



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE CIÊNCIAS BIOLÓGICAS
FACULDADE DE CIÊNCIAS BIOLÓGICAS

FLÁVIA MONTEIRO FARIAS

**USO DE ALGORITMO DE APRENDIZADO DE MÁQUINA PARA DIFERENCIAR
DADOS MORFOMÉTRICOS RETINIANOS QUANTO AO SEXO DA PESSOA**

BELÉM

2021

FLÁVIA MONTEIRO FARIAS

USO DE ALGORITMO DE APRENDIZADO DE MÁQUINA PARA DIFERENCIAR
DADOS MORFOMÉTRICOS RETINIANOS QUANTO AO SEXO DA PESSOA

Trabalho de conclusão de curso do curso de licenciatura em Ciências Biológicas apresentado ao colegiado do Instituto de Ciências Biológicas da Universidade Federal do Pará, como requisito parcial para a obtenção do grau de licenciada em ciências biológicas.

Orientador: Prof. Dr. Givago da Silva Souza.
Departamento de – NMT- UFPA.

BELÉM

2021

FLÁVIA MONTEIRO FARIAS

USO DE ALGORITMO DE APRENDIZADO DE MÁQUINA PARA DIFERENCIAR
DADOS MORFOMÉTRICOS RETINIANOS QUANTO AO SEXO DA PESSOA

Trabalho de conclusão de curso do curso de licenciatura em Ciências Biológicas apresentado ao colegiado do Instituto de Ciências Biológicas da Universidade Federal do Pará, como requisito parcial para a obtenção do grau de licenciada em ciências biológicas.

Orientador: Prof. Dr. Givago da Silva Souza. Departamento de – NMT- UFPA.



Avaliador: Letícia Miquilini de Arruda Farias, Universidade do Estado do Pará



Avaliador: Alódia Brasil Costa, Universidade Federal do Pará



BELÉM

2021

AGRADECIMENTOS

Agradeço À Universidade Federal do Pará por fornecer as condições de pesquisa necessárias a realização desta pesquisa.

Agradeço a todos os voluntários que aceitaram participar dessa pesquisa.

Agradeço ao meu Orientador Prof. Dr. Givago da Silva Souza por todas as orientações.

Agradeço a todos os colegas do laboratório de Neurologia Tropical da universidade que contribuíram para a realização dessa pesquisa.

Agradeço a minha família por todo apoio e incentivo para a conclusão dessa pesquisa.

Meus sinceros agradecimentos.

SUMÁRIO

1. INTRODUÇÃO.....	11
1.1. DIMORFISMO SEXUAL NA RETINA HUMANA.....	11
1.2. TOMOGRAFIA DE COERÊNCIA ÓPTICA	12
1.3. APRENDIZADO DE MÁQUINA	14
1.4. JUSTIFICATIVA	15
1.5. OBJETIVOS	16
1.5.1. Objetivo Geral	16
1.5.2. Objetivos específicos	16
2. MATERIAL & MÉTODOS	17
2.1. O ESTUDO.....	17
2.1.1. Critérios de inclusão e exclusão	17
2.2. AQUISIÇÃO DE IMAGENS	18
2.2.1. O exame.....	18
2.2.2. O protocolo.....	19
2.3. APRENDIZADO DE MÁQUINA	21
2.4. ANÁLISES DOS DADOS	23
3. RESULTADOS	24
4. DISCUSSÃO.....	28
5. CONCLUSÃO.....	30
6. REFERÊNCIAS BIBLIOGRÁFICAS	31
7. ANEXO	34

LISTA DE FIGURAS, GRÁFICOS E TABELAS

Figura 1. Morfologia da mácula retiniana humana.....	12
Figura 2. Interferometria de baixa coerência da luz na tomografia de coerência óptica.	13
Figura 3. Método de classificação do algoritmo kNN.....	15
Figura 4. Equipamento Spectralis HRA+OCT que opera na tecnologia do domínio espectral, localizado no núcleo de medicina tropical da Universidade Federal do Pará.	19
Figura 5. Protocolo da mácula realizado para obtenção dos valores de espessura e volume das diferentes camadas da retina realizado duas vezes na mesma região ponto a ponto com o equipamento Spectralis HRA+OCT.	20
Figura 6. Segmentação das camadas retinianas realizada com o equipamento Spectralis HRA+OCT.	21
Figura 7. Etapas do aprendizado de máquina supervisionado com a implementação do algoritmo kNN.	23
Tabela 1. Critérios de exclusão de participação no estudo com a tomografia de coerência óptica no domínio espectral. 17	
Tabela 2. Resultados das análises de dimorfismo sexual entre indivíduos adultos pertencentes a faixa etária de 20 a 40 anos dos dados de espessura e volume médios obtidos com a tomografia de coerência óptica do domínio espectral das diferentes camadas retinianas. Erro! Indicador não definido.	
Tabela 3. Resultados das comparações realizadas com o Anova 1 critério entre os valores de k para cada camada retiniana.....	26
Gráfico 1. Resultados das acurácias médias de classificação dos dados da retina como sendo de participantes do sexo masculino e do sexo feminino, de cada implementação do algoritmo kNN para cada valor de K por cada camada retiniana. 27	

LISTA DE ABREVIATURAS, SIGLAS OU SÍMBOLOS

CCG – camada de células ganglionares

CFNR – camada de fibras nervosas retinianas

CNI – camada nuclear interna

CNE – camada nuclear externa

CPI – camada plexiforme interna

CPE – camada plexiforme externa

EPR – epitélio pigmentar retiniano

ETDRS - *Early Treatment Diabetic Retinopathy Study*

kNN - *k- nearest neighbors*

MLE – membrana limitante externa

MLI – membrana limitante interna

MB – Membrana de Bruch

OCT – optical coherence tomography

SDOCT -: *Spectral Domain-Optical Coherence Tomography*

RESUMO

A presente pesquisa comparou as acurácias de classificação obtidas com a implementação de diferentes valores de K (2 a 10) do algoritmo de aprendizado de máquina *k-nearest neighbors* (kNN) em classificar os valores de espessura e volume das camadas da retina como pertencentes a participantes do sexo masculino ou a participantes do sexo feminino. O objetivo é avaliar se o parâmetro de K do algoritmo kNN interfere na classificação do dimorfismo sexual presente nos dados morfométricos retinianos. A aquisição dos dados foi realizada na mácula retiniana com a tomografia de coerência óptica no domínio espectral (tomógrafo *Spectralis HRA+OCT*) em 64 pessoas (38 mulheres e 26 homens) de visão normal, acuidade visual normal ou corrigida $\leq 20/40$, sem doenças oculares ou doenças sistêmicas, pertencentes a faixa etária de 20 a 40 anos. A análise de aprendizado de máquina considerou como características dos dados a espessura nas nove regiões do ETDRS e o volume macular total de cada camada retiniana e como classes o sexo feminino e sexo masculino. O ANOVA 1 critério e Tukey HSD *post-hoc* foram utilizados para as comparações estatísticas sobre as medidas de acurácia obtidas com as diferentes implementações do algoritmo kNN com diferentes parâmetros de k, considerando o nível de significância de $< 0,05$. O algoritmo kNN classifica com maior acurácia ($> 0,70$) as camadas mais internas da retina (CFRN, CCG, CNI, CPI, retina interna) e retina total, onde observamos diferenças significativas ($p < 0,05$) entre os sexos, quando comparado a acurácia de classificação ($> 0,60$) das camadas que não possuem diferenças significativas entre os sexos (CPE, CNE, EPR e retina externa). O uso de diferentes valores de K na implementação do algoritmo kNN apresenta efeito de interação significativo $F = 2,20$ ($p = 0,03$) entre as médias de acurácia de classificação da retina total. Por outro lado, não foram encontradas diferenças significativas entre as acurácias dos diferentes valores de k obtidos usando os dados morfométricos das diferentes camadas da retina ($p > 0,05$). A utilização de diferentes valores de K do algoritmo kNN não afeta o desempenho do algoritmo em classificar as medidas de espessura e volume das camadas da retina como pertencentes a pessoas do sexo masculino ou do sexo feminino.

Palavras-chave: Aprendizado de máquina – retina humana – dimorfismo sexual – algoritmo kNN

ABSTRACT

The present research compared the classification accuracies obtained with the implementation of different K values (2 to 10) of the machine learning algorithm k-nearest neighbors (kNN) in classifying the thickness and volume values of the retinal layers as belonging to male participants or to female participants. The objective is to evaluate whether the K parameter of the kNN algorithm interferes in the classification of sexual dimorphism present in the retinal morphometric data. Data acquisition was performed in the retinal macula with optical coherence tomography in the spectral domain (Spectralis HRA+OCT tomograph) in 64 people (38 women and 26 men) with normal vision, normal or corrected visual acuity $\leq 20/40$, without eye diseases or systemic diseases, belonging to the age group of 20 to 40 years. The machine learning analysis considered as characteristics of the data the thickness in the nine regions of the ETDRS and the total macular volume of each retinal layer and as classes the female and male sex. One-way ANOVA and Tukey HSD post-hoc were used for statistical comparisons on the accuracy measures obtained with different implementations of the kNN algorithm with different k parameters, considering a significance level of < 0.05 . The kNN algorithm classifies more accurately (> 0.70) the innermost layers of the retina (CFRN, CCG, CNI, CPI, inner retina) and total retina, where we observed significant differences ($p < 0.05$) between genders, when compared to the classification accuracy (> 0.60) of the layers that do not have significant differences between genders (CPE, CNE, EPR and external retina). The use of different K values in the implementation of the kNN algorithm presents a significant interaction effect $F = 2.20$ ($p = 0.03$) between the mean classification accuracy of the total retina. On the other hand, no significant differences were found between the accuracies of the different k values obtained using the morphometric data of the different layers of the retina ($p > 0.05$). The use of different K values of the kNN algorithm does not affect the performance of the algorithm in classifying retinal layer thickness and volume measurements as belonging to males or females.

Keywords: Machine learning – human retina – sexual dimorphism – kNN algorithm

1. INTRODUÇÃO

1.1. DIMORFISMO SEXUAL NA RETINA HUMANA

O dimorfismo sexual entre humanos pode ser observado na retina, a espessura da retina é significativamente mais espessa em indivíduos do sexo masculino quando comparados a indivíduos do sexo feminino para a mesma faixa etária (Adhi et al., 2012; Çubuk et al., 2018; Palazon-Cabanes et al., 2020). No entanto, quando se avalia as camadas da retina essas diferenças podem existir apenas para camadas específicas, entre elas a camada nuclear interna e a camada nuclear externa (Invernizzi et al., 2018; Nieves-Moreno et al., 2018; Ooto et al., 2011). Reconhecer a presença do dimorfismo sexual na retina humana é fundamental para o diagnóstico correto das doenças retinianas, principalmente para estabelecer os valores normativos que serão a métrica de comparação com as condições anômalas.

O dimorfismo sexual na retina humana tem sido investigado com a tomografia de coerência óptica (*optical coherence tomography* – OCT) na mácula retiniana. A mácula pertence a região central da retina, responsável pela visão central, e que conta com a maior densidade de fotorreceptores, além disso é constituída de outras células neuronais importantes como as células ganglionares, bipolares, amácrinas e horizontais (Bear, Connors & Paradiso, 2020). A mácula é uma pequena região com 6 mm de diâmetro, subdividida em fóvea, círculo interno e círculo externo de 1, 3 e 6 mm de diâmetro, aproximadamente. A fóvea é uma região avascular e identificada por uma depressão, onde se encontra a maior densidade de cones fotorreceptores (Yanoff & Duker, 2019; Figura 1).

É possível visualizar de forma não invasiva a organização da mácula com o OCT, que está organizada em 7 camadas neuronais, um epitélio e duas membranas limitantes por meio do arranjo de suas células. A retina neurosensorial pode ser subdividida em: camada de fibras nervosas retinianas (CFNR), camada de células ganglionares (CCG), camada plexiforme interna (CPI), camada nuclear interna (CNI), camada plexiforme externa (CPE), camada nuclear externa (CNE), camada de fotorreceptores (segmentos internos e externos dos fotorreceptores) e epitélio pigmentar retiniano (EPR), membrana limitante interna (MLI) e membrana limitante externa (MLE) (Sommers, 2013; Staurenghi et al., 2014; Figura 1).

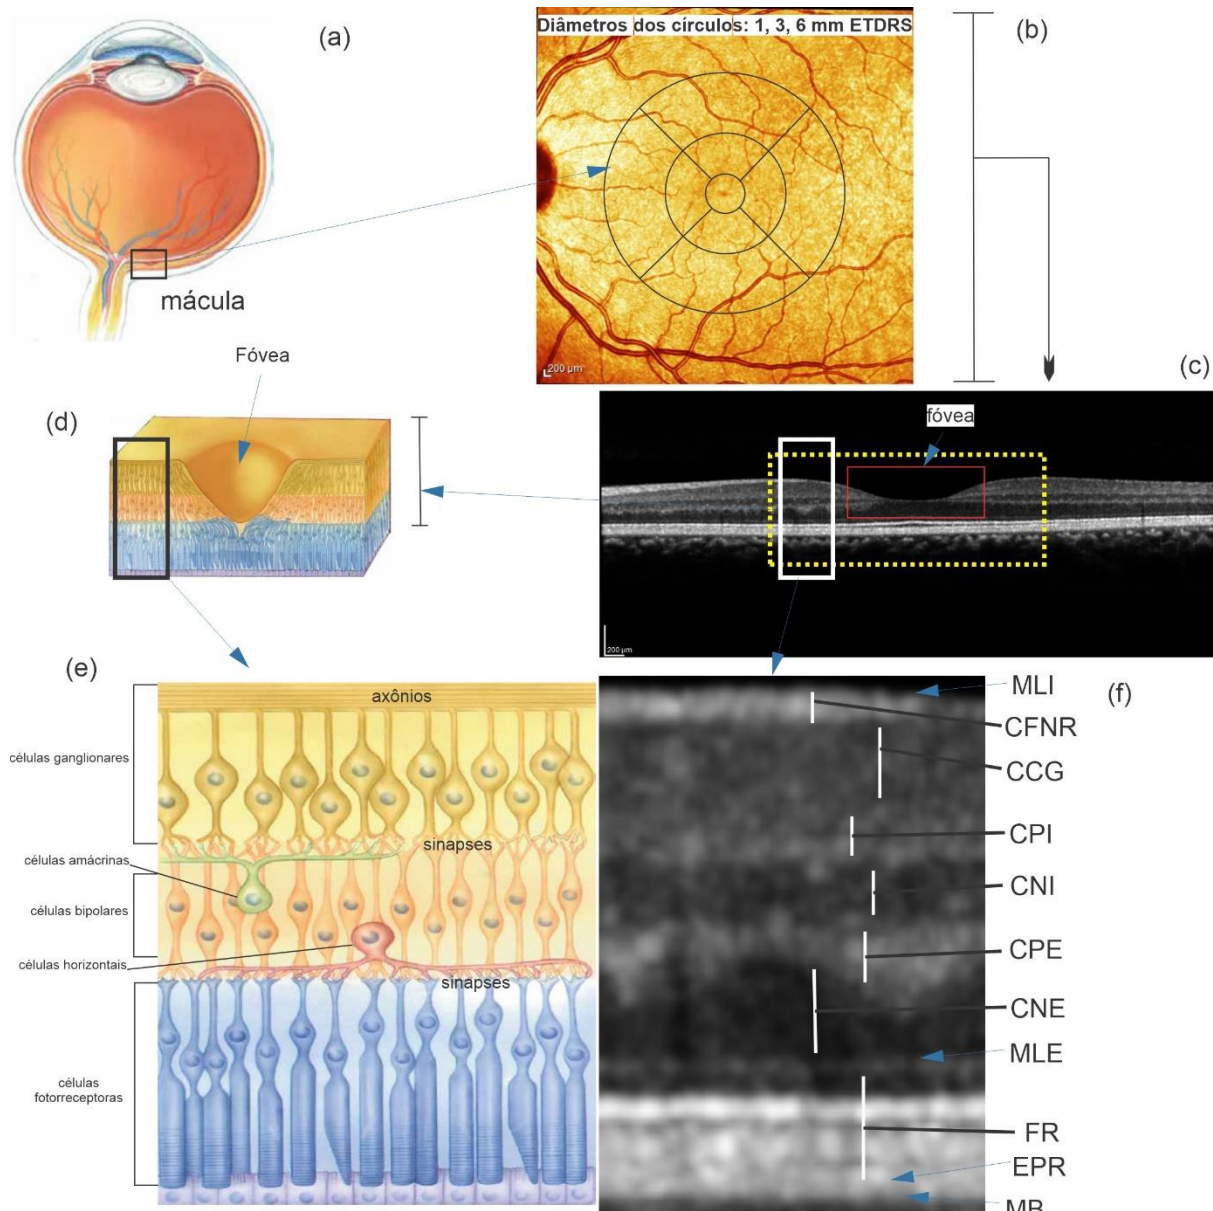


Figura 1. Morfologia da mácula retiniana humana. (a) corte transversal do globo ocular sinalizando a mácula. (b) imagem tomográfica da mácula retinianas e suas três regiões circulares segundo o ETDRS. (c) imagem tomográfica bidimensional da mácula sinalizando a fóvea (retângulo vermelho) e círculo interno (retângulo amarelo). (d) aumento do círculo interno sinalizando a depressão foveal e as camadas da retina. (e) organização das células neuronais nas camadas da retina. (f) imagem tomográfica da retina humana sinalizando a organização laminar da retina e todas as suas camadas. ETDRS = *Early Treatment Diabetic Retinopathy Study*. Ilustrações adaptadas de Bear, Connors & Paradiso, 2020.

1.2. TOMOGRAFIA DE COERÊNCIA ÓPTICA

O OCT é um método de aquisição de imagens indolor e não invasivo que permite a visualização e avaliação da mácula, do nervo óptico, da coroide e da vascularização da retina. Ele constrói as imagens com base no princípio da interferometria da luz de baixa coerência que

permite que feixes de luz possam interferir construtivamente ou destrutivamente. O interferômetro de Michelson é o fundamento para a construção dos equipamentos de OCT, o qual demonstra que uma luz de baixa coerência pode trazer informações microestruturais da retina ao ser dividida e enviada para duas estruturas com alta capacidade de reflexão (retina e espelho de referência), a recombinação desses feixes de luz refletidos produz padrões de interferência (Huang et al., 1991; Swanson et al., 1993; Figura 2).

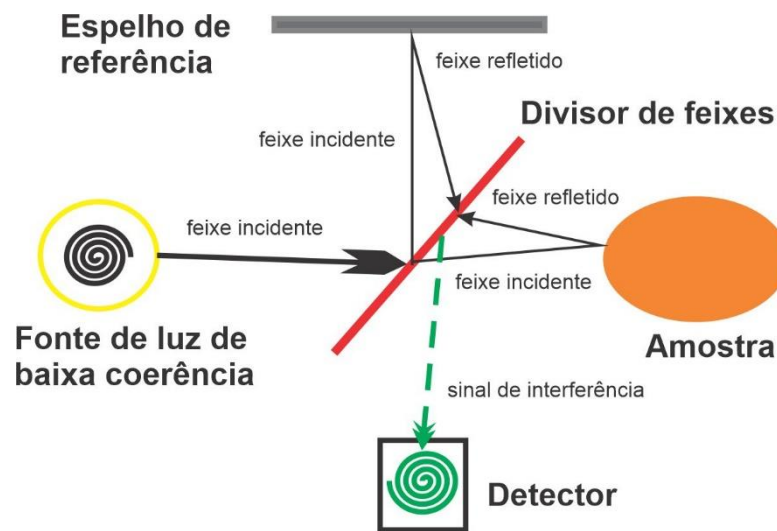


Figura 2. Interferometria de baixa coerência da luz na tomografia de coerência óptica. Fonte de baixa coerência emite um feixe de luz que é dividido em dois feixes por um divisor de feixes, os feixes são enviados cada um para um espelho de referência e uma amostra com alta capacidade de reflexão que promovem a reflexão dos feixes, sendo recombinados novamente e produzindo um padrão de interferência que deve ser detectado por um detector.

O OCT realiza escaneamentos de profundidade, chamado de *A-scan* (do inglês *amplitude scan*) ponto a ponto na amostra analisada, dentro do escaneamento de profundidade as reflexões ocorrem em diferentes profundidades e quando recombinadas com os feixes de referência que são refletidos do espelho de referência produzem os padrões de interferência que são detectados por um detector. As imagens bidimensionais, chamadas *B-scans* (do inglês *Brightness Scan*), de OCT são geradas pela união de centenas a milhares de *A-scans* e as imagens tridimensionais são geradas pela união de centenas de *B-scans* (van Velthoven et al., 2007; Schmitt, 1999).

A propriedade espectral da luz, isto é, de possuir diferentes comprimentos de onda permite produzir um espectro de interferências das várias ondas de diferentes comprimentos de onda. A tecnologia mais utilizada atualmente de tomografia de coerência óptica é a do domínio

espectral da luz que detecta o espectro de interferência simultaneamente com um espectrômetro para a produção das imagens bidimensionais e tridimensionais em poucos segundos, permitindo a visualização e a obtenção de informações estruturais das camadas retinianas que serão muito importantes para o diagnóstico das doenças retinianas (Schmidt-Erfurth et al., 2005; Walther et al., 2011).

1.3. APRENDIZADO DE MÁQUINA

Os algoritmos de aprendizado de máquina tem sido uma ferramenta facilitadora no diagnóstico de doenças oculares, por meio do desenvolvimento de modelos de classificação para grandes volumes de dados obtidos com o OCT (Vermeer et al., 2011). Algumas pesquisas realizadas com o OCT, utilizaram algoritmos de aprendizado de máquina como floresta aleatória (do inglês *random forest*) e k-vizinhos mais próximos (*k-nearest neighbor*) no diagnóstico de glaucoma, edema macular e degeneração macular relacionada à idade (Barella et al., 2013; Kim, Cho & Oh, 2017; Hussain et al., 2018).

Os algoritmos matemáticos de aprendizado de máquina podem realizar uma tarefa de classificação de um conjunto de dados, para isso o algoritmo deve formular uma função ou classificador que estabeleça uma associação entre as características ou atributos dos dados (peso, altura, área, por exemplo) com as suas respectivas classes. Nesse caso, o aprendizado consiste na execução de uma tarefa de treinamento, a experiência desenvolvida dentro dessa tarefa pode ser avaliada por uma medida de desempenho do algoritmo que indique a eficiência do algoritmo em classificar uma amostra. Ao final do processo de aprendizado, o modelo de classificação ou classificador gerado durante o treinamento pode ser aplicado em outro conjunto de dados para classificar novos dados (Langley & Simon, 1995; Jordan & Mitchell, 2015).

O aprendizado de máquina pode gerar modelos de classificação baseados no aprendizado de uma tarefa com as classes rotuladas no início do processo de aprendizado, chamado de aprendizado de máquina supervisionado, por outro lado, quando as classes não são conhecidas o algoritmo deve aprender padrões sobre o conjunto de dados baseados apenas nas características do conjunto de dados ou nas semelhanças entre as amostras para produzir os modelos de classificação, chamado de aprendizado de máquina do tipo não supervisionado (Shalev-Shwartz & Ben-David, 2014; Jordan & Mitchell, 2015).

Esta pesquisa utilizou o algoritmo de aprendizado de máquina supervisionado k-vizinhos mais próximos (*k-nearest neighbor* – kNN) para classificar dados morfométricos da retina humana, o kNN utiliza o método de aprendizado baseado em instâncias para desenvolver os modelos de classificação dos dados, no qual o algoritmo memoriza os dados do conjunto de

treinamento e os define como instâncias dispersas em um espaço n-dimensional. O kNN utiliza essas instâncias para classificar novas instâncias baseado nas semelhanças das instâncias já memorizadas. A hipótese indutiva assumida pelo kNN é de que as instâncias mais semelhantes de uma instância pesquisada estão dispersas próximo a instância pesquisada. Então, o modelo de classificação desenvolvido com o kNN se baseia em um sistema de votação, no qual os K vizinhos mais próximos de uma instância são encontrados a partir do cálculo de uma distância e a classe da maioria dos K vizinhos mais próximos definem a classe da instância pesquisada (Mitchell, 1997). Por exemplo, se o parâmetro de k do algoritmo kNN for igual a 10, o algoritmo realiza a classificação de uma amostra ou dado baseado nas classes dos 10 vizinhos mais próximos da amostra ou instância pesquisada, o algoritmo estabelece as instâncias mais próximas pelo cálculo de uma distância, por exemplo, a distância de Manhattan. Após definir as instâncias mais próximas, o algoritmo realiza um sistema de votação no qual a classe que mais se repete entre os 10 vizinhos mais próximos irá definir a classe da instância pesquisada (Figura 3).

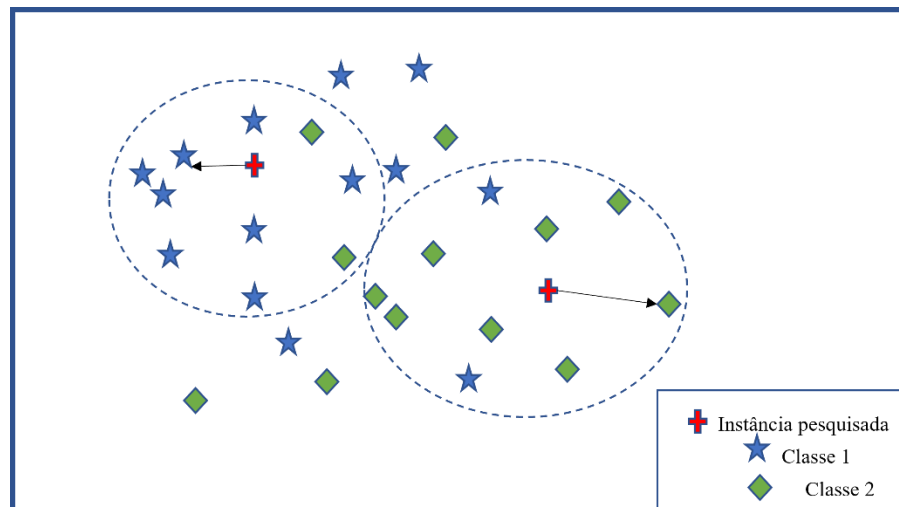


Figura 3. Método de classificação do algoritmo kNN. Linha pontilhada define a distância máxima dos 10 vizinhos mais próximos. A classe 1 define a classe da primeira instância pesquisada, pois é a classe majoritária dos 10 vizinhos mais próximos. A classe 2 define a classe da segunda instância pesquisada, pois é a classe majoritária dos 10 vizinhos mais próximos à instância pesquisada.

1.4. JUSTIFICATIVA

O desenvolvimento de métodos de classificação automáticos para a análise de dados obtidos com o a tomografia de coerência óptica podem auxiliar no diagnóstico de doenças oculares, para isso devem ser realizadas investigações de como o uso dos algoritmos de

aprendizado de máquina atuam sobre os dados da retina, a fim de desenvolver uma melhor compreensão de como os parâmetros dos algoritmos podem ser utilizados para esses dados, a sua efetividade na identificação das amostras, e mais especificamente, como o uso dos algoritmos podem ser utilizados na detecção do dimorfismo sexual na retina de humanos. Diante disso, a presente pesquisa propõe-se a avaliar o desempenho do algoritmo *k-nearest neighbors* ao modificar seus parâmetros ou valores de K em identificar os dados de espessura e volume das camadas da retina como pertencentes a pessoas do sexo masculino ou a pessoas do sexo feminino e avaliar se diferentes parâmetros de k do algoritmo kNN interferem na detecção do dimorfismo sexual presente nos dados morfométricos da retina e de suas camadas.

1.5. OBJETIVOS

1.5.1. Objetivo Geral

Comparar o desempenho obtido na implementação de diferentes valores de K (2 a 10) do algoritmo de aprendizado de máquina *k-nearest neighbors* (kNN) ou k – vizinhos mais próximos na classificação dos valores de espessura e volume das camadas da retina de adultos de visão normal como pertencentes a pessoas do sexo masculino e a pessoas do sexo feminino, a fim de observar se diferentes parâmetros de K influenciam na acurácia de classificação do algoritmo kNN na detecção do dimorfismo sexual presente nos dados morfométricos da retina.

1.5.2. Objetivos específicos

Observar o dimorfismo sexual presente nas médias de espessura e volume da retina e das camadas retinianas entre adultos saudáveis do sexo masculino e do sexo feminino pertencentes a faixa etária de 20 a 40 anos.

Mensurar a acurácia de classificação com diferentes parâmetros de K (2 a 10) do algoritmo kNN na classificação dos dados de espessura e volume das camadas retinianas como sendo de participantes do sexo feminino e do sexo masculino.

2. MATERIAL & MÉTODOS

2.1. O ESTUDO

Foram recrutados por conveniência 70 participantes pertencentes a faixa etária de 20 a 40 anos durante os anos de 2018 a 2019, para a realização do método de exame de tomografia de coerência óptica no laboratório de neurologia tropical da Universidade Federal do Pará. O estudo foi aprovado pelo comitê de Ética e Pesquisa em Seres Humanos do Núcleo de Medicina Tropical da Universidade Federal do Pará, protocolo (# 3.285.557). o estudo é do tipo transversal, analítico, observacional e descritivo.

O estudo desenvolvido consiste em 3 etapas: a primeira etapa é de aquisição dos dados com o método de aquisição de imagens da tomografia de coerência óptica e a análise dos resultados com o teste T para amostras independentes para identificação do dimorfismo sexual nas camadas da retina, considerando o nível de significância de $< 0,05$; a segunda etapa é de aplicação do algoritmo de aprendizado de máquina sobre os dados quantitativos da retina (volume e espessura) e a obtenção das medidas de desempenho do algoritmo (acurácia); e a terceira etapa é a análise das acurácias de classificação do algoritmo com o teste estatístico ANOVA um critério e *post-hoc* de Tukey, nível de significância de $< 0,05$ para as comparações estatísticas.

2.1.1. Critérios de inclusão e exclusão

Os participantes incluídos no estudo foram pessoas de visão normal, com acuidade visual normal ou corrigida de menor ou igual a 20/40, pertencentes a faixa etária de 20 a 40 anos. Além disso, não poderiam ter qualquer tipo de doença sistêmica, doença ocular, alta miopia ou ser fumante; ter realizado procedimento cirúrgico ocular, quimioterápico, radioterápico ou de terapia hormonal; ser usuário de medicamentos neuropsiquiátricos ou de colírios (exceto lubrificantes). Os critérios de exclusão estão detalhados na tabela 1.

Tabela 1. Critérios de exclusão de participação no estudo com a tomografia de coerência óptica no domínio espectral.

Fumantes	A partir de 1 ano continuamente, em qualquer período da vida
-----------------	--

Doença ocular Catarata, glaucoma, uveíte, lesão retiniana, infecção recente (até 3 meses), degenerações retinianas

Doença sistêmica Hipertensão, diabetes, câncer, hanseníase, tuberculose

Alta miopia ≥ 6 dioptrias

2.2. AQUISIÇÃO DE IMAGENS

2.2.1. O exame

O método de exame é realizado em período diurno, em ambiente iluminado e em única sessão, por um operador com pelo menos 1 ano de experiência em avaliar imagens de retina. O método permite avaliar a mácula retiniana, em suas camadas e vascularização, e nervo óptico. Cada participante observa uma luz azul de referência no equipamento *HRA+OCT Spectralis* (modelo *Heidelberg Engineering*, Alemanha; Figura 3), sem a necessidade de dilatação da pupila ou de oclusão de um dos olhos. Caso o participante apresente sensibilidade à luz, é ofertado um protetor ocular para o olho que não está sendo avaliado durante o exame, isso pode diminuir o desconforto ocular. É importante ressaltar que a maioria dos participantes realiza o exame confortavelmente, pois ele é não invasivo, indolor e feito em poucos segundos.



Figura 4. Equipamento Spectralis HRA+OCT que opera na tecnologia do domínio espectral, localizado no núcleo de medicina tropical da Universidade Federal do Pará.

2.2.2. O protocolo

Realiza-se a aplicação do protocolo desenvolvido para a mácula retiniana em duas aquisições com o equipamento *HRA+OCT Spectralis*, sendo obtidos dados quantitativos de espessura (μm) e volume (mm^3) da retina total e das camadas retinianas. O protocolo consiste em uma aquisição de imagens simultânea com luz infravermelha (*IR+OCT*), com realização de 1040 escaneamentos por segundo do tipo *A-scan*, para formar uma imagem bidimensional do tipo *B-scan* de qualidade mínima de 40 decibéis, são designadas 25 linhas de varredura por onde são enviados os *A-scans*, o quadrante do cubo macular ($5,9\text{mm} \times 5,9\text{mm}$) é centrado na fóvea e são avaliadas as 9 regiões da mácula definidas pelo *Early Treatment Diabetic Retinopathy Study* (ETDRS).

Os dados quantitativos da retina seguem a resolução do ETDRS que considera a mácula dividida em 3 círculos de diâmetros 1 mm, 3 mm e 6 mm. O círculo de menor diâmetro é chamado de fóvea, onde se encontram a maior densidade de fotorreceptores e é uma região avascular, sendo nutrida pela coroide. Os círculos de diâmetro 3 mm e 6 mm são subdivididos cada um em 4 regiões: nasal, temporal, superior e inferior (Figura 4).

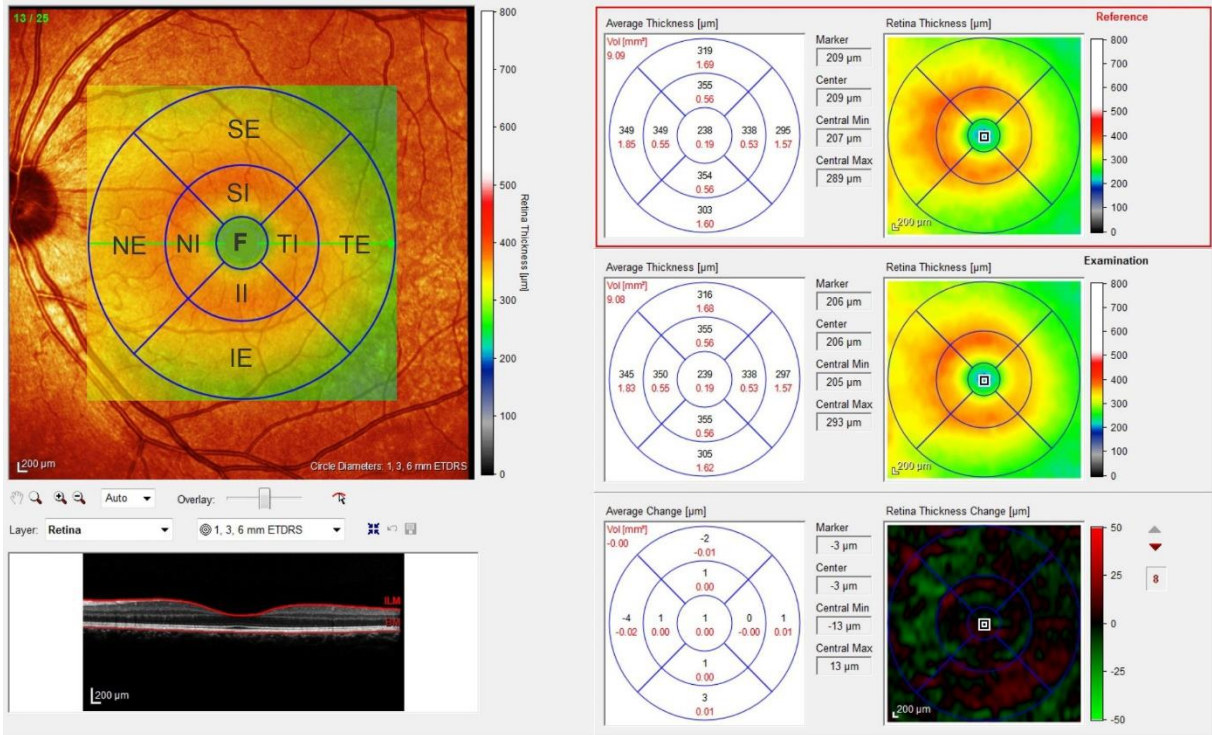


Figura 5. Protocolo da mácula realizado para obtenção dos valores de espessura e volume das diferentes camadas da retina realizado duas vezes na mesma região ponto a ponto com o equipamento *Spectralis* HRA+OCT. O cubo macular centrado na fóvea tem as nove regiões da mácula identificadas como: fóvea (F); círculo interno: nasal interna (NI), superior interna (SI), temporal interna (TI), inferior interna (II); círculo externo: nasal externa (NE), superior externa (SE), temporal externa (TE), inferior externa (IE).

A retina tem suas camadas avaliadas e para isso considera-se 10 segmentações da retina obtidas com o equipamento *HRA+OCT Spectralis* (Figura 5): retina total (a partir da membrana limitante interna até a membrana de *Bruch*), camada de fibras nervosas da retina (CFNR), camada de células ganglionares (CCG), camada plexiforme interna (CPI), camada nuclear interna (CNI), camada plexiforme externa (CPE), camada nuclear externa (CNE), epitélio pigmentar retiniana (EPR), retina interna (a partir da membrana limitante interna até a membrana limitante externa) e retina externa (a partir da membrana limitante externa até a membrana de *Bruch*). O *HRA+OCT Spectralis* não obtêm a espessura individual da camada de fotorreceptores, mas a espessura conjunta do EPR e dos segmentos dos fotorreceptores, denominada como retina externa.




Figura 6. Segmentação das camadas retinianas realizada com o equipamento Spectralis HRA+OCT. A retina externa inclui a espessura do epitélio pigmentar retiniano (EPR) e a espessura dos segmentos dos fotorreceptores (SFR)

Os dados de espessura e volume obtidos das 9 regiões do ETDRS da mácula retiniana de cada participante são planejados manualmente e caracterizam uma amostra para cada uma das 10 segmentações da retina, conforme sejam do sexo masculino ou do sexo feminino. A espessura de cada uma das 9 regiões do ETDRS foi considerada como uma característica, incluindo o volume macular, para a análise de aprendizado de máquina, ou seja, o algoritmo deve utilizar essas características para classificar a amostra como sendo do sexo masculino ou do sexo feminino.

2.3. APRENDIZADO DE MÁQUINA

Foi realizado a análise de aprendizado de máquina supervisionado, os arquivos planejados das segmentações da retina são convertidos em arquivos de valores separados por vírgula (do inglês *Comma-separated values - csv*) e seguem para a implementação com o código desenvolvido para o algoritmo K- vizinhos mais próximos ou *k-nearest neighbors (kNN)* que normaliza os dados em unidades de desvio padrão com a função *preprocessing.standard_scale*, antes da fase de treinamento do algoritmo. Além disso, dentro da análise de aprendizado de máquina, serão considerados duas classes para o treinamento com o algoritmo: sexo masculino e sexo feminino. O conjunto de dados total será dividido em dois subconjuntos, treinamento (70%) e teste (30%). Então, o algoritmo deve aprender a classificar as amostras do conjunto de treinamento conforme sejam do sexo masculino ou do sexo feminino, para isso considerando valores diferentes para K (Figura 6).

O algoritmo *kNN* possui diversos parâmetros que podem ser ajustados conforme o tipo de análise dos dados, entre eles o número de vizinhos (K) mais próximos que é usado para identificar a que classe pertence a amostra analisada, as classes que mais se repetem entre os k vizinhos definem a classe da instância pesquisada. Para identificar os vizinhos mais próximos é utilizado uma métrica da distância a ser usada na classificação que poderá ser uma das distâncias possíveis: 'manhattan', 'minkowski', 'chebyshev', 'hamming' ou 'euclidean'. Será implementado pelo programa Python com a função *sklearn.neighbors.KNeighborsClassifier*. Os valores de K definidos serão iguais a: 2, 3, 4, 5, 6, 7, 8, 9 e 10.

O aprendizado desenvolvido com o conjunto de treinamento é testado no conjunto de teste com a validação cruzada *k-fold (10-fold cross validation)* de 10 realizada 10 vezes para cada valor de K do algoritmo kNN (2, 3, 4, 5, 6, 7, 8, 9, e 10). Serão obtidos 10 valores de acurácia por meio da validação do modelo e em cada validação a amostra total é particionada em 10 partes iguais, sendo 9 partes definidas como o conjunto de treinamento do algoritmo e 1 parte como o conjunto de teste do algoritmo, obtendo a acurácia ao final da validação (Figura 6). O aprendizado se caracteriza pela obtenção da medida de desempenho do classificador, que nesse estudo definiu-se como a acurácia de classificação.

A acurácia faz o cálculo de todos os acertos de classificação (TP - valor positivo verdadeiro, TN - valor negativo verdadeiro) e divide pela soma dos erros (FP - valor positivo falso, FN - valor negativo falso) e acertos de classificação.

$$Accuracy = \frac{(TP+TN)}{(TP+FP+TN+FN)}$$

Equação 1

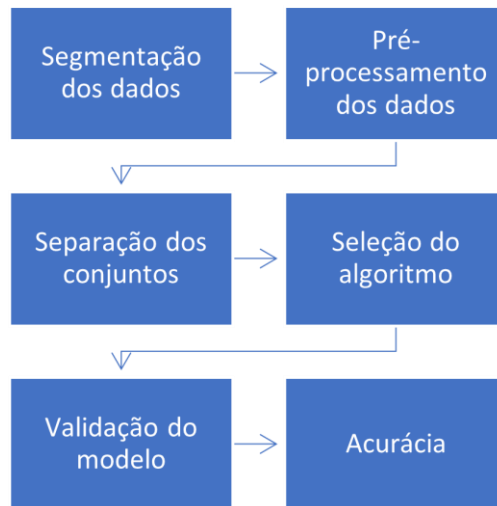


Figura 7. Etapas do aprendizado de máquina supervisionado com a implementação do algoritmo *kNN*.

A análise de aprendizado de máquina supervisionada com a aplicação do algoritmo *kNN* sobre os dados visa observar quais as medidas de desempenho do algoritmo em classificar os dados de forma automática em relação ao sexo dos participantes, para isso foram utilizados diferentes valores de *K* com o intuito de observar se há diferenças significativas de classificação das camadas retinianas quando se considera diferentes valores de *K*.

2.4. ANÁLISES DOS DADOS

Foi aplicado o teste *T* para amostras independentes sobre os dados de espessura e volume das 10 segmentações da retina obtidos com o método de tomografia de coerência óptica, a fim de observar a presença das diferenças entre os sexos, considerando o nível de significância de $< 0,05$. Os valores de acurácia obtidos com a implementação de cada valor de *k* do algoritmo *kNN* foram analisados com o teste estatístico ANOVA um critério e teste de Tukey para as múltiplas comparações, considerando o nível de significância de $< 0,05$. O programa BioStat 5.0 foi utilizado para realizar todas as análises estatísticas e o programa Python 3.8 foi utilizado para realizar todas as análises de aprendizado de máquina com o algoritmo *kNN*.

3. RESULTADOS

Foram analisados 140 olhos de 70 participantes. Após uma análise criteriosa das imagens obtidas com a tomografia de coerência óptica, foram excluídos 6 participantes da pesquisa em virtude de apresentarem alterações na retina ou erros de segmentação das imagens. A análise final contou com a participação de 64 participantes pertencentes a faixa etária de 20 a 40 anos, sendo 38 do sexo feminino ($26,05 \pm 4,68$ anos) e 26 do sexo masculino ($26,19 \pm 4,96$ anos).

A partir da amostra total de 128 olhos, foram selecionados de forma aleatória 64 olhos, sendo direito ou esquerdo. A partir da aplicação do teste T para amostras independentes sobre os dados, observou-se que há diferenças significativas entre as medidas de volume e espessura retiniana obtidas de homens e mulheres pertencentes a faixa etária de 20 a 40 anos para a retina total, CFNR, CCG, CPI, CNI e retina interna ($p < 0,05$), considerando as medidas maiores para indivíduos do sexo masculino quando comparadas a indivíduos do sexo feminino. Já para a retina externa, CPE, CNE e EPR não foram observadas diferenças significativas entre os sexos nas medidas de espessura e volume (tabela 2).

Tabela 2. Resultados das análises de dimorfismo sexual entre indivíduos adultos pertencentes a faixa etária de 20 a 40 anos dos dados de espessura e volume médios obtidos com a tomografia de coerência óptica do domínio espectral das diferentes camadas retinianas.

CAMADA RETINIANA	MEDIDAS	SEXO	SEXO	P-VALOR
		MASCULINO	FEMININO	
RETINA TOTAL (MLI- MB)	Espessura (μm)	322,88 \pm 11,25	309,93 \pm 12,45	<0,0001*
	Volume (mm^3)	8,97 \pm 0,33	8,65 \pm 0,37	0,0007*
RETINA INTERNA (MLI-MLE)	Espessura (μm)	240,07 \pm 10,42	227,92 \pm 12,34	0,0001*
	Volume (mm^3)	6,69 \pm 0,31	6,40 \pm 0,35	0,001*
CFNR	Espessura (μm)	27,77 \pm 2,11	25,55 \pm 2,21	0,0001*

CCG	Volume (mm ³)	0,94 ± 0,08	0,87±0,09	0,003*
	Espessura (µm)	43,19±2,23	40,25±3,47	0,0001*
CPI	Volume (mm ³)	1,18±0,07	1,12±0,09	0,003*
	Espessura (µm)	36,01±1,60	33,91±2,66	0,0002*
CNI	Volume (mm ³)	0,96± 0,05	0,92±0,07	0,009*
	Espessura (µm)	35,56±2,15	33,17±2,31	<0,0001*
CPE	Volume (mm ³)	1,01±0,05	0,96±0,06	0,001*
	Espessura (µm)	29,05±2,63	28,92±3,83	0,88
CNE	Volume (mm ³)	0,81±0,06	0,80±0,10	0,83
	Espessura (µm)	68,67±8,27	66,41±6,47	0,23
EPR	Volume (mm ³)	1,78±0,22	1,73±0,17	0,27
	Espessura (µm)	15,07±0,99	14,61±1,15	0,10
RETINA EXTERNA (MLE-MB)	Volume (mm ³)	0,40±0,03	0,39±0,03	0,08
	Espessura (µm)	82,87±2,23	81,68±2,42	0,05
	Volume (mm ³)	2,28±0,06	2,25±0,06	0,05

Valores médios de espessura e volume na mácula retiniana em indivíduos do sexo masculino e sexo feminino. *Valores significativamente mais espessos no grupo do sexo masculino comparados ao grupo do sexo feminino, utilizando o teste T para amostras independentes (nível de significância de < 0,05).

Todos os valores de K (2 a 10) do algoritmo kNN classificaram corretamente com acurácia média superior a 60% os dados das camadas CFNR, CCG, CNI e retina interna como sendo do sexo masculino ou do sexo feminino. Os resultados de **alta acurácia** ($\geq 0,70$) foram obtidos para as camadas: **retina total** (k = 6, 7 e 9), **CFNR** (k = 3, 5, 7, 8 e 9), **CCG** (k = 4 e 6), **CPI** (k = 3, 8 e 10), **CNI** (k = 2, 4, 7 e 9), **retina interna** (k = 3, 6, 7, 8 e 10). Em relação

as camadas que não apresentaram diferenças significativas entre os sexos nas medidas de espessura e volume das camadas retinianas, o algoritmo kNN classificou com acurácia média superior a 60% as camadas: **CPE** (k = 5 e 9), **CNE** (k = 2, 3, 4, 5, 6), **EPR** (k = 2, 3, 4, 7, 8 e 9) e **retina externa** (k = 4 e 5).

A partir da aplicação do teste ANOVA um critério sobre as médias de acurácias de cada implementação do algoritmo kNN com valores de k =2 a k = 10 por camada retiniana, observou-se que há diferenças significativas ($< 0,05$) entre as médias de acurácia de classificação do algoritmo *kNN* quando se leva em consideração diferentes valores de K para a retina total (Gráfico 1). O efeito de interação entre as acurácias dos valores de k da retina total foi significativo $F = 2,20$ ($p = 0,03$; tamanho do efeito 0,18), mas após as comparações múltiplas não foi possível identificar diferenças nessas comparações. Não foram encontradas diferenças significativas das acurácias obtidas usando dados morfométricos das camadas da retina (tabela 3).

Tabela 2. Resultados das comparações realizadas com o Anova 1 critério entre os valores de k para cada camada retiniana.

<i>Camadas retinianas</i>	<i>Valor de F (interação)</i>	<i>Valor de p</i>
CFNR	0,71	0,68
CCG	0,74	0,65
CPI	1,37	0,22
CNI	0,92	0,50
CPE	0,34	0,94
CNE	1,69	0,11
EPR	1,93	0,06
Retina externa	1,75	0,09
Retina interna	1,33	0,23




Gráfico 1. Resultados das acurácias médias de classificação dos dados da retina como sendo de participantes do sexo masculino e do sexo feminino, de cada implementação do algoritmo kNN para cada valor de K por cada camada retiniana.

4. DISCUSSÃO

O algoritmo kNN apresenta alta acurácia ($> 0,70$) na classificação dos dados de espessura e volume da retina como sendo de pessoas do sexo feminino ou do sexo masculino, em relação as camadas mais internas da retina (CFRN, CCG, CNI, CPI), retina interna e retina total, onde observamos diferenças significativas ($p < 0,05$) entre os sexos em relação as medidas de tais camadas. Por outro lado, o kNN também apresenta bons resultados ($> 0,60$) na classificação das camadas que não possuem diferenças significativas entre os sexos (CPE, CNE, EPR) e na retina externa (0,70).

As medidas de espessura e volume da retina total, retina interna, CFRN, CCG, CPI, CNI são maiores nos homens do que nas mulheres. Os resultados sobre dimorfismo sexual observados nessa pesquisa com o Spectralis HRA+OCT (SDOCT) corroboram os resultados de outras pesquisas com equipamentos de tomografia SDOCT que realizaram a mesma segmentação da retina e que também avaliaram os efeitos do sexo sobre as medidas de espessura e volume das camadas da retina. Nieves-Moreno et al. (2018) avaliaram o impacto do sexo sobre as camadas da retina e observaram as medidas de espessura e volume da retina total, da CCG, CPI, CNI como mais espessos em indivíduos do sexo masculino em relação a indivíduos do sexo feminino. O estudo de Palazon-Cabanes et al. (2020) estabeleceu os valores normativos para as camadas da retina e avaliou o efeito do sexo sobre a espessura, encontrando as medidas de espessura da retina total, da CCG, da CPI, da CNI, da retina interna também mais espessas em pessoas do sexo masculino quando comparadas a pessoas do sexo feminino.

No entanto, a presente pesquisa não encontrou diferenças significativas ($p > 0,05$) entre as médias de acurácias obtidas na implementação do modelo com diferentes valores de k (variação 2 a 10) do algoritmo kNN na detecção do dimorfismo sexual da retina humana em medidas de espessura e volume das camadas retinianas. Outro estudo que também avaliou a acurácia de classificação obtida por diferentes valores de K (variação 1 a 10) do algoritmo kNN foi o desenvolvido por Safitri & Juniati (2017) que obtiveram médias de acurácias semelhantes para diferentes valores de k na detecção de retinopatia diabética em imagens de fundo de olho. O modelo desenvolvido por Pawlovsky & Nagahashi (2014) com o algoritmo kNN para o prognóstico de câncer de mama utilizou diferentes valores de k (variação 1 a 10), eles observaram que valores maiores de k apresentavam acurácias mais altas (média 0,76).

O algoritmo kNN tem sido amplamente implementado em modelos de classificação para diagnóstico de doenças retinianas e apresenta resultados satisfatórios. A classificação do estágio de retinopatia diabética em imagens de fundo de olho também já foi realizada com o algoritmo kNN por Bandyopadhyay et al (2018) que obtiveram acurácia média de 94% no desempenho do modelo. O modelo proposto por Chowdhury & Banerjee (2019) com o kNN apresentou alta acurácia ($>0,90$) na detecção das alterações retinianas em decorrência da retinopatia diabética e da degeneração macular relacionada a idade. Kim, Cho & Oh (2017) desenvolveram um modelo de diagnóstico de glaucoma baseado na espessura da CFNR no nervo óptico e obtiveram acurácia média de 97%. Já o modelo proposto por Fink et al. (2008) obteve alta acurácia ($> 0,90$) utilizando $k = 7$ na classificação de imagens do nervo óptico para detecção de glaucoma. O modelo de detecção de glaucoma proposto por Acharya et al. (2017) também encontrou acurácia semelhante ($> 0,90$) na classificação de imagens de nervo óptico, utilizando $k = 10$.

Em modalidades de predição fora do âmbito das doenças oculares, o kNN também apresenta resultados melhores do que com a implementação de outros algoritmos de aprendizado de máquina, como foi observado por Adil et al. (2018) que obtiveram alta acurácia ($> 0,90$) na predição de olhos fechados e olhos abertos utilizando dados de eletroencefalografia e valor de $k = 1$. Rajput et al. (2020) desenvolveram um modelo de detecção de hipertensão em estágios iniciais por meio da classificação do algoritmo kNN das alterações nos sinais de eletrocardiografia e obtiveram 99% de acurácia no desempenho do modelo. O estudo realizado por Ali et al (2020) obteve 100% de acurácia na classificação de doenças cardíacas utilizando o $k = 2$.

5. CONCLUSÃO

A utilização de diferentes valores de K do algoritmo kNN não afeta o desempenho do algoritmo em classificar as medidas de espessura e volume das camadas da retina como pertencentes a pessoas do sexo masculino ou do sexo feminino. As medidas de espessura e volume na mácula retiniana das camadas mais internas da retina são significativamente maiores em pessoa do sexo masculino em relação a pessoas do sexo feminino.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ACHARYA, U. Rajendra et al. A novel algorithm to detect glaucoma risk using texture and local configuration pattern features extracted from fundus images. **Computers in biology and medicine**, v. 88, p. 72-83, 2017.

ADHI, Mehreen et al. Macular thickness by age and gender in healthy eyes using spectral domain optical coherence tomography. **PLoS One**, v. 7, n. 5, p. e37638, 2012.

ADIL, Syed Hasan et al. Prediction of Eye State Using KNN Algorithm. In: **2018 International Conference on Intelligent and Advanced System (ICIAS)**. IEEE, 2018. p. 1-5.

ALI, Md Mamun et al. Heart disease prediction using supervised machine learning algorithms: Performance analysis and comparison. **Computers in Biology and Medicine**, v. 136, p. 104672, 2021.

BANDYOPADHYAY, Shreyasi et al. Gradation of diabetic retinopathy using KNN classifier by morphological segmentation of retinal vessels. In: **International Proceedings on Advances in Soft Computing, Intelligent Systems and Applications**. Springer, Singapore, 2018. p. 189-198.

BARELLA, Kleyton Arlindo et al. Glaucoma diagnostic accuracy of machine learning classifiers using retinal nerve fiber layer and optic nerve data from SD-OCT. **Journal of ophthalmology**, v. 2013, 2013.

BEAR, Mark; CONNORS, Barry; PARADISO, Michael A. **Neuroscience: Exploring the Brain, Enhanced Edition: Exploring the Brain**. Jones & Bartlett Learning, 2020.

CHOWDHURY, Amrita Roy; BANERJEE, Sreeparna. Case Based reasoning in retina abnormalities detection. In: **2019 4th International Conference on Information Systems and Computer Networks (ISCON)**. IEEE, 2019. p. 273-278.

ÇUBUK, Mehmet et al. Effects of age and gender on macular thickness in healthy subjects using spectral optical coherence tomography/scanning laser ophthalmoscopy. **International ophthalmology**, v. 38, n. 1, p. 127-131, 2018.

FINK, F. et al. ICA analysis of retina images for glaucoma classification. In: **2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. IEEE, 2008. p. 4664-4667.

HUANG, David et al. Optical coherence tomography. *science*, v. 254, n. 5035, p. 1178-1181, 1991.

HUSSAIN, Md Akter et al. Classification of healthy and diseased retina using SD-OCT imaging and Random Forest algorithm. **PloS one**, v. 13, n. 6, p. e0198281, 2018.

INVERNIZZI, Alessandro et al. Normative data for retinal-layer thickness maps generated by spectral-domain OCT in a white population. **Ophthalmology Retina**, v. 2, n. 8, p. 808-815. e1, 2018.

JORDAN, Michael I.; MITCHELL, Tom M. Machine learning: Trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p. 255-260, 2015.

KIM, Seong Jae; CHO, Kyong Jin; OH, Sejong. Development of machine learning models for diagnosis of glaucoma. **PloS one**, v. 12, n. 5, p. e0177726, 2017.

LANGLEY, Pat; SIMON, Herbert A. Applications of machine learning and rule induction. **Communications of the ACM**, v. 38, n. 11, p. 54-64, 1995.

NIEVES-MORENO, María et al. Impacts of age and sex on retinal layer thicknesses measured by spectral domain optical coherence tomography with Spectralis. **PLoS One**, v. 13, n. 3, p. e0194169, 2018.

OTO, Sotaro et al. Effects of age, sex, and axial length on the three-dimensional profile of normal macular layer structures. **Investigative ophthalmology & visual science**, v. 52, n. 12, p. 8769-8779, 2011.

PALAZON-CABANES, Ana et al. Normative database for all retinal layer thicknesses using SD-OCT posterior pole algorithm and the effects of age, gender and axial length. **Journal of clinical medicine**, v. 9, n. 10, p. 3317, 2020.

PAWLOVSKY, Alberto Palacios; NAGAHASHI, Mai. A method to select a good setting for the kNN algorithm when using it for breast cancer prognosis. In: **IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)**. IEEE, 2014. p. 189-192.

RAJPUT, Jaypal Singh et al. Automated detection of severity of hypertension ECG signals using an optimal bi-orthogonal wavelet filter bank. **Computers in Biology and Medicine**, v. 123, p. 103924, 2020.

SAFITRI, Diah Wahyu; JUNIATI, Dwi. Classification of diabetic retinopathy using fractal dimension analysis of eye fundus image. In: **AIP conference proceedings**. AIP Publishing LLC, 2017. p. 020011.

SCHMIDT-ERFURTH, Ursula et al. Three-dimensional ultrahigh-resolution optical coherence tomography of macular diseases. **Investigative ophthalmology & visual science**, v. 46, n. 9, p. 3393-3402, 2005.

SCHMITT, Joseph M. Optical coherence tomography (OCT): a review. **IEEE Journal of selected topics in quantum electronics**, v. 5, n. 4, p. 1205-1215, 1999.

SHALEV-SHWARTZ, Shai; BEN-DAVID, Shai. **Understanding machine learning: From theory to algorithms**. Cambridge university press, 2014.

SOMMERS, Ignatius G. **Histology and Histopathology of the Eye and its Adnexa**. Butterworth-Heinemann, 2013.

STAURENGHI, Giovanni et al. Proposed lexicon for anatomic landmarks in normal posterior segment spectral-domain optical coherence tomography: the IN• OCT consensus. **Ophthalmology**, v. 121, n. 8, p. 1572-1578, 2014.

SWANSON, Eric A. et al. In vivo retinal imaging by optical coherence tomography. **Optics letters**, v. 18, n. 21, p. 1864-1866, 1993.

MITCHELL, Tom M. **Machine learning**. McGraw-Hill Science, 1997.


VAN VELTHOVEN, Mirjam EJ et al. Recent developments in optical coherence tomography for imaging the retina. **Progress in retinal and eye research**, v. 26, n. 1, p. 57-77, 2007.

VERMEER, K. A. et al. Automated segmentation by pixel classification of retinal layers in ophthalmic OCT images. **Biomedical optics express**, v. 2, n. 6, p. 1743-1756, 2011.

WALTHER, Julia et al. Optical coherence tomography in biomedical research. **Analytical and bioanalytical chemistry**, v. 400, n. 9, p. 2721-2743, 2011.

YANOFF, Myron; DUKER, J. **Ophthalmology**. 5th. 2019.

7. ANEXO



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Avaliação por Tomografia de Coerência Óptica (OCT) das diferentes estruturas retinianas e do nervo óptico.

Pesquisador: Givago da Silva Souza

Área Temática:

Versão: 3

CAAE: 01086118.3.0000.5172

Instituição Proponente: Núcleo de Medicina Tropical-NMT/ Universidade Federal do Pará - UFPA

Patrocinador Principal: CONSELHO NACIONAL DE DESENVOLVIMENTO CIENTIFICO E TECNOLÓGICO-CNPQ
Universidade Federal do Pará

DADOS DO PARECER

Número do Parecer: 3.265.557

Apresentação do Projeto:

O projeto pretende avaliar a espessura das camadas retinianas de pessoas adultas saudáveis do sexo masculino e feminino, por faixa etária.

Objetivo da Pesquisa:

Objetivo Primário:

Avaliar a espessura das camadas retinianas de pessoas adultas saudáveis do sexo masculino e feminino, por faixa etária.

Objetivo Secundário:

- Avaliar se o sexo influencia na espessura das camadas retinianas.
- Identificar os valores normativos para a espessura da retina de pessoas saudáveis.
- Verificar se há perda de camadas de fibras nervosas conforme a senescência do organismo humano.
- Avaliar através da tomografia de coerência óptica as camadas da retina. Comparar a espessura

Endereço: Av. Generalíssimo Deodoro, 92

Bairro: Umarizal

CEP: 66.055-040

UF: PA

Município: BELEM

Telefone: (91)3201-0961

E-mail: cepbel@ufpa.br