



GÖZ SAĞLIĞINDA YAPAY ZEKÂNIN GELİŞİMİ

Gamze Nur ÇULHA¹, Burak KAYA^{1*}

¹Aydın Adnan Menderes University, Faculty of Engineering, Department of Computer Engineering, 09100, Aydın, Türkiye

Özet: Günümüzde yapay zekâ, hızla gelişen bir teknoloji olarak göz sağlığı ile ilgilenen oftalmoloji alanında devrim niteliğinde yeniliklere öncülük etmektedir. Bu sayede retina görüntüleri başta olmak üzere, çeşitli göz verileri kullanılarak hastalıkların analiz edilmesi, tahminlenmesi ve tedavi süreçlerinin iyileştirilmesi mümkün hale gelmiştir. Zaman içerisinde makine öğrenmesi ve derin öğrenmenin ön plana çıkması, oftalmoloji kapsamındaki çalışmalara da hız kazandırmış, pek çok konuda teknik zorlukları ve sınırlamaları kaldırarak, yenilikçi çözüm yöntemlerinin önünü açmıştır. Gelişmiş algoritmalarla desteklenen sistemler, büyük veri kümeleri üzerinde yüksek doğrulukla analiz yaparak, kişiselleştirilmiş sağlık hizmeti gibi imkanlar da sunmaktadır. Bu gelişmeler günümüzde yaygınlaşmaya devam eden tele-oftalmoloji uygulamaları için kritik bir role sahip olup, gelecek çalışmalara ışık tutmaktadır. İlerleyen dönemlerde sağlayacağı birçok avantajın yanında çeşitli dezavantajları da beraberinde getirebilecek yapay zekâ uygulamalarının, sağlık hizmetlerinin geleceğinde kritik bir rol oynayarak, yeni fırsatlar ve zorluklar yaratması tahmin edilmektedir. Tüm bu süreç göz önünde bulundurularak, oftalmolojide yapay zekâ teknolojilerinin tarihsel gelişimi, mevcut uygulamaları ve geleceğe yönelik potansiyeli kapsamlı bir şekilde incelenmiştir.

Anahtar kelimeler: Yapay zekâ, Makine öğrenmesi, Oftalmoloji, Tele-oftalmoloji

The Evolution of Artificial Intelligence in Eye Health

Abstract: Artificial intelligence (AI) is rapidly evolving and leading revolutionary innovations in ophthalmology, a field dedicated to eye health. By utilizing various ocular data, particularly retinal images, AI enables analysis, prediction, and improvement of disease management and treatment processes. The evolutionary process starting from traditional machine learning algorithms towards advanced deep learning architectures such as convolutional neural networks (CNNs), recurrent neural networks (RNNs), and transformer-based models has enabled the systematic overcoming of technical limitations in the field of ophthalmic diagnostics. AI-powered systems, supported by advanced algorithms, analyze large datasets with high accuracy, facilitating personalized healthcare services. Beyond diagnostic applications, AI enables personalized treatment planning, real-time disease monitoring, and scalable tele-ophthalmology solutions that expand access to eye care in underserved areas. While AI applications in ophthalmology offer numerous advantages, they may also introduce challenges that need to be addressed. The clinical translation of these technologies faces multifaceted challenges, including data privacy concerns, algorithmic interpretability requirements, cross-population generalizability limitations, and regulatory compliance complexities. As AI continues to shape the future of healthcare services, it is expected to create both new opportunities and obstacles. Considering these factors, this review provides a comprehensive examination of the historical development, current applications, and future potential of AI technologies in ophthalmology.

Keywords: Artificial intelligence, Machine learning, Ophthalmology, Tele-ophthalmology

*Sorumlu yazar (Corresponding author): Aydın Adnan Menderes University, Faculty of Engineering, Department of Computer Engineering, 09100, Aydın, Türkiye

E mail: bkay5292@gmail.com (B. KAYA)

Gamze Nur ÇULHA  <https://orcid.org/0009-0007-6715-8266>

Burak KAYA  <https://orcid.org/0000-0002-5856-8614>

Gönderi: 05 Ağustos 2025

Kabul: 30 Ekim 2025

Yayınlanma: 15 Kasım 2025

Received: August 05, 2025

Accepted: October 30, 2025

Published: November 15, 2025

Cite as: Çulha GN, Kaya B. 2025. The evolution of artificial intelligence in eye health. BSJ Eng Sci, 8(6): 2042-2050.

1. Giriş

Oftalmoloji, göz hastalıklarının teşhis ve tedavisine odaklanan, hızla gelişen bir tıp alanıdır (Benet ve Pellicer-Valero, 2021). İnsan yaşam kalitesini doğrudan etkileyen en önemli sağlık faktörlerinden biri olan görme sağlığı kapsamında Dünya Sağlık Örgütü verilerine göre, dünya genelinde yaklaşık 2,2 milyar insan görme bozukluğu veya körlük ile yaşamaktadır (World Health Organization, 2019). Bu değerin yaklaşık yarısı önlenemez veya tedavi edilebilir durumda olmasına rağmen diyabetik retinopati (DR), glokom, yaşa bağlı makula dejenerasyonu (AMD) ve katarakt gibi hastalıklar, erken teşhis edilmediğinde geri dönüşü olmayan görme kayıplarına neden olabilmekte ve

özellikle yaşlanan nüfus ve artan dijital ekran kullanımı ile birlikte giderek daha büyük bir halk sağlığı sorunu haline gelmektedir (Jampol vd., 2020; Stahl, 2020). Oftalmolojide kullanılan oftalmoskop, Optik Koherens Tomografi (OCT), göz dibi (fundus) görüntüleme ve biyometrik analizler gibi çeşitli geleneksel ve modern yöntemler, oftalmologlar tarafından yapılan değerlendirmelerle hastalıkların teşhis ve tedavi sürecinde kullanılmaktadır. Artan hasta sayısı ve karmaşık veri analizi ihtiyacı, geleneksel tanı yöntemlerinin etkinliğini sınırlayarak hataya yol açabilmektedir.

Son yıllarda sağlık alanında önemli bir dönüşüm başlatan yapay zekâ teknolojileri, oftalmoloji kapsamında da



büyük bir devrim yaratarak görüntüleme analizlerinde daha hassas tanı ve bireyselleştirilmiş tedavi yöntemlerinin geliştirilmesini mümkün kılmıştır. Makine Öğrenmesi (ML) ve Derin Öğrenme (DL) gibi yapay zekâ yaklaşımları, büyük veri kümelerini analiz eden ve görüntülerdeki karmaşık örüntüleri tespit edebilen güçlü bir araç olarak öne çıkarak, klinisyenlerin karar verme süreçlerine yardımcı olabilmektedir. Son yıllardaki teknolojik gelişmeler, oftalmolojide yapay zekâ uygulamalarının kapsamını hızla genişletmektedir (Ting vd., 2018). Bu gelişmeler, gerçek zamanlı görüntü analizi sistemleri, tele-oftalmoloji çözümleri ve kişiselleştirilmiş tedavi planlaması gibi yenilikler getirmektedir. Bunlar, sağlık hizmetlerine erişimin kısıtlı olduğu bölgelerde, teşhis ve tedavi süreçlerinin iyileştirilmesine önemli katkılar sağlamaktadır.

Bu çalışma kapsamında geçmişten günümüze makine öğrenmesinin oftalmolojideki yeri, literatürdeki çalışmalar analiz edilip, uygulamalardaki başarı örneklerine ve sınırlamalarına dikkat çekilerek gelecek perspektifleriyle değerlendirilmiştir.

2. Oftalmolojide Yapay Zekâ

Alan Turing'in makinelerin düşünebileceği fikrini ortaya atıp Turing testini tanıtmasıyla (Turing, 1950) gündeme gelen yapay zekâ (Artificial Intelligence, AI); tıp (Alhejaily, 2024), robotik (Yildiz, 2025), robotik (Sucuoglu, 2025) ve daha pek çok endüstride hayatımıza girmeye başlamıştır. Zaman içerisinde en etkili olduğu alanlardan biri, bireylerin ve toplumların refah seviyesini belirleyen en temel unsurlardan olan sağlıktır. Hastalıkların teşhis ve tedavisinden kişiselleştirilmiş sağlık sistemlerine kadar pek çok alanda etkisini görmekte olduğumuz yapay zekâ, göz sağlığı ve hastalıkları ile ilgilenen oftalmoloji alanında da erken dönemlerden itibaren kullanılmaya başlanmıştır.

İlk yıllarında temel olarak mantık tabanlı sistemler ve sembolik yapılar üzerinde yoğunlaşan yapay zekânın oftalmolojideki ilk uygulamaları ile, retina görüntüleri üzerinde uygulanan çeşitli görüntü işleme (image processing), öznitelik çıkarımı (feature extraction), örüntü tanıma (pattern recognition) tekniklerinin biyomedikal alanda nasıl kullanılabileceği gösterilmiş ve bilgisayar destekli tanı sistemlerinin (CAD) temeli oluşturulmuştur. O dönemlerde retinal damar analizi için eşikleme, kenar tespiti veya morfolojik işlemler gerektirmeden gri seviye veriler üzerinde işlem yapan doğrudan keşif algoritmaları (direct exploratory algorithms) (Can vd., 1999), eşleşmiş filtreleme (matched filtering) yöntemi kullanılarak damar profillerini Gauss fonksiyonları ile modelleme (Zhou vd. 1994) gibi yöntemler geliştirilmiştir. Bu ve benzeri çalışmaların karmaşık görüntülerde hataya açık olması, hızlı ve kullanıcı dostu olmamaları, daha hassas çıkarım yapılmak istenmesi gibi etmenler; geleneksel programlama yöntemlerinin yetersiz kaldığını göstermektedir.

Bu sorunlara çözüm olarak, Samuel (1959)

bilgisayarların deneyimlerden otomatik olarak öğrenmesini sağlayan makine öğrenmesi kavramını ortaya atmıştır. Bu yaklaşımı izleyen yıllarda, günümüzde yaygın olarak kullanılan birçok algoritma geliştirilmiştir (Cover ve Hart, 1967; MacQueen, 1967; Duda ve Hart, 1973; Quinlan, 1986; Cortes ve Vapnik, 1995). Yapılan yenilikler, oftalmoloji kapsamında retinal görüntü analizini ve hastalıkların erken teşhis edilmesini kolaylaştırarak tespit süreçlerinde tanı doğruluğunu artırmıştır. İlk çalışmalarda, retinal görüntülerin içeriği hakkında çıkarımlar yapmak için Bayes ağları kullanılan STARE (Structured Analysis of the Retina) sistemi ön plana çıkmaktadır (Goldbaum vd., 1996). Görüntüleri otomatik olarak teşhis edebilen, görüntüler arasında karşılaştırma yapabilen, temel özellikleri ölçebilen, içerikleri açıklayabilen ve benzer içeriklere sahip görüntüleri arayabilen gelişmiş bir görüntü yönetim sistemi olan STARE, sonrasındaki pek çok çalışmaya temel oluşturmaktadır. Yaygın olarak görülen yaşa bağlı makula dejenerasyonu, glokom gibi birçok göz hastalığının tespiti için zaman içerisinde geliştirilen Random Forest (RF), Support Vector Machines (SVM), K-Nearest Neighbor (KNN) vb. algoritmalar karşılaştırılarak, makine öğrenmesi yöntemleri ile başarılı sonuçlar elde edilmeye çalışılmıştır (Burgansky-Eliash vd., 2005; Kim vd., 2017; Rohm vd., 2018). Teşhiste tanısal doğruluğu artırmaya yönelik yalnızca OCT görüntüleri kullanmanın yanı sıra farklı verilerin birleştirilmesi ile de çeşitli çalışmalar yapılmıştır. Bunlardan biri OCT ve Standart Otomatik Perimetri (SAP) ölçümlerini birleştirerek, Bayeşçi Makine Öğrenimi Sınıflandırıcıları kullanmanın, glokomlu gözlerin tespitindeki tanısal doğruluğu artırıp artırmadığını araştırmaktadır. Özellikle, Relevance Vector Machine (RVM) ve Subspace Mixture of Gaussians (SSMoG) algoritmalarının performansı değerlendirilmiştir (Bowd vd., 2008). Erken teşhis ve tespitlerin yanı sıra kişiselleştirilmiş sağlık sistemlerine de hizmet eden makine öğrenmesi; kontakt lens sensörleri ile göz içi basıncındaki 24 saatlik değişimleri hassas bir şekilde ölçerek, RF algoritmalarıyla analiz edilip her hastaya özel tanı modelleri oluşturulması (Martin vd., 2018) şeklindeki çalışmalarla, günümüzdeki tele-oftalmoloji uygulamalarının temeli atmaktadır.

Makine öğrenmesinin günümüzde yaygın olarak kullanılan algoritmalarından biri olan Yapay Sinir Ağlarının (Artificial Neural Network, ANN) gelişimi; görsel verilerin işlenmesi ve analiz edilmesinde önemli bir dönüm noktası olmuş, oftalmolojinin yüksek kaliteli ve standardize edilmiş verileri içermesi ve görüntü tabanlı bir disiplin olması sebebiyle, yapay zekâ teknolojilerinin bu alanda uygulanmasını mümkün kılmıştır. İlk başarılı örneklerinden biri, diyabetik retinopatinin otomatik tespiti için geliştirilen ANN tabanlı tarama sistemidir (Gardner vd., 1996). Geri yayılım (backpropagation) yöntemi kullanan bir yapay sinir ağı, retinal görüntülerdeki belirli özellikleri tanımak üzere eğitilmiştir. Bu modelin diyabetik retinopati

tespitindeki performansı değerlendirildiğinde göz hastalıkları uzmanına benzer bir doğrulukla sonuç verdiği gözlemlenmiştir. Glokom gibi hastalıkların tespitinde de kullanılan yapay sinir ağları (Huang ve Chen, 2005; Muramatsu vd., 2010), geleneksel makine öğrenmesi algoritmalarından farklı olarak, ham görüntüleri işleyerek manuel özellik seçimini azaltması, gürültülü verilerde daha başarılı olması ve otomatik öğrenme sağlaması sebebiyle; daha önce doktorlar tarafından etiketlenmiş fundus görüntüleri üzerinde manuel değerlendirmeye kıyasla daha hızlı ve tutarlı sonuçlar üretmiştir.

ANN, ilk çıktığı dönemlerde her ne kadar bazı problemlere çözüm getirmiş olsa da veri seti boyutlarındaki ve çeşitliliğindeki sınırlamalar, donanımsal yetersizlikler, kullanılan modellerinin günümüzdekilere kıyasla çok daha basit kalması; verimlilik gibi yeni sorunları beraberinde getirmektedir. Bu dönemdeki kısıtlı veri ve donanım imkânlarına rağmen, Yann LeCun tarafından geliştirilen LeNet, Konvolüsyonel Sinir Ağı (Convolutional Neural Network, CNN) yaklaşımının ilk başarılı örneklerinden biri olarak öne çıkmıştır (LeCun vd., 1989). Özellikle el yazısı rakam tanıma alanındaki başarısıyla dikkat çeken bu model, günümüz oftalmoloji uygulamalarını da şekillendiren daha karmaşık CNN mimarilerinin temelini atmıştır.

2000'li yılların başındaki donanımsal gelişmelerle ImageNet (Deng vd., 2009) gibi büyük ölçekli veri kümelerine erişimin kolaylaşması, bu alandaki çalışmaların çok daha karmaşık problemlere odaklanmasını mümkün kılmıştır. Hesaplama gücündeki artış ve büyük veri kavramının popüler olması, makine öğrenmesinin bir alt dalı olan derin öğrenmenin gelişimindeki dönüm noktalarından biri olmuştur. AlexNet (Krizhevsky vd., 2012), GoogleNet (Szegedy vd., 2014), VGG (Simonyan ve Zisserman, 2015), ResNet (He vd., 2015) gibi farklı CNN mimarilerinin ortaya çıkmasıyla görsel tanıma ve sınıflandırma alanındaki başarılar önemli ölçüde artmıştır. Özellikle oftalmoloji alanında, Messidor (Decenciere vd., 2014), EyePACS (Kaggle, 2015), DRIVE (Staal vd., 2004), APTOS (Kaggle, 2019) gibi veri setlerinin oluşmaya başlamasıyla birlikte, bu derin ağ mimarileri; OCT, fundus görüntüleri ve diğer tıbbi görüntüleme tekniklerinde hastalık tespiti ve sınıflandırma süreçlerini büyük ölçüde iyileştirmiştir. Böylelikle diyabetik retinopati, makula dejenerasyonu, glokom gibi çeşitli göz hastalıklarının tanısında insan gözü ile atlanabilecek ince detayların yakalanması kolaylaşmış; yüksek doğruluk oranlarına sahip otomatik tanı sistemlerinin geliştirilmesine zemin hazırlanmıştır.

Derin öğrenme ve CNN'in oftalmolojide uygulanabilirliğini test etme amacıyla Kaggle'da yer alan bir veri seti üzerinde ilk CNN tabanlı diyabetik retinopati çalışmalarından biri gerçekleştirilmiştir (Pratt vd., 2016). Çalışmanın sonucunda geliştirilen model %75 oranında doğruluk (accuracy) ve %95 oranında duyarlılık (sensitivity) elde etmiştir. Yine diyabetik retinopati tespiti için Gulshan vd. (2016) tarafından EyePACS-1 ve

Messidor-2 veri setleriyle daha büyük ölçekli bir model eğitilmiştir. Eğitilen model ile oftalmolog seviyesinde doğruluk elde edilmeye çalışılmış ve AI tabanlı teşhis sistemlerinin klinik kullanıma uygun hale getirilmesi hedeflenmiştir. Bu gelişmelerin ardından, halka açık veri setleri kullanılarak klinik ortamda doğrudan uygulanabilir bir otonom yapay zekâ sistemi geliştirilmiş ve FDA onayı alan ilk diyabetik retinopati teşhis modeli olarak bilinen IDx-DR ile tıbbi tanı süreçlerinde AI'nin güvenilirliği resmileştirilmiştir (Abramoff vd., 2016). Derin öğrenmenin oftalmolojide oldukça popüler olduğu bu dönemlerde daha başarılı ve kapsamlı sonuçlar elde etmek için; çeşitli CNN mimarilerinin geliştirilmesi (Chen vd., 2015), dikkat mekanizmaları (attention mechanism) gibi modüllerin eklenmesinin (Li vd., 2020) yanı sıra; farklı etnik gruplar ve demografik özelliklere sahip geniş bir hasta popülasyonunun retinal görüntülerinin (Ting vd., 2017) ve ultra geniş açılı fundus görüntülerinin (UWFI) kullanılması (Nagasato vd., 2018) vb. pek çok yöntemin yoğun olarak kullanıldığı görülmektedir.

Zaman içerisinde sadece statik veri kümelerini değil, temeli Recurrent Neural Network (RNN) (Elman, 1990) yapısına dayanan fakat derin öğrenmenin gelişmesiyle daha karmaşık modellerde kullanılması sağlanan Long Short-Term Memory (LSTM) (Hochreiter ve Schmidhuber, 1997) mimarisi ile zamana dayalı dinamik verileri de kapsayan çalışmalar da yapılmıştır. Bu sayede; göz tansiyonunun düzenli aralıklarla ölçülmesi (Gheisari vd., 2021), retina kalınlığının takip süreci boyunca kaydedilmesi (Kugelman vd., 2018), görme alanı (visual field) testlerinin periyodik sonuçları gibi verilerle hastalıkların seyrini öngörmek (Park vd., 2019) ve erken uyarı mekanizmaları oluşturmak mümkün hale gelmiştir. Standart LSTM'lerin özellikle etiketleme veya sınıflandırma görevlerinde, yalnızca geçmiş verilere dayanması hatalı sonuçlara yol açabileceği göz önünde bulundurularak hem geçmiş hem de gelecek bilgileri analiz edip, verilerin iki yönlü işlenmesiyle DR gibi hastalıkların tespitinde yüksek doğruluk elde eden çift yönlü LSTM (BiLSTM) modelleri kullanılmıştır (Schuster ve Paliwal, 1997; Phridviraj vd., 2023). Aynı zamanda retina görüntülerinden öznetelik çıkarmada CNN mimarileri ile, zamana bağlı özellikleri yakalamak için RNN yapıları hibrit şekilde ele alınmıştır (Jiang vd., 2018; Romo-Bucheli vd., 2020).

RNN, LSTM, Multi Layer Perceptron (MLP) (Rumelhart vd., 1986), Generative Adversarial Networks (GANs) (Goodfellow vd., 2014) gibi farklı derin öğrenme mimarilerinin gelişimiyle birlikte, farklı görevlerde etkili olabilecek bileşenlerinin bir arada kullanıldığı çok aşamalı (multi-stage) ve hibrit yapıların oftalmoloji alanındaki kullanımı yaygınlaşmıştır. Bu sistemlerde, bir modelin çıktısının diğer bir modele girdi olarak aktarıldığı ardışık yapılar sayesinde segmentasyon, özellik çıkarımı ve sınıflandırma gibi görevler sıralı biçimde gerçekleştirilebilmektedir. Örneğin, De Fauw vd. (2018), OCT görüntülerinden elde edilen segmentasyon haritalarını sınıflandırma ağına aktararak, yönlendirme

gerektiren hastalıkların tespitinde yüksek doğruluk sağlayan iki aşamalı bir model geliştirmiştir. Benzer şekilde, Demir ve Taşcı (2021), fundus görüntülerinden özellik çıkarımı için R-CNN ve LSTM mimarilerini birleştirmiş; ardından NCAR algoritması ile seçilen öznelikleri SVM sınıflandırıcısıyla değerlendirerek çok aşamalı ve hibrit bir yapay zekâ mimarisi önermiştir. Bununla birlikte, fundus görüntülerine ek olarak kornea kalınlığı, göz içi basıncı gibi klinik parametrelerin de modele entegre edilmesiyle, farklı veri türlerinin birlikte işlendiği gelişmiş karar destek sistemleri oluşturulmuştur. Örneğin, Schlosser vd. (2022), OCT biyobelirteç sınıflandırması ile görme keskinliği tahmini gibi ardışık görevleri bir araya getirerek, hasta verilerinden kişiselleştirilmiş tahminler üreten çok aşamalı bir sistem tasarlamıştır. Iliuță vd. (2024) ise, oftalmolojide dijital ikiz yaklaşımını kullanarak; görüntü ve klinik verileri bütünleştiren, tanı, tedavi önerisi, takip ve glokom progresyonu tahminini içeren dört katmanlı, entegre bir yapay zekâ destekli karar destek sistemi sunmuştur.

Gittikçe daha karmaşık yapılar gördüğümüz son dönemlerde, özellikle Doğal Dil İşleme (NLP) alanında devrim yaratan Transformer mimarisi (Vaswani vd., 2017), veriler arasındaki ilişkileri kurmak için "self-attention" mekanizmasını kullanarak, verinin farklı bölümleri arasındaki bağımlılıkları paralel olarak öğrenebilmesi sayesinde görüntüler üzerinde de başarılar elde etmiş; göz hastalıklarının erken tanısı ve sınıflandırılması gibi alanlarda devrim niteliğinde gelişmeler sağlamıştır. İlk denemelerde 20 farklı retina hastalığından oluşan MuReD veri setinde kullanılan (Rodríguez vd., 2022) Transformer mimarisi; zaman içinde düzensiz aralıklarla alınan fundus görüntülerini işleyerek, hastalığın gelişme riskini tahmin etmeyi amaçlayan LSTA modeli (Holste vd., 2024) gibi pek çok çalışma ile veri yoğunluğuyla başa çıkabilen ve yüksek doğruluk oranı elde edilen özelleştirilebilir imkân sunmaktadır. Önerilen DeiT, SViT gibi farklı Transformer

modelleri konvolüsyon tabanlı modellerle karşılaştırılmış, karmaşık desenleri tespit edip genelleme yeteneği kazanarak daha başarılı sonuçlar vermiştir (Wu vd., 2021; Payout vd. 2022; Fan vd., 2023; He vd., 2023; Nazih vd., 2023; Hemalakshmi vd., 2024). Böylece oftalmoloji alanında da CNN modelleri yerine tercih edilebilecek alternatifler oluşmuştur.

Günümüzde geline son noktada, oftalmoloji kapsamındaki yapay zekâ uygulamaları, hastalıkların teşhis ve tedavisinden kişiselleştirilmiş çözümlere kadar hızla günlük hayatımıza entegre olmaktadır. Retinal görüntülerin bir fundus kamerası ile çekilip sisteme yüklenmesi ile anormallikleri analiz ederek sonuçları sağlık uzmanına raporlayan FDA onaylı EyeArt AI System (Solanki vd., 2017) gibi teknolojiler, yalnızca doktorların işini kolaylaştıran araç olmaktan çıkıp, çevrimiçi çözümlerle de erişimi sınırlı bölgelerde, bu teknolojilerin uygulanabileceğini göstermektedir (Akkara ve Kuriakose, 2019). Dağıtık makine öğrenmesi (Distributed Machine Learning), bulut bilişim (Cloud Computing) ve Nesnelerin Tıbbi İnterneti (IoMT) teknolojileri birleştirilerek, tele-oftalmoloji uygulamalarını geliştirmeyi amaçlayan çeşitli yenilikçi yaklaşımlar sunulmaktadır (Das vd., 2019). Her geçen gün artarak sonraki adımların temelini oluşturan bu gelişmelerin, günlük hayata daha kolay entegre edilebilen uygulamalarla ileri seviyeye taşınması beklenmektedir. Bu doğrultuda, yapılan çalışma kapsamında, yapay zekâ teknolojilerinin oftalmolojideki yeri; literatürdeki çalışmaların analizi ve uygulamalardaki başarı örnekleri üzerinden değerlendirilmiştir.

3. Sonuç

Göz sağlığında yapay zekânın gelişimi, yıllar içinde çeşitli teknolojik atılımlar ve model iyileştirmeleri ile önemli bir yol kat etmiştir. Şekil 1'deki zaman çizelgesi, yapay zekâ yaklaşımlarının gelişimi ile göz hastalıklarının teşhis ve tedavisinde kullanılan yöntemlerin kısa bir tarihçesini göstermektedir.



Şekil 1. Yapay zekânın oftalmolojideki gelişimi.

Geleneksel yöntemlerle başlayan süreç, makine öğrenmesi ve derin öğrenmenin ortaya çıkışıyla pek çok sınırlamayı aşmış; donanım ve veri açısından yeterliliklerle hız kazanmıştır. Özellikle CNN mimarilerinin yaygınlaşmasıyla birlikte, Konvolüsyonel Ağlar'ın oftalmolojideki yüksek kaliteli ve standardize edilmiş retina görüntüleri üzerinde başarılı sonuçlar elde ederek hastalıkların erken teşhisinin ve tespitinin yanı sıra tedavi yöntemlerine getirdiği yenilikler, kişiselleştirilmiş sağlık sistemlerine de zemin hazırlamıştır. İlerleyen dönemlerde, zamana bağlı verilerin analiz edilmesinde kullanılan LSTM, hastalık süreçlerinin takibini kolaylaştırmış, konvolüsyon yapıları ile birleştirilerek, hibrit modeller sayesinde farklı verilerin bir arada değerlendirilmesine olanak sağlamıştır. Bu sayede genelleştirilebilen sistemler ortaya çıkmıştır. Gitgide, Transformer gibi daha karmaşık

mimarilerin yaygınlaşması, hız ve verimliliği ön plana çıkarmıştır. Bu da tele-oftalmoloji kapsamındaki uygulamaların yaygınlaşmasını tetiklemiştir. İvmelenerek artan tüm bu gelişmeler, sistemlerin gün geçtikçe daha akıllı hale gelmesine neden olmaktadır. Bu durum, gelecekteki çalışmaların daha gelişmiş yapay zekâ modelleri ve derin öğrenme teknikleriyle desteklenerek teşhis doğruluğunu artırmaya, hasta takibini iyileştirmeye ve sağlık hizmetlerine erişimi daha da kolaylaştırmaya odaklanacağını göstermektedir. Şekil 1'deki tarihsel gelişimin bir yansıması olarak, geçmişten günümüze çeşitli AI tabanlı yöntemler farklı oftalmolojik durumlar için kullanılmıştır. Tablo 1, bu çalışmalardan seçilmiş örnekleri; yazarları, kullanılan veri türleri, uygulanan yöntemler, başarı oranları ve öne çıkan özellikleri açısından karşılaştırmalı olarak sunmaktadır.

Tablo 1. Oftalmolojide yapay zekâ temelli çalışmaların özeti ve karşılaştırması

Yazarlar (Yıl)	Veri seti	Yöntem	Başarı oranı	Öne çıkan özellikler
Gardner vd. (1996)	Fundus kamera ile elde edilmiş 347 fundus görüntüsü	ANN	Duyarlılık: %88,4 Özgüllük: %83,5	Backpropagation algoritmasıyla eğitilen bir ANN modeli kullanılmıştır.
Goldbaum vd. (1996)	43 farklı vasküler retina hastalığına ait görüntülerin yer aldığı STARE veri seti	Bayes ağları	Doğruluk: %84,00-%89,00- %78,00	Otomatik analiz ve teşhis yapan STARE sistemi üzerine odaklanılmıştır.
Abramoff vd. (2016)	Messidor-2 veri seti (1748 fundus görüntüsü)	CNN	Duyarlılık: %96,80 Özgüllük: %87,00	DR tespiti için geliştirilen IDx-DR, FDA onayına sahip ilk otonom yapay zekâ sistemlerinden biridir.
Gulshan vd. (2016)	EyePACS-1 veri seti (9963 fundus görüntüsü) ve Messidor-2 veri seti (1748 fundus görüntüsü)	CNN	Duyarlılık: %87,00-%96,10 Özgüllük: %98,50-%93,90	Geliştirilen model, otomatik tarama sistemlerinin klinik uygulanabilirliğini göstermektedir.
Ting vd. (2017)	494 661 fundus görüntüsü (Singapur Ulusal DR Tarama Programı ve 10 çok etnikli kohort)	CNN	Duyarlılık: %90,50-%100- %96,40-%93,20 Özgüllük: %91,60-%91,10- %87,20-%88,70	Çeşitli demografik özelliklere ve etnik kökenlere sahip geniş bir hasta popülasyonunun retinal görüntüleri kullanılmıştır.
Park vd. (2019)	1689 gözden alınan görme alanı testleri	LSTM	-	Zaman içerisindeki görsel alanın ilerlemesini tahmin etmek için bir model geliştirilmiştir.
Fan vd. (2023)	1636 hastaya ait klinik ölçümler (Ocular Hypertension Treatment Study, OHTS)	Transformer	AUROC: %82,00 ile %91,00 arasında	Glokom tespiti için geliştirilen, genellenebilirliği yüksek ve açıklanabilirlik sunan DeiT modeli, görüntü tabanlı tıbbi tanı alanında Transformer tabanlı yaklaşımların potansiyelini ortaya koymaktadır.
Iliuță vd. (2024)	263 göze ait fundus görüntüleri ve klinik bilgilerden oluşan GRAPE veri seti	Hibrit	-	Hasta verileri, gerçek zamanlı güncellemelerle desteklenerek kişiselleştirilmiş tedavi önerileri için öngörüler elde edilmiştir.

AUROC: areas under the receiver operating characteristic curve

Tablo 1'deki oftalmoloji alanında yapay zekâ uygulamalarına yönelik çalışmalar incelendiğinde, erken dönemlerde kullanılan geleneksel yapay sinir ağları ve olasılıksal modellerin zamanla yerini derin öğrenme temelli yapılara bıraktığı gözlemlenmektedir. Bu değişim, yalnızca başarı oranlarında bir artışı değil, aynı zamanda veri işleme kapasitesi, genellenebilirlik ve klinik uygunluk gibi çok boyutlu kriterlerde de önemli bir dönüşümü beraberinde getirmiştir.

Literatürdeki çalışmaların büyük bir kısmı, retinal görüntüleri temel alarak model performansını ölçmeye odaklanmıştır. Görüntü tabanlı bu yaklaşımlar, yüksek duyarlılık ve özgüllük oranları sunmasına karşın; çoğunlukla sabit veriler üzerinde çalıştıkları için hasta geçmişi, bireysel risk faktörleri veya zamana bağlı klinik değişiklikleri dışarda bırakmaktadır. Zamansal veri analizlerinde, hastanın geçmiş verileri dikkate alınarak hastalık seyrini öngörebilme ve bu sayede proaktif müdahale, kişiselleştirilmiş tedavi planlaması gibi önemli uygulamaların gerçekleşmesi sağlanabilmektedir. Ancak zamana bağlı verilerde, veri toplama sıklığı ve hasta takip sürekliliği gibi klinik zorluklarla karşılaşmaktadır. Bu durum, özellikle kronik ve zamanla ilerleyen göz hastalıklarının erken evre teşhisinde sınırlayıcı bir etki yaratmaktadır.

Veri türleri bakımından değerlendirildiğinde, görme alanı test sonuçları veya hasta klinik bilgileri gibi daha dinamik ve zamana duyarlı verilerin kullanıldığı sınırlı sayıda çalışma dikkat çekmektedir. Bu tür yaklaşımlar, hastalık seyrinin izlenmesi ve bireyselleştirilmiş tedavi planlarının oluşturulması açısından daha yüksek klinik değer taşımaya rağmen, veri bütünlüğü, etiketleme zorlukları ve model karmaşıklığı gibi nedenlerle sınırlı kalmaktadır.

Yöntem tercihlerine bakıldığında, geniş ölçekte CNN gibi klasik derin öğrenme modelleri benimsenmiştir. Yerel öznitelik çıkarımı ve uzamsal korelasyon yakalama konusunda oldukça etkili olan CNN'ler, konvolüsyon katmanlarının hiyerarşik yapısı sayesinde görüntülerdeki küçük lezyonları ve damar anormalliklerini hassasiyetle tespit edebilmektedir. Transformer tabanlı yaklaşımların da alana dahil olmaya başladığı son dönemlerde, görüntünün farklı bölgeleri arasındaki uzak mesafeli bağımlılıkları modelleyebilen self-attention mekanizması sayesinde, çoklu lezyon içeren karmaşık retinal görüntülerde daha kapsamlı analiz imkânı sunmaktadır. Bu durum büyük ölçekli global bağlamları yakalamada sınırlı kalan CNN'lerin özellikle karmaşık retinal yapıların analizi söz konusu olduğunda, Transformer tabanlı modellerin de tercih edilebileceğini göstermektedir. Genelleştirilebilirlik açısından değerlendirildiğinde, Transformer tabanlı yaklaşımların geniş veri çeşitliliğine karşı daha dirençli olabileceği; buna karşın CNN tabanlı modellerin çoğunlukla veri dağılımına duyarlı yapıları nedeniyle bu konuda sınırlı kalabileceği görülmektedir. Klinik uygulanabilirlik doğrultusunda CNN'lerin daha düşük hesaplama maliyetinin olması ve hızlı sonuç vermesi, gerçek zamanlı teşhis sistemlerinde avantaj

sağlamaktadır. Ayrıca Grad-CAM (Gradient-weighted Class Activation Mapping) tabanlı görselleştirme yöntemleri, bu modellerin karar süreçlerini daha şeffaf hale getirmektedir. Transformer'ların açıklanabilirlik tarafında sunduğu dikkat haritaları, oftalmologların model kararlarını anlamasında ve güven oluşturmada etkili olabilmektedir. Böylece hem yorumlanabilirlik artmakta hem de modelin karmaşık yapısal ilişkileri açıklayabilme potansiyeli desteklenmektedir.

Genel olarak değerlendirildiğinde, yapay zekâ temelli modellerin oftalmolojiye entegrasyonu umut verici olsa da, veri çeşitliliği, etik ilkelere uyum, açıklanabilirlik ve klinik bağlamda uygulanabilirlik gibi açılardan hâlen çözülmesi gereken önemli metodolojik ve yapısal sorular bulunmaktadır. Literatür bu alanda önemli bir temel oluşturmuş olmakla birlikte, gelecekteki araştırmalarda çok katmanlı veri entegrasyonu, açıklanabilir AI tekniklerinin yaygınlaştırılması ve gerçek dünya klinik senaryolarla daha uyumlu değerlendirme protokollerinin geliştirilmesi yönünde bir evrime ihtiyaç duyulmaktadır.

4. Tartışma ve Gelecek Perspektifleri

Yapay zekânın ortaya çıkmasıyla oftalmoloji alanında dönüşüm başlatarak hızla artmaya devam eden uygulamalar, özellikle büyük veri setlerinin işlenmesinde kaydedilen teknolojik ilerlemeler ve derin öğrenme modellerinin çeşitlenmesi ile tanı ve tedavi süreçlerinde daha etkin çözümler ortaya koymaktadır. Pek çok avantajı beraberinde getiren bu uygulamalar, özellikle karmaşık görüntü analizlerinde sıkça rastlanabilen insan kaynaklı hataların minimuma indirilerek yüksek doğruluk oranları ile daha tutarlı ve güvenilir teşhisler sunabilmektedir. Bunu yaparken büyük miktarda tıbbi görüntüyü saniyeler içinde analiz ederek klinisyenlere hızlı geri bildirim sağlaması, teşhis ve tedavi süreçlerini hızlandırmaktadır. Uzaktan yapılan göz muayenelerinde anlık görüntüleme ve analiz yetenekleri sunan teleoftalmoloji ile daha geniş bir hasta kitlesine erişim sağlanarak saat farkı veya mesai saatleri gibi kısıtlamalara maruz kalmadan, ihtiyaç duyulduğunda hızlı bir şekilde tanı ve değerlendirme hizmetlerinden faydalanılabilmektedir. Ayrıca bu gelişmeler, uzun vadede hastanelerin ve sağlık kuruluşlarının, süreçleri otomatize edip operasyonel ve iş gücü maliyetlerini azaltmasıyla da ekonomik açıdan büyük avantajlar sunmaktadır.

Sağladığı avantajların yanında çeşitli dezavantajları da barındıran oftalmolojik uygulamalar, sürekli güncel tutulmak istenmektedir. Zamanla yeni verilerle güncellenmesi gereken modeller, düzenli bakım ve optimizasyona ihtiyaç duymaktadır. Bu durum, kurum ve kuruluşların gerekli donanım ve yazılım altyapısını oluşturabilmesi için ciddi altyapı maliyetlerine neden olmaktadır. Aynı zamanda hasta verilerinin yapay zekâ sistemleri tarafından işlenmesi, veri güvenliği ve hasta gizliliği açısından önemli riskler doğurabilmektedir. Dolayısıyla, hasta haklarının korunması, etik standartların gözetilmesi ve geliştirilen araçların klinik

onay süreçlerinden geçmesi gibi çok sayıda önemli adım da eş zamanlı olarak değerlendirilmelidir. Bu noktada bazı yasal düzenleme gereksinimlerine de ihtiyaç duyulmaktadır.

Muhtemel avantaj ve dezavantajlar doğrultusunda gelecek perspektifleri değerlendirildiğinde, modern sağlık sisteminin temelini oluşturan çalışmalar ışığında; tele-oftalmoloji ve uzaktan tanı sistemlerinin yaygınlaşması, internet altyapısındaki gelişmeler ve 5G/6G teknolojilerinin yüksek hız ve düşük gecikme süresi daha kapsamlı ve anlık bir veri akışı sağlama potansiyeline sahiptir. IoMT ekosistemine entegre edilen akıllı cihazlar sayesinde, hastaların ev konforunda ya da uzakta bulundukları coğrafi bölgelerde göz sağlığı verilerinin takibi mümkün hâle gelebilmektedir. Bununla birlikte federe öğrenme ve benzeri dağıtık yapay zekâ yaklaşımları, hasta verilerinin farklı kurumlar arasında fiziksel olarak paylaşılmasına gerek kalmadan ortak model geliştirme imkânı sunmaktadır. Bu yöntem, özellikle hassas sağlık verilerinin gizliliğini koruma konusunda daha güvenli bir çözüm olarak dikkat çekmektedir.

Tıbbi görüntü analizinde denetimsiz ve kendi kendini denetleyen (self-supervised) öğrenme yöntemleri de son dönemlerde öne çıkan diğer konulardan biridir. Bu yöntem, etiketlenmemiş verilerden faydalanarak modelin veri içindeki doğal ilişkilerden öğrenmesini sağlamaktadır. Geleneksel denetimli öğrenme yaklaşımlarının, büyük miktarda manuel olarak etiketlenmiş veriye ihtiyaç duyması hem maliyet hem de zaman açısından ciddi bir sorun oluşturduğu için Segment Anything Model (SAM), Contrastive Language-Image Pre-training (CLIP) gibi self-supervised öğrenme yöntemleri günümüzde tercih edilen modeller arasındadır (Koleilat vd., 2025). Bunların yanında, giderek yaygınlaşan büyük dil modelleri (Large Language Models, LLMs) sağlık alanında da büyük yankı uyandırmaya başlamıştır. BioGPT gibi modeller oftalmoloji kapsamında da literatür ve klinik raporların analizi, hasta hikayelerinin yorumlanması ve tedavi önerilerinin üretilmesi gibi alanlarda önemli bir potansiyele sahiptir (Luo vd., 2022). Gelecekte, bu ve benzeri yaklaşımların hem bilimsel hem de klinik açıdan devrim niteliğinde yenilikler ortaya koyması beklenmektedir.

Sonuç olarak, yapay zekâ teknolojileri görsel veri ağırlıklı ve kritik öneme sahip bir tıp alanı olan oftalmolojide hâlihazırda önemli bir dönüşüm başlatmıştır. Gelecekte veri kalitesini artırmaya ve klinik uygulamalara yönelik ölçeklenebilir ve açıklanabilir modeller geliştirilmeye devam edilerek, göz sağlığı hizmetlerinin daha hızlı, güvenilir ve erişilebilir hâle gelmesi öngörülmektedir.

Katkı Oranı Beyanı

Yazarların katkı yüzdeleri aşağıda verilmiştir. Yazarlar makaleyi incelemiş ve onaylamıştır.

	G.N.Ç.	B.K.
K	50	50
T	50	50
Y	50	50
VTI	50	50
VAY	50	50
KT	50	50
YZ	50	50
KI	50	50
GR	50	50

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= yazım, KI= kritik inceleme, GR= gönderim ve revizyon.

Çatışma Beyanı

Yazarlar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Kaynaklar

- Abramoff MD, Lou Y, Erginay A, Clarida W, Amelon R, Folk JC, Niemeijer M. 2016. Improved automated detection of diabetic retinopathy on a publicly available dataset through integration of deep learning. *Invest Ophthalmol Vis Sci*, 57(13): 5200-5206.
- Akkara JD, Kuriakose A. 2019. Role of artificial intelligence and machine learning in ophthalmology. *Kerala J Ophthalmol*, 31(2): 150-160.
- Alhejaily AMG. 2024. Artificial intelligence in healthcare (Review). *Biomed Rep*, 22(1): 11.
- Benet D, Pellicer-Valero OJ. 2021. Artificial intelligence: the unstoppable revolution in ophthalmology. *Surv Ophthalmol*, 67(1): 252-270.
- Bowd C, Hao J, Tavares IM, Goldbaum MH, Zangwill LM, Weinreb RN, Sample PA. 2008. Bayesian machine learning classifiers for combining structural and functional measurements to classify healthy and glaucomatous eyes. *Invest Ophthalmol Vis Sci*, 49(3): 945-953.
- Burgansky-Eliash Z, Wollstein G, Bilonick RA, Ishikawa H, Kagemann L, Schuman JS, Fudenberg SJ. 2005. Optical coherence tomography machine learning classifiers for glaucoma detection: A preliminary study. *Invest Ophthalmol Vis Sci*, 46(11): 4147-4152.
- Can A, Shen H, Turner JN, Tanenbaum HL, Roysam B. 1999. Rapid automated tracing and feature extraction from retinal fundus images using direct exploratory algorithms. *IEEE Trans Inf Technol Biomed*, 3(2): 125-138.
- Chen X, Xu Y, Wong DWK, Wong TY, Liu J. 2015. Glaucoma detection based on deep convolutional neural network. In: *Proceedings of the 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, August 25-29, Milan, Italy, pp: 745-748.
- Cortes C, Vapnik V. 1995. Support-vector networks. *Machine Learn*, 20(3): 273-297.
- Cover T, Hart P. 1967. Nearest neighbor pattern classification. *IEEE Trans Inf Theory*, 13(1): 21-27.

- Das A, Rad P, Choo KKR, Nouhi B, Lish J, Martel J. 2019. Distributed machine learning cloud teleophthalmology IoT for predicting AMD disease progression. *Future Gener Comput Syst*, 93: 486-498.
- De Fauw J, Ledsam JR, Romera-Paredes B, Nikolov S, Tomasev N, Blackwell S, et al. 2018. Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nat Med*, 24(9): 1342-1350.
- Decenciere A, Zhang X, Cazuguel G, Lay B, Cochener B, Massin C, et al. 2014. Feedback on a publicly distributed image database: The Messidor database. *Image Anal Stereol*, 33(3): 231-234.
- Demir F, Taşı E. 2021. An effective and robust approach based on R-CNN+LSTM model and NCAR feature selection for ophthalmological disease detection from fundus images. *J Pers Med*, 11(12): 1276.
- Deng J, Dong W, Socher R, Li LJ, Li K, Fei-Fei L. 2009. ImageNet: A large-scale hierarchical image database. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 20-25, Miami, USA, pp: 248-255.
- Duda RO, Hart PE. 1973. *Pattern classification and scene analysis*. Wiley-Interscience, New York, USA, pp: 1-7.
- Elman JL. 1990. Finding structure in time. *Cogn Sci*, 14(2): 179-211.
- Fan R, Liu H, Wang Y, Zhao X, Li J, Xu Y. 2023. Detecting glaucoma from fundus photographs using deep learning without convolutions: Transformer for improved generalization. *Ophthalmol Sci*, 3(1): 100233.
- Gardner NM, Keating D, Williamson TH, Elliott AT. 1996. Automatic detection of diabetic retinopathy using an artificial neural network: A screening tool. *Br J Ophthalmol*, 80(11): 940-944.
- Gheisari S, Shariflou S, Phu J, Kennedy PJ, Agar A, Kalloniatis M, et al. 2021. A combined convolutional and recurrent neural network for enhanced glaucoma detection. *Sci Rep*, 11: 1945.
- Goldbaum M, Moezzi S, Taylor A, Chatterjee S, Boyd J, Hunter E, Jain R. 1996. Automated diagnosis and image understanding with object extraction, object classification, and inferencing in retinal images. In: *Proceedings of the IEEE International Conference on Image Processing (ICIP)*, September 16-19, Lausanne, Switzerland.
- Goodfellow IJ, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. 2014. Generative adversarial networks. *arXiv preprint arXiv:1406.2661*. URL: <https://arxiv.org/abs/1406.2661> (accessed date: 02 April 2025).
- Gulshan V, Peng L, Coram M, Webster DR. 2016. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 316(22): 2402-2410.
- He J, Wang J, Han Z, Ma J, Wang C, Qi M. 2023. An interpretable transformer network for the retinal disease classification using optical coherence tomography. *Sci Rep*, 13: 3637.
- He K, Zhang X, Ren S, Sun J. 2015. Deep residual learning for image recognition. *arXiv preprint arXiv:1512.03385*. URL: <https://arxiv.org/pdf/1512.03385v1> (accessed date: 02 April 2025).
- Hemalakashmi GR, Murugappan M, Sikkandar MY, Begum SS, Prakash NB. 2024. Automated retinal disease classification using hybrid transformer model (SViT) using optical coherence tomography images. *Neural Comput Appl*, 36(16): 9171-9188.
- Hochreiter S, Schmidhuber J. 1997. Long short-term memory. *Neural Comput*, 9(8): 1735-1780.
- Holste G, Wang T, Lee J, Patel A, Nguyen T, Chen H. 2024. Harnessing the power of longitudinal medical imaging for eye disease prognosis using Transformer-based sequence modeling. *arXiv preprint arXiv:2405.08780*. URL: <https://arxiv.org/abs/2405.08780> (accessed date: 02 April 2025).
- Huang ML, Chen HY. 2005. Development and comparison of automated classifiers for glaucoma diagnosis using Stratus optical coherence tomography. *Invest Ophthalmol Vis Sci*, 46(11): 4121-4129.
- Iliuță ME, Moisescu MA, Pop E, Mitulescu TC. 2024. Personalized diagnosis and treatment using digital twins in ophthalmology. In: *Proceedings of the 2024 IEEE International Conference on Engineering, Technology and Innovation (ICE/ITMC)*, June 17-19, Trondheim, Norway, pp: 1-8.
- Jampol LM, Glassman AR, Sun J. 2020. Evaluation and care of patients with diabetic retinopathy. *New England J Med*, 382(17): 1629-1637.
- Jiang J, Liu X, Liu L, Wang S, Long E, Yang H, et al. 2018. Predicting the progression of ophthalmic disease based on slit-lamp images using a deep temporal sequence network. *PLoS One*, 13(7): e0201142.
- Kaggle. 2015. Diabetic retinopathy detection. URL: <https://www.kaggle.com/c/diabetic-retinopathy-detection> (accessed date: 02 April 2025).
- Kaggle. 2019. APTOS 2019 blindness detection. URL: <https://www.kaggle.com/c/aptos2019-blindness-detection> (accessed date: 02 April 2025).
- Kim SJ, Cho KJ, Oh S. 2017. Development of machine learning models for diagnosis of glaucoma. *PLoS One*, 12(5): e0177726.
- Koleilat T, Asgariandehkordi H, Rivaz H, Xiao Y. 2025. MedCLIP-SAMv2: Towards universal text-driven medical image segmentation. *Med Image Anal*, 106: 103749.
- Krizhevsky A, Sutskever I, Hinton GE. 2012. ImageNet classification with deep convolutional neural networks. In: *Proceedings of the 25th Conference on Neural Information Processing Systems (NeurIPS)*, December 3-6, Lake Tahoe, USA, pp: 1097-1105.
- Kugelman J, Alonso-Caneiro D, Read SA, Vincent SJ, Collins MJ. 2018. Automatic segmentation of OCT retinal boundaries using recurrent neural networks and graph search. *Biomed Opt Express*, 9(11): 5759-5777.
- LeCun Y, Boser B, Denker JS, Henderson D, Howard RE, Hubbard W, Jackel LD. 1989. Backpropagation applied to handwritten zip code recognition. *Neural Comput*, 1(4): 541-551.
- Li L, Xu M, Liu H, Li Y, Wang X, Jiang L, et al. 2020. A large-scale database and a CNN model for attention-based glaucoma detection. *IEEE Trans Med Imaging*, 39(2): 413-425.
- Luo R, Sun L, Xia Y, Qin T, Zhang S, Poon H, Liu TY. 2022. BioGPT: generative pre-trained transformer for biomedical text generation and mining. *Brief Bioinform*, 23(6): bbac409.
- MacQueen J. 1967. Some methods for classification and analysis of multivariate observations. In: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, June 21-July 18, Berkeley, USA, pp: 281-297.
- Martin KR, Mansouri K, Weinreb RN, Wasilewicz R, Gislser C, Hennebert J, et al. 2018. Use of machine learning on contact lens sensor-derived parameters for the diagnosis of primary open-angle glaucoma. *Am J Ophthalmol*, 194: 46-53.
- Muramatsu C, Hayashi Y, Sawada A, Hatanaka Y, Hara T, Yamamoto T, Fujita H. 2010. Detection of retinal nerve fiber layer defects on retinal fundus images for early diagnosis of glaucoma. *J Biomed Opt*, 15(1): 016021.
- Nagasato D, Tabuchi H, Ohsugi H, Masumoto H, Enno H, Ishitobi N, et al. 2018. Deep neural network-based method for detecting central retinal vein occlusion using ultrawide-field fundus ophthalmoscopy. *J Ophthalmol*, 2018: 1875431.

- Nazih W, Aseeri AO, Atallah OY, El-Sappagh S. 2023. Vision transformer model for predicting the severity of diabetic retinopathy in fundus photography-based retina images. *IEEE Access*, 11: 1-1.
- Park K, Kim J, Lee J. 2019. Visual field prediction using recurrent neural network. *Sci Rep*, 9: 8385.
- Phridviraj MSB, Bhukya R, Madugula S, Manjula A, Vodithala S, Waseem MS. 2023. A bi-directional long short-term memory-based diabetic retinopathy detection model using retinal fundus images. *Healthc Anal*, 3: 100174.
- Playout C, Duval R, Boucher MC, Cheriet F. 2022. Focused attention in transformers for interpretable classification of retinal images. *Med Image Anal*, 82: 102608.
- Pratt H, Coenen F, Broadbent DM, Harding SP, Zheng Y. 2016. Convolutional neural networks for diabetic retinopathy. *Procedia Comput Sci*, 90: 200-205.
- Quinlan JR. 1986. Induction of decision trees. *Mach Learn*, 1(1): 81-106.
- Rodríguez MA, AlMarzouqi H, Liatsis P. 2022. Multi-label retinal disease classification using transformers. *arXiv preprint arXiv:2207.02335*. URL: <https://arxiv.org/abs/2207.02335> (accessed date: 02 April 2025).
- Rohm M, Tresp V, Müller M, Hufendiek K, Kern C, Manakov I, et al. 2018. Predicting visual acuity by using machine learning in patients treated for neovascular age-related macular degeneration. *Ophthalmology*, 125(7): 1028-1036.
- Romo-Bucheli D, Schmidt-Erfurth U, Bogunović H. 2020. End-to-end deep learning model for predicting treatment requirements in neovascular AMD from longitudinal retinal OCT imaging. *IEEE J Biomed Health Inform*, 24(12): 3456-3465.
- Rumelhart DE, Hinton GE, Williams RJ. 1986. Learning representations by back-propagating errors. *Nature*, 323(6088): 533-536.
- Samuel AL. 1959. Some studies in machine learning using the game of checkers. *IBM J Res Dev*, 3(3): 210-229.
- Schlosser T, Beuth F, Meyer T, Sampath Kumar A, Stolze G, Furashova O, et al. 2024. Visual acuity prediction on real-life patient data using a machine learning based multistage system. *Sci Rep*, 14(1): 5532.
- Schuster M, Paliwal KK. 1997. Bidirectional recurrent neural networks. *IEEE Trans Signal Process*, 45(11): 2673-2681.
- Simonyan K, Zisserman A. 2015. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*. URL: <https://arxiv.org/pdf/1409.1556v6> (accessed date: 02 April 2025).
- Solanki K, Bhaskaranand M, Ramachandra C, Bhat S, Nittala MG, Sadda SR, Cuadros J. 2017. Validation of EyeArt automated diabetic retinopathy screening system on large cohort of mydriatic and non-mydriatic telescreening data from EyePACS. *Invest Ophthalmol Vis Sci*, 58(8): 3775.
- Staal J, Abramoff MD, Niemeijer M, Viergever MA, van Ginneken B. 2004. Ridge-based vessel segmentation in color images of the retina. *IEEE Trans Med Imaging*, 23(4): 501-509.
- Stahl, A. 2020. The diagnosis and treatment of age-related macular degeneration. *Deutsches Aerzteblatt Online*, 117(29-30), 513-520.
- Sucuoglu HS. 2025. Development of Real-Time Fire Detection Robotic System with Hybrid-Cascade Machine Learning Detection Structure. *Processes*, 13(6): 1712.
- Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, et al. 2014. Going deeper with convolutions. *arXiv preprint arXiv:1409.4842*. URL: <https://arxiv.org/pdf/1409.4842v1> (accessed date: 02 April 2025).
- Ting DSW, Cheung CY, Lim G, Tan GSW, Quang ND, Gan A, et al. 2017. Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes. *JAMA*, 318(22): 2211-2223.
- Ting DSW, Pasquale LR, Peng L, Campbell JP, Lee AY, Raman R, Tan GSW, Schmetterer L, Keane PA, Wong TY. 2018. Artificial intelligence and deep learning in ophthalmology. *Br J Ophthalmol*, 103(2): 167-175.
- Turing AM. 1950. Computing machinery and intelligence. *Mind*, 59(236): 433-460.
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. 2017. Attention is all you need. In: *Proceedings of the 30th Conference on Neural Information Processing Systems (NeurIPS)*, December 4-9, Long Beach, USA, pp: 5998-6008.
- World Health Organization. 2019. World report on vision. URL: <https://www.who.int/publications-detail/world-report-on-vision> (accessed date: 02 April 2025).
- Wu J, Hu R, Xiao Z, Chen J, Liu J. 2021. Vision transformer-based recognition of diabetic retinopathy grade. *Med Phys*, 48(12): 7850-7863.
- Yildiz O. 2025. Digital Twin-Based Ray Tracing Analysis for Antenna Orientation Optimization in Wireless Networks. *Electronics*, 14(15): 3023.
- Zhou L, Rzeszutarski MS, Singerman LJ, Chokreff JM. 1994. The detection and quantification of retinopathy using digital angiograms. *IEEE Trans Med Imaging*, 13(4): 619-626.