



**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS FLORIANO
CURSO TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE
SISTEMAS**

BIANCA FREIRE MARQUES

**REVISÃO SISTEMÁTICA DE BANCO DE DADOS DE RETINOGRÁFIAS EM
PACIENTES COM DMRI: DISPOSITIVOS DE ABORDAGENS COMPUTACIONAIS**

**FLORIANO
2026**

BIANCA FREIRE MARQUES

REVISÃO SISTEMÁTICA DE BANCO DE DADOS DE RETINOGRAFIAS EM
PACIENTES COM DMRI: DISPOSITIVOS DE ABORDAGENS COMPUTACIONAIS

Trabalho de Conclusão de Curso (artigo científico) apresentado como exigência parcial para obtenção do diploma do Curso de Tecnologia em Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Floriano.

Orientadora: Prof^a. Dr^a. Rafael Ângelo Santos Leite.

Coorientador: Prof. Dr. José Joaquim de Moura Ramos.

FLORIANO

2026

REVISÃO SISTEMÁTICA DE BANCO DE DADOS DE RETINOGRÁFIAS EM PACIENTES COM DMRI: DISPOSITIVOS DE ABORDAGENS COMPUTACIONAIS

Bianca Freire Marques¹
Prof. Dr. Rafael Ângelo Santos Leite²
Prof. Dr. José Joaquim de Moura Ramos³

RESUMO

A Degeneração Macular Relacionada à Idade (DMRI) é uma das principais causas de perda visual em pessoas idosas, afetando a mácula e comprometendo funções visuais essenciais como leitura, reconhecimento de rostos e percepção de cores. O diagnóstico precoce é fundamental para controlar o avanço da doença, sendo a retinografia e a Tomografia de Coerência Óptica (OCT) os principais exames utilizados na prática clínica. Nos últimos anos, a aplicação de técnicas de inteligência artificial à análise de imagens retinianas tem se mostrado promissora, desde que sustentada por bases de dados de qualidade. Este trabalho tem como objetivo realizar uma revisão sistemática dos principais bancos de dados de imagens retinianas relacionados à DMRI, investigando suas características, os dispositivos utilizados para a captação das imagens e as abordagens computacionais aplicadas em pesquisas. A metodologia inclui a busca em bases acadêmicas como PubMed, Scopus e Web of Science, com critérios de inclusão e exclusão bem definidos. Espera-se que os resultados contribuam para a consolidação de informações relevantes sobre os *datasets* disponíveis, apontando oportunidades e limitações no uso desses dados para fins computacionais. Este estudo busca apoiar futuras pesquisas no desenvolvimento de soluções tecnológicas mais precisas e acessíveis voltadas ao diagnóstico automatizado da DMRI.

Palavras-chave: degeneração macular; imagem retiniana; inteligência artificial; bancos de dados; revisão sistemática.

ABSTRACT

Age-Related Macular Degeneration (AMD) is one of the leading causes of visual impairment in the elderly, affecting the macula and compromising essential visual functions such as reading, facial recognition, and color perception. Early diagnosis is crucial to slow the progression of the disease, with retinography and Optical Coherence Tomography (OCT) being the main diagnostic tools used in clinical practice. In recent years, the application of artificial intelligence techniques to retinal image analysis has shown promising results, provided that it is supported by high-quality databases. This study aims to conduct a systematic review of the main retinal image datasets related to AMD, investigating their characteristics, the imaging devices used for image acquisition, and the computational approaches applied in research. The methodology includes searching academic databases such as PubMed, Scopus, and Web of Science, with well-defined inclusion and exclusion criteria. The expected outcome is to contribute to the consolidation of relevant information about the available datasets, highlighting opportunities and limitations in their use for computational purposes. This research seeks to support future studies in the development of more accurate and accessible technological solutions for automated AMD diagnosis.

Keywords: macular degeneration; retinal image; artificial intelligence; databases; systematic review.

Data de aprovação: 16/06/2026

1 INTRODUÇÃO

A Degeneração Macular Relacionada à Idade (DMRI) é uma condição ocular progressiva que afeta a mácula, região central da retina responsável pela visão detalhada e pela percepção de cores. Trata-se de uma das principais causas de perda visual em idosos, especialmente em países com populações envelhecidas (Lim et al., 2012), impactando significativamente a qualidade de vida dos pacientes. Estimativas apontaram que cerca de 196 milhões de pessoas foram afetadas pela DMRI em 2020, com projeções de que esse número alcance 288 milhões até 2040 (Mares et al., 2024), tornando a doença um relevante problema de saúde pública global. A doença manifestou-se nas formas seca ou úmida. A forma seca esteve associada ao afinamento da mácula e ao acúmulo de drusas (Auw-Haedrich; Staubach; Witschel, 2002), enquanto a forma úmida envolveu o crescimento anormal de vasos sanguíneos sob a retina, com possível vazamento de fluido e sangue (Campochiaro, 2013; Vidal et al., 2023).

A identificação precoce da DMRI mostrou-se essencial para minimizar a progressão da doença. Nesse contexto, exames como a Tomografia de Coerência Óptica (OCT) e a retinografia desempenharam papel fundamental na análise estrutural da retina e na detecção de alterações características, como drusas e neovascularização (Schmitt, 1999).

¹Graduanda em Análise e Desenvolvimento de Sistemas. Instituto Federal do Piauí – Floriano
biancafreiremarquess@gmail.com

²Mestre e Doutor em Ciência da Propriedade Intelectual (UFS). Professor do Ensino Básico, Técnico e Tecnológico. Instituto Federal do Piauí - Campus Floriano. rafaelangelo@ifpi.edu.br

³Doutor (cum laude) e Pós-doutorado em Inteligência Artificial. Professor da Universidade da Coruña – Espanha. joaquim.demoura@udc.es

O avanço das tecnologias de imageamento retiniano, com destaque para o OCT de domínio espectral (SD-OCT) e o OCT de varredura por fonte (SS-OCT), permitiu a visualização tridimensional de alta resolução das camadas retinianas, ampliando as possibilidades de análise clínica e computacional (Frank-Publig et al., 2025).

Nos últimos anos, a aplicação de técnicas de inteligência artificial (IA) e aprendizado de máquina à análise de imagens médicas ganhou destaque, com o objetivo de automatizar e padronizar diagnósticos (López-Varela et al., 2022). Modelos baseados em redes neurais convolucionais (CNNs), como a arquitetura U-Net (Ronneberger, Fischer e Brox, 2015), foram amplamente empregados para tarefas de segmentação e classificação em imagens retinianas, apresentando resultados comparáveis ou superiores à avaliação humana em diversas situações (Pramil et al., 2023; Mukherjee et al., 2025). Em particular, abordagens que exploram a informação volumétrica tridimensional dos volumes de OCT demonstraram desempenho superior às abordagens bidimensionais tradicionais na segmentação de estruturas como drusas e fluido retiniano (Goyanes et al., 2024; López-Varela et al., 2022). No entanto, o desenvolvimento eficaz dessas soluções dependeu diretamente da disponibilidade de bancos de dados de imagens retinianas bem estruturados, anotados por especialistas e representativos da diversidade clínica dos pacientes.

Trabalhos que compilaram conjuntos de dados já existentes representaram um passo inicial essencial na construção de ferramentas computacionais inovadoras, pois otimizaram o tempo de pesquisa e possibilitaram que os esforços fossem direcionados à proposição de metodologias mais eficazes. Apesar da importância estratégica desses conjuntos de dados, a literatura ainda carece de uma sistematização abrangente que catalogue os principais bancos de dados disponíveis para pesquisas sobre DMRI, identificando seus dispositivos de captura, características técnicas e as abordagens computacionais que os utilizaram. Neste sentido, o objetivo geral deste trabalho foi realizar uma revisão sistemática para identificar e analisar os principais bancos de dados de imagens retinianas disponíveis para estudos em DMRI, considerando os dispositivos de captura utilizados, as abordagens computacionais aplicadas, suas métricas de desempenho e suas contribuições para o avanço do diagnóstico automatizado da doença. Esperou-se, com isso, contribuir para a construção de uma base sólida que auxiliasse futuras pesquisas e o desenvolvimento de soluções tecnológicas voltadas ao diagnóstico da DMRI.

2 REFERENCIAL TEÓRICO

2.1 DEGENERAÇÃO MACULAR RELACIONADA À IDADE

A Degeneração Macular Relacionada à Idade (DMRI) é uma das principais causas de perda de visão entre idosos, afetando a mácula (a parte central da retina responsável pela visão detalhada e pela percepção de cores). Ela se apresenta em duas formas: seca e úmida (Lim et al., 2012). A forma seca é mais comum e envolve o afinamento da mácula, com acúmulo de drusas (depósitos extracelulares entre o epitélio pigmentar da retina e a membrana de Bruch (Auw-Haedrich; Staubach; Witschel, 2002)). Já a forma úmida é mais agressiva e caracteriza-se pela neovascularização coroidal, ou seja, o crescimento anormal de vasos sanguíneos sob a retina, que podem vaziar fluido ou sangue, resultando em danos severos à visão (Vidal et al., 2023; Campochiaro, 2013).

2.2 DIAGNÓSTICO DA DMRI E MODALIDADES DE IMAGEAMENTO

A detecção precoce da DMRI mostrou-se fundamental para prevenir a progressão da doença. Entre os principais exames utilizados estiveram a Tomografia de Coerência Óptica (OCT) e a retinografia. A OCT permitiu a visualização em alta resolução das camadas da retina, sendo eficaz na identificação de alterações como espessamento da mácula, presença de fluido e drusas (Schmitt, 1999). A retinografia, por sua vez, forneceu imagens coloridas da retina que permitiram observar alterações pigmentares e o acúmulo de drusas. Além dessas modalidades, a autofluorescência do fundo de olho (FAF) e a angiografia por OCT (OCT-A) foram crescentemente utilizadas para caracterização mais detalhada das lesões (Mares et al., 2024).

Dois tipos principais de OCT foram amplamente empregados na prática clínica e em pesquisas: o SD-OCT e o SS-OCT. O SS-OCT apresentou vantagens como maior velocidade de varredura, melhor penetração tecidual e padrões de escaneamento mais densos, o que permitiu visualização mais detalhada da coróide (Pramil et al., 2023). Os dispositivos mais utilizados em pesquisas sobre DMRI incluíram o Heidelberg Spectralis, o Zeiss Cirrus e o Topcon, cada um com características técnicas distintas que afetaram a qualidade e a padronização das

imagens geradas (Mukherjee et al., 2025). Destaca-se que o dispositivo Topcon SS-DRI-Triton-OCTA, com taxa de varredura de 100.000 scans por segundo e comprimento de onda de 1 μm , ofereceu profunda penetração tecidual e excelente resolução axial, sendo empregado em estudos longitudinais de DMRI neovascular (Goyanes et al., 2024).

2.3 TERAPIAS ANTIANGIOGÊNICAS

Embora não exista cura para a DMRI, especialmente na forma úmida, terapias antiangiogênicas têm se mostrado eficazes no controle da progressão da doença. Inibidores do fator de crescimento endotelial vascular (anti-VEGF) são os mais utilizados e têm apresentado bons resultados na estabilização ou até mesmo na melhora da acuidade visual (Amoaku et al., 2015).

2.4 INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO DA DMRI

Nos últimos anos, o uso de inteligência artificial e aprendizado profundo foi amplamente investigado como ferramenta de suporte ao diagnóstico da DMRI. Modelos baseados em redes neurais convolucionais (CNNs), como a arquitetura U-Net (Ronneberger, Fischer e Brox, 2015), foram aplicados para segmentar e quantificar automaticamente estruturas retinianas como drusas, fluido sub-retiniano e zonas de atrofia (Frank-Publig et al., 2025; Pramil et al., 2023). A U-Net destacou-se por sua estrutura encoder-decoder que combinou extração de características com localização precisa de pixels, tornando-a especialmente adequada para tarefas de segmentação em imagens médicas (Mukherjee et al., 2025).

Uma evolução natural da U-Net foi sua extensão para o processamento tridimensional, especialmente relevante dado o caráter volumétrico dos exames de OCT. Goyanes et al. (2024) realizaram a primeira comparação sistemática entre abordagens 2D e 3D end-to-end para segmentação de drusas em volumes OCT, utilizando o framework nnU-Net. Os resultados demonstraram superioridade consistente da abordagem 3D, com média de Dice de 0,47 e Cohen's kappa de 0,68 frente a Dice de 0,17 e kappa de 0,43 da abordagem 2D. Os autores concluíram que

a informação espacial tridimensional é fundamental para a precisão diagnóstica, sendo a abordagem 2D propensa ao sobreajuste. De modo complementar, López-Varela et al. (2022) propuseram uma metodologia totalmente automática para segmentação e visualização 3D do fluido associado à DMRI úmida em volumes OCT, utilizando transfer learning a partir de um modelo de segmentação de tumores cerebrais em MRI. A abordagem atingiu coeficientes Dice de 0,949 e 0,960 para diferentes configurações de volume Topcon (OCT256 e OCT320, respectivamente), demonstrando a eficácia do aproveitamento de conhecimento de domínios relacionados quando dados retinianos são escassos.

No contexto da classificação automatizada de estágios da DMRI, Leingang et al. (2023) desenvolveram um classificador de dois estágios utilizando dados do PINNACLE Consortium. O modelo consistiu em uma ResNet50 para classificação em nível de B-scan, seguida de quatro ResNets que integraram as representações de todos os B-scans para classificar o volume OCT completo nas categorias Normal, iAMD, GA e nAMD. O classificador atingiu AUC de 0,94 em conjunto de teste real-world, com destaque para AUC de 0,97 para detecção de neovascularização macular (MNV). A validação externa no UK Biobank (175.869 volumes) confirmou a capacidade de generalização do modelo para populações e dispositivos distintos dos utilizados no treinamento. O uso de Monte Carlo Dropout permitiu, adicionalmente, estimar a incerteza das predições, identificando casos ambíguos e aumentando a confiabilidade clínica do sistema.

Outra arquitetura relevante foi a DeepLabV3 (Chen et al., 2017), que utilizou convoluções dilatadas para capturar contexto em múltiplas escalas, demonstrando boa capacidade de generalização entre diferentes dispositivos de imageamento. Outras arquiteturas relevantes incluíram as redes neurais recorrentes (RNNs), úteis para análise longitudinal de dados sequenciais, e as redes generativas adversariais (GANs), empregadas tanto para síntese de imagens quanto para aumento de dados em conjuntos de treinamento reduzidos (Frank-Publig et al., 2025). Modelos híbridos que combinaram extração de características profundas com classificadores tradicionais, como o Support Vector Machine (SVM), também demonstraram resultados promissores (Goyanes et al., 2025). Uma limitação recorrente na literatura foi a dependência dos modelos ao dispositivo de imageamento utilizado no

treinamento, o que dificultou a generalização para equipamentos distintos (Mukherjee et al., 2025).

2.5 BANCOS DE DADOS E IMAGENS RETINIANAS

A eficácia de métodos computacionais dependeu diretamente da qualidade e diversidade dos dados utilizados para treinamento e validação. Bancos de dados de imagens retinianas foram essenciais nesse processo, pois forneceram as imagens e as anotações necessárias para treinar e avaliar algoritmos de aprendizado de máquina. No entanto, a falta de padronização entre datasets, quanto à qualidade das imagens, formato das anotações e presença de metadados clínicos, ainda representou um desafio importante (Vidal et al., 2023). Além disso, a maioria dos grandes conjuntos de dados relevantes para DMRI não possuiu acesso público irrestrito, sendo oriundos de ensaios clínicos controlados ou repositórios institucionais (Mares et al., 2024).

O PINNACLE Consortium (NCT04269304) constituiu um dos maiores e mais relevantes datasets identificados na literatura. Leingang et al. (2023) descreveram a extração de 156.872 volumes OCT de 6.616 pacientes dos hospitais de Southampton e Moorfields (UK), coletados ao longo de doze anos de rotina clínica (2007–2019) com dispositivos Topcon. Esse repositório, denominado PINN, incluiu dados de pacientes com mais de 50 anos diagnosticados com DMRI em diferentes estágios. Um subconjunto curado de 3.765 volumes de 1.849 olhos foi utilizado para treinar o classificador de estágios, enquanto 96 volumes anotados por especialistas em retina compuseram o conjunto de teste independente. Mares et al. (2024) destacaram que o ensaio PINNACLE como um todo reuniu mais de 400.000 imagens OCT multimodais com seguimento de até 3 anos. O banco de dados do Moorfields Eye Hospital, com 137.379 volumes de OCT captados pelo dispositivo Topcon 3DOCT2000, representou outro conjunto de grande escala voltado especificamente para a DMRI neovascular (Frank-Publig et al., 2025). O registro Fight Retinal Blindness! (FRB!), por sua vez, constituiu um exemplo de base de dados do mundo real, utilizada para validar algoritmos de monitoramento de fluido em pacientes com DMRI neovascular em tratamento anti-VEGF (Mares et al., 2024). Já o IRIS Registry, mantido pela Academia Americana de Oftalmologia, emergiu como uma das maiores bases de dados de retina

do mundo, embora sua integração com ferramentas de IA ainda se encontrasse em desenvolvimento no período analisado.

Um aspecto crítico identificado na revisão foi a ausência de datasets públicos com anotações de drusas em volumes 3D de OCT. Goyanes et al. (2024) relataram que a impossibilidade de comparação direta com outros estudos de segmentação de drusas decorreu justamente dessa lacuna, que limita a reprodutibilidade científica e o desenvolvimento de benchmarks padronizados. O dataset utilizado por esses autores, composto por 1.294 B-scans anotados por especialista de pacientes com DMRI neovascular, captados com o dispositivo SS-DRI-Triton-OCTA (Topcon), permanece privado, reforçando a necessidade urgente de repositórios públicos e bem anotados para a área.

3 METODOLOGIA

Esta pesquisa caracterizou-se como uma revisão sistemática da literatura, conduzida com o objetivo de identificar, catalogar e analisar os principais bancos de dados de retinografias e imagens de OCT disponíveis para estudos sobre DMRI, bem como os dispositivos de captura e as abordagens computacionais a eles associadas.

A busca bibliográfica foi realizada nas bases de dados PubMed, Scopus e Web of Science, utilizando combinações dos seguintes termos de pesquisa: "age-related macular degeneration", "AMD", "retinal imaging dataset", "OCT database", "deep learning", "convolutional neural network", "retinal fundus", "geographic atrophy" e "neovascular AMD". A busca foi limitada a publicações em inglês ou português, publicadas entre 2018 e 2025, de forma a abranger os desenvolvimentos mais recentes na área.

Os critérios de inclusão adotados foram: (i) estudos que descreveram ou utilizaram bancos de dados de imagens retinianas para pesquisas sobre DMRI; (ii) artigos que apresentaram abordagens computacionais baseadas em aprendizado de máquina ou aprendizado profundo aplicadas a esses datasets; (iii) publicações que identificaram explicitamente o dispositivo de imageamento utilizado para a captação das imagens. Foram excluídos estudos que não descreveram o dataset utilizado, trabalhos sobre doenças retinianas não relacionadas à DMRI sem componente comparativo, e publicações sem informação sobre a modalidade de imageamento.

Após a aplicação dos critérios de inclusão e exclusão, os dados extraídos de cada estudo selecionado foram organizados em tabelas sintéticas contendo as seguintes informações: nome ou identificação do banco de dados, tipo de imagem retiniana, número de imagens ou olhos, dispositivo de captura, disponibilidade de acesso público e patologia ou contexto clínico. Adicionalmente, foram catalogadas as abordagens computacionais empregadas em cada estudo, bem como as principais métricas de desempenho reportadas.

4 RESULTADOS E DISCUSSÕES

A partir da revisão sistemática conduzida, foram identificados onze bancos de dados ou coortes de imagens retinianas relevantes para pesquisas sobre DMRI. O Quadro 1 apresenta a síntese das características dos principais conjuntos de dados identificados, incluindo o tipo de imagem, o número de imagens ou olhos, o dispositivo de captura e a disponibilidade de acesso.

Quadro 1 – Principais bancos de dados de imagens retinianas identificados para estudos sobre DMRI

BANCO DE DADOS	TIPO DE IMAGEM	N DE IMAGENS/OLHOS	DISPOSITIVO DE CAPTURA	ACESSO PÚBLICO	PATOLOGIA
PINNACLE Consortium (NCT04269304)	OCT	>400.000/156.872	Topcon (T-1000, T-2000, Triton)	Parcial	DMRI
HARBOR Trial	SD-OCT	~2.400	Zeiss Cirrus	NÃO	DMRI
Moorfields Eye Hospital AMD Database	SD-OCT	137.379	Topcon 3DOCT2000	NÃO	DMRI
SWAGGER Cohort (NCT04469140)	SS-OCT	126 olhos (treino); 30 olhos (teste)	Zeiss Plex Elite 9000	PARCIAL	DMRI
NIH/NEI Dataset (NCT01352975)	SD-OCT	25.728	Heidelberg Spectralis e Zeiss Cirrus	NÃO	DMRI
FILLY Trial (Fase 2)	SD-OCT / FAF	Não especificado	Heidelberg Spectralis	NÃO	DMRI
OAKS e DERBY Trials (Fase 3)	SD-OCT / FAF	Não especificado	Heidelberg Spectralis	NÃO	DMRI
MACUSTAR Consortium	OCT / FAF	Não especificado	Não especificado	NÃO	DMRI

Fight Retinal Blindness! (FRB!)	SD-OCT	Não especificado	Heidelberg Spectralis	NÃO	DMRI
IRIS Registry	OCT	>1.000,000	Não especificado	NÃO	DMRI
Dataset DMRI neovascular (Goyanes et al., 2024)	SS-OCT	1.294	Topcon SS-DRI-Triton-OCTA	NÃO	DMRI

Fonte: Elaborado pela autora.

Os resultados evidenciaram que a maioria dos estudos identificados utilizou o OCT como principal modalidade de imageamento, com destaque para o SD-OCT presente em dispositivos como o Heidelberg Spectralis e o Zeiss Cirrus, amplamente empregados em ensaios clínicos de grande escala como o PINNACLE Consortium e o HARBOR Trial (Frank-Publig et al., 2025; Mares et al., 2024). O PINNACLE Consortium destacou-se como o maior dataset identificado: Leingang et al. (2023) descreveram a extração de 156.872 volumes OCT de 6.616 pacientes ao longo de doze anos de rotina clínica nos hospitais de Southampton e Moorfields (UK), enquanto o ensaio PINNACLE completo reuniu mais de 400.000 imagens OCT multimodais. O banco de dados do Moorfields Eye Hospital, com 137.379 volumes de OCT captados pelo dispositivo Topcon 3DOCT2000, representou outro conjunto de grande escala voltado especificamente para a DMRI neovascular (Frank-Publig et al., 2025).

Um dos principais desafios identificados na revisão foi a limitação de acesso público aos datasets, uma vez que a maioria dos conjuntos de dados proveio de ensaios clínicos controlados com acesso restrito, como o HARBOR Trial, o FILLY Trial e os ensaios OAKS e DERBY. Entre os datasets com algum nível de acesso compartilhado, destacou-se o SWAGGER Cohort (NCT04469140), utilizado por Pramit et al. (2023) para o desenvolvimento de um algoritmo de segmentação de atrofia geográfica baseado em SS-OCT. O algoritmo DeepGPET, desenvolvido por Burke et al. (2023), representou uma contribuição relevante por ter sido disponibilizado como ferramenta open-source para segmentação da coroide, ainda que o dataset OCTANE utilizado em seu desenvolvimento não fosse de acesso público irrestrito.

O Quadro 2 apresenta as principais abordagens computacionais identificadas nos estudos revisados, associadas aos datasets utilizados e às métricas de desempenho reportadas.

Quadro 2 – Abordagens computacionais identificadas e seus resultados

ESTUDO	DATASET	ABORDAGEM COMPUTACIONAL	PRINCIPAL RESULTADO
Leingang et al. (2023)	PINNACLE Consortium (PINN) — 3.765 volumes Topcon (treino); 96 volumes (teste)	CNN dois estágios: ResNet50 (B-scan) + 4 ResNets (volume); Monte Carlo Dropout	AUC = 0,94 (real-world); AUC = 0,997 para MNV; AUC = 0,994 em validação externa Duke dataset
Frank-Publig et al. (2025)	PINNACLE, HARBOR, Moorfields, FRB!	CNN, U-Net, GAN, RNN	Revisão; AUC de até 0,85 para predição de progressão
Mares et al. (2024)	PINNACLE, HARBOR, FILLY, OAKS, FRB!	CNN, DL para segmentação de fluido e atrofia	Razão PR/RPE como marcador de progressão da AG — validado nos ensaios OAKS e DERBY
Pramil et al. (2023)	SWAGGER Cohort	U-Net com imagens pseudocolor (SS-OCT)	SDC = 0,92; ICC = 0,99 para área de AG
Mukherjee et al. (2025)	NIH/NEI (Spectralis e Cirrus)	U-Net e DeepLabV3 (generalização entre dispositivos)	Dice = 0,87 (RPEDC); MAE de ILM = 1,82 pixels
Goyanes et al. (2024)	Dataset privado DMRI neovascular — 1.294 B-scans, SS-DRI-Triton-OCTA (Topcon)	nnU-Net 3D full resolution vs. 2D (comparação end-to-end)	Dice 3D = $0,47 \pm 0,23$; kappa 3D = 0,68 vs. Dice 2D = $0,17 \pm 0,14$; kappa 2D = 0,43. Abordagem 3D superior em todos os folds ($p < 0,0001$)
López-Varela et al. (2022)	Dataset privado — 48 volumes OCT Topcon Triton (42 AMD, 6 controles)	U-Net com transfer learning (MRI → OCT) + reconstrução 3D	Dice = 0,949 (OCT256); Dice = 0,960 (OCT320); IoU = 0,903 e 0,921 respectivamente
Goyanes et al. (2025)	Dataset próprio HCSC (CSCR)	nnU-Net 3D full resolution, DenseNet-121 e SVM	Dice = 0,74 para segmentação de fluido; acurácia = 0,64 para predição de resposta ao PDT

Fonte: Elaborado pela autora

As abordagens computacionais identificadas na revisão seguiram uma tendência clara de adoção de arquiteturas de aprendizado profundo. A U-Net (Ronneberger, Fischer e Brox, 2015) e suas variantes foram as mais recorrentes,

sendo empregadas tanto para segmentação de camadas retinianas quanto para detecção de lesões específicas como drusas, fluido sub-retiniano e atrofia geográfica (Pramil et al., 2023; Burke et al., 2023; Mukherjee et al., 2025). Frank-Publig et al. (2025) destacaram que o desempenho de modelos baseados em U-Net melhorou consistentemente com o aumento do tamanho dos datasets de treinamento, reforçando a importância da disponibilidade de grandes conjuntos de dados bem anotados.

Uma contribuição de particular relevância foi reportada por Leingang et al. (2023), que desenvolveram e avaliaram um classificador automatizado de estágios de DMRI diretamente a partir de dados de rotina clínica real-world. O modelo de dois estágios (ResNet50 para B-scans individuais seguida de ResNets para classificação volumétrica) atingiu AUC de 0,94 no conjunto de teste interno e AUC de 0,994 no dataset externo Duke, validando sua capacidade de generalização a outros dispositivos OCT. O uso de estimativas de incerteza via Monte Carlo Dropout permitiu identificar automaticamente predições confiáveis, o que representa um avanço importante para aplicações clínicas reais.

No que diz respeito à segmentação tridimensional, Goyanes et al. (2024) demonstraram de forma pioneira a superioridade das abordagens 3D sobre as 2D para segmentação de drusas em volumes OCT. Utilizando o framework nnU-Net com configuração full resolution 3D em um dataset de 1.294 B-scans de pacientes com DMRI neovascular (dispositivo Topcon SS-DRI-Triton-OCTA), os autores obtiveram Dice médio de 0,47 e Cohen's kappa de 0,68 para o modelo 3D, contra Dice de 0,17 e kappa de 0,43 para o modelo 2D, com diferenças estatisticamente significativas ($p < 0,0001$). A análise qualitativa confirmou que a abordagem 3D identificou corretamente as localizações das drusas mesmo diante de pequenas variações de contorno. Os autores atribuíram os valores de Dice relativamente baixos ao reduzido tamanho das drusas em relação ao volume total da imagem, problema inerente à segmentação desse tipo de estrutura. De modo complementar, López-Varela et al. (2022) demonstraram que o transfer learning a partir de domínios relacionados — no caso, modelos de segmentação de tumores cerebrais em MRI — permitiu atingir coeficientes Dice superiores a 0,94 para segmentação de fluido associado à DMRI úmida em volumes OCT Topcon, mesmo com um número reduzido de amostras de treinamento (35 volumes).

Mares et al. (2024) demonstraram ainda que o uso de algoritmos baseados na razão entre perda de integridade dos fotorreceptores e perda de EPR, o chamado índice PR/EPR, constituiu um dos marcadores mais confiáveis para predição da progressão da atrofia geográfica, validado nos ensaios clínicos OAKS e DERBY. Um desafio recorrente identificado na literatura foi a dependência dos modelos ao dispositivo de captura utilizado no treinamento. Mukherjee et al. (2025) demonstraram que modelos U-Net e DeepLabV3 (Chen et al., 2017) treinados com imagens do Heidelberg Spectralis apresentaram redução de desempenho quando testados em imagens do Zeiss Cirrus, ainda que os resultados permanecessem clinicamente úteis. Essa limitação apontou para a necessidade de datasets multidevice e de estratégias de adaptação de domínio para o desenvolvimento de modelos com maior capacidade de generalização.

É importante destacar que o estudo de Goyanes et al. (2025), embora apresente contribuições metodológicas relevantes no campo da segmentação de fluido em OCT, foi desenvolvido para Coriorretinopatia Serosa Central (CSCR) e não para DMRI. Sua inclusão nesta revisão justificou-se pela relevância da abordagem computacional proposta, com uso de nnU-Net 3D e fusão de características, e pela possibilidade de extrapolação metodológica para o contexto da DMRI. Da mesma forma, o estudo de López-Varela et al. (2022), embora focado em visualização 3D de fluido em DMRI úmida, não foi desenvolvido com um dataset de DMRI de grande escala, sendo sua principal contribuição a demonstração da viabilidade do transfer learning e da reconstrução volumétrica para esse contexto clínico.

5 CONSIDERAÇÕES FINAIS

Esta revisão sistemática permitiu identificar e catalogar doze conjuntos de dados ou coortes de imagens retinianas relevantes para pesquisas sobre DMRI, evidenciando o cenário atual dos datasets disponíveis, dos dispositivos de captura predominantes e das abordagens computacionais mais empregadas na área.

Os resultados indicaram que o OCT, nas modalidades SD-OCT e SS-OCT, constituiu a principal fonte de dados para o desenvolvimento de algoritmos de IA voltados à DMRI, com destaque para os dispositivos Heidelberg Spectralis, Zeiss Cirrus e Topcon. A maioria dos grandes conjuntos de dados identificados provém de ensaios clínicos controlados com acesso restrito, o que representou uma limitação

significativa para a reprodutibilidade científica e para o desenvolvimento de modelos de diagnóstico acessíveis. A ausência de datasets públicos anotados para segmentação 3D de drusas em OCT foi identificada como uma lacuna crítica, destacada por Goyanes et al. (2024), que inviabiliza comparações diretas entre estudos e dificultou o estabelecimento de benchmarks padronizados. A criação de repositórios públicos e bem anotados de imagens retinianas para DMRI mostrou-se, portanto, uma necessidade urgente da área.

No que diz respeito às abordagens computacionais, as arquiteturas baseadas em U-Net (Ronneberger, Fischer e Brox, 2015) dominaram a literatura, apresentando resultados expressivos em tarefas de segmentação de camadas retinianas, detecção de drusas e quantificação de atrofia geográfica. A evolução dessas arquiteturas para o processamento volumétrico 3D mostrou-se particularmente promissora, com Goyanes et al. (2024) demonstrando ganhos substanciais em relação às abordagens 2D para segmentação de drusas, e López-Varela et al. (2022) validando a reconstrução 3D intuitiva do fluido retiniano como ferramenta de suporte clínico. Além disso, Leingang et al. (2023) demonstraram que modelos de classificação de estágios da DMRI baseados em CNNs podem alcançar desempenho de nível especialista (AUC = 0,94) diretamente em dados de rotina clínica real-world, abrindo caminho para implementações clínicas práticas. No entanto, a dependência dos modelos ao dispositivo de imagem utilizado no treinamento ainda se mostrou um obstáculo relevante para a generalização clínica dessas ferramentas. Estratégias de adaptação de domínio e o desenvolvimento de datasets multidevice representaram direções promissoras para pesquisas futuras.

Como limitação deste trabalho, destaca-se que a revisão se baseou em um seleto grupo de artigos, o que pode ter deixado de fora outros conjuntos de dados relevantes presentes na literatura. Sugere-se que trabalhos futuros incluam novas bases de dados, visando conferir maior robustez aos resultados e proporcionar uma visão integral sobre o panorama dos bancos de imagens retinianas para DMRI.

REFERÊNCIAS

AMOAKU, W. M.; CHAKRAVARTHY, U.; GALE, R.; GAVIN, M.; GHANCHI, F.; GIBSON, J. et al. Defining response to anti-VEGF therapies in neovascular AMD. **Eye**, v. 29, n. 6, p. 721-731, 2015.

AUW-HAEDRICH, C.; STAUBACH, F.; WITSCHHEL, H. Optic disk drusen. **Survey of Ophthalmology**, v. 47, n. 6, p. 515-532, 2002.

BURKE, J.; ENGELMANN, J.; HAMID, C.; REID-SCHACHTER, M.; PEARSON, T.; PUGH, D. et al. An Open-Source Deep Learning Algorithm for Efficient and Fully Automatic Analysis of the Choroid in Optical Coherence Tomography. **arXiv preprint arXiv:2307.00904**, 2023.

CAMPOCHIARO, P. A. Ocular neovascularization. **Journal of Molecular Medicine**, v. 91, p. 311-321, 2013.

CHEN, L. C.; PAPANDREOU, G.; KOKKINOS, I.; MURPHY, K.; YUILLE, A. L. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 40, n. 4, p. 834-848, 2017.

FRANK-PUBLIG, S.; BIRNER, K.; RIEDL, S.; REITER, G. S.; SCHMIDT-ERFURTH, U. Artificial intelligence in assessing progression of age-related macular degeneration. **Eye**, v. 39, p. 262-273, 2025.

GOYANES, E.; DE MOURA, J.; FERNÁNDEZ-VIGO, J. I.; GARCÍA-FEIJÓO, J.; NOVO, J.; ORTEGA, M. 3D features fusion for automated segmentation of fluid regions in CSCR patients: an OCT-based photodynamic therapy response analysis. **Journal of Imaging Informatics in Medicine**, v. 38, p. 476-495, 2025.

GOYANES, E.; LEYVA, S.; HERRERO, P.; DE MOURA, J.; NOVO, J.; ORTEGA, M. Fully-automatic end-to-end approaches for 3D drusen segmentation in Optical Coherence Tomography images. **Procedia Computer Science**, v. 246, p. 1100-1109, 2024.

LEINGANG, O.; RIEDL, S.; MAI, J.; REITER, G. S.; FAUSTMANN, G.; FUCHS, P. et al. Automated deep learning-based AMD detection and staging in real-world OCT datasets (PINNACLE study report 5). **Scientific Reports**, v. 13, n. 19545, 2023.

LIM, L. S.; MITCHELL, P.; SEDDON, J. M.; HOLZ, F. G.; WONG, T. Y. Age-related macular degeneration. **The Lancet**, v. 379, n. 9827, p. 1728-1738, 2012.

LÓPEZ-VARELA, E.; VIDAL, P. L.; OLIVIER PASCUAL, N.; NOVO, J.; ORTEGA, M. Fully-automatic 3D intuitive visualization of age-related macular degeneration fluid accumulations in OCT cubes. **Journal of Digital Imaging**, v. 35, p. 1271-1282, 2022.

MARES, V.; NEHEMY, M. B.; BOGUNOVIC, H.; FRANK, S.; REITER, G. S.; SCHMIDT-ERFURTH, U. AI-based support for optical coherence tomography in age-related macular degeneration. **International Journal of Retina and Vitreous**, v. 10, n. 31, 2024.

MUKHERJEE, S.; DE SILVA, T.; DUIC, C.; JAYAKAR, G.; KEENAN, T. D. L.; THAVIKUL WAT, A. T.; CHEW, E.; CUKRAS, C. Validation of deep learning-based automatic retinal layer segmentation algorithms for age-related macular degeneration with 2 spectral-domain OCT devices. **Ophthalmology Science**, v. 5, n. 3, p. 100670, 2025.

PRAMIL, V.; DE SISTERNES, L.; OMLOR, L.; LEWIS, W.; SHEIKH, H.; CHU, Z. et al. A deep learning model for automated segmentation of geographic atrophy imaged using swept-source OCT. **Ophthalmology Retina**, v. 7, n. 2, p. 127-141, 2023.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: convolutional networks for biomedical image segmentation. In: INTERNATIONAL CONFERENCE ON MEDICAL IMAGE COMPUTING AND COMPUTER-ASSISTED INTERVENTION, 18., 2015, Munich. **Anais...** Cham: Springer, 2015. p. 234-241.

SCHMITT, J. M. Optical coherence tomography (OCT): a review. **IEEE Journal of Selected Topics in Quantum Electronics**, v. 5, n. 4, p. 1205-1215, 1999.

VIDAL, P. L.; DE MOURA, J.; ALMUIÑA, P.; FERNÁNDEZ, M. I.; ORTEGA, M.; NOVO, J. Comprehensive fully-automatic multi-depth grading of the clinical types of macular neovascularization in OCTA images. **Applied Intelligence**, v. 53, n. 21, p. 25897-25918, 2023.