam toda a interpretação nas mãos do profissional de saúde que lida com o diagnóstico. Desse modo, a pesquisa proposta, abrindo caminho para aplicar estratégias de IA na solução de um problema de interesse para a Oftalmologia, constitui uma contribuição relevante na área. Adicionalmente, o uso de uma base de dados oriunda de centenas de exames realizados com o OCT permite assegurar a realização da pesquisa. (Figura 1) Sobretudo, evita a perda de sequência nos segmentos do trabalho em função da falta de controle sob a dedicação e colaboração dos pacientes envolvidos.

Portanto, é altamente desejável conseguir uma estratégia de IA para realizar classificações no âmbito dos tratamentos oftalmológicos. Entretanto, observa-se que tais diagnósticos têm sido concentrados no escopo da análise clínica e, desse modo, diferentemente das técnicas atualmente utilizadas e com base na Engenharia Paraconsistente de Características (PFE) ⁽³⁾, pode-se aplicar e comparar diferentes modelos inteligentes que poderão auxiliar no pré-diagnóstico do EMD.

1.3 Objetivos

O objetivo deste estudo é estabelecer qual dos modelos inteligentes baseados na Engenharia Paraconsistente de Características (PFE) podem ser aplicados em casos de EMD e, também, comparar os modelos inteligentes na caracterização do pré-diagnóstico de EMD.

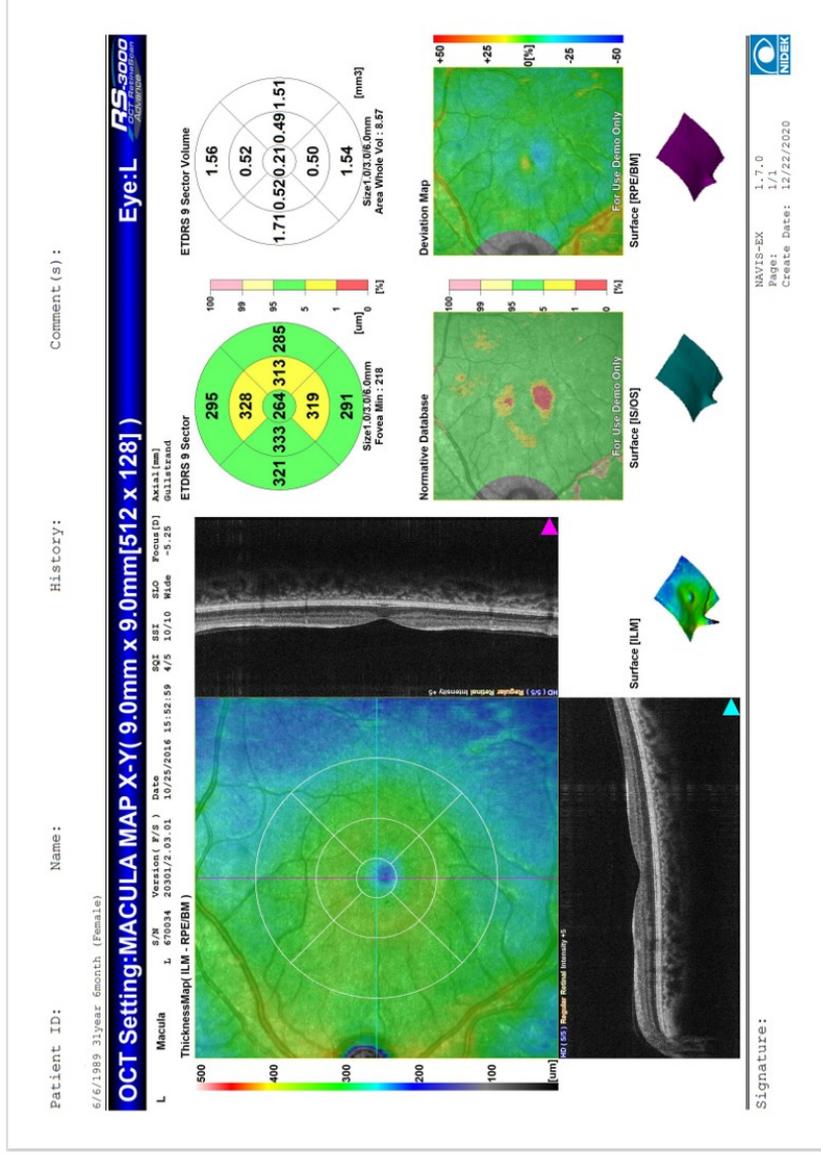


Figura 1: O OCT em uso, e imagem-exemplo de um exame sem EMD.

2 Revisão da Literatura

Visando viabilizar esta revisão de literatura, registra-se que foi realizada a busca por artigos científicos, publicados a partir de 2016 em periódicos nacionais e internacionais da área de Oftalmologia, em bases de dados, incluindo *Periódicos da CAPES*, *Google Acadêmico*, *PubMed* e no *Clarivate Analytics*. A pesquisa retornou diversos registros cujos temas específicos envolvem uma variedade de áreas dentro da Oftalmologia, como classificação de retinopatias, edema macular diabético, glaucoma e retinite toxoplásmica. Além disso, foram abordados tópicos relacionados ao desenvolvimento de algoritmos de inteligência artificial e aprendizado de máquina para diagnóstico e classificação de doenças oculares, engenharia de recursos paraconsistentes, padronização de medidas clínicas e análise de dados biomédicos. No entanto, nenhum dos artigos encontrados trata do pré-diagnóstico do EMD com base na PFE. Apesar dessa lacuna, apresenta-se a seguir um resumo dessas abordagens científicas.

No início da revisão de literatura, Gulshan et al. (2016) objetivaram aplicar aprendizado profundo para criar um algoritmo que detecte automaticamente retinopatia diabética e edema macular diabético em fotografias de fundo de retina.⁽⁴⁾ Os autores utilizaram redes neurais convolucionais profundas para classificar imagens de retina, centradas na mácula, foram coletadas retrospectivamente de fontes nos EUA e Índia, resultando em um conjunto de desenvolvimento de 128.175 imagens. A validação ocorreu em dois conjuntos de dados: EyePACS-1 (9.963 imagens) e Messidor-2 (1.748 imagens). O algoritmo mostrou alta sen-

sibilidade (90,3% a 97,5%) e especificidade (93,4% a 98,5%) na detecção de retinopatia diabética referenciável e edema macular.

Em revisão realizada por Fenner et al., em 2018, objetivaram explorar e avaliar técnicas automatizadas de avaliação de imagens para a detecção de retinopatia diabética (RD).⁽⁵⁾ Foram utilizadas redes neurais convolucionais (CNNs) dentro do campo de *deep learning* (DL) para interpretar imagens retiniais, comparando os resultados com classificadores humanos e ajustando automaticamente em caso de erro. As características do estudo incluem a aplicação de DL para identificar RD referível sem necessidade de pré-programação de características específicas da RD. Incluem algoritmos de DL capazes de detectar características como microaneurismas em imagens de fundo de olho. O tamanho da base de dados utilizada é substancial, aproveitando conjuntos de dados multiétnicos para o treinamento e teste dos algoritmos. Os resultados alcançados são notáveis, com sensibilidades e especificidades geralmente superiores a 90% e 95%, respectivamente. A precisão preditiva negativa dos algoritmos atuais para detecção de RD é superior a 99%, indicando uma probabilidade inferior a 1% de falha na detecção de RD grave, retinopatia diabética proliferativa (RDP) ou edema macular (EMD). Além disso, alguns algoritmos foram testados com sucesso na detecção de outras doenças oculares, como glaucoma e degeneração macular relacionada à idade (AMD).

Ahuja e Halperin (2019) avaliaram a aplicação da Inteligência Artificial (IA) na Oftalmologia, especialmente, em doenças da retina como a retinopatia diabética (RD) e a degeneração macular relacionada à idade (DMRI), utilizando-se

de técnicas de aprendizado profundo (*deep learning* - DL) para análise de imagens de tomografia de coerência óptica (OCT).⁽⁶⁾ Em adição, permitindo identificar, localizar e quantificar características patológicas, utilizando-se de técnicas que incluem redes neurais convolucionais (CNN) que, através de múltiplas camadas, aprendem a detectar padrões em grandes conjuntos de dados de imagem. Os classificadores utilizados são baseados em modelos de DL que extraem e classificam características diretamente das imagens. A base de dados varia conforme o estudo, mas geralmente envolve milhares de imagens OCT rotuladas para treinar e validar os modelos. Por exemplo, um estudo de Kim et al. (2017) utilizaram três tipos de registros (camada de fibras nervosas da retina, parâmetros de campo visual e exame oftalmológico geral) para atingir alta precisão na classificação de glaucoma.⁽⁷⁾ Os resultados alcançados demonstram alta precisão e especificidade dos modelos de IA na detecção e classificação de doenças oculares. Modelos como o desenvolvido por Ahn et al. (2018) alcançaram uma precisão de 92,2% apenas com fotografias de fundo de olho, mostrando grande potencial para a triagem em larga escala e assistência no diagnóstico por oftalmologistas.⁽⁸⁾

Em 2019 Ting et al. apresentaram uma revisão abrangente dos avanços em sistemas de aprendizado profundo (DL) aplicados à oftalmologia. Discute-se o potencial desses sistemas para revolucionar o diagnóstico e a triagem de condições oculares, como RD e DMRI.⁽⁹⁾ A implementação de Redes Neurais Convolucionais (CNNs - *Convolutional Neural Networks*) é destacada por sua capacidade de classificar doenças oculares com precisão através da análise de

imagens de fundo de olho e tomografia de coerência óptica (OCT). O texto detalha o uso de conjuntos de dados significativos, como EyePACS-1 e Messidor-2, e enfatiza o treinamento e teste do sistema de DL em um conjunto diversificado de mais de 100.000 imagens de retina de várias etnias. Os resultados demonstram que os sistemas de DL alcançaram um desempenho diagnóstico clinicamente viável, evidenciado por sua alta sensibilidade e especificidade na identificação de doenças oculares significativas.

Kuwayama et al. em 2019, empregaram técnicas de aprendizado profundo com redes neurais convolucionais (CNN) para analisar imagens de OCT para a detecção automatizada de doenças coriorretinianas, o estudo incluem a utilização de 1.200 imagens de OCT diagnosticadas por um especialista em retina.⁽¹⁰⁾ Destas, 1.100 imagens foram usadas para treinamento, aumentadas para 59.400 através de técnicas de espelhamento horizontal, rotação e translação. As 100 imagens restantes foram usadas para avaliar o modelo treinado. Os classificadores utilizados são modelos CNN treinados para identificar e classificar características patológicas em imagens de OCT. A base de dados inclui imagens de OCT de olhos normais e com diversas doenças maculares, como degeneração macular relacionada à idade (AMD), retinopatia diabética (RD) e membranas epirretinianas (ERM). Os resultados alcançados mostraram que o modelo de detecção automatizada de doenças acertou a doença candidata principal em 83% das imagens e a segunda candidata em 7%. A precisão e o *recall* do modelo CNN variaram entre 0,75 e 1,00 para diferentes doenças, demonstrando a viabilidade do uso de IA para a detecção automatizada de doenças maculares a partir

de imagens de OCT.

Diferentemente, Cabanes et al. forneceram valores de referência para a espessura das camadas maculares, utilizando o Algoritmo de Polo Posterior (PPA) do dispositivo Spectralis SD-OCT, analisando as correlações com idade, gênero e comprimento axial.⁽¹¹⁾ A técnica utilizada foi a Tomografia de Coerência Óptica (OCT) com o PPA, que permite a segmentação automática das camadas maculares. A base de dados foi composta por 300 olhos de sujeitos saudáveis, com idades entre 18 e 84 anos. Os resultados mostraram correlações negativas significativas entre a idade e a espessura da maioria das camadas maculares.

No trabalho apresentado por Liu et al. em 2021, validaram um sistema de aprendizagem profunda (DLS) para detectar Edema Macular Diabético (EMD) em fotografias de fundo de olho coloridas (CFP), utilizando como referência a espessura da retina e a presença de fluido obtidos por OCT tridimensional.⁽¹²⁾ O DLS foi desenvolvido e treinado com conjuntos de dados da Tailândia, Reino Unido e Estados Unidos. E uma validação foi realizada utilizando 3.060 olhos únicos de 1.582 pacientes em populações de triagem da Austrália, Índia e Tailândia, e, separadamente, validado em populações de triagem com 698 olhos de 537 pacientes do Reino Unido. Em comparação com especialistas, o DLS demonstrou maior especificidade (80%) e sensibilidade (81%) em um conjunto de dados abrangendo vários países; especificidade (80%) e sensibilidade (100%) em dados do Reino Unido. Conclui-se que o DLS supera especialistas na detecção de EMD, reduzindo encaminhamentos falso-positivos e aliviando a carga sobre os cuidados oftalmológicos especializados.

A colaboração internacional do grupo de trabalho para a padronização da nomenclatura de Uveíte (SUN) tem como principal objetivo determinar critérios de classificação para a retinite toxoplásmica utilizando aprendizado de máquina para analisar casos de retinites posteriores infecciosas e panuveítes infecciosas.⁽¹³⁾ A principal técnica utilizada foi o aprendizado de máquina, especificamente, a regressão logística multinomial, a coleta e seleção de casos foram inseridas em um banco de dados preliminar e revisadas para seleção no banco de dados final utilizando técnicas de consenso formal. Apenas casos com supermaioria (> 75%) foram mantidos. O banco de dados final foi separado em conjuntos de treinamento ($\approx 85\%$) e validação ($\approx 15\%$), para o aprendizado de máquina. A base de dados consistiu em 803 casos de uveítes posteriores infecciosas/panuveítes, incluindo 174 casos de retinite toxoplásmica. Destes, 213 casos de retinite toxoplásmica foram coletados, e 174 (82%) alcançaram supermaioria no acordo do diagnóstico e foram utilizados na fase de aprendizado de máquina. Nos resultados, a precisão geral para uveítes posteriores infecciosas/panuveítes foi de 92,1% no conjunto de treinamento e 93,3% no conjunto de validação, mostrando a eficácia do uso de aprendizado de máquina para este propósito.

Com os objetivos de padronizar valores para espessura e volume retiniano e espessura coroidal, e analisar a relação desses parâmetros com idade, sexo e comprimento axial do globo ocular na população brasileira. O trabalho apresentado por Lucena em 2023, utilizou-se da OCT de domínio espectral (SD-OCT) para medições não invasivas e confiáveis da retina e coroide.⁽¹⁴⁾ A amostra incluiu indivíduos voluntários, entre 18 e 70 anos de idade, divididos por faixa

etária, sendo 211 indivíduos (102 homens e 109 mulheres), com medidas de espessura e volume da retina e espessura da coroide. Os dados foram analisados em relação a variáveis como idade, sexo e comprimento axial do globo ocular (AXL). Nos resultados, os homens apresentaram espessura e volume de retina maiores que mulheres. A espessura e volume da retina tendem a diminuir com a idade, exceto no subcampo central. A espessura da coroide também diminuiu com a idade e com AXL maiores.

Avaliar a precisão diagnóstica da quantificação automatizada do volume de fluido macular central (CMFV) utilizando tomografia de coerência óptica (OCT) para o edema macular diabético (EMD), foi o objetivo de You et al. (2021) onde envolveram a aplicação de um algoritmo de aprendizado profundo para quantificar automaticamente os volumes de fluido em varreduras volumétricas de angiografia OCT (6×6 mm), totalizando 215 pacientes com diabetes, dos quais um olho de cada paciente foi examinado, os resultados mostraram que o volume de fluido macular central (CMFV) quantificado por aprendizado profundo apresentou uma área sob a curva ROC (AUROC) mais alta em comparação com a espessura do subcampo central (CST) para o diagnóstico de EMD.⁽¹⁵⁾ Isso sugere que a quantificação automatizada do volume de fluido é um modelo melhor para identificar EMD em comparação com a medição da espessura do subcampo central.

Wang et al. empregaram a técnica de DeepLab, combinada com OCT, para identificar com precisão as áreas afetadas pelo edema, com objetivo de desenvolver e avaliar um método automatizado de segmentação de edema macular utilizando redes neurais profundas. As principais características do estudo in-

cluem a utilização de imagens OCT para treinar, validar e testar os modelos, com um total de 5676 imagens, distribuídas em 3460 imagens para a fase de treinamento, 1163 para validação e 1053 para testes.⁽¹⁶⁾ Os resultados demonstraram que o OCT-DeepLab superou os métodos tradicionais de segmentação, como os modelos C-V e SBG, em métricas de precisão, sensibilidade, especificidade e F1-score. O OCT-DeepLab obteve uma precisão de 95.79%, sensibilidade de 95.16%, especificidade de 97.31% e F1-score de 95.43%, evidenciando uma performance superior na segmentação automática de edema macular.

Varadarajan et al. (2020) utiliza aprendizado profundo com a rede neural convolucional Inception-v3 para prever edema macular diabético de envolvimento central (ci-EMD) a partir de fotografias de fundo de olho obtidas por OCT.⁽¹⁷⁾ Esse avanço é significativo, pois permite uma previsão precisa do grau de ci-EMD diretamente a partir de imagens monoscópicas do fundo ocular, aprimorando a eficiência e a precisão no diagnóstico de condições oculares graves.

No trabalho de Moraes et al., um algoritmo de aprendizado profundo, fazendo uma análise quantitativa de OCT para uma doença de retina, chamada degeneração macular relacionada à idade neovascular e utilizando também a acuidade visual, destaca a importância de segmentar recursos diferentes na varredura de volume de OCT.⁽¹⁸⁾

No estudo de Almeida Jr. et al. (2021), o ceratocone, uma doença corneana progressiva multifatorial, caracterizada patologicamente por fatores-chave genéticos, bioquímicos e ambientais e, conseqüentemente, a ectasia corneana (EC) é caracterizada por uma distorção progressiva da curvatura da córnea, num total

de 777 amostras, utilizando um conjunto de 52 características fornecidas pelo Pentacam, utilizando-se de uma nova estratégia de Inteligência Artificial (IA) baseada na PFE e *Support Vector Machine* (SVM), mostrando total eficácia no auxílio ao diagnóstico auxiliado por IA.⁽¹⁹⁾

Adicionalmente, registra-se que alguns artigos investigaram o impacto da IA na oftalmologia, abordando tanto as aplicações atuais quanto as perspectivas futuras. Os autores exploram amplamente as aplicações da IA em diagnósticos retinianos e inovações futuras.^(20,21) No mesmo sentido, o estudo de Sengupta et al. focaram no uso de *deep learning* em imagens de fundo de olho, criticando suas limitações e destacando seu potencial diagnóstico.⁽²²⁾ Teikari et al. abordaram a integração de *deep learning* em dispositivos de imagem oftalmológica, melhorando a precisão diagnóstica em tempo real.⁽²³⁾

O estudos concentraram-se na aplicação da IA para o edema macular diabético, destacando avanços na medicina de precisão e classificação de risco.^(24,25) Estes compartilham pontos comuns significativos em relação à metodologia e aos modelos utilizados na aplicação da IA na oftalmologia. Todos eles empregam técnicas de *deep learning*, tais como redes neurais convolucionais (CNNs), para analisar imagens oftalmológicas, aproveitando a capacidade dessas redes de processar e interpretar dados visuais com alta precisão. Sengupta et al.⁽²²⁾ e Wu et al.⁽²⁵⁾ destacaram a eficácia das CNNs na detecção e classificação de condições oftalmológicas a partir de imagens de fundo de olho. Tais estudos utilizam grandes bases de dados de imagens retinianas para treinar e validar os modelos de IA, garantindo a robustez e a generalização dos resultados.

Nos estudos revisados, a validação cruzada é comumente utilizada para avaliar a performance dos modelos, assegurando a confiabilidade dos resultados obtidos. Apesar desses pontos em comum, os artigos diferem significativamente em seus focos específicos e nas particularidades metodológicas. Enquanto Schmidt-Erfurth et al. ⁽²⁰⁾ e Hogarty et al. ⁽²¹⁾, por exemplo, ofereceram uma visão abrangente das aplicações da IA na Oftalmologia, abordando uma ampla gama de condições oftalmológicas e tecnologias, Longhui et al. ⁽²⁴⁾ e Wu et al. ⁽²⁵⁾ focam especificamente no edema macular diabético, aplicando metodologias de IA para Medicina de precisão e classificação de risco. Complementarmente, Hogarty et al. (2020) exploraram o uso de *smartphones* como dispositivos clínicos, analisando sua viabilidade técnica e aceitação clínica; aspectos que diferem dos demais estudos.⁽²⁶⁾

Diante da Revisão Bibliográfica apresentada, após uma análise detalhada da atual literatura acadêmica nota-se que não há precedentes da abordagem específica da aplicação de modelos de IA para o pré-diagnóstico de EMD com base na PFE. A pesquisa proposta não apenas preenche uma lacuna significativa no conhecimento científico atual, mas também representa um avanço substancial nas metodologias de diagnóstico precoce de condições oftalmológicas complexas. Ao explorar novas possibilidades para a detecção e avaliação do EMD; este trabalho contribui de maneira singular para o campo da Oftalmologia e da IA. Além disso, os resultados esperados desta tese podem abrir novas perspectivas para o uso de Inteligência Artificial na área médica, oferecendo uma ferramenta eficaz e acessível para profissionais de saúde. A inovação reside não apenas

na abordagem metodológica, mas também na capacidade de integrar tecnologias avançadas para melhorar os resultados clínicos e a qualidade de vida dos pacientes. Desse modo, a aplicação e comparação dos modelos de IA experimentados neste estudo, objetivando o pré-diagnóstico do EMD com base na PFE é, de fato, inovadora, conforme descrito doravante.

3 Material e Método

Neste Capítulo, são apresentados os Materiais e Métodos especialmente utilizados para a construção da técnica proposta. As explicações estão complementadas por meio de algoritmos, diagramas, figuras, tabelas e outros elementos gráficos.

O algoritmo projetado para processar e classificar o conjunto de dados disponíveis, detalhados a seguir, foi chamado de *AlgEdema*, conforme apresentado adiante, ilustrado na Figura 2 e detalhado na sequência.

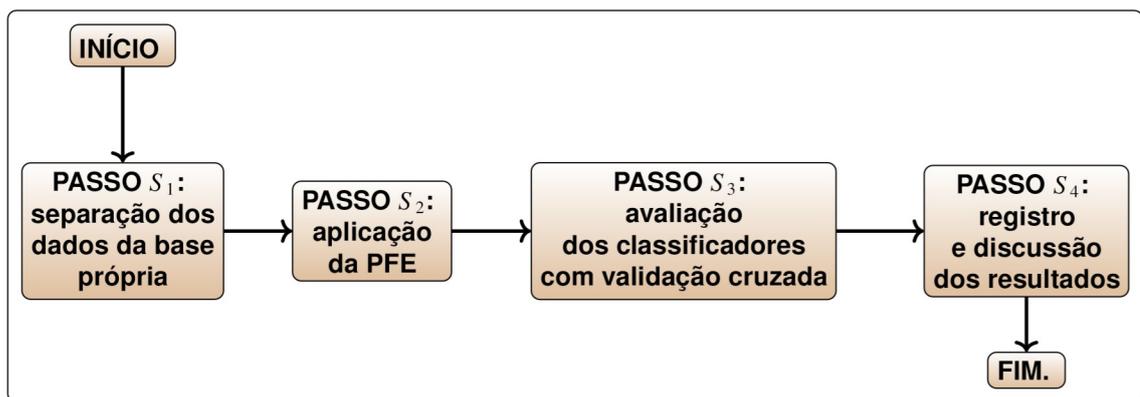


Figura 2: A sequência de passos para o método proposto, a qual caracteriza o Algoritmo *AlgEdema*.

Para executar o Algoritmos *AlgEdema*, a base de dados associada a ele conta com 700 instâncias, ou seja, exames, e 26 atributos, isto é, *features* para cada instância. Os exames do Centro de Pesquisa Rubens Siqueira, foram previamente laudados pelo orientador deste trabalho, Prof. Dr. Rubens Siqueira, assim como, pela sua equipe, com base nas imagens oriundas do Tomógrafo de Coerência Óptica da Nidek, modelo RS-3000 Advance 2, conforme ilustrado nas Figuras 3, 4 e 5.

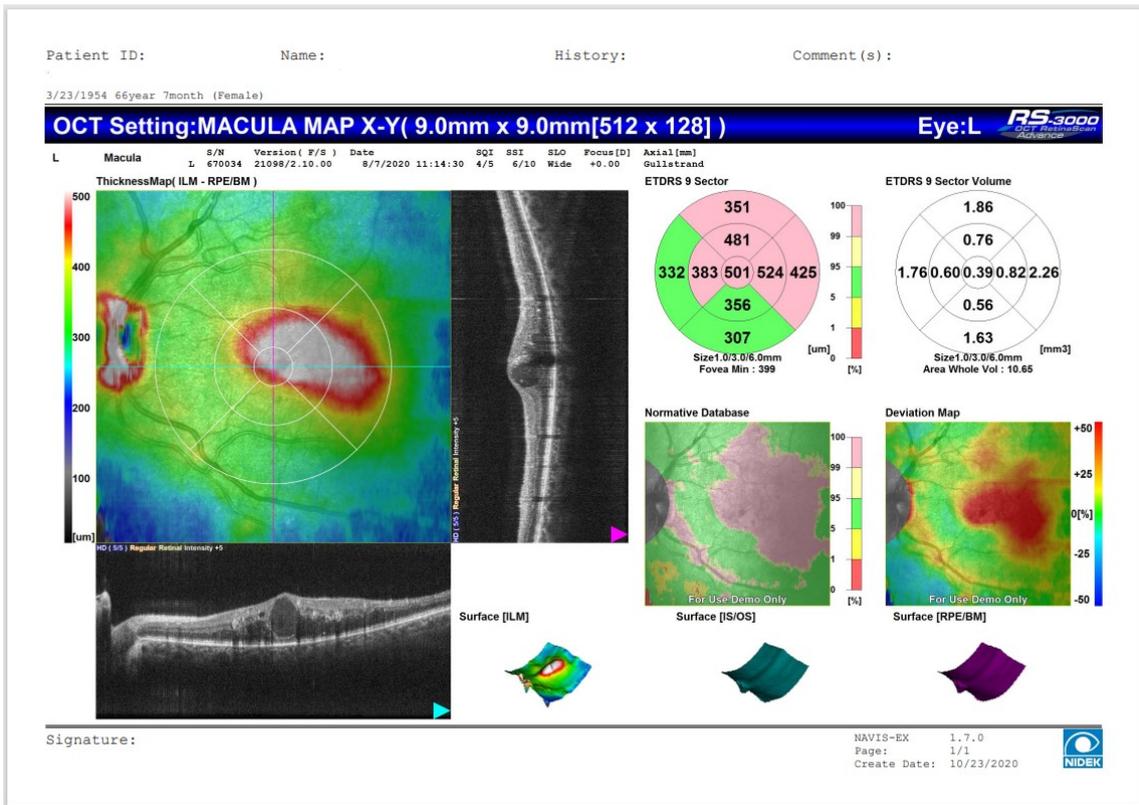


Figura 3: Imagem-exemplo de um exame OCT, com EMD.

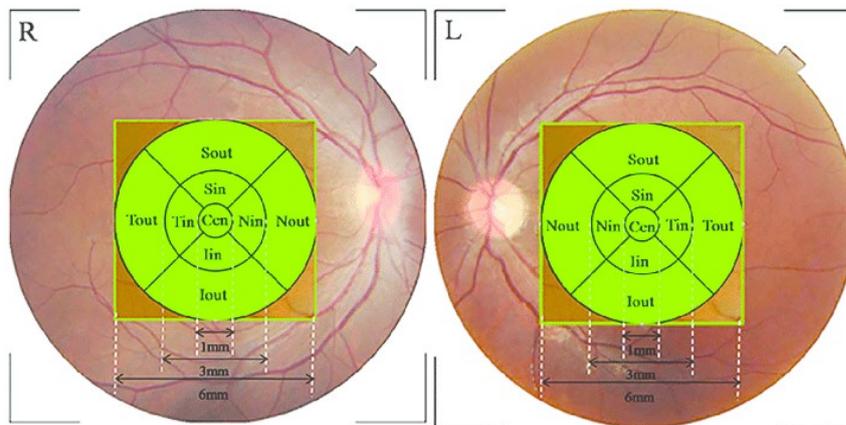


Figura 4: Imagens capturadas durante um exame OCT.

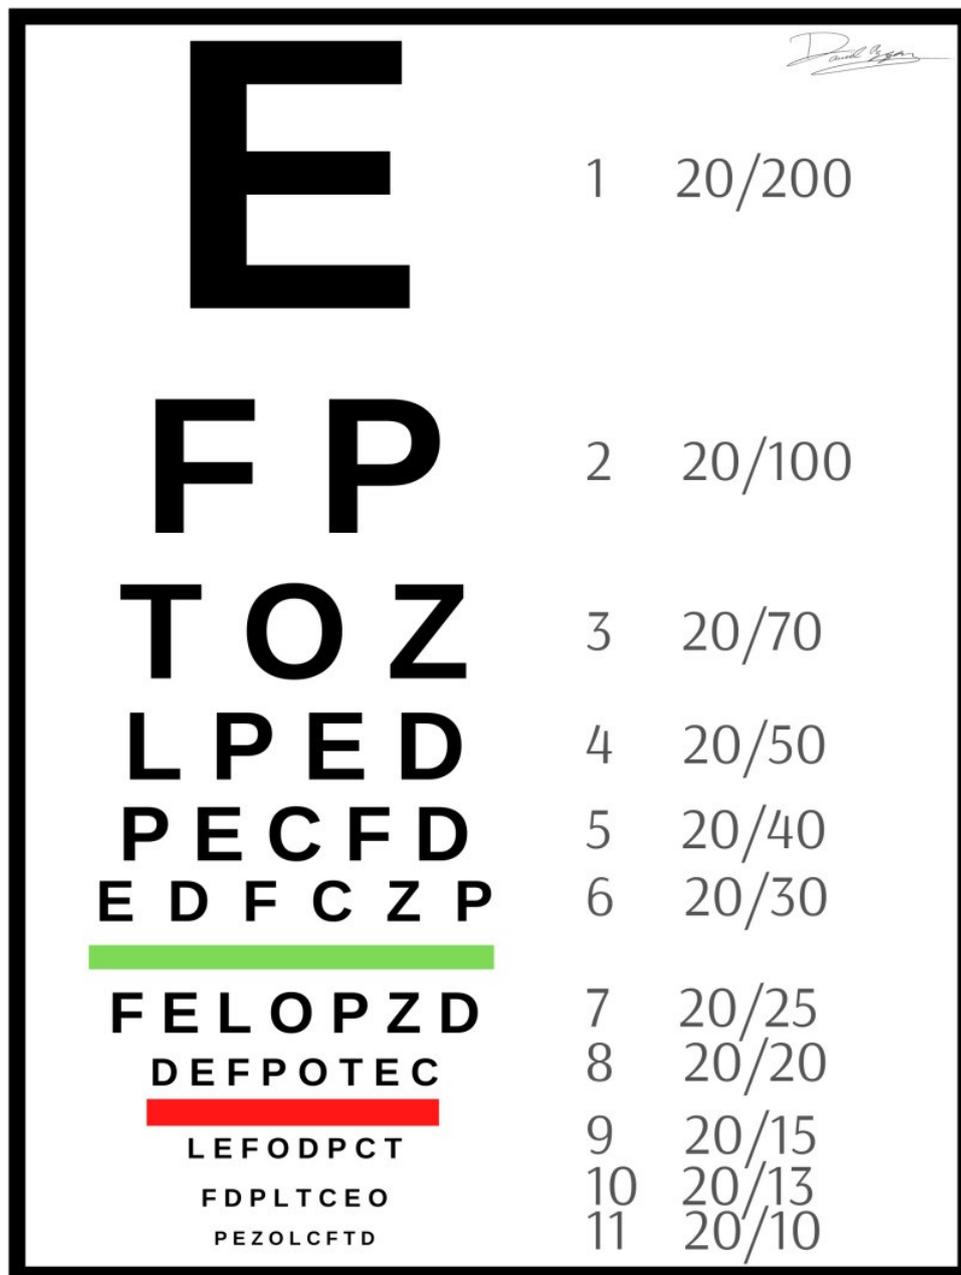


Figura 5: Quadro de Snellen ⁽²⁷⁾, usado durante os exames da retina.

- **ALGORÍTMO *AlgEdema*** -----
- **INÍCIO**
 - **PASSO S_1 :** As *features* da base de dados são preparadas para uso.
 - **PASSO S_2 :** A Engenharia Paraconsistente de Características (PFE) ⁽³⁾ é usada para classificar as *features* mais relevantes.
 - **PASSO S_3 :** As *features* selecionadas da etapa anterior alimentam, separadamente, os classificadores avaliados, ou seja, *Support Vector Machine* (SVM) ^(28, 29, 30), K-vizinhos Mais Próximos (KNN) ^(29, 30, 31), Árvores de Decisão (DTREE) ^(29, 30, 32) e Regressão Logística (LR). ^(29, 30, 33)
 - **PASSO S_4 :** As suas métricas associadas ao desempenho dos classificadores são registradas e discutidas.
 - **FIM.**

Particularmente, as *features* da base de dados, mencionadas no PASSO 1 do Algoritmo *AlgEdema* são as que constam na Tabela 1, com alguns exemplos particulares de caso constando na Tabela 2. Portanto, para cada exame realizado, um conjunto de 26 *features* compõe o vetor de características que é utilizado como entrada para a PFE. Inicialmente, os dados foram carregados de uma planilha estruturada e pré-processados para remover instâncias com valores nulos, garantindo a integridade e a qualidade do procedimento.

Adicionalmente, registre-se que, para viabilizar a modelagem, foi essencial transformar as classes categóricas em formatos numéricos adequados para análise, utilizando codificação de rótulos *LabelEncoder*. Esse processo foi aplicado às características principais como diagnóstico, olho e sexo dos pacientes,

preparando os dados para análise estatística e modelagem preditiva.

Prosseguindo, a análise PFE foi utilizada valendo-se de cada conjunto de 26 *features* associado com um rótulo, isto é, 0 ou 1, indicando a qual classe o vetor pertence, ou seja, exame com resultado normal e exame com resultado patológico, respectivamente. Essencialmente, a PFE funciona com base na Lógica Paraconsistente ⁽³⁾ e de acordo com um processo que considera dois critérios independentes para mensurar a adequação das características:

- α , que representa o valor de similaridade intraclasses;
- β , que representa a dissimilaridade interclasses.

Conforme detalhado por Guido (2019) ⁽³⁾, as variáveis α e β são consideradas para se calcular o grau de certeza, $G_1 = \alpha - \beta$, e o grau de contradição, $G_2 = \alpha + \beta - 1$, de um conjunto de vetores de características (VCs) representantes de determinadas classes, onde $(-1 \leq G_1, G_2 \leq 1)$.

Especificamente, $G_1 = -1$ e $G_1 = 1$ são duas situações extremas que representam falsidade absoluta e verdade plena, respectivamente. De modo análogo, $G_2 = -1$ e $G_2 = 1$ são dois casos extremos que representam indefinição total e ambiguidade completa, respectivamente, como pode se observar no Plano Paraconsistente apresentado na Figura 6.

O resultado da análise é um ponto $P = (G_1, G_2)$ que é tanto melhor quanto mais próximo estiver do ponto ideal, isto é, $(G_1, G_2) = (1, 0)$, conforme detalhado em ⁽³⁾. Assim, procurar-se-ão características que atraiam $(P = G_1, G_2)$ para o vértice $(1, 0)$.

Aplicando a PFE aos dados do problema em questão, notou-se que ele

Tabela 1: Conjunto de 26 *features* utilizadas neste trabalho: acrônimos e seus significados

Número de Ordem	Acrônimos	Significados
1	ID	Código do paciente
2	olho R/L	Definição do olho examinado (Right ou Left)
3	AcuidadeVisual	Grau de acuidade visual do paciente
4	etdrs9_2	Anel Interno Superior
5	etdrs9_4	Anel Interno Inferior
6	etdrs9_6	Anel Externo Superior
7	etdrs9_8	Anel Externo Inferior
8	foveamin	Medida da fóvea mínima
9	etdrs9v_2	Volume do Anel Interno Superior
10	etdrs9v_4	Volume do Anel Interno Inferior
11	etdrs9v_6	Volume do Anel Externo Superior
12	etdrs9v_8	Volume do Anel Externo Inferior
13	whole/total	Medida do Volume da área total
14	Diagnostico	Fenótipo verificado pelo Médico
15	sexo	Gênero do paciente (Masculino ou Feminino)
16	etdrs9_1	Centro do Anel da ETDRS
17	etdrs9_3	Anel Interno Nasal
18	etdrs9_5	Anel Interno Temporal
19	etdrs9_7	Anel Externo Nasal
20	etdrs9_9	Anel Externo Temporal
21	etdrs9v_1	Volume do Centro do anel da ETDRS
22	etdrs9v_3	Volume do Anel Interno Nasal
23	etdrs9v_5	Volume do Anel Interno Temporal
24	etdrs9v_7	Volume do Anel Externo Nasal
25	etdrs9v_9	Volume do Anel Externo Temporal
26	idade	Idade do paciente no dia do exame

Tabela 2: Conjunto de 26 *features* utilizadas neste trabalho, com exemplo de dados coletados de acordo com o número de ordem constante na Tabela 1. Com relação aos diagnósticos, isto é, a *feature* com número de ordem 14, as 8 primeiras linhas correspondem a casos normais, as quatro próximas correspondem a casos normais com anomalias, as quatro seguintes a casos N-MER, as quatro na sequência a casos S, seguidas de quatro casos S-MER e, finalmente, quatro casos S-PERIFOVEAL.

	1	2	15	3	4	5	6	7	8	9	10	11	12	13	16	17	18	19	20	21	22	23	24	25	26	
454	R	M	-0.18	242	330	302	300	289	277	297	239	253	197	197	0.19	0.52	0.47	0.47	0.45	1.47	1.58	1.27	1.34	7.77	76.69	
479	R	F	-0.44	182	215	270	202	205	230	283	222	238	143	143	0.14	0.34	0.42	0.32	0.32	1.22	1.22	1.5	1.18	1.26	6.71	77.41
488	L	M	-0.1	286	361	352	348	344	321	335	321	312	235	235	0.22	0.57	0.55	0.55	0.54	1.7	1.78	1.7	1.65	9.28	48.27	
488	R	M	-0.1	280	366	360	358	341	325	336	314	314	223	223	0.22	0.58	0.57	0.56	0.54	1.73	1.78	1.67	1.67	9.3	48.27	
497	L	F	-0.18	245	293	311	290	286	246	283	257	234	206	206	0.19	0.46	0.49	0.46	0.45	1.31	1.5	1.36	1.25	7.47	54.63	
497	R	F	-0.14	271	290	310	277	277	253	293	262	227	206	206	0.21	0.46	0.49	0.44	0.44	1.34	1.56	1.39	1.2	7.52	54.63	
614	L	F	-0.18	245	293	292	306	290	290	306	276	266	210	210	0.19	0.46	0.46	0.48	0.46	1.54	1.62	1.47	1.42	8.1	36.24	
861	L	F	-0.14	288	340	338	334	332	298	309	270	281	235	235	0.23	0.53	0.53	0.53	0.52	1.58	1.64	1.43	1.49	8.49	67.12	
15998	R	M	-1	134	308	191	88	169	205	309	330	169	37	37	0.11	0.49	0.3	0.14	0.27	1.09	1.64	1.75	0.9	6.67	70.21	
17744	R	F	-1.3	434	369	389	375	347	296	306	285	272	378	378	0.34	0.58	0.61	0.59	0.55	1.57	1.62	1.51	1.45	8.82	66.82	
10292	L	M	-2.7	267	225	263	292	206	237	198	255	189	185	185	0.21	0.35	0.41	0.46	0.32	1.26	1.05	1.36	1.01	6.44	79.67	
11513	L	F	-1.3	231	239	299	261	231	247	282	239	262	147	147	0.18	0.38	0.47	0.41	0.36	1.31	1.5	1.27	1.39	7.37	80.31	
13107	L	M	-0.18	313	348	353	341	336	301	310	292	286	265	265	0.25	0.55	0.56	0.54	0.53	1.6	1.65	1.55	1.52	8.73	74.92	
13488	L	M	-0.48	311	334	327	352	311	308	315	318	271	235	235	0.24	0.53	0.51	0.55	0.49	1.64	1.67	1.69	1.44	8.76	55.74	
13488	R	M	-0.6	325	318	348	357	313	299	315	295	280	311	311	0.26	0.5	0.55	0.56	0.49	1.59	1.67	1.57	1.49	8.67	55.74	
14370	L	F	-0.3	296	386	356	336	328	368	354	296	306	269	269	0.23	0.61	0.56	0.53	0.52	1.95	1.88	1.57	1.62	9.47	70.30	
11274	L	M	-0.14	316	332	342	323	306	297	338	298	272	277	277	0.25	0.52	0.54	0.51	0.48	1.58	1.79	1.58	1.44	8.7	44.03	
11294	R	F	-0.85	347	304	319	342	365	294	333	347	330	294	294	0.27	0.48	0.5	0.54	0.57	1.56	1.77	1.84	1.75	9.29	69.93	
11762	R	M	-1.4	506	417	485	453	405	305	352	326	330	458	458	0.4	0.66	0.76	0.71	0.64	1.62	1.87	1.73	1.75	10.14	78.53	
19065	L	M	-0.34	549	533	463	349	483	410	338	274	343	467	467	0.43	0.84	0.73	0.55	0.76	2.17	1.8	1.45	1.82	10.55	66.62	
16807	R	M	-0.4	319	284	292	303	377	206	274	297	389	281	281	0.25	0.45	0.46	0.48	0.59	1.09	1.46	1.58	2.06	8.42	57.10	
16896	L	M	-1.3	719	366	633	582	266	338	499	551	234	164	164	0.57	0.58	1	0.91	0.42	1.03	2.65	2.92	1.24	12.08	58.74	
17522	R	M	-1.18	460	492	429	372	415	383	351	299	435	370	370	0.36	0.77	0.68	0.58	0.65	2.03	1.86	1.59	2.31	10.83	62.71	
19158	L	F	-0.85	436	402	334	442	407	341	373	396	345	311	311	0.34	0.63	0.53	0.69	0.64	1.81	1.98	2.1	1.83	10.56	67.60	
17824	L	F	-2.7	258	331	322	312	235	298	305	334	318	96	96	0.2	0.52	0.51	0.49	0.37	1.58	1.62	1.77	1.69	8.76	76.51	
17940	L	F	-1	214	287	318	340	262	315	316	362	392	75	75	0.17	0.45	0.5	0.53	0.41	1.67	1.68	1.92	2.08	9.42	69.22	
17941	R	M	-0.3	320	368	314	359	399	342	327	301	335	218	218	0.25	0.58	0.49	0.56	0.63	1.81	1.74	1.6	1.78	9.45	51.74	
17973	R	M	-2.7	210	178	184	317	156	476	324	263	325	0	0	0.17	0.28	0.29	0.5	0.25	2.53	1.72	1.4	1.72	8.85	64.54	

identificou as melhores características entre as 26 *features* analisadas. As características selecionadas foram 'olho R/L' (definição do olho examinado, direito ou esquerdo), 'etdrs9v_7' (volume do anel externo nasal), 'sexo' (gênero do paciente, masculino ou feminino) e 'etdrs9_6' (anel externo superior).

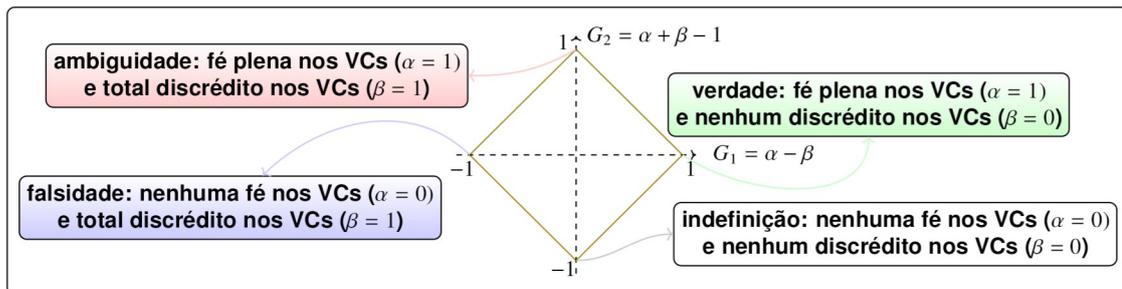


Figura 6: O Plano Paraconsistente onde as variáveis G_1 e G_2 estão destacadas.

Com relação ao PASSO 3 do Algoritmo *AlgEdema*, diferentes classificadores foram testados. Particularmente, conforme descrito por Bishop (2006),⁽²⁹⁾ o termo genérico *Machine Learning* envolve o desenvolvimento de algoritmos que permitem aos computadores aprenderem a partir de dados e fazer previsões ou decisões sem serem explicitamente programados para tal. Este campo abrange uma variedade de técnicas e abordagens, incluindo aprendizado supervisionado, não supervisionado e por reforço. O aprendizado supervisionado, uma das principais abordagens, treina modelos com dados rotulados para fazer classificações, enquanto o aprendizado não supervisionado identifica estruturas ocultas em dados não rotulados. Nesse contexto, os algoritmos discutidos nesta tese são de aprendizado supervisionado e se aplicam principalmente a tarefas de classificação e regressão.

Bishop explica que a SVM é um algoritmo que cria hiperplanos para separar dados em classes distintas, mostrando-se particularmente eficaz em problemas

de alta dimensionalidade.⁽²⁹⁾ Haykin (2012) destaca a robustez da SVM em classificação e regressão.⁽³⁰⁾ O SVM foi selecionado como uma das possibilidades a ser testada devido à sua capacidade robusta de lidar eficazmente com conjuntos de dados complexos e multidimensionais, características frequentemente encontradas em aplicações médicas.

Notavelmente, a SVM utilizada corresponde à estrutura apresentada na Figura 7, de forma que o treinamento valeu-se de uma estratégia semi-supervisionada, como segue:

- inicialmente, de forma completamente não-supervisionada, os núcleos de função de base radial (RBF) dos elementos intermediários foram ajustados de modo que o i -ésimo elemento apresente saída máxima, ou seja, 1 para o i -ésimo caso de treinamento. O i -ésimo elemento intermediário da SVM possui função de transferência

$$\frac{1}{1 + e^{-\text{distância euclidiana}\{i\text{-ésimo caso de treinamento} ; j\text{-ésimo caso de treinamento}\}}}$$

sendo $(0 \leq i, j \leq X)$ e $X = \frac{700}{2} = 350$ a metade dos casos existentes na base de dados.

- em seguida, de modo completamente supervisionado, os valores 0 e 1 foram utilizados para rotular casos de pacientes saudáveis e afetados patologicamente, respectivamente, de modo a estabelecer um sistema linear de dimensão $(X) \times (X) = (350 \times 350)$ para o qual a solução implica os pesos p_i .

Notavelmente, cada um dos casos de treinamento refere-se a uma equa-

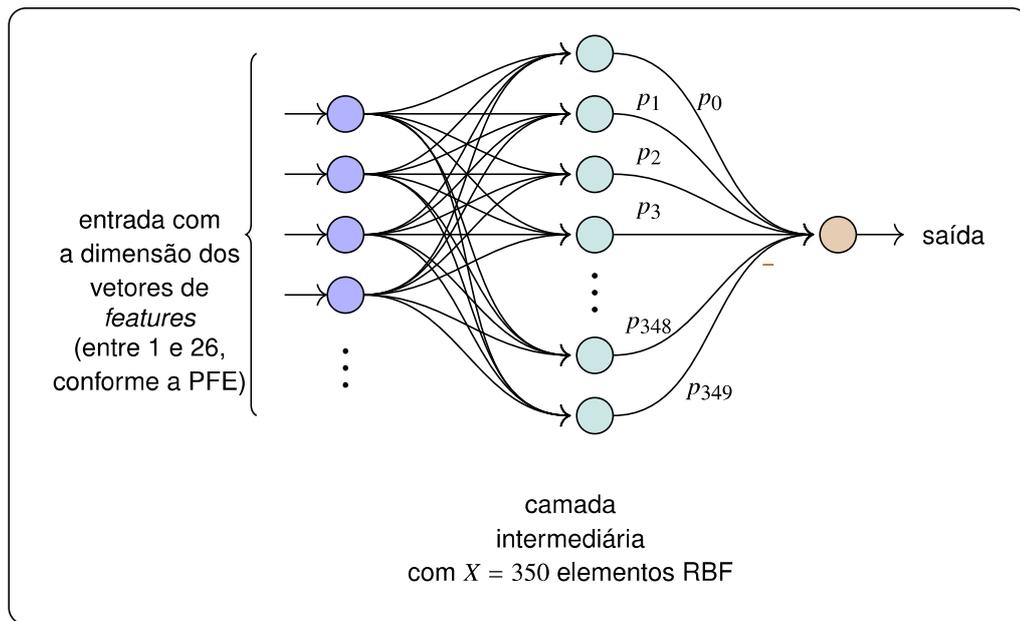


Figura 7: SVM utilizada como técnica *knowledge-based* de identificação dos padrões.

ção do sistema. Dessa forma, a SVM encontra-se pronta para o uso de modo que cada caso de teste é apresentado na camada de entrada e atravessa a camada intermediária produzindo $X - 1$ valores que são combinados linearmente com os pesos p_i e produzem um valor de saída que implica o resultado da classificação. Se esse valor estiver mais próximo de 0 ou 1, rotula-se o elemento de teste como sendo o caso de um paciente saudável ou afetado patologicamente, respectivamente.

Diferentemente, o KNN é um método de classificação baseado na atribuição de uma amostra à classe mais comum entre seus k -vizinhos mais próximos no espaço de características. Bishop ⁽²⁹⁾ o descreve como um método que classifica dados com base na proximidade e Haykin ⁽³⁰⁾ o considera intuitivo e eficaz para classificação. Sua simplicidade de implementação o torna útil em situações onde a relação entre variáveis é complexa e não linear. Notavelmente, o KNN opera de maneira distinta em relação ao SVM, pois dispensa a necessidade de

um *pipeline* com escalonamento dos dados, calculando diretamente as distâncias entre os vetores de *features*.

Assim, sendo o KNN um critério *pattern-matching* de reconhecimento de padrões, aqui baseado em distâncias Euclidianas, a classe atribuída ao vetor-teste é a do vetor-modelo para o qual ele dista minimamente, considerando-se todos os vetores-modelos. Para viabilizar tal estratégia, $X = \frac{700}{2} = 350$ vetores foram usados como vetores-modelo e outros 350 como vetores-teste. A seleção de quais, dentre os 700 vetores, foram usados como modelos e quais foram usados como testes foi realizada com base em uma validação cruzada, assim como, no caso da SVM.

Adicionalmente, no caso das DTREEs, vale lembrar que elas constituem modelos de aprendizado que utilizam uma estrutura de árvore para tomar decisões baseadas nas características dos dados. Bishop ⁽²⁹⁾ mostra que tais árvores utilizam uma estrutura hierárquica para previsões, dividindo repetidamente o espaço de características em subconjuntos mais homogêneos, oferecendo uma abordagem intuitiva e interpretável para a modelagem de dados. Haykin ⁽³⁰⁾ destaca sua versatilidade e interpretabilidade.

Neste trabalho, a árvore implementada para classificar os casos normais e patológicos baseou-se em inspeção, por distâncias Euclidianas, da similaridade entre os vetores de *features*, do seguinte modo:

- a base de 700 vetores é dividida aleatoriamente em duas partes iguais, com metade dos casos normais e metade dos casos patológicos em cada parte. Uma das metades é usada para modelamento e a outra para testes. Adota-

se um processo de validação cruzada de modo a repetir a estratégia aqui descrita inúmeras vezes;

- na metade da base usada para modelamento, distribuem-se, nós filhos à esquerda e à direita de um nó raiz, os vetores de *features* dos casos normais e patológicos, respectivamente;
- cada vetor da metade da base reservada para testes passa pelo nó raiz da árvore e é colocado à esquerda ou à direita caso ele possua menor diferença média em módulo, ou maior diferença média em módulo, respectivamente, em relação à primeira *feature* disponível nos vetores, considerando-se todos os vetores do lado esquerdo e todos os do lado direito;
- o vetor de testes anteriormente colocado no nó à esquerda ou à direita é então movido para um nó em nível subsequente, à esquerda ou à direita, caso ele possua módulo menor ou maior, respectivamente, em relação ao módulo médio dos vetores existentes no seu nó pai, desconsiderando-se ele próprio no cálculo do módulo médio;
- o processo repete-se recursivamente para todos os vetores da base de testes. Ao final, vetores mais à esquerda são rotulados como normais e vetores mais à direita como patológicos.

Finalmente, observa-se que a LR é uma técnica estatística empregada para modelar a probabilidade de um evento binário, como a presença ou ausência de uma característica. Bishop ⁽²⁹⁾ modela a probabilidade de variáveis categóricas usando a função logística, assegurando que as previsões estejam no intervalo

[0, 1] e Haykin ⁽³⁰⁾ enfatiza a LR como ideal para problemas de classificação binária. O treinamento do modelo baseado em LR ocorre ajustando-se os parâmetros do modelo aos dados de treinamento. Diferentemente do SVM, a Regressão Logística não requer escalonamento dos dados, porém é sensível à escala das variáveis de entrada, sendo crucial garantir que as características estejam corretamente preparadas para otimizar a performance do modelo.

Particularmente, a intenção no caso da LR é a de minimizar o erro quadrático médio em relação à uma função logística, ou seja, $y_i = \frac{1}{1+e^{-\sum_{i,j}(\alpha_i f_{i,j})}}$ ⁽³⁴⁾. Desse modo, tem-se, numa dimensão Z que varia entre 1 e 26, ou seja, o número de *features* selecionadas pela PFE:

$$\left\{ \begin{array}{l} -\ln\left(\frac{1}{y_0} - 1\right) = \alpha_0 f_{0,0} + \alpha_1 f_{1,0} + \alpha_{Z-1} f_{Z-1,0} + \dots \\ -\ln\left(\frac{1}{y_1} - 1\right) = \alpha_0 f_{0,1} + \alpha_1 f_{1,1} + \alpha_{Z-1} f_{Z-1,1} + \dots \\ \dots \\ -\ln\left(\frac{1}{y_{M-1}} - 1\right) = \alpha_0 f_{0,M-1} + \alpha_1 f_{1,M-1} + \alpha_{Z-1} f_{Z-1,M-1} + \dots \end{array} \right. \quad (1)$$

permitindo um modelamento baseado em uma função logística tal qual a que está exibida na Figura 8.

Em termos de implementações, alguns trechos de código considerados mais importantes são os que envolvem a leitura dos dados de entrada, processam, a construção e treinamento dos modelos, além da avaliação do desempenho de classificação de cada modelo sob teste. Nesse sentido, as importações de bibliotecas são essenciais, pois trazem todas as ferramentas necessárias para

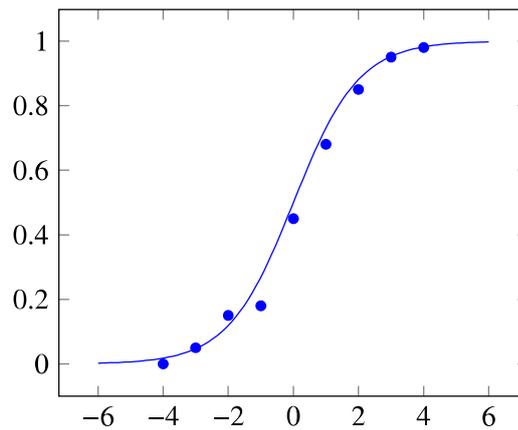


Figura 8: Exemplo genérico de regressão logística para um caso de dimensão 2. A curva casa aproximadamente aos pontos em azul, minimizando o erro quadrático médio ⁽³⁴⁾.

manipulação dos dados, construção e avaliação dos modelos, conforme destaque na Figura 9.

```
# -*- coding: utf-8 -*-
import pandas as pd
#biblioteca para manipulação dos dados em si
#carregá-los da planilha na memória, pré-processamento
import numpy as np
#biblioteca para manipulação numérica que a gente usa

from paraconsistentLIB_07 import BestParaconsistent
from paraconsistentLIB_07 import *
# biblioteca do Guido

from sklearn.tree import DecisionTreeClassifier
from sklearn.svm import SVC

from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler #normalizando dados
from sklearn.preprocessing import LabelEncoder
from sklearn.preprocessing import OneHotEncoder
# biblioteca de aprendizado de máquina

from sklearn.metrics import accuracy_score
from sklearn.metrics import roc_curve, auc
from sklearn.metrics import precision_score, recall_score, f1_score
#estatísticas
```

Figura 9: Importação de algumas bibliotecas em linguagem Python.

O código apresentado na Figura 10, carrega os dados e realiza o pré-processamento, o qual constitui trecho fundamental, pois sem dados preparados, o modelo não funcionará corretamente.

```

#Preparação de Dados
df_treino = pd.read_csv('Base_OCT_2022_700_ID.csv', sep=";")
#df_treino = pd.read_csv('Base_OCT_2022_700_ID - Cópia.csv', sep=";")
# Só sim e não

df_treino = df_treino.loc[:, ~df_treino.isnull().any()]
#remover valores nulos
df_treino.head()
df_treino.shape

print('Número de instâncias: {}\nNúmero de atributos: {}'.format(len(df_treino), len(df_treino.columns)))

df_treino[0:7]

# Frequência das Labels
labels = df_treino.iloc[:, 1:4].columns.values

for l in labels:
    print("Label: ", l)
    print(df_treino[l].value_counts(), '\n')

```

Figura 10: Preparação e pré-processamento dos dados.

Registre-se que o treinamento dos modelos é crucial para o funcionamento do sistema. Na Figura 12 consta um trecho de código no qual a separação dos dados em treino e teste, e o treinamento do modelo SVM com 26 *features*, ocorre. O mesmo está exibido na Figura 13 para o modelo SVM com quatro *features* selecionadas pela PFE.

```

le = LabelEncoder() #para transformar as classes 'S', 'N', 'NM'
#em categorias numericas - 4 classes 'S', 'N', 'NM', 'SM' ou mais
df_treino.iloc[:,1] = le.fit_transform(df_treino.iloc[:,1]).astype('float64')
le.classes_ # mostra nomes das caracteristicas/diagnosticos

array(['N', 'N-ANOMALIAS', 'N-MER', 'S', 'S-MER', 'S-PERIFOVEAL'],
      dtype=object)

```

Figura 11: Transformando a classe-fenótipos.

```

#SVC
# Pipeline pode ser usado como estimator
# e evita a mistura treino e teste

pipe = Pipeline([('scaler', StandardScaler()), ('svc', SVC(probability=True))])

# Agora treinamos o modelo
pipe.fit(X_train, y_train)

```

Figura 12: Código do treinamento do modelo SVM com as 26 *features* originais.

```

# Pipeline pode ser usado como estimator
# e evita a mistura treino e teste

pipe_paraconsistent = Pipeline([('scaler', StandardScaler()), ('svc', SVC( probability=True))])

# Agora treinamos o modelo
pipe_paraconsistent.fit(X_train_paraconsistent, y_train_paraconsistent)

```

Figura 13: Código do treinamento do modelo SVM com quatro *features* selecionadas pela PFE.

Em caráter complementar, registre-se que o exame OCT *Setting: MACULA MAP A X-Y*, que além dos dados dos pacientes fornecem, como saída, um conjunto de 21 características, como na Figura 3, foi usado para a interpretação clínica medidas em ‘*um*’ (microns), implicando o delineamento dos nove setores maculares (ETDRS 9 Sector ETDRS - *Early Treatment Diabetic Retinopathy Study* - Grade do Estudo de Retinopatia Diabética de Tratamento Precoce), os volumes de cada parte anterior em milímetros cúbicos, fóvea mínima e volume de área total, dentro dos quais medimos a espessura da camada macular, já citados na Tabela 1. As Figuras 14 e 15 contêm dados normativos para espessura da retina em vários subcampos do ETDRS, e um exemplo de ETDRS 9 do olho esquerdo, respectivamente.

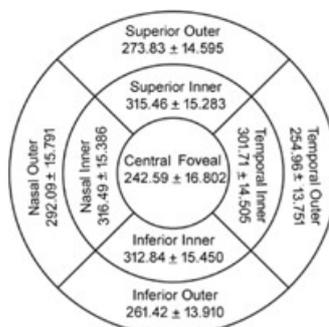


Figura 14: Dados normativos para espessura da retina em vários subcampos do ETDRS (35).

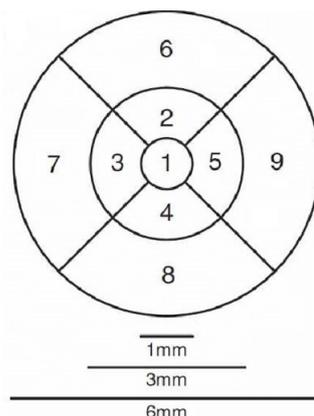


Figura 15: Um exemplo de ETDRS 9 do olho esquerdo, baseado na Figura 14.

Os resultados do presente estudo, detalhados no próximo Capítulo, são apresentados de maneira objetiva por meio de matrizes confusão, conforme genericamente exibido na Tabela 11, por meio de curvas ROC, de acordo com a Figura 19. Proporciona uma análise detalhada da capacidade preditiva dos modelos SVM, KNN, DTREE e LR em diversos cenários.

Além disso, as seguintes métricas foram calculadas para mostrar o desempenho da segmentação:

- Acurácia, que é a probabilidade do teste acertar o diagnóstico.
- Sensibilidade, que corresponde ao percentual de resultados positivos dentre as pessoas que têm a enfermidade sendo investigada.
- Especificidade, que é a capacidade do mesmo teste ser negativo nos indivíduos que não apresentam a doença que está sendo investigada.
- Valor Preditivo Positivo (VPP), que é a probabilidade de haver a doença em quem o teste diagnóstico é positivo.
- Valor Preditivo Negativo (VPN), que é a probabilidade de não haver a doença em quem o teste diagnóstico é negativo.

- Pontuação F1 ou *F1-SCORE*, que é calculado como a média harmônica entre precisão e *recall*. A precisão mede a quantidade de vezes que o seu modelo acerta em relação ao total de vezes que ele tenta acertar. O *recall* mede a quantidade de vezes que o seu modelo acerta em relação ao total de vezes que ele deveria ter acertado.
- *AUC-Scores*, ou Área Sob a Curva (AUC), que é uma métrica utilizada para avaliar o desempenho global de modelos de classificação. Ela representa a área sob a curva da característica de operação do receptor (ROC), que mapeia a relação entre a taxa de verdadeiros positivos (VP) e a taxa de falsos positivos (FP).
- As curvas de característica de operação do receptor (Curva-ROC), plotadas para avaliar o desempenho geral da segmentação. Com base na curva ROC, calcula-se a AUC.

Estas métricas, conforme o exemplo da Figura 16, oferecem *insights* valiosos sobre como cada algoritmo se comporta em termos de sensibilidade, especificidade e capacidade geral de classificação, essenciais para a aplicação prática em contextos clínicos e de pesquisa, viabilizando uma análise comparativa robusta e fundamentada para aplicações clínicas e médicas.

```

from sklearn.metrics import classification_report # métricas de validação
print(classification_report(y_test, resultado_svc, target_names=le.classes_))
#print(classification_report(y_test, resultado_svc))

```

	precision	recall	f1-score	support
N	0.88	0.99	0.93	102
N-ANOMALIAS	0.00	0.00	0.00	4
N-MER	0.00	0.00	0.00	7
S	0.68	0.81	0.74	21
S-MER	0.00	0.00	0.00	2
S-PERIFOVEAL	0.00	0.00	0.00	4
accuracy			0.84	140
macro avg	0.26	0.30	0.28	140
weighted avg	0.74	0.84	0.79	140

Figura 16: Código de algumas métricas de validação e apresentação dos resultados.

4 Resultados

Particularmente, os 700 exames diagnosticados estão separados em 351 olhos direito e 349 esquerdos, sendo ainda 385 exames de pacientes do sexo masculino e 315 exames de pacientes do sexo feminino. O total é de 387 pacientes, sendo 214 homens e 173 mulheres, com idades entre 23 e 91, implicando a idade média de 62,5 anos.

Os testes foram realizados levando em consideração dois cenários, em ambos os cenários para os quatro modelos classificadores, isto é, SVM, KNN, DTREE e LR, com e sem o uso da PFE, totalizando 16 testes distintos.

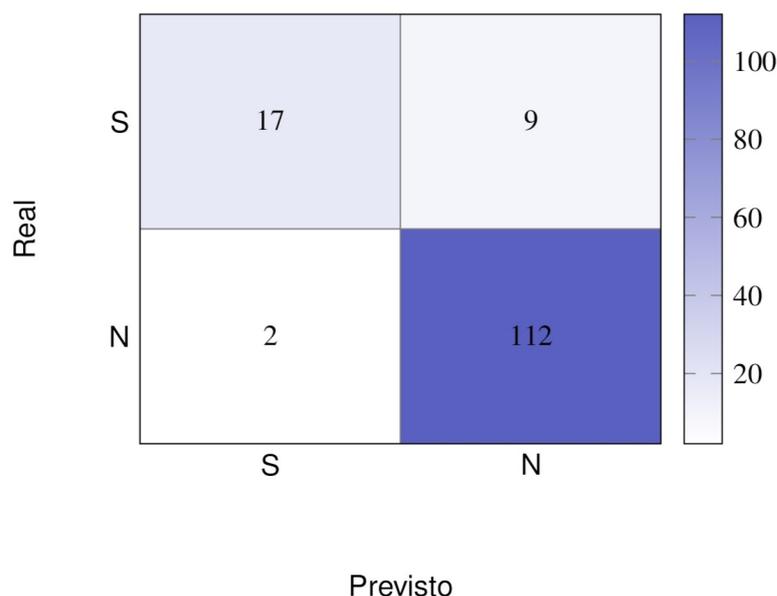
No caso do **Cenário 1**, tem-se duas classes/fenótipos, ou seja, S-sim e N-não, isto é, ter ou não ter o Edema Macular Diabético, conforme a Tabela 3.

Tabela 3: Acrônimos, Fenótipos e quantidades utilizadas no cenário 1

Abreviação	Fenótipo	Quantidade
S	Sim com Edema de Macula	131
N	Não	569

Os resultados dos testes de SVM e KNN para 26 *features* se mostraram melhores com 129 acertos que corresponde a uma precisão de 92%, e a Matriz Confusão pode ser verificada na Tabela 4, seguido por LR com 127 acertos nos valores preditivos e DTREE com 120.

A Tabela 5 apresenta uma comparação de desempenho entre os quatro modelos de aprendizado de máquina adotados, isto é, SVM, DTREE, KNN e LR, utilizando duas configurações de *features*: normais (26) e paraconsistentes (4). Os modelos SVM e KNN com *features* normais destacaram-se, alcançando acu-

Tabela 4: Matriz Confusão SVM e KNN para 26 *features* e dois fenótipos

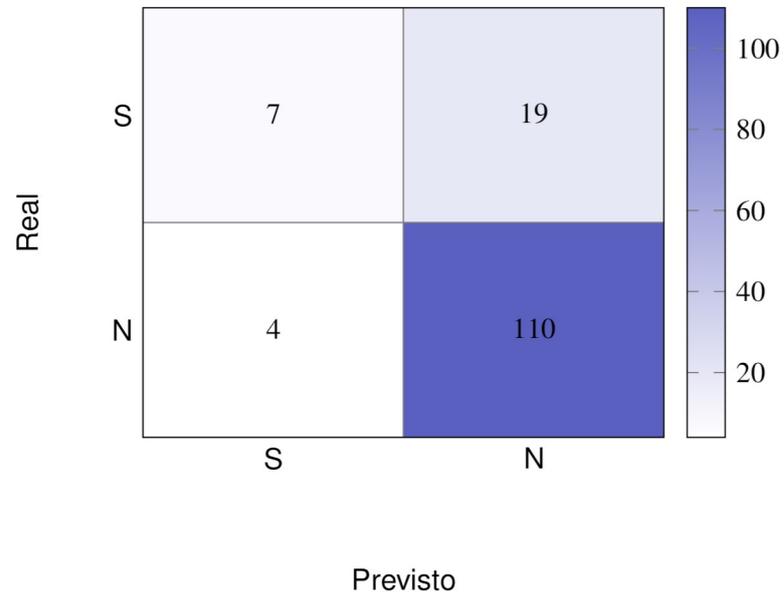
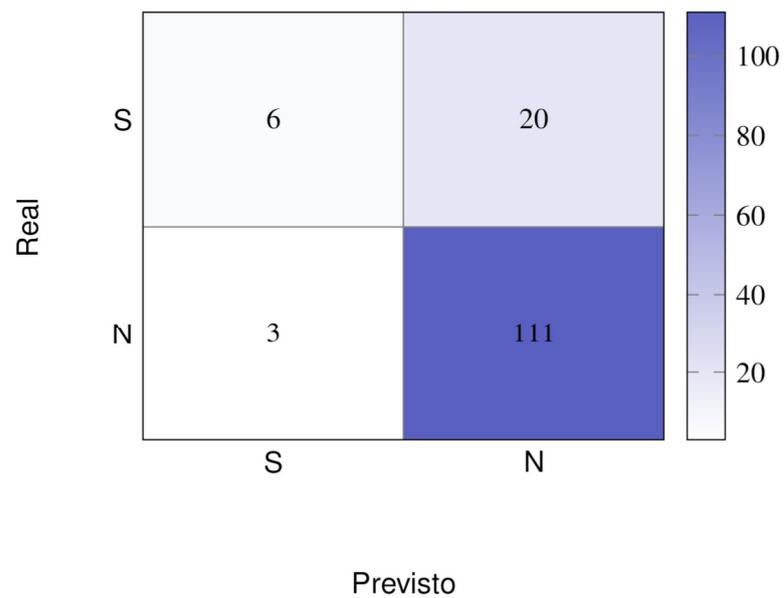
rácia de 92% e *AUC-Scores* superiores a 81%. Em contraste, o uso de *features* paraconsistentes resultou em desempenho significativamente inferior em todos os modelos, com acurácia máxima de 84% e *AUC-Scores* abaixo de 62%. O DTREE e o LR também tiveram desempenho aceitável com *features* normais, mas menos eficiente em comparação com SVM e KNN.

Para os testes com o uso da PFE, onde utilizou-se as quatro *features* classificadas como as melhores pela biblioteca Paraconsistente, isto é, 'olho R/L', 'etdrs9v_7 – volume do anel externo Nasal', 'gênero' e 'etdrs9_6 – anel externo superior', observaram-se os melhores desempenhos nos métodos SVM e LR, sendo ambos com 117 acertos e uma acurácia de 84%. As matrizes confusões resultantes, estão representadas pela Tabela 6 no caso da SVM, e na Tabela 7 no caso da LR, notando ainda o KNN com 108 e DTREE com 106 acertos.

Na Tabela 8, estão exibidas as métricas estatísticas para facilitar a comparação de desempenho dos modelos SVM e KNN com as 26 *features* e os

Tabela 5: Desempenho dos Modelos no Cenário 1: dois fenótipos/classes

Modelos	Features	Pontuação de classificação	Acurácia (%)	Sensibilidade (%)	Especificidade (%)	VPP (%)	VPN (%)	S: F1-Score	N: F1-Score	AUC-Score(%)
SVM	Normal (26)	129	92	89	93	65	98	76	95	81.8
SVM	Paraconsistente (4)	117	84	64	85	27	96	38	91	61.7
DTREE	Normal (26)	120	86	64	90	54	93	58	91	73.4
DTREE	Paraconsistente (4)	106	76	33	84	31	86	32	85	58.3
KNN	Normal (26)	129	92	89	93	65	98	76	95	82
KNN	Paraconsistente (4)	108	77	35	84	27	89	30	86	57.7
LR	Normal (26)	127	91	93	90	54	99	68	95	76
LR	Paraconsistente (4)	117	84	67	85	23	97	34	91	60

Tabela 6: Matriz Confusão SVM para quatro *features* (PFE) e dois fenótiposTabela 7: Matriz Confusão LR para quatro *features* (PFE) e dois fenótipos

modelos SVM e LR com quatro *features* e PFE. Observando a Tabela 8, o modelo SVM e KNN possui a maior precisão, isto é, 92%, seguido pelos modelos SVM_Paraconsistente e LR_Paraconsistente, ambos com 84%. O modelo SVM_KNN também se destaca com a maior sensibilidade, ou seja, 89%, maior especificidade, isto é, 93%, e maior valor preditivo positivo, ou seja, 65%. Porém, os três modelos apresentam valores preditivos negativos altos, com SVM_KNN em 98%, SVM_Paraconsistente em 96% e LR_Paraconsistente em 97%.

Tabela 8: Métricas estatísticas

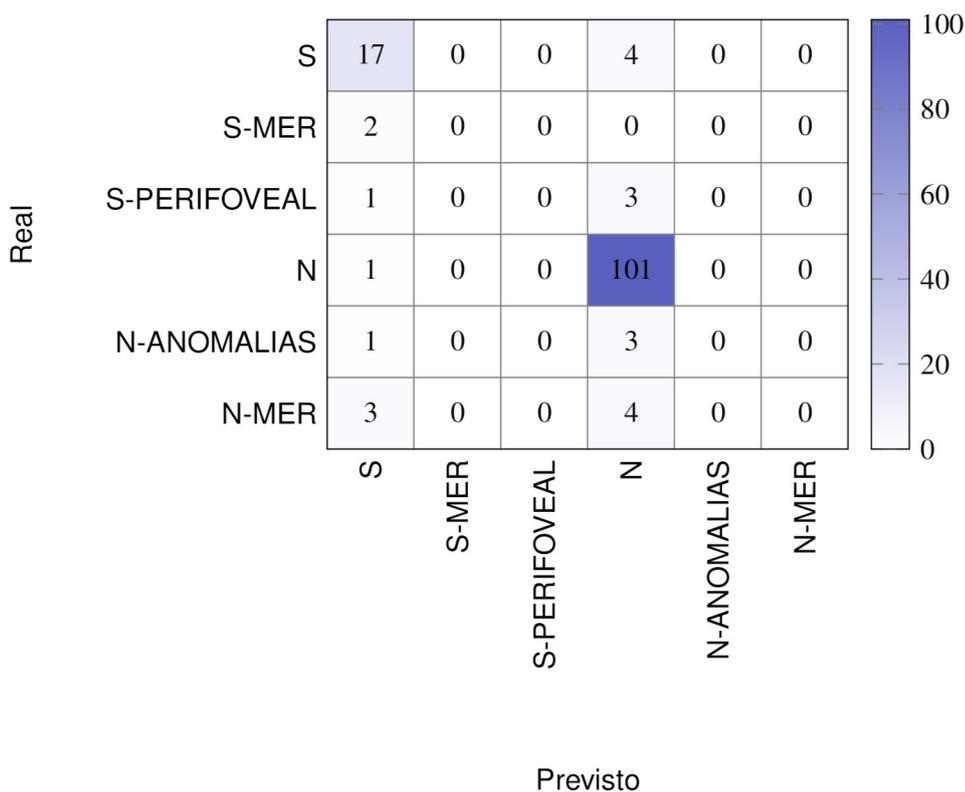
Métrica	SVM e KNN com 26 features (Tabela 4)	SVM com 4 features (Tabela 6)	LR com 4 features⁷ (Tabela 7)
Precisão/Acurácia (%)	92	84	84
Sensibilidade/ <i>Recall</i> (%)	89	64	67
Especificidade (%)	93	85	85
Valor Preditivo Positivo (%)	65	27	23
Valor Preditivo Negativo (%)	98	96	97

No **Cenário 2**, a divisão foi realizada em seis diferentes classes/fenótipos, isto é, S-sim (com Edema de Macula), S-Mer (sim com edema e membrana epirretiniana), S-Perifoveal (sim com edema perifoveal), N-Não, N-Anomalias (não mas possui outras anomalias), N-Mer (não mas com membrana epirretiniana) com diferentes quantidades, conforme a Tabela 9. Considerou-se como "outras anomalias", exames diagnosticados com artefato, buraco macular, sobreposição temporal, tração vítreo macular e cicatriz perifoveal.

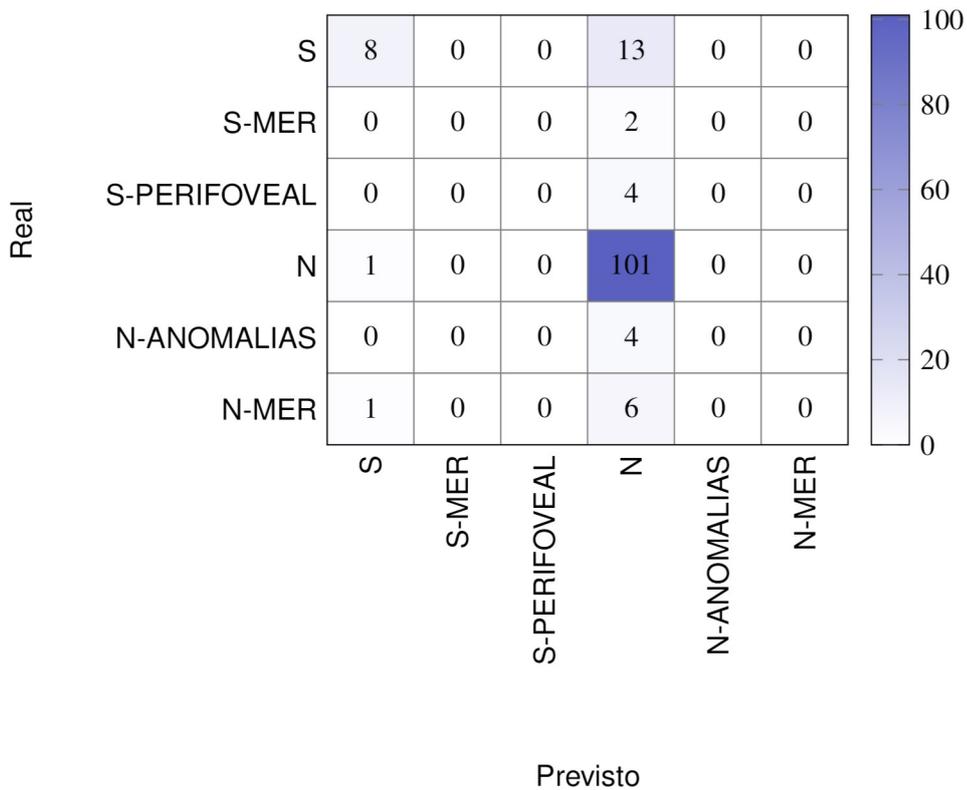
Tabela 9: Acrônimos, Fenótipos e quantidades utilizadas no cenário 2

Abreviação	Fenótipo	Quantidade
S	Sim com Edema de Macula	104
S-Mer	Sim com edema e membrana epirretiniana	10
S-Perifoveal	Sim com edema Perifoveal	17
N	Não	511
N-Anomalias	Não mas possui outras anomalias	22
N-Mer	Não mas com membrana epirretiniana	36

Os testes sem o uso da PFE resultaram em 118 acertos nos valores preditivos e uma acurácia de 84% pelo SVM, de acordo com a Tabela 10, seguido por LR, KNN e DTREE com 114, 113 e 96 acertos, respectivamente.

Tabela 10: Matriz Confusão SVM para 26 *features* e seis fenótipos

Com a PFE, o método LR obteve melhor rendimento com 109 acertos nos valores preditivos e uma acurácia de aproximadamente 78%; como pode ser observado na Tabela 11, seguido pelo modelo SVM com 108 acertos.

Tabela 11: Matriz Confusão LR para quatro *features* (PFE) e seis fenótipos

Transformando as matrizes da Tabela 10, Tabela 11 e Tabela 12 em matrizes 2x2, similar ao que foi disposto na Tabela 7, tem-se as métricas organizadas na Tabela 13.

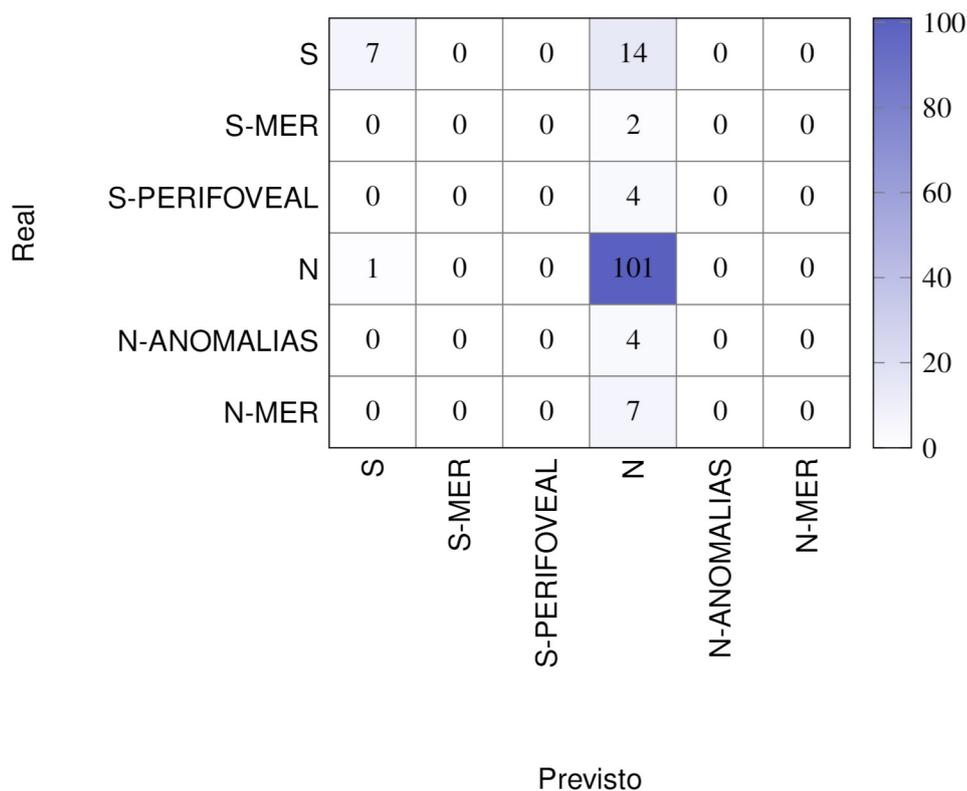
Tabela 12: Matriz Confusão SVM para quatro *features* (PFE) e seis fenótipos

Tabela 13: Métricas estatísticas

Métrica	SVM com 26 <i>features</i> (Tabela 10)	LR com 4 <i>features</i> (Tabela 11)	SVM com 4 <i>features</i> (Tabela 12)
Precisão/Acurácia (%)	91	85	85
Sensibilidade/ <i>Recall</i> (%)	80	80	87.5
Especificidade (%)	93	85	84.8
Valor Preditivo Positivo (%)	74	29	25
Valor Preditivo Negativo (%)	95	98	99

A Tabela 14 contém uma comparação do desempenho dos quatro modelos de aprendizado de máquina, isto é, SVM, DTREE, KNN e LR, utilizando 26 *features* e a PFE com quatro *features* em um cenário com seis fenótipos/classes. Os modelos SVM e LR com 26 *features* são os que apresentaram o melhor desempenho, com acurácias superiores a 81% e AUC-Scores de 82.7% e 72.8%,

respectivamente. Em contraste, as quatro *features* paraconsistentes resultaram em desempenho inferior em todos os modelos, com AUC-Scores abaixo de 65%. O DTREE apresentou o pior desempenho geral, especialmente com *features* paraconsistentes. KNN implicou um bom desempenho com 26 *features*, mas seu desempenho caiu significativamente com o uso de quatro *features*.

Numa análise comparativa das curvas ROC-AUC, o modelo SVM com 26 *features* apresentou uma AUC de 0.82, como pode-se verificar na Figura 17. Esse valor indica que o modelo tem uma boa capacidade de discriminação, conseguindo distinguir entre as classes positivas e negativas na maioria dos casos. Em contraste, o modelo SVM com quatro *features* implica uma AUC de 0.62, conforme a Figura 18. Esse valor sugere uma capacidade de discriminação significativamente menor, indicando que a redução das *features* pode ter levado à perda de informações críticas para uma classificação precisa.

Ao comparar os desempenhos nos Cenários 1 e 2, observa-se que os modelos SVM e LR com *features* normais apresentaram os melhores resultados em ambos os casos. No Cenário 1, com dois fenótipos/classes, SVM e KNN alcançaram acurácia de 92% e AUC-Scores superiores a 81%. Já no Cenário 2, com seis fenótipos/classes, SVM e LR mantiveram bom desempenho com acurácias de 84.3% e 81%, respectivamente, e AUC-Scores de 82.7% e 72.8%.

Em contraste, o uso de *features* paraconsistentes resultou em desempenho significativamente inferior em todos os modelos e cenários. A complexidade aumentada no Cenário 2 causou uma queda geral de desempenho, especialmente, na sensibilidade e nos AUC-Scores.

Tabela 14: Desempenho dos Modelos no Cenário 2: seis fenótipos/classes

Modelos	features	Pontuação de classificação	Acurácia (%)	Sensibilidade (%)	Especificidade (%)	VPP (%)	VPN (%)	S: F1-Score	N: F1-Score	AUC-Score (%)
SVM	Normal (26)	118	84.3	68	83	81	99	74	93	82.7
SVM	Paraconsistente (4)	108	77	88	77	33	99	48	86	64.6
DTREE	Normal (26)	96	68.6	43	82	29	88	34	85	53.8
DTREE	Paraconsistente (4)	85	61	38	75	29	77	32	76	48.9
KNN	Normal (26)	113	80.7	76	84	76	95	76	89	58.5
KNN	Paraconsistente (4)	108	69	60	74	29	89	39	81	47.3
LR	Normal (26)	114	81	86	81	57	100	69	89	72.8
LR	Paraconsistente (4)	117	78	80	78	38	99	52	87	56

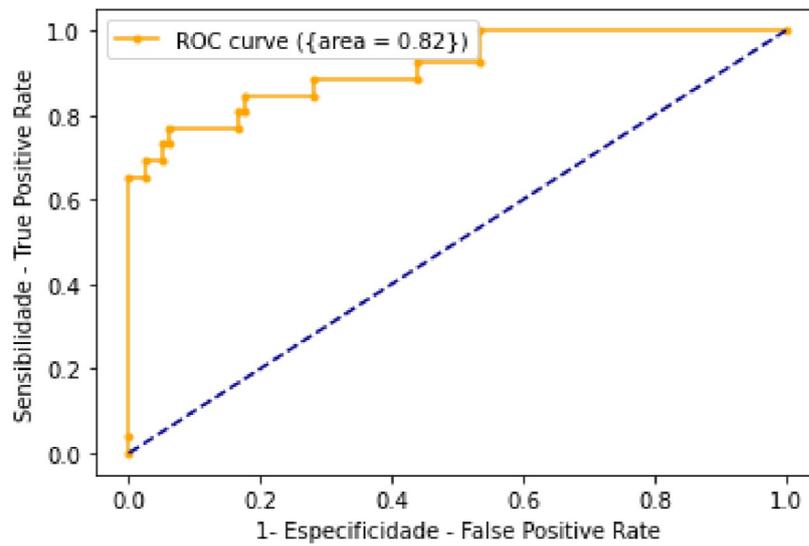


Figura 17: Curva ROC-AUC, modelo SVM e KNN com 26 *features* e dois fenótipos.

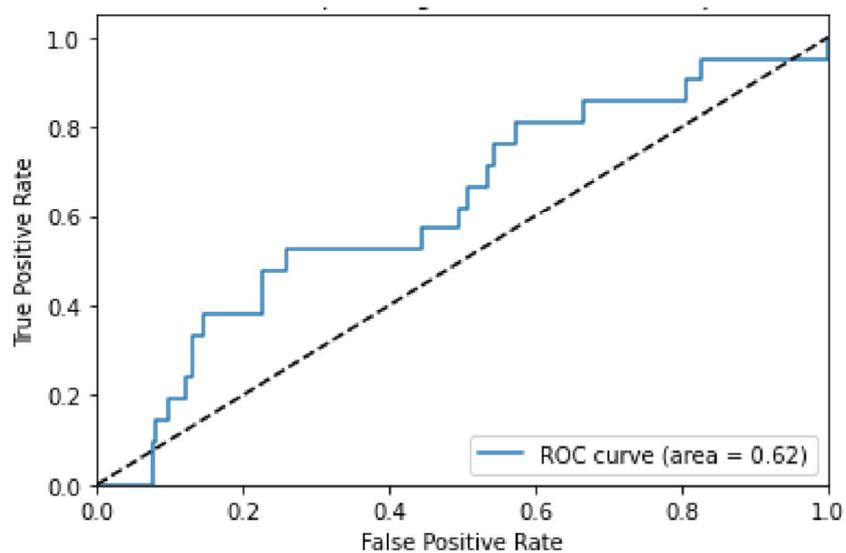


Figura 18: Curva ROC-AUC, modelo SVM com quatro *features* (PFE) e dois fenótipos.

Para o modelo SVM utilizado no **Cenário 2** com seis fenótipos ou classes, a curva ROC e as AUCs para o modelo SVM com 26 *features* são apresentadas na Figura 19. Observa-se que a classe 0 (N) e a classe 3 (S) apresentaram desempenho superior, com $AUC = 0.89$, indicando uma boa capacidade de discriminação. No entanto, a classe 1 (N-Anomalias) teve um desempenho substancialmente inferior, com $AUC = 0.53$, o que sugere dificuldades em separar essa classe das demais.

Modelo SVM com quatro *features*, apresentado na Figura 20, a classe 3 (S) apresentou o melhor desempenho, com $AUC = 0.90$, seguido pela classe 0, com $AUC = 0.87$. A classe 1 (N-Anomalias) teve uma melhoria marginal em relação ao modelo de 26 *features* ($AUC = 0.58$), mas ainda, assim, permanece uma das classes com menor capacidade de discriminação.

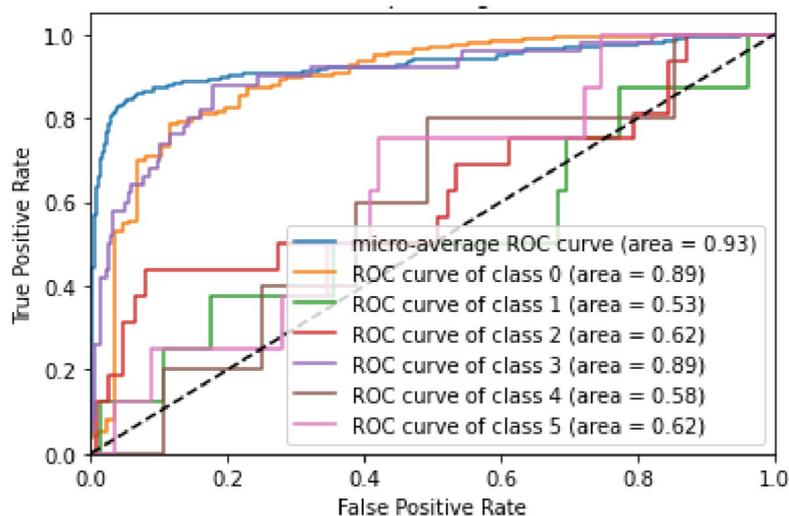


Figura 19: Curva ROC-AUC, modelo SVM com 26 *features* e seis fenótipos.

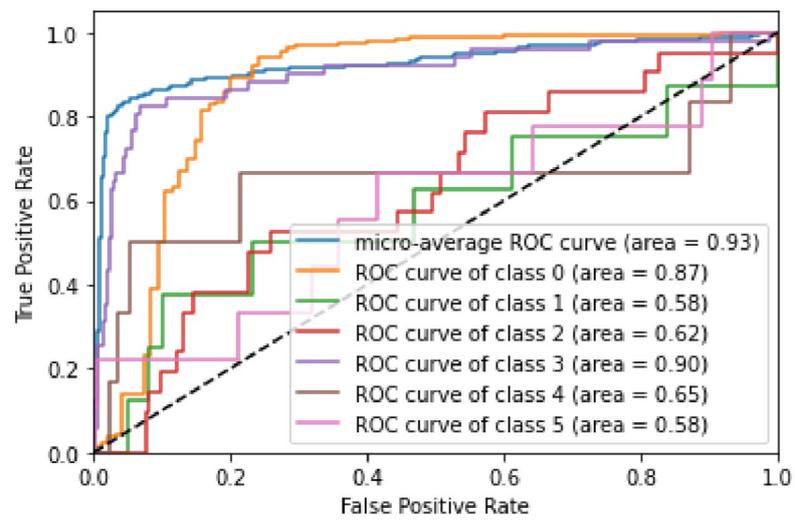


Figura 20: Curva ROC-AUC, modelo SVM com quatro *features* (PFE) e seis fenótipos.

5 Discussão

A análise das publicações, juntamente com os métodos existentes, revela que não há precedentes que tratem especificamente da aplicação de modelos de IA para o pré-diagnóstico de EMD. Dessa forma, o método e a pesquisa propostos não apenas preenchem uma lacuna importante no conhecimento científico, como também representa um avanço nas metodologias de diagnóstico precoce de condições oftalmológicas. A ausência de trabalhos na área, principalmente, com base na PFE, impossibilita uma comparação mais abrangente. A utilização de uma base de dados clínicos originada da OCT, garante a realização do estudo e ocasiona a veracidade das informações decorrentes da PFE, pois inibe grande parte da falseabilidade por ocorrências humanas.

Aqui exploramos novas possibilidades para a detecção e avaliação do EMD, contribuindo de maneira única para os campos da Oftalmologia e da IA. Portanto, a aplicação e comparação dos modelos de IA testados nesta tese, com o objetivo de pré-diagnosticar o EMD com base na PFE, é genuinamente inovadora.

Neste estudo apresentou-se uma Metodologia para avaliar a eficácia de algoritmos de aprendizado de máquina na detecção de Edema de Mácula. A abordagem envolve o uso da lógica paraconsistente para selecionar as características mais relevantes dos dados e a aplicação dos classificadores SVM, LR, KNN e DTREE para treinar e testar modelos preditivos. As análises visam comparar o desempenho dos modelos com todas as características disponíveis e com um subconjunto das melhores características selecionadas pela PFE, vi-

sando melhorar a precisão dos diagnósticos médicos automatizados.

O modelo SVM com 26 *features* e apenas dois fenótipos, demonstrou desempenho superior em precisão, especificidade e valor preditivo positivo, destacando-se como o mais robusto e confiável para a classificação correta das instâncias. Apesar disso, os modelos SVM e KNN do Cenário 1, apresentaram a mesma sensibilidade, indicando que a adição de mais *features* no SVM não comprometeu sua capacidade de detectar verdadeiros positivos. O modelo LR com quatro *features*, embora inferior em várias métricas, mostrou-se ligeiramente melhor no valor preditivo negativo, sugerindo uma maior confiabilidade na identificação de instâncias negativas. Esta análise comparativa fornece *insights* valiosos sobre a eficácia dos modelos SVM e LR, auxiliando na escolha do modelo mais adequado para diferentes cenários de classificação. O modelo paraconsistente utiliza apenas quatro *features*, o que reduz significativamente a complexidade computacional em comparação com o modelo tradicional que usa 26 *features*. Isso implica a melhora nos tempos de treinamento e o menor consumo de recursos computacionais, o que é crucial em ambientes com recursos limitados.

Levando em consideração o custo-benefício, a coleta e o processamento de 26 *features* com 18200 dados podem ser dispendiosos e logisticamente desafiadores. O uso de apenas quatro *features* e 2800 dados representa uma abordagem mais econômica e prática, especialmente, em contextos com limitações financeiras ou de infraestrutura.

A quantidade menor de dados e *features* facilita a implementação rápida do modelo em sistemas de triagem clínica. Isso é particularmente útil em contex-

tos em que o tempo de resposta é crítico, como em clínicas oftalmológicas que precisam de diagnósticos rápidos para tratamento imediato. Modelos com muitas *features* estão mais propensos ao *overfitting*, onde o modelo se ajusta muito bem aos dados de treinamento, mas tem desempenho ruim em novos dados. Usando apenas quatro *features*, o modelo paraconsistente pode ser mais robusto e generalizável a novos conjuntos de dados, aumentando sua aplicabilidade prática. Embora o modelo paraconsistente apresente métricas de desempenho ligeiramente inferiores em termos de acurácia, precisão, sensibilidade e especificidade; as diferenças percentuais são relativamente pequenas: por exemplo, a acurácia do SVM diminui cerca de 4% e a sensibilidade fica próxima de 6%. Esses pequenos *trade-offs* podem ser aceitáveis quando considerados os benefícios operacionais e práticos mencionados acima. Embora os modelos com 26 *features* impliquem curvas ROC superiores com AUC mais altas, os modelos paraconsistentes com quatro *features* ainda oferecem curvas ROC adequadas para triagem clínica. A diferença em AUC entre os modelos normais e paraconsistentes reflete a complexidade e quantidade de dados usados, mas a simplicidade e a eficiência computacional dos modelos paraconsistentes tornam os valiosos, especialmente em contextos com recursos limitados e necessidade de diagnósticos rápidos. Além disso, a menor propensão ao *overfitting* e a facilidade de manutenção dos modelos paraconsistentes também são aspectos críticos que favorecem sua adoção.

A maior dificuldade para a realização deste trabalho de doutorado envolveu a criação da base de dados e, também, a decisão sobre qual seria a melhor

maneira de como tratar os dados. Compreender o funcionamento da Engenharia Paraconsistente associada a cada um dos modelos de aprendizado demandou considerável tempo.

Em termos de trabalhos futuros, pretende-se coletar mais exames para melhorar a representatividade dos dados e ajudar a treinar modelos mais robustos. Bases de dados maiores ajudam a generalizar melhor os padrões de reconhecimento, diminuindo a distribuição desigual dos diagnósticos, aumentando a capacidade do modelo de reconhecer corretamente os casos menos frequentes. Investigar e testar outros algoritmos de aprendizado de máquina e técnicas de *deep learning*, que pode melhorar significativamente a precisão e a eficácia dos sistemas de diagnóstico automatizados para o Edema de Mácula Diabético, além de combinar algoritmos de aprendizado de máquina com a velocidade de processamento da computação quântica, oferecendo diagnósticos mais rápidos e precisos, também é parte do planejamento para os trabalhos vindouros.

6 Conclusões

O modelo paraconsistente de quatro *features* e 2800 dados oferece uma solução prática e eficiente que pode ser mais adequada para ambientes com recursos limitados, exigindo menos tempo e custo para implementação, ao mesmo tempo em que mantém um desempenho suficientemente alto para a triagem eficaz de Edema Macular Diabético. Assim, a PFE pode ser utilizada para a classificação da patologia ocular, reduzindo a dimensionalidade do problema, e ainda, assim, mantendo uma acurácia comparável.

Referências Bibliográficas

- [1] Alam M, Le D, Lim Ji, and X RVP, Chanand Yao. Supervised machine learning based multi-task artificial intelligence classification of retinopathies. J Clin Med, 2019 Jun 18; 8(6):872.
- [2] Shahriari MH, Sabbaghi H, Asadi F, Hosseini A, and Khorrami Z. Artificial intelligence in screening, diagnosis, and classification of diabetic macular edema: A systematic review. Surv Ophthalmol, 2023 Jan; 68(1):42-53.
- [3] Guido RC. Paraconsistent feature engineering [lecture notes]. IEEE Signal Process Mag, 2019 Jan; 36(1):154-158.
- [4] Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, and et al. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. JAMA [Internet], 2016 Dec 13 [cited 2024 Sep 7]; 316(22):2402-2410. Available from: <https://jamanetwork.com/journals/jama/fullarticle/2588763>.
- [5] Fenner BJ, Wong RLM, Lam WC, Tan GSW, and Cheung GCM. Advances in retinal imaging and applications in diabetic retinopathy screening: A review. Ophthalmol Ther, 2018 Dec 10; 7(2):333-346.
- [6] Ahuja AS and Halperin LS. Understanding the advent of artificial intelligence in ophthalmology. J Curr Ophthalmol, 2019 Jun; 31(2):115-117.

- [7] Kim SJ, Cho KJ, and Oh S. Development of machine learning models for diagnosis of glaucoma. PLoS One, 2017 May 23; 12(5):1-16.
- [8] Ahn JM, Ahn KS, Cho SH, Lee KB, and Kim US. A deep learning model for the detection of both advanced and early glaucoma using fundus photography. PLoS One [Internet], 2018 Jan 1 [cited 2024 Sep 7]; 13(11):1-8. Available from: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0207982>.
- [9] Ting DSW, Pasquale LR, Peng L, Campbell JP, Lee AY, Raman R, and et al. Artificial intelligence and deep learning in ophthalmology. British Journal of Ophthalmology, 2019 Feb; 103(2):167–175.
- [10] Kuwayama S, Ayatsuka Y, Yanagisono D, Uta T, Usui H, Kato A, and et al. Automated detection of macular diseases by optical coherence tomography and artificial intelligence machine learning of optical coherence tomography images. J Ophthalmol, 2019 Apr 9;2019:1–7.
- [11] Palazon-Cabanes A, Palazon-Cabanes B, Rubio-Velazquez E, Lopez-Bernal MD, Garcia-Medina JJ, and Villegas-Perez MP. Normative database for all retinal layer thicknesses using sd-oct posterior pole algorithm and the effects of age, gender and axial length. J Clin Med [Internet], 2020 Oct 15 [cited 2021 Feb 21];9(10):3317. Available from: <https://www.mdpi.com/2077-0383/9/10/3317>.
- [12] Liu X, Ali TK, Singh P, Shah A, McKinney SM, and et al. P, Ruamviboonsuk. Deep learning to detect oct-derived diabetic macular edema from color

- retinal photographs: A multicenter validation study. Ophthalmology Retina, 2022 May 1;6(5):398–410.
- [13] Sun Working Group. Classification criteria for toxoplasmic retinitis. Am J Ophthalmol [Internet], 2021 Aug 1 [cited 2021 Jun 28]; 228:134–141. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S0002939421001677>.
- [14] de Lucena MM. Padronização de valores para espessura e volume retiniano e espessura coroidal, e sua relação com idade, sexo e comprimento axial do globo ocular. Master's thesis, Ribeirão Preto, SP, 2024 May 3 [cited 2024 Sep 7]. Available from: <https://www.teses.usp.br/teses/disponiveis/17/17165/tde-29072024104411/>.
- [15] You QS, Tsuboi K, Guo Y, Wang J, Flaxel CJ, Bailey ST, and et al. Comparison of Central Macular Fluid Volume With Central Subfield Thickness in Patients With Diabetic Macular Edema Using Optical Coherence Tomography Angiography. JAMA Ophthalmol [Internet], 2021 Jul 1 [cited 2024 Sep 7]; 139(7):734–741. Available from: <https://jamanetwork.com/journals/jamaophthalmology/fullarticle/2779909>.
- [16] Wang Z, Zhong Y, Yao M, Ma Y, Zhang W, Li C, and et al. Automated segmentation of macular edema for the diagnosis of ocular disease using deep learning method. Scientific Reports, 2021 Jun 28 [cited 2024 Sep 7];11(1):1–12. Available from: <https://www.nature.com/articles/s41598-021-92458-8>.

- [17] Varadarajan AV, Bavishi P, Ruamviboonsuk P, Chotcomwongse P, Venugopalan S, Narayanaswamy A, and et al. Predicting optical coherence tomography-derived diabetic macular edema grades from fundus photographs using deep learning. Nature Communications, 2020 Jan 8 [cited 2024 Sep 7]; 11(1):1–8. Available from: <https://www.nature.com/articles/s41467-019-13922-8>.
- [18] Moraes G, Fu DJ, Wilson M, Khalid H, Wagner SK, Korot E, and et al. Quantitative analysis of oct for neovascular age-related macular degeneration using deep learning. Ophthalmology, 2021 May; 128(5):693–705.
- [19] de Almeida Jr GC, Guido RC, Neto JS, Rosa JM, Castiglioni L, and de Mattos et al. LC. Corneal tomography multivariate index (ctmvi) effectively distinguishes healthy corneas from those susceptible to ectasia. Biomedical Signal Process Control [Internet], 2021 Sep 1 [cited 2021 Aug 1]; 70(June):102995. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S1746809421005929>.
- [20] Schmidt-Erfurth U, Sadeghipour A, Gerendas BS, Waldstein SM, and Bogunović H. Artificial intelligence in retina. Prog Ret Eye Res, 2018 Nov 1; 67:1–29.
- [21] Hogarty DT, Mackey DA, and Hewitt AW. Current state and future prospects of artificial intelligence in ophthalmology: a review. Clin Exp Ophthalmol [Internet], 2019 Jan 1 [cited 2024 Sep 7]; 47(1):128–139.

Available from: <https://onlinelibrary.wiley.com/doi/full/10.1111/ceo.13381>.

- [22] Sengupta S, Singh A, Leopold HA, Gulati T, and Lakshminarayanan V. Ophthalmic diagnosis using deep learning with fundus images – a critical review. Artif Intell Med, 2020 Jan 1; 102:101758.
- [23] Teikari P, Najjar RP, Schmetterer L, and Milea D. Embedded deep learning in ophthalmology: making ophthalmic imaging smarter. Ther Adv Ophthalmol [Internet], 2019 Jan 1 [cited 2024 Sep 7]; 11. Available from: <https://journals.sagepub.com/doi/full/10.1177/2515841419827172>.
- [24] Li L, Zhang W, Tu X, Pang J, Lai IF, Jin C, and et al. Application of artificial intelligence in precision medicine for diabetic macular edema. Asia-Pacific Journal of Ophthalmology [Internet], 2023 Sep 13 [cited 2024 Sep 7]; 12(5):486–494. Available from: https://journals.lww.com/apjoo/fulltext/2023/09000/application_of_artificial_intelligence_in.9.aspx.
- [25] Wu T, Liu L, Zhang T, and Wu X. Deep learning-based risk classification and auxiliary diagnosis of macular edema. Intell-Based Med, 2022 Jan 1; 6:100053.
- [26] Hogarty DT, Hogarty JP, and Hewitt AW. Smartphone use in ophthalmology: What is their place in clinical practice? Surv Ophthalmol, 2020 Mar 1; 65(2):250–262.

- [27] Snellen. Snellen Chart. In: A Compendium of Tests, Scales and Questionnaires [Internet]. Psychology Press, 2020 [cited 2024 Sep 7]. p. 349–351. Available from: <https://www.taylorfrancis.com/books/9781000102147/chapters/10.4324/9781003076391-92>.
- [28] Cortes C and Vapnik V. Support-vector networks. Mach Learn [Internet], 1995 Sep [cited 2024 Sep 7]; 20(3):273–297. Available from: <http://link.springer.com/10.1007/BF00994018>.
- [29] Bishop CM. Pattern Recognition and Machine Learning. Springer, New York, 2006 [cited 2024 Sep 7]. Available from: <http://research.microsoft.com/cmbishop>.
- [30] Haykin S. Neural Networks and Learning Machines [Internet]. Pearson, Upper Saddle River, NJ, 3rd edition, 2012 [cited 2024 Sep 7]. Available from: <http://dni.dali.dartmouth.edu/9umv9yghhaoq/13-dayana-hermann-1/read-0131471392-neural-networks-and-learning-machines.pdf>.
- [31] Cover T, Thomas M, and Hart PE. Nearest neighbor pattern classification. IEEE Trans Inf Theory [Internet], 1967 Jan [cited 2024 Sep 7]; 13(1):21–27. Available from: <http://ieeexplore.ieee.org/document/1053964/>.
- [32] Quinlan JR. Induction of decision trees. Machine Learning [Internet], 1986

Mar [cited 2024 Sep 7]; 1(1):81–106. Available from: <https://link.springer.com/article/10.1007/BF00116251>.

[33] Prabhakaran S. Logistic regression - a complete tutorial with examples in r, 2017.

[34] Ruggiero MAG and Lopes VLR. Cálculo Numérico: Aspectos Teóricos e Computacionais. Editora Pearson, São Paulo, Brasil, 2002.

[35] Chopra S, Sodhi PKS, Goel AD, Kaur S, and Bajwa GS. Effects of morphological variables on macular and choroidal thickness using sd-oct. International Journal of Ophthalmology e Visual Science, 2019 Feb 13 [cited 2024 Sep 7]; 4(1):1–6. Available from: <https://www.sciencepg.com/article/10.11648/j.ijovs.20190401.11>.