

# Detecção automática de doenças da visão em imagens de reflexo vermelho utilizando Deep Features e Ensemble

Matheus Henrique A. Nunes<sup>1</sup>, João Dallyson S. Almeida<sup>1</sup>, Italo Francyles S. da Silva<sup>1</sup>,  
Geraldo Braz Júnior<sup>1</sup>

<sup>1</sup>Vision and Image Processing Lab – Universidade Federal do Maranhão (UFMA)  
São Luís – MA – Brasil

{matheushanunes, jdallyson, francyles, geraldo}@nca.ufma.br

**Abstract.** *Brückner’s Test, popularly known as red reflex exam, is a simple and painless diagnosis method aimed at early detection of vision related diseases. Observing retinal red reflex with an direct ophthalmoscope, internal structural features are identified and can alert to a compromised eye health. The methodology combines characteristic descriptors based on deep learning and classifiers to identify the presence of pathologies in red reflex images, and studies highlighted the use of the convolucional neural network DeepLoc and an ensemble combining Linear Regression, Random Forest and SVM classifiers, achieving 93.20% of accuracy, sensibility of 84.50% and specificity of 93.20%.*

**Resumo.** *O Teste de Brückner, popularmente conhecido como o exame do reflexo vermelho, é um método simples e indolor de diagnóstico cujo objetivo é detectar patologias oculares. Observando o reflexo retiniano vermelho, com o auxílio de um equipamento chamado oftalmoscópio direto, é possível identificar características das estruturas internas do olho que podem indicar possíveis problemas de saúde ocular. Para identificar a presença de patologias em imagens de reflexo vermelho, essa metodologia utiliza descritores de características baseados em aprendizado profundo e classificadores. Os experimentos realizados utilizando a rede neural convolucional DeepLoc em conjunto com um ensemble dos classificadores Regressão Logística, Random Forest e SVM alcançaram uma acurácia de 93,20%, sensibilidade de 84,50% e especificidade de 93,20%.*

## 1. Introdução

A Atenção Primária à Saúde é uma estratégia governamental cujo objetivo é melhorar a saúde dos cidadãos por meio de prevenção contínua [Cruz 2008], e a ação dos profissionais é essencial para a descoberta de patologias em fases iniciais, aumentando as chances de cura. A presença de uma atenção oftalmológica minuciosa se faz necessária para a manutenção de uma boa qualidade de vida.

Muitas crianças não têm acesso adequado à saúde ocular, e doenças como o Retinoblastoma podem ser ignoradas por falta de profissionais para realizar exames de diagnóstico. O censo oftalmológico de 2019, realizado pelo Conselho Brasileiro de Oftalmologia (CBO), mostrou que apenas 29% dos municípios brasileiros possuem oftalmologistas. Apesar de existirem mais de 16 mil oftalmologistas no Brasil, a má distribuição desses profissionais faz com que 23% da população esteja sem acesso a esse tipo de

serviço [CBO 2019]. O diagnóstico precoce do Retinoblastoma e de outras doenças oculares é crucial, pois lesões em estágio inicial têm maior probabilidade de cura. Além disso, indivíduos com histórico familiar precisam de uma avaliação desde o nascimento [Aguiar 2010]

A identificação rápida dessas doenças pode ser extremamente eficaz para o combate às mesmas. Manter os profissionais de saúde envolvidos no cuidado infantil para detectar anomalias é um ponto-chave para uma melhor taxa de cura [Khedekar et al. 2019].

A triagem executada pelo Teste do Reflexo Vermelho (TRV) é essencial para a detecção de doenças como a catarata, inflamações na retina ou vítreo, que podem levar até a cegueira total. Em relação ao retinoblastoma, há uma taxa de mortalidade relacionada, então a identificação da presença da doença pode significar redução da morbimortalidade associada [Tamura and Teixeira 2009].

A principal contribuição deste trabalho é a proposição de um novo método para a detecção de patologias da visão em imagens de reflexo vermelho na região retiniana, utilizando a rede *DeepLoc* para extrair *deep features* em conjunto com um *ensemble* dos classificadores Regressão Logística, Random Forest e *Support Vector Machine* (SVM). Dessa forma, o processo de verificação de doenças através do TRV poderá ser mais prático e confiável, permitindo a sua aplicação em plataformas de fácil acesso ao público.

## 2. Trabalhos Relacionados

Na literatura não há tantos trabalhos diretamente relacionados. Dentre os disponíveis, os principais são os trabalhos de [Silva et al. 2018], [Pinto et al. 2020] e [Martins et al. 2021]. O primeiro engloba uma parte maior do processo, da aquisição a segmentação da região de interesse, enquanto os outros dois dão mais enfoque ao processo de classificação, tal qual esta pesquisa.

Com um escopo mais delimitado, Rivas et al. (2014) desenvolveram um esquema que usa a teoria da lógica fuzzy para combinar uma série de classificadores especializados na detecção de leucocoria a partir de imagens do reflexo retiniano. A metodologia apresentou uma taxa de precisão de 92%, com uma taxa de verdadeiros positivos de 89% e uma taxa de falsos positivos de 11%.

Silva et al. (2019) apresentou contribuições para as etapas de localização de olhos, segmentação do reflexo retiniano e classificação do mesmo, a partir de descritores de textura e cor. Com o uso do classificador SVM, estas características são analisadas separadamente e em conjunto, sendo verificado que a análise de cores por meio da combinação das Matrizes de Coocorrência de níveis de Cores (CLCM) com as métricas do histograma de cores local grid 5x5 contribuiu de melhor forma com o classificador, trazendo uma taxa de 95,25% de acurácia, 98,9% de especificidade, resultados bem avaliados. No tópico de trabalhos futuros de sua pesquisa, é mencionada a utilização de Deep Features como modelo de aprendizagem profunda, sendo um dos pontos-chave desta pesquisa.

Pinto et al. (2020) propõe a utilização de Redes Neurais Convolucionais para o processo de extração de características e classificação do modelo. Resultados de experimentos com o uso de *embeddings* e meta-classificadores combinados com diferentes espaços de cor como HSV (Hue, Saturation, Value) e Lab entregaram taxas satisfatórias,

alcançando 83,2% de acurácia na detecção de problemas oculares, em 128 imagens.

Martins et al. (2021) apresentaram um método para detectar problemas ocular em imagens de reflexo vermelho oriundas do Teste de Brückner. Para tanto, utilizaram descritores de cor dominante e momento de cor, técnicas de otimização e classificador XGBoost. Seus experimentos alcançaram 92% de acurácia, 98% de especificidade e 76% de sensibilidade.

Mais recentemente, porém com um escopo mais limitado que o nosso, o estudo de Kriangsakdachai et al. (2022) utilizou imagens de reflexo vermelho para classificar imagens de indivíduos com ou sem ambliopia. O método proposto inclui etapas de detecção de faces, detecção dos olhos, ambos usando Haar Cascade, detecção da pupila com a Mask RCNN e, por último, a classificação da ambliopia usando DenseNet. O método foi testado em 200 imagens e alcançou acurácia de 72,25%, sensibilidade de 75,5% e especificidade de 0,69%.

Apesar dos resultados não serem suficientes para superar os encontrados na pesquisa de Silva et al. (2019), Pinto et al. (2020) validaram a utilização de redes neurais convolucionais (CNNs) como classificadores no processo de detecção de patologias da visão. Este é um ponto importante para demonstrar a necessidade da continuidade dos estudos nesta temática, e é de onde esta pesquisa abordou, investindo na utilização de *Deep Features* combinadas ao classificador *Ensemble*.

### 3. Materiais e Método

Neste trabalho, a metodologia consistiu na combinação de descritores de características baseados em *deep features* com aplicação de técnicas de redução de dimensionalidade e classificadores. A Figura 1 apresenta as etapas do método proposto, que serão apresentadas a seguir.

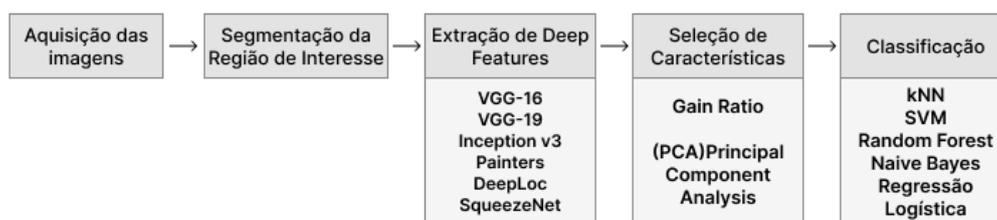


Figura 1. Etapas do método proposto.

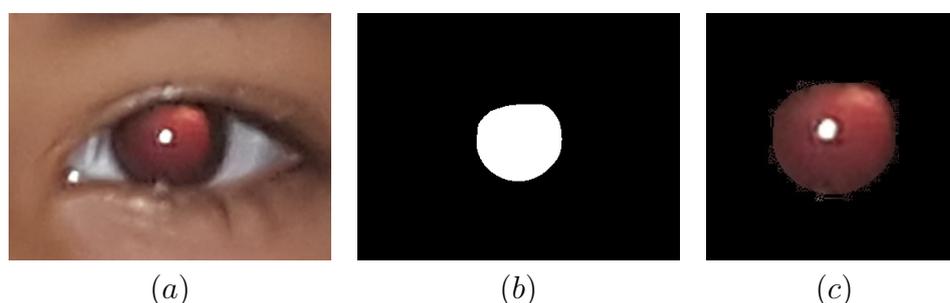
#### 3.1. Aquisição das Imagens e Pré-Processamento

Os experimentos foram executadas com a mesma base de dados utilizada por Silva et al. (2019), formada por imagens de pacientes de uma clínica oftalmológica localizada na cidade X, seguindo recomendações padrão propostas para o Teste de Brückner, já que os pacientes não usavam óculos e estavam com as pupilas dilatadas. Por meio da captura de imagens de um smartphone com a função flash ativada, simulando o procedimento com o oftalmoscópio direto, foi possível ter um resultado armazenado semelhante ao do exame para posterior estudo e classificação. A base é formada por 108 imagens, 88 de pacientes em condição normal e 30 com condições patológicas. Duas imagens utilizadas na base são apresentadas na Figura 2.



**Figura 2. (a) Imagem classificada com patologias e (b) imagem classificada sem patologias.**

Além da base original de imagens com suas características, foram usadas as imagens contendo marcações da região de interesse para posterior tratamento. Estas imagens estão representadas em escala de preto e branco e foram extraídas a partir do método proposto por Silva et al. (2019), que segundo o autor, utiliza uma arquitetura de rede completamente convolucional chamada U-net. Abaixo, na Figura 3, há um exemplo das imagens e seus formatos antes e depois da aplicação da máscara. Esta imagem pertence à classe "normal", sem a presença de patologias.



**Figura 3. (a) Imagem original com reflexo vermelho, (b) imagem de máscara contendo a região de interesse extraída a partir de (a) e (c) imagem pós-aplicação da máscara.**

### 3.2. Extração de Deep Features

A etapa de extração de *deep features* visa representar de forma semântica estruturas específicas em uma imagem, de forma que haja distinção entre pontos e regiões de interesse de outras áreas que não possuem características relevantes. Assim, descritores de características baseados em CNNs são uma opção para se obter um mapa de informações das regiões de interesse da imagem de entrada, e possuem um desempenho satisfatório nesta tarefa devido a sua grande capacidade em reconhecimento de padrões e extração de informações [Ma et al. 2021]. Além disso, métodos que aplicam técnicas de aprendizado profundo possuem comprovadamente maior desempenho de correspondência e potencial comparados a métodos tradicionais [Ma et al. 2021].

As técnicas usadas para tal são conhecidas pelo seu poder de generalização para tarefas de uso geral. Este é o caso da Rede Neural Convolucional VGG-16 [Simonyan and

Zisserman 2014], que para a tarefa de classificação de imagens a partir de outras bases de dados, tem a sua última camada totalmente conectada removida e suas 4096 ativações geradas pela penúltima camada descritas em forma de vetor de características, que podem ser combinadas a classificadores como SVM.

Assim, foram testadas diferentes CNNs que utilizam o mesmo método para extração de *deep features* a partir das imagens de entrada. Dentre elas, a VGG-19 [Simonyan and Zisserman 2014], Inception v3 [Szegedy et al. 2016], SqueezeNet [Iandola et al. 2016], Painters [Godec et al. 2019] e DeepLoc [Almagro Armenteros et al. 2017]. Cada uma das redes utilizadas possui uma arquitetura específica e por esta razão a dimensionalidade da saída varia entre os modelos. A Tabela 1 apresenta a quantidade de características geradas por cada uma das redes usadas neste passo.

**Tabela 1. Dimensionalidade do vetor de características gerado por cada uma das redes usadas.**

Rede Usada	Número de Características
VGG-16 / VGG-19	4096
Inception v3 / Painters	2048
SqueezeNet	1000
DeepLoc	512

### 3.3. Seleção de Características

O conhecimento extraído da informação de entrada é formalizado em vetores de características, que podem armazenar grandes quantidades de dados. Como esses vetores apresentam dimensionalidade elevada, é possível que algumas características representadas sejam redundantes ou pouco relevantes. Para isso, se faz necessária a aplicação de técnicas de redução de dimensionalidade, que buscam remover características redundantes ou irrelevantes ao problema, sem se desfazer de informações cruciais. Isso significa que mesmo com menos características que a entrada original, padrões e variância de informações essenciais para a descrição correta tendem a ser mantidas, diminuindo a quantidade de memória e tempo necessárias para seu processamento [Zebari et al. 2020].

Neste passo, foram extraídas características das mesmas imagens com e sem as operações de segmentação da região de interesse. As 108 imagens estavam classificadas nas classes *normal* e *patologia* e suas características foram extraídas a partir de diferentes redes neurais convolucionais.

Posteriormente, técnicas de redução de características foram aplicadas neste passo, como Análise de Componentes Principais (PCA) [Hastie et al. 2009] e *Gain Ratio* [Quinlan 1986]. Também foi aplicado um método para remoção de características com muita repetição de valores zero, que tendem a indicar áreas fora da região de interesse da classificação.

### 3.4. Treinamento e Classificação

As redes utilizadas para extração de *Deep Features* foram escolhidas por já estarem treinadas em um grande conjunto de dados de imagens, o que significa que as características extraídas são altamente discriminativas e representativas. Além disso, por estarem facilmente acessíveis em várias bibliotecas de aprendizado de máquina, como TensorFlow,

Keras e no Orange [Demšar et al. 2013], ferramenta utilizada para extração de características, seleção e classificação.

Foram usados diferentes métodos para o processo de classificação das características adquiridas e pré-processadas. Dentre os modelos, pode-se listar kNN, Máquina de Vetor de Suporte (SVM), Random Forest, Regressão Logística e Naive Bayes. Além disso, cada uma das redes e métodos contou com três formas de amostragem entre treino e validação. Foram usadas as estratégias de *Cross-validation* com 5 e 10 *folds* e *Leave one out*. A Tabela 2 mostra as configurações aplicadas nos classificadores.

**Tabela 2. Parâmetros utilizados nos classificadores.**

Classificador	Parâmetros utilizados
SVM	Kernel RBF, Tolerância numérica de 0,001; Limite de 100 iterações
Reg. Logística	Regularização Ridge (L2)
Random Forest	Número de árvores: 10
kNN	K = 5; Distância Euclidiana; Peso uniforme

#### 4. Resultados

Para avaliar comparativamente a aplicação da metodologia apresentada na Seção 3 e propôr um método que combine os melhores desempenhos em relação à extração, seleção de características e classificação, foram testados os cinco classificadores propostos pela pesquisa, descritos na Seção 3.4.

As Tabelas 3, 4 e 5 indicam o desempenho dos classificadores combinados aos extratores de características baseados em aprendizado profundo, separadas pelas técnicas de redução de dimensionalidade de validação cruzada com 5 e 10 *folds* e *Leave-one-out*. Nestes experimentos a classificação foi realizada a partir das características extraídas nas imagens resultantes das operações para delimitação da região de interesse, ordenadas a partir da métrica de sensibilidade. Os dez melhores resultados de cada combinação estão presentes. As tabelas apresentam o tipo de experimento realizado: *Leave one out* (LOO), *Cross-validation* em 10 *folds* (CV-10) ou *Cross-validation* em 5 *folds* (CV-5); e as métricas de avaliação: Acurácia (A), F1-Score (F1), Especificidade (E) Sensibilidade (S).

Dentre os resultados com melhor média de classificação, percebe-se a forte presença do classificador Regressão Logística combinado com o descritor de características baseado na rede *DeepLoc*. Para avaliação do método e obtenção de métricas, foi usada a técnica de validação cruzada em cinco *folds*, e os resultados mostram o desempenho da combinação: foram alcançados 91,5% de acurácia, 83,90% de sensibilidade e 91,5% de especificidade.

A partir da presença constante dos classificadores Random Forest, Regressão Logística e SVM, foi testada também a aplicação de um *ensemble* entre os três, visando alcançar métricas mais eficientes. Esta combinação foi utilizada com as técnicas aplicadas ao modelo de maior sensibilidade, com a extração de características baseada na rede *DeepLoc* e validação cruzada em cinco *folds*. Com isso, índices de sensibilidade, especificidade e precisão foram aumentados, e podem ser verificados na Tabela 6:

**Tabela 3. Resultados usando a técnica de redução de dimensionalidade *Gain Ratio*.**

<b>Embed.</b>	<b>Classificador</b>	<b>Amostra</b>	<b>AUC</b>	<b>A</b>	<b>F1</b>	<b>E</b>	<b>S</b>
DeepLoc	Random F	CV-10	0,87	88,10	87,80	88,10	76,20
DeepLoc	Random F	LOO	0,91	85,60	84,40	85,60	64,30
Inception v3	SVM	CV-5	0,90	84,70	83,90	84,70	66,20
DeepLoc	Random F	CV-5	0,88	84,70	83,90	84,70	66,20
DeepLoc	SVM	LOO	0,89	84,70	84,40	84,70	70,60
DeepLoc	Naive Bayes	LOO	0,83	83,90	84,00	83,90	74,70
VGG-19	Naive Bayes	LOO	0,58	83,90	82,20	83,90	59,40
VGG-19	Naive Bayes	CV-10	0,71	83,10	80,20	83,10	52,50
VGG-19	Random F	LOO	0,66	83,10	81,50	83,10	59,10
DeepLoc	Naive Bayes	CV-10	0,81	82,20	82,30	82,20	72,00

**Tabela 4. Resultados usando a técnica de redução de dimensionalidade *PCA-10*.**

<b>Embed.</b>	<b>Classificador</b>	<b>Amostra</b>	<b>AUC</b>	<b>A</b>	<b>F1</b>	<b>E</b>	<b>S</b>
DeepLoc	Regressão L	LOO	0,89	90,70	90,50	90,70	81,40
VGG-16	Regressão L	LOO	0,89	90,70	90,50	90,70	81,40
DeepLoc	SVM	LOO	0,94	89,00	88,30	89,00	72,10
DeepLoc	Random F	CV-10	0,89	82,20	81,60	88,20	65,40
DeepLoc	SVM	CV-10	0,93	88,10	88,70	88,10	74,00
DeepLoc	Regressão L	CV-10	0,92	88,10	88,10	88,10	80,60
DeepLoc	kNN	LOO	0,85	84,70	83,60	84,70	64,00
DeepLoc	Random F	LOO	0,89	84,70	83,90	84,70	61,10
VGG-16	Random F	LOO	0,89	84,70	83,90	84,70	61,10
DeepLoc	kNN	CV-10	0,87	83,90	82,60	83,90	61,60

**Tabela 5. Resultados usando a técnica de redução de dimensionalidade *Remove Sparse Values*.**

<b>Embed.</b>	<b>Classificador</b>	<b>Amostra</b>	<b>AUC</b>	<b>A</b>	<b>F1</b>	<b>E</b>	<b>S</b>
DeepLoc	Regressão L,	CV-5	0,89	<b>91,50</b>	91,30	<b>91,50</b>	<b>83,90</b>
DeepLoc	Regressão L	LOO	0,90	90,70	90,50	90,70	83,90
DeepLoc	Regressão L	CV-10	0,91	89,00	88,80	89,00	78,70
VGG-16	Regressão L	LOO	0,87	88,10	87,30	88,10	69,60
DeepLoc	Random F	LOO	0,91	87,30	86,90	87,30	73,70
DeepLoc	SVM	LOO	0,92	86,40	85,20	86,40	64,60
VGG-19	Regressão L	LOO	0,90	86,40	85,40	86,40	66,80
DeepLoc	SVM	CV-5	0,90	85,60	84,70	85,60	66,50
DeepLoc	Random F	CV-10	0,91	85,60	84,90	85,60	68,70
VGG-19	Regressão L	CV-10	0,90	85,60	84,70	85,60	66,50

Por último, a Tabela 7 mostra os resultados de trabalhos citados na revisão da literatura comparados aos resultados alcançados pelo nosso método em relação à acurácia, especificidade e sensibilidade.

**Tabela 6. Métricas alcançadas a partir da aplicação de *ensemble* entre os classificadores Random Forest, Regressão Logística e SVM.**

Embed.	Classificador	AUC	A	F1	P	E	S
DeepLoc	Ensemble	0,92	93,20	93,10	93,20	93,20	84,50

**Tabela 7. Comparação de resultados**

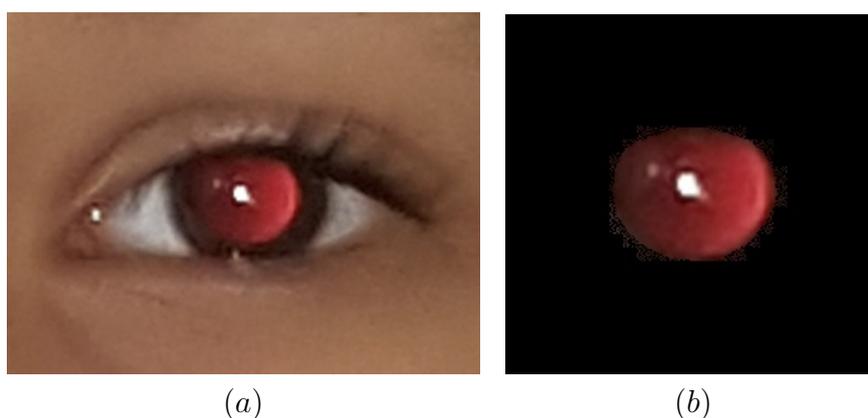
Autor	Técnicas aplicadas	A (%)	E (%)	S (%)
[Silva 2019]	CLCM + MHLC 5x5 e SVM	95,25	98,90	84,66
[Pinto et al. 2020]	CNNs e Meta-classificadores	90,60	97,77	70
[Martins et al. 2021]	Descritores de Cor + XGBoost	92%	98	76
<b>Método Proposto</b>	<b>DeepLoc e Ensemble</b>	<b>93,2</b>	<b>93,2</b>	<b>84,5</b>

Em comparação com os métodos descritos na Seção 2, o método proposto, que usa descritores de características baseados em redes neurais convolucionais, se equiparou em relação à sensibilidade quando comparado as técnicas utilizadas por Silva et al. (2019), mesmo não as superando quanto as outras métricas. Porém, em paralelo ao método de Pinto et al. (2020), que também utilizou técnicas baseadas em CNNs, o método proposto, inclusive, alcançou maior acurácia e sensibilidade. Nosso método superou, também, a acurácia e sensibilidade obtida por Martins et al. (2021).

#### 4.1. Estudos de Casos

Na seção de estudos de caso, imagens da base e suas respectivas classificações são apresentadas para uma análise guiada sobre o método de classificação proposto por esta pesquisa.

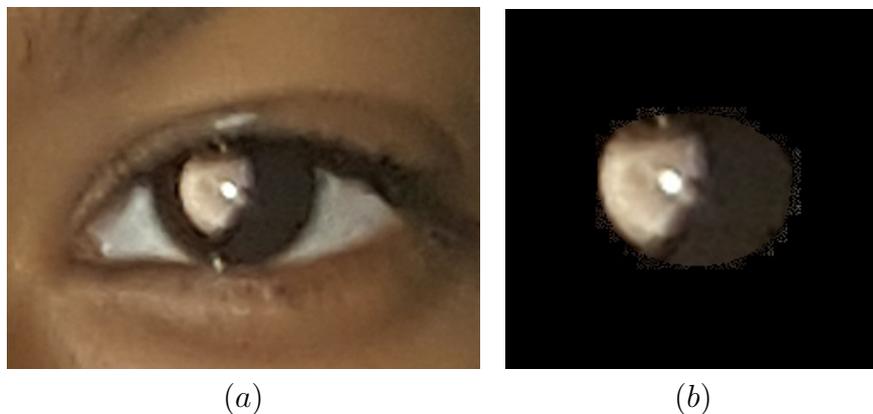
Na Figura 4, é ilustrada uma imagem classificada corretamente por todos os classificadores como não patológica. Imagens de olhos saudáveis tendem a apresentar um reflexo em cor avermelhada mais uniforme e intensa [Silva 2019].



**Figura 4. Imagens (a) original e (b) com a aplicação da máscara com a região de interesse, da classe sem patologias.**

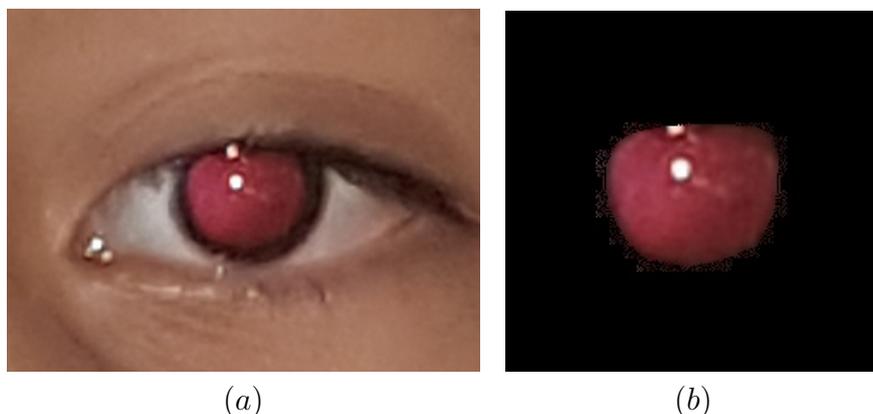
Já a Figura 5 conta com uma imagem classificada corretamente como patológica por todos os classificadores. Percebe-se um reflexo esbranquiçado em parte da retina, diferindo do reflexo vermelho comum. Isso caracteriza a leucocoria. O diagnóstico de

leucocoria pode ser sinal da presença de doenças como catarata, retinoblastoma e doenças da retina e vítreo [Tamura and Teixeira 2009].



**Figura 5. Imagens (a) original e (b) com a aplicação da máscara com a região de interesse, da classe com patologias.**

A Figura 6 ilustra um caso que oferece dificuldade para os classificadores por apresentar reflexo vermelho, porém em menor intensidade que na Figura 4. A baixa intensidade do reflexo também pode ser um sinal da presença de patologias. Usando o descritor de características baseado na rede *DeepLoc* e a técnica de validação cruzada de *5 folds*, três dos cinco classificadores propostos definiram a imagem como pertencente à classe normal. O classificador baseado em Regressão Logística classificou corretamente a presença de patologias.



**Figura 6. Imagens (a) original e (b) com a aplicação da máscara com a região de interesse, da classe com patologia e gerou classificações falhas.**

## 5. Conclusão

Esta pesquisa se propôs a desenvolver um novo método para a detecção de patologias oculares a partir de imagens de reflexo vermelho, usando *deep features*. O procedimento adotado pode ser dividido em cinco etapas (Figura 1). A primeira foi o pré-processamento, onde foram utilizadas técnicas para oclusão de elementos fora da região de interesse nas imagens obtidas anteriormente. Foram aplicadas operações binárias para a remoção de

píxeis indiferentes à incorporação de características, que delimitam, por exemplo, regiões periféricas ao olho do paciente.

Já para a extração de *deep features*, foram utilizados descritores de características baseados em Redes Neurais Convolucionais. Em seguida, foram aplicadas técnicas para redução de dimensionalidade. Para a classificação, foram executados e testados diferentes métodos como Regressão Logística e Random Forest em experimentos realizados usando validação cruzada e *Leave one out*, obtendo cerca de 83,9% de sensibilidade combinando o descritor de características baseado na rede neural *DeepLoc* e o classificador Regressão Logística usando validação cruzada. Posteriormente, com a aplicação de um *ensemble* entre os classificadores Random Forest, Regressão Logística e SVM índices maiores foram alcançados, com 84,5% de sensibilidade.

Os resultados alcançados evidenciam o bom desempenho de *deep features* para descrição de características em imagens e corroboram a importância do uso de CNNs para tal. Os resultados são comparáveis aos obtidos nas pesquisas anteriores relacionadas a esta base de imagens e evidenciam a importância de estudos mais detalhados nesta área de atuação. Há margem para melhora e mais técnicas podem ser empregadas a fim de oferecer uma melhor acurácia na detecção como, por exemplo, aplicar *data augmentation*. A quantidade de imagens da base foi um dos fatores limitantes e incrementá-la pode significar um melhor espaço de amostragem para treinamento do modelo. Além disso, pode-se investigar a utilização de outros modelos pré-treinados na etapa de extração de *deep features*, tais como, EfficientNet [Tan and Le 2019] e ConvNeXt [Zoph et al. 2018].

Os resultados apresentados são promissores e indicam também como este modelo pode contribuir para a produção de uma plataforma auxiliar para a detecção de patologias da visão, servindo de apoio ao profissional oftalmológico que é quem pode validar o resultado e oferecer um diagnóstico mais apurado.

## Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, Fundação de Amparo a Pesquisa do Maranhão (FAPEMA), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Empresa Brasileira de Serviços Hospitalares (Ebserh) Brazil (Proc. 409593/2021-4).

## Referências

- Aguiar, A. S. C. d. (2010). Validação de tecnologia para avaliação do teste do reflexo vermelho. Dissertação (Mestrado em Enfermagem) - Faculdade de Farmácia, Odontologia e Enfermagem. Universidade Federal do Ceará, Fortaleza.
- Almagro Armenteros, J. J., Søndersby, C. K., Søndersby, S. K., Nielsen, H., and Winther, O. (2017). Deeploc: prediction of protein subcellular localization using deep learning. *Bioinformatics*, 33(21):3387–3395.
- CBO (2019). Atenção primária à saúde no brasil. [https://www.cbo.com.br/novo/publicacoes/condicoes\\_saude\\_ocular\\_brasil2019.pdf](https://www.cbo.com.br/novo/publicacoes/condicoes_saude_ocular_brasil2019.pdf).
- Cruz, A. (2008). Atenção primária à saúde no brasil. <https://bvsms.saude.gov.br/bvs/periodicos/consensus35.pdf>.

- Demšar, J., Curk, T., Erjavec, A., Gorup, Č., Hočevar, T., Milutinovič, M., Možina, M., Polajnar, M., Toplak, M., Starič, A., et al. (2013). Orange: data mining toolbox in python. *the Journal of machine Learning research*, 14(1):2349–2353.
- Godec, P., Pančur, M., Ilenič, N., Čopar, A., Stražar, M., Erjavec, A., Pretnar, A., Demšar, J., Starič, A., Toplak, M., et al. (2019). Democratized image analytics by visual programming through integration of deep models and small-scale machine learning. *Nature communications*, 10(1):4551.
- Hastie, T., Tibshirani, R., and Friedman, J. (2009). *The elements of statistical learning: data mining, inference, and prediction*. Springer.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., and Keutzer, K. (2016). Squeezenet: Alexnet-level accuracy with 50x fewer parameters and 0.5 mb model size. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 4856–4864.
- Khedekar, A., Devarajan, B., Ramasamy, K., Muthukkaruppan, V., and Kim, U. (2019). Smartphone-based application improves the detection of retinoblastoma. *Eye*, 33:1.
- Kriangsakdachai, S., Ayudhya, S. P. N., Kusakunniran, W., Ayudhya, W. D. N., Chantarasagul, C., Manasboonpermpool, R., Sathianvichitr, K., Sangsre, P., and Surachatkumtonekul, T. (2022). Anomaly detection in red reflex images using deep learning approaches. In *TENCON 2022-2022 IEEE Region 10 Conference (TENCON)*, pages 1–6. IEEE.
- Ma, J., Jiang, X., Fan, A., Jiang, J., and Yan, J. (2021). Image matching from handcrafted to deep features: A survey. *International Journal of Computer Vision*, 129(1):23–79.
- Martins, C. M. d. S., de Santos, R. D. A., Almeida, J. D. S. d., Junior, G. B., and Teixeira, J. A. M. (2021). Detecção de patologias oculares em imagens de reflexo vermelho utilizando descritores de cor. In *Anais do XXI Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 346–357. SBC.
- Pinto, A. M., Almeida, J. D. S., Braz Júnior, G., and Silva, I. F. S. (2020). Detecção de patologias da visão em imagens de reflexo vermelho utilizando deep learning. In *Anais da VIII Jornada de Informática do Maranhão (eJIM)*.
- Quinlan, J. R. (1986). Induction of decision trees. In *Machine learning*, volume 1, pages 81–106. Springer.
- Rivas-Perea, P., Baker, E., Hamerly, G., and Shaw, B. F. (2014). Detection of leukocoria using a soft fusion of expert classifiers under non-clinical settings. *BMC ophthalmology*, 14:1–15.
- Silva, I. F., Almeida, J. D., Teixeira, J. A., Junior, G. B., and de Paiva, A. C. (2018). Teste automático de brückner baseado em imagens. In *Anais do XVIII Simpósio Brasileiro de Computação Aplicada à Saúde*. SBC.
- Silva, I. F. S. d. (2019). Detecção automática da presença de patologia na visão baseada em imagens do teste de brückner. Master’s thesis, Universidade Federal do Maranhão.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 2818–2826.
- Tamura, M. and Teixeira, L. F. (2009). Leukocoria and the red reflex test. *Einstein (São Paulo)*, 7.
- Tan, M. and Le, Q. V. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. pages 6105–6114. PMLR.
- Zebari, R., Abdulazeez, A., Zeebaree, D., Zebari, D., and Saeed, J. (2020). A comprehensive review of dimensionality reduction techniques for feature selection and feature extraction. *Journal of Applied Science and Technology Trends*, 1(2):56–70.
- Zoph, B., Vasudevan, V., Shlens, J., and Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 8697–8710.