



Derin Öğrenme ve Özellik Seçimi Yaklaşımları Kullanılarak Göz Hastalıkları Tespiti

Eye Disease Detection Using Deep Learning and Feature Selection Approaches

Ahmet Ciran¹, Erdal Özbay^{2*}

¹ Fırat Üniversitesi, Bilgisayar Mühendisliği Bölümü, aciran@gmail.com
ORCID: <https://orcid.org/0000-0003-0280-5542>

² Fırat Üniversitesi, Bilgisayar Mühendisliği Bölümü, erdalozbay@firat.edu.tr
ORCID: <https://orcid.org/0000-0002-9004-4802>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 5 Nisan 2024
Revizyon 30 Nisan 2024
Kabul 1 Mayıs 2024
Online 30 Haziran 2024

Anahtar Kelimeler:

Göz hastalıkları, Derin öğrenme,
Özellik seçimi, PSO, Bayesian

ÖZ

Göz sağlığı, önemli bir halk sağlığı konusudur ve göz hastalıkları dünya çapında ciddi sağlık sorunlarına neden olmaktadır. Göz hastalıkları, görme yeteneğini etkileyebilen ve yaşam kalitesini önemli ölçüde azaltabilen çeşitli sağlık sorunlarıdır. Bunlar arasında normal göz sağlığı, glukom, diyabetik retinopati ve katarakt önemli yer tutmaktadır. Bu hastalıkların erken tanınması ve uygun tedavi yöntemlerinin uygulanması, göz sağlığının korunması ve görme kayıplarının en aza indirilmesi açısından hayati öneme sahiptir. Son dönemlerde, göz hastalıklarının teşhisi için yapay zekâ tekniklerinin kullanımı yaygınlaşmaktadır. Bu teknikler, görüntü analizi ve derin öğrenme gibi ileri algoritmaları içerir ve hastalıkların erken teşhisi ve tedavisi için önemli bir araç haline gelmektedir. Bu çalışmada, göz hastalıklarının fundus görüntülerinden doğru teşhis edilmesi için derin öğrenme ve özellik seçimi yöntemlerinin kombinasyonu yoluyla metasezgisel yöntemlerle optimize edilmiş bir metodoloji geliştirilmiştir. Bu çalışmada, dört sınıflı bir veri setinden elde edilen görüntüler üzerinde özellik çıkarımı için önceden eğitilmiş derin öğrenme mimarileri olan ResNet101, DenseNet201 ve DarkNet53 kullanılmıştır. Bu mimarilerden elde edilen özellikler birleştirilerek bir hibrit özellik havuzu oluşturulmuştur. Oluşturulan bu havuz, görüntülerin daha etkili bir şekilde temsil edilmesini sağlamak için kullanılmıştır. Elde edilen özelliklerin içinden önemsiz olanları elemek için metasezgisel bir optimizasyon yöntemi olan parçacık sürü optimizasyonu (PSO) kullanılmıştır. Görüntülerin sınıflandırılması için makine öğrenmesi yöntemlerinden olan destek vektör makinesi (SVM) tercih edilmiştir. SVM'nin performansını artırmak amacıyla, hiperparametrelerin seçimi için Bayesian optimizasyon yöntemi kullanılmıştır. Bu optimizasyon tekniği, SVM'nin daha iyi bir şekilde ayarlanmasına ve veri setine uyum sağlamasına yardımcı olmuştur. Deneysel çalışmaların sonuçlarına göre, sınıflandırma doğruluğu %93.8 olarak belirlenmiştir. Bu sonuçlar, önerilen yöntemin göz hastalıklarının tespitinde etkili bir araç olarak kullanılabilirliğini göstermektedir. Bu çalışma, yapay zeka tekniklerinin tıbbi görüntüleme alanında önemli bir rol oynayabileceğini ve göz hastalıklarının erken teşhisinde kullanılabilecek potansiyel bir araç olduğunu vurgulamaktadır.

ARTICLE INFO

Article history:

Received 5 April 2024
Received in revised form 30 April 2024
Accepted 1 May 2024
Available online 30 June 2024

Keywords:

Eye diseases, Deep learning,
Feature selection, PSO, Bayesian

Doi: 10.24012/dumf.1465929

* Sorumlu Yazar

ABSTRACT

Eye health is a significant public health concern, and eye diseases pose serious health problems worldwide. Eye diseases encompass various health issues that can affect vision and significantly reduce quality of life. Among these, normal eye health, glaucoma, diabetic retinopathy, and cataracts hold significant importance. Early detection of these diseases and the application of appropriate treatment methods are vital for preserving eye health and minimizing vision loss. In recent years, the use of artificial intelligence techniques for diagnosing eye diseases has become increasingly widespread. These techniques involve advanced algorithms such as image analysis and deep learning, becoming crucial tools for early diagnosis and treatment of diseases. In this study, a methodology optimized through metaheuristic methods was developed for accurately diagnosing eye diseases from fundus images using a combination of deep learning and feature selection techniques. Pre-trained deep learning architectures, including ResNet101, DenseNet201, and DarkNet53, were utilized for feature extraction from images obtained from a four-class dataset. The features obtained from these architectures were merged to create a hybrid feature pool, enhancing the effective representation of images. Particle swarm optimization (PSO), a metaheuristic optimization method, was employed to eliminate insignificant features from the obtained features. Support vector machine (SVM), one of the machine learning methods, was chosen for image classification. Bayesian optimization was utilized for hyperparameter selection to enhance SVM performance, aiding in its better adjustment and adaptation to the dataset. According to the results of experimental studies, a classification accuracy of 93.8% was achieved. These findings demonstrate that the proposed method can be effectively utilized as a tool for detecting eye diseases. This study highlights the potential of artificial intelligence techniques in medical imaging and emphasizes their role in early diagnosis of eye diseases.

Giriş

Retina, göz anatomisinin temel bir bileşenidir ve gözün arka kısmında bulunan ışığa duyarlı bir tabakadır. Retina, göz içine giren ışığı algılayarak, dış dünyadan gelen görüntüleri sinir sinyallerine dönüştürmek üzere özel olarak adapte olmuştur. Bu işlem, görsel bilgilerin beyin tarafından işlenmesi ve yorumlanması için temel bir adımdır. Retinanın görevi, aldığı ışık sinyallerini optik sinir lifleri aracılığıyla beyindeki optik kortekse iletmektir. Optik korteks, bu sinyalleri işleyerek nesnelere tanımlamamıza ve çevremizi anlamamıza yardımcı olur. Bunun için, retina sağlığı görsel algımızın temelini oluşturur ve görme yeteneğimizin korunması için hayati öneme sahiptir [1].

Erken teşhis edilmemiş olan göz hastalıkları, retinada kalıcı hasarlara neden olabilir ve bu durum geri dönüşü olmayan görme kaybına yol açabilir. Bu nedenle, göz sağlığını korumak ve görme yeteneğini sürdürmek için hastalıkların erken aşamada tespit edilmesi kritik öneme sahiptir. Erken teşhisin sağlanması, uygun tedavi yöntemlerinin zamanında uygulanmasını sağlayarak görme kaybının önlenmesine veya en aza indirilmesine yardımcı olmaktadır. Göz hastalıklarının belirtilerini ihmal etmemek ve düzenli göz muayeneleri yapmak, sağlıklı bir görme yaşamı için önemli adımlardır [2, 3].

Göz hastalıklarının teşhisinde kullanılan teknikler arasında, retina görüntülerinin analiz edilmesine odaklanan birkaç yaygın yöntem bulunmaktadır. Bunların başında, "color fundus photography" (CFP) gelmektedir. CFP, retina tabakasının renkli görüntülerini oluşturmak için kullanılan bir yöntemdir ve göz sağlığına ilişkin birçok detayı ortaya çıkarabilir. Bunun yanı sıra, optik koherens tomografi (OCT) gibi bir başka teknik de yaygın olarak kullanılmaktadır. OCT, göz dokularının yüksek çözünürlüklü kesitsel görüntülerini üretir ve retina tabakasındaki yapısal değişiklikleri incelemek için etkili bir araçtır. Bu teknikler, göz hastalıklarının erken teşhisinde ve tedavisinde önemli bir rol oynamaktadır, çünkü hastalıkların belirtileri ve ilerlemesi hakkında değerli bilgiler sağlarlar [4].

Göz, yaklaşık 23mm çapında, küre şeklinde bir yapıya sahiptir ve dıştan içe doğru sırasıyla sert tabaka, damar tabaka ve sinir tabakası olmak üzere üç katmandan oluşmaktadır. Bu üç katmanın önde oluşturduğu bazı önemli yapılar arasında kornea, lens, iris, pupil ve ön kamaradır. Lens, 60'lı yaşlardan sonra saydamlığını kaybederek opaklaşmaya başlamaktadır. Lens, irisin arkasında yer alır ve göze giren ışığın retinadaki alıcı hücrelere odaklanmasını sağlamaktadır. Lensin opaklaşması ve ışık geçirgenliğinin azalması, retinadaki alıcı hücrelere yeterli miktarda görüntü ulaşmasını engeller ve sonuç olarak görme yeteneğinde azalmaya neden olmaktadır [5].


Katarakt, diyabetik retinopati ve glokom gibi göz hastalıkları, görme sağlığını ciddi şekilde etkileyebilen ve yaşam kalitesini olumsuz yönde etkileyebilen yaygın sağlık sorunlarıdır.

Katarakt, dünya çapında körlüğün önde gelen nedenlerinden biridir. 1990'lı yıllarda, Dünya Sağlık Örgütü'nün verilerine göre, körlüğün %43'ünde kataraktın etkili olduğu tespit edilmiştir, bu da 45 milyon kör insanın yaşadığı anlamına gelmektedir. Körlük, iyi gören gözde 10/200'den daha az

görme olarak tanımlanmaktadır, yani 3/60'tan az. Her yıl 5 ila 10 milyon arasında yeni katarakt vakası tespit edilmektedir. Katarakt gelişiminde yaş en belirgin faktördür ancak ırk, yüksek irtifa, diyabet, beslenme alışkanlıkları, ilaç kullanımı, kardiyovasküler hastalıklar ve uzun süreli güneş ışığına maruz kalma gibi diğer faktörler de rol oynamaktadır [6]. Katarakt, körlüğün en yaygın nedeni olduğundan, katarakt cerrahisinin tek etkili tedavi yöntemi olduğu vurgulanarak bu hastalığın tedavisine verilen önemin büyüklüğü daha iyi anlaşılabilir [7].

Diabetes Mellitus (DM), vücudun yeterli miktarda insülin üretilmediği veya ürettiği insülin hormonunu etkili bir şekilde kullanmadığı durumlarda ortaya çıkan, dünya çapında yaygın görülen kronik bir hastalıktır [8]. DM şu anda yaklaşık 450 milyon insanı etkilemektedir [9]. Uluslararası Diyabet Federasyonu'na (IDF) göre DM'nin 2030 yılına kadar yaklaşık %8 oranında artması beklenmektedir [10]. 2040 yılına gelindiğinde DM hasta sayısının yaklaşık 600 milyona ulaşması ve bunların yaklaşık 200 milyonuna diyabetik retinopati (DR) tanısı konması beklenmektedir [11,12]. Diyabetin bir komplikasyonu olarak DR, değişen düzeylerde görme bozukluğuyla birlikte görme kaybına ve körlüğe yol açabilen bir göz retinası hastalığıdır [13].

Glokom, genellikle optik sinirin kalınlaşmasıyla meydana gelen bir durumdur ve dünya çapında yaygın körlük nedenlerinden biridir [14]. Bu hastalık, optik sinire zarar vererek geri dönüşü olmayan körlüğe yol açabilir ve küresel olarak körlüğün başlıca sebeplerinden biridir. Ancak, durum erken teşhis edilip tedavi edilirse, görme kaybı önlenir veya en azından geciktirilir. 2013 yılında dünya genelinde yaklaşık olarak 64,3 milyon kişinin glokom olduğu tahmin edilerek bu sayının 2040 yılında yaklaşık olarak 112 milyona ulaşması beklenmektedir. Bu durum, 40 ila 80 yaş arasındaki insanlar üzerinde önemli bir etkiye sahip olacaktır [15]. Şekil 1'de, fundus görüntüsü üzerinden göz hastalıkları görseleştirilmiştir.



Şekil 1. Fundus görüntülerinden (a) Katarakt hastalığı (b) Diyabetik retinopati hastalığı (c) Glokom hastalığı (d) Normal göz

Derin öğrenme modelleri, özellikle Evrişimli Sinir Ağları (ESA), tıbbi görüntü analizi alanında yeni ve etkili bir perspektif sunmaktadır, bu da onları giderek daha popüler hale getirmektedir. Bu modeller, çeşitli tıbbi uygulamalarda kullanılarak önemli sonuçlar elde etmektedir. Örneğin, cilt kanseri sınıflandırmasında derin öğrenme yöntemlerinin kullanılması, tanı sürecini geliştirme ve tedavi planlarını iyileştirme potansiyeline sahiptir. Aynı şekilde, otizm gibi karmaşık genetik etkileşimlerin değerlendirilmesinde de derin öğrenme modelleri büyük önem taşımaktadır. Bunun yanı sıra, yoğun bakım ünitelerinde hasta izleme ve tahmin etme gibi kritik görevlerde de makine öğrenmesi yöntemleri başarıyla uygulanmaktadır. Bu gelişmeler, tıbbi

uygulamalarda derin öğrenme ve makine öğrenmesi tekniklerinin kullanımının artmasını teşvik etmektedir. Bu teknolojilerin daha geniş bir şekilde benimsenmesiyle birlikte, tıbbi tanı ve tedavi süreçlerindeki verimliliğin ve doğruluğun artması beklenmektedir [16-18].

Bu çalışma, önemli biyolojik etkiye sahip olan göz hastalıklarını tespit etmek için derin öğrenme gibi yapay zeka yöntemlerini kullanmayı hedeflemektedir. Bu alanda yapılan birçok araştırma, literatürde geniş bir şekilde yer almaktadır. Göz hastalıklarının erken teşhisi ve tedavisi, görme sağlığının korunması ve körlük riskinin azaltılması açısından kritik öneme sahiptir. Derin öğrenme gibi yapay zeka teknikleri, büyük miktarda veriyi analiz etme ve karmaşık desenleri tanıma konusunda önemli bir potansiyele sahiptir. Bu nedenle, göz hastalıklarının tespitinde derin öğrenme gibi ileri tekniklerin kullanılması, teşhis sürecini iyileştirme ve daha etkili tedavi stratejileri geliştirme potansiyeline sahiptir. Makalemizin literatüre katkıları şöyle özetlenebilir:

- Fundus görüntülerinden göz hastalıklarının etkili ve doğru teşhisi için otomatik bir yöntem geliştirilmesi.
- Hastalıkların farklı özelliklerinin öğrenilmesi için ön-eğitilmiş modellerin hibrit bir şekilde kullanılması.
- Öznitelik boyutunun metasezgisel bir yöntem olan PSO ile indirgenmesi.
- Bayesian yöntemi ile hiperparametre optimizasyonu sağlanan SVM sınıflandırıcısı ile %93.8 doğruluk oranı ile göz hastalıklarının sınıflandırılması.

İlgili Çalışmalar

Son yıllarda ESA, göz hastalıklarının tespiti alanında araştırmacılar tarafından yoğun bir şekilde kullanılmıştır. Bu derin öğrenme modelleri, fundus görüntüleri ve diğer tıbbi görüntüler üzerinde yapılan çalışmalarda önemli bir rol oynamaktadır. Göz hastalıklarının erken teşhisinin önemi göz önüne alındığında, ESA'nın bu alandaki kullanımı büyük bir öneme sahiptir. ESA modelleri, fundus görüntülerindeki patolojik özellikleri tanımlama ve sınıflandırma konusunda etkili bir şekilde çalışmaktadır. Bu teknolojiler, glokom, diyabetik retinopati, katarakt ve diğer göz hastalıklarının teşhisinde ve tedavisinde önemli bir araç olmuşlardır.

Hatanaka ve ekibi, glokom tespiti sırasında kupa alanının zor tespit edilmesi sorununa odaklanarak, optik disk üzerinde dikey bir profil kullanarak çanak-disk oranını ölçmek için yeni bir yöntem geliştirmişlerdir. Önerilen yöntemde, ilk olarak görüntülerden kan damarları temizlenmiş ve ardından disk kenarının tespiti için Canny kenar algılama filtresi kullanılmıştır. Daha sonra, renkli görüntü verisi üzerinde kupa-disk oranı hesaplanmıştır. Toplamda 79 görüntü verisinin kullanıldığı bu yöntemde, 25'i glokom vakası olan hastalardan elde edilen verilere dayanarak %80 hassasiyet ve %85 özgüllük başarımları elde edilmiştir [19].

Carrillo ve ekibi, Kolombiya'da yaygın görülen göz tansiyonu hastalığını ele almış ve bu hastalığın otomatik olarak tespiti için yapay zekâ tabanlı yeni bir hesaplama yöntemi önermiştir. Bu yeni yöntem, kupa ve disk boyutu arasındaki eşik değere dayalı olarak yapılan yeni ölçümler sayesinde,

literatürdeki diğer disk segmentasyon yöntemlerine kıyasla daha yüksek bir başarı elde etmiştir. Araştırmanın sonuçlarına göre, yeni yöntem glokom tespitinde %88.5 başarı göstermiştir [20].

Pratt ve diğerleri, ESA'nın DR teşhisinde etkili bir performans sergilediğini göstermektedir. Bu araştırmalardan birinde, Kaggle veri bilimi platformunda 8 bin görüntüyü içeren bir DR sınıflandırması yapılmıştır. Bu kapsamda, veri artırma teknikleri kullanılarak MAs, HEMs ve retinal EXs gibi karmaşık DR lezyon özelliklerini tanımlamak için bir ESA mimarisi geliştirilmiştir. Elde edilen deneysel sonuçlar, 5000 doğrulama setinden elde edilen verilerle değerlendirilmiş ve %75 doğruluk ile %95 hassasiyet değerleri elde edilmiştir. Bu sonuçlar, ESA tabanlı yaklaşımların DR teşhisinde etkili bir araç olarak kullanılabilirliğini desteklemektedir [21].

Özbay araştırmasında, DR aşamalarının otomatik olarak tanınması için yeni bir çok katmanlı mimari kullanılarak aktif derin öğrenme (ADL) yöntemi kullanılmışlardır. Bu yöntemde, retinal lezyonların tespitini kolaylaştırmak için öncelikle görüntü, yapay arı kolonisi (ABC) algoritması kullanılarak segmente edilmekte ve eşik değeri görüntü histogramının sonuçlarına göre belirlenmektedir. Ayrıca, otomatik olarak segmente edilmiş retinal özelliklerin çıkarılması için etiketleme verimli bir ESA mimarisi olan ADL-ESA geliştirilmiştir. Bu model, iki aşamalı bir sürece sahiptir. İlk olarak, eğitim örneklerinde temel doğruluk etiketleri kullanılarak basit veya karmaşık retinal özellikler öğrenilmekte ve ikinci aşamada, önemli lezyon özelliklerini ve retinal görüntü içinde ilgi alanlarını belirlemek için kullanışlı maskeler sağlanmaktadır. EyePacs veri setine uygulanan ADL-ESA modeli, 35122 retinal görüntü içeren veri setinde %99.66 doğruluk, %93.76 özgüllük, %96.71 duyarlılık ve %94.58 F-ölçümü elde etmişlerdir [22].

Asaoka ve arkadaşları, çeşitli özellikleri tanımlayarak glokom tespiti için yeni bir derin öğrenme algoritmasının bir versiyonunu geliştirmişlerdir. Bu özellikler arasında göz için toplam 52, ortalama ve standart sapma değerleri bulunmaktadır. Araştırmacılar, sınıflandırıcı olarak derin sinir ağı (FNN) kullanmışlardır. Daha sonra bu sınıflandırıcıyı rastgele ormanlar, gradyan artırma, destek vektör makineleri ve sinir ağı gibi diğer makine öğrenimi sınıflandırıcıları ile birleştirmişlerdir. Sonuç olarak, araştırmacılar glokom tespiti için derin bir topluluk çözümü sunmuşlardır. Derin FNN sınıflandırıcısı kullanarak %92.5 AUC değeri elde etmişlerdir [23].

Ağalday ve Çınar yaptıkları çalışmada otomatik katarakt teşhisi için ESA ve derin artık ağlar (DRN) gibi sınıflandırma yöntemleri kullanılmıştır. Veri seti, 5000 hastanın sağ ve sol gözlerine ait renkli fundus fotoğraflarını içermekte olup, doktorların her hastanın gözüne uyguladığı teşhislere yönelik anahtar kelimeleri içermektedir. Bu veri seti, hastaların 8 farklı etikete göre sınıflandırıldığı ve renkli fundus görüntüleri kullanılarak farklı katarakt semptomlarının özelliklerinin belirlendiği bir yapıya sahiptir. Yapılan analizler sonucunda, DRN yönteminin ESA yöntemine kıyasla daha yüksek bir doğruluk oranına sahip olduğu tespit edilmiştir. Bu sonuç, katarakt teşhisinde DRN yönteminin etkinliğini vurgulamaktadır [24].

Metin ve Karasulu çalışmalarında halka açık OCT veri setleri üzerinde deneyler yapılmıştır. ESA'ya dayalı ResNet50 ve MobileNetV2 modelleri, yüksek sınıflandırma performansı elde ettikleri için kullanılmıştır. Çeşitli retina hastalıklarının sınıflandırılmasında derin öğrenme tabanlı mimariler oluşturulmuş ve test edilmiştir. Deneysel sonuçlara göre, her iki model de dikkate alındığında ortalama %81 ila %94 makroskopik doğruluk elde edilmiştir. Çalışmada test edilen ResNet50 ve MobileNetV2 modellerinin ortak değerlendirilmesi sonucunda ortalama F1 puanı elde edilmiş; CNV için 0.75, Drusen için 0.86, DME için 0.90 ve normal retina için 0.96 olarak elde edilmiştir. Bu sonuçlar literatürdeki çalışmalarla karşılaştırıldığında yüksek düzeyde doğruluk elde edildiği görülmüştür [25].


Materyal ve Metot

Bu çalışmada, görüntülerden özellik çıkarımı için geleneksel olarak kullanılan ESA tabanlı DenseNet201, DarkNet53 ve ResNet101 modelleri, 24 bitlik görüntüler üzerinde özellik çıkarma sürecinde birleştirilmiştir. Bu hibrit yaklaşım, daha kapsamlı ve detaylı bir özellik setinin elde edilmesini sağlamıştır. Elde edilen bu özellikler daha sonra PSO optimizasyon tekniği kullanılarak işlenmiş ve önemsiz özellikler çıkarılmıştır. Bu adım, sınıflandırma performansını artırmak ve gereksiz bilgi yükünü azaltmak için önemli bir adım olmuştur.

Sonraki aşamada, göz hastalıklarının tespiti için SVM modeli Bayesian yöntemiyle optimize edilmiş ve makine öğrenmesi sınıflandırıcıları olarak kullanılmıştır. Bu yöntem, SVM'de kullanılan hiperparametrelerin en uygun olanını seçmek için kullanılmıştır.

Makine öğrenmesi tekniklerinin etkinliğini değerlendirmek için yapılan sınıflandırmaların test edilmesi önemlidir. Bu bağlamda, modelin performansını belirlemek için bir karmaşıklık matrisi kullanılmıştır. Bu matris daha sonra doğruluk, kesinlik, duyarlılık ve F-ölçütü gibi metriklerin hesaplanmasında kullanılmıştır. Bu metrikler, modelin sınıflandırma performansını ayrıntılı bir şekilde değerlendirmek için kullanılmıştır.

Bu bölümde çalışmada kullanılan veri seti, DenseNet201, DarkNet53 ve ResNet101 ESA mimarileri, PSO, SVM makine öğrenmesi sınıflandırması ve Bayesian optimizasyon yöntemi incelenmiştir. Araştırmada önerilen yöntem Şekil 2'de verilmiştir.




Şekil 2. Önerilen metodolojinin akış diyagramı

Veri Seti

Bu araştırmada, kamuya açık bir veri kümesi kullanılmıştır [26]. İlgili veri kümesinde toplamda 4217 adet fundus görüntüsü bulunmaktadır. Bu görüntülerin 1038 tanesi katarakt hastalığına sahip, 1098 tanesi diyabetik retinopati hastalığına sahip, 1007 tanesi glukom hastalığına sahip ve 1074 tanesi sağlıklı gözleri temsil eden görüntülerdir. Veri setinde yer alan görüntüler 512x512 piksel, 24-bit ve renkli görüntülerdir.

Araştırmada kullanılan veri seti geniş kapsamlı bir şekilde incelenmiş ve farklı göz hastalıklarının belirlenmesi için çeşitli sınıflar içeren bir yapıya sahiptir. Bu görüntülerin renkli olması, görüntü işleme algoritmalarının ve derin öğrenme modellerinin doğruluğunu artırmak için önemli bir özelliktir. Veri setindeki her sınıfa ait yeterli sayıda görüntü olması, modelin eğitiminde dengeli ve doğru sonuçlar elde etmek açısından önemli bir avantaj sağlamaktadır. Bu zengin veri kümesi, araştırmanın güvenilirliğini ve etkinliğini artırmıştır. Araştırmada kullanılan veri setinin etiket sütununa göre dağılımı Şekil 3'te gösterilmiştir.



Şekil 3. Veri setinin etiket sütununa göre dağılımı

Özellik Çıkarımı

ESA mimarisi geliştirmek oldukça zaman alıcı ve kaynak gerektiren bir süreçtir. Bu süreç, geniş miktarda veri toplamayı ve karmaşık model optimizasyonlarını içermektedir. Ancak, önceden eğitilmiş ESA modellerinin transfer öğrenimi için kullanılması, daha hızlı ve verimli sonuçlar elde etmeyi mümkün kılmaktadır. MobilNet, ResNet101, DarkNet53, VGG16, DenseNet201 ve GoogleNet gibi popüler önceden eğitilmiş modeller, transfer öğrenimi için tercih edilen modeller arasındadır.


Bu araştırmada, ImageNet veri setinden önceden eğitilmiş ağırlıklar kullanarak DenseNet201, DarkNet53 ve ResNet101 gibi modeller ile özellik çıkarımı yapılmıştır. Bu yaklaşımla, mevcut modellerin görsel özelliklerini öğrenme yetenekleri, hedef görevde daha iyi performans elde etmek için kullanılmıştır. Ağırlık transferi sayesinde, mevcut modelin öğrendiği genel desenler hedef görevde de etkili şekilde kullanılarak daha hızlı ve verimli bir öğrenme süreci sağlanmıştır.

Veri Sınırlı Sinir Ağı (ESA)

ESA, bilgisayarlı görü ve görüntü işleme alanlarında yaygın olarak kullanılan bir yöntemdir, özellikle görüntü içeren verilerin sınıflandırılması gibi birçok alanda etkilidir. Yapay Sinir Ağı (Artificial Neural Network, YSA- ANN) tabanlı

olan ESA, klasik sinir ağlarından farklıdır; çünkü evrişim işlemleri, otomatik öznitelik elde etme ve çeşitli soyutlama işlemleri yapabilen katmanlardan oluşmaktadır. Bu katmanlar, özniteliklerin çıkarılması ve soyutlama işlemleri için gerekli bilgiyi sağlarlar [27]. Görüntü işlemede önceki yöntemler, görüntülerden özellik çıkarmak için ayrı bir süreç gerektirmektedir. Ancak derin öğrenme bu ihtiyacı çözmektedir. Çünkü ağ eğitimi sırasında özellik çıkarımını otomatik olarak gerçekleştirmektedir.


Derin öğrenme, her katmanın bir önceki katmanın çıktısını girdi olarak aldığı, katmanlar arasında sıralı bir yapıya sahip olan bir makine öğrenme algoritmasıdır. Öğrenme süreci denetlenebilir, denetlenebilir veya yarı denetlenebilir. LeCun ve ekibinin tanımına göre derin öğrenme, bir temsili öğrenme yöntemi olarak değerlendiriliyor [28]. Temsil öğrenme algoritmaları, verileri en uygun şekilde temsil edecek şekilde optimize ederler [29]. Şekil 4'te ESA'nın yapısı görülmektedir.



Şekil 4. ESA mimarisi

DenseNet Mimarisi

DenseNet modelleri, diğer ESA yapılarından önemli bir şekilde farklılık göstermektedir. Bu fark, yoğun bloktaki her katmanın, o bloktaki tüm önceki katmanlardan girdi alması ve kendi özellik haritasını sonraki katmanlara iletmesidir. Bu özellik, bilgi akışını etkili bir şekilde artırarak daha derin ve geniş model yapısının oluşturulmasına olanak tanımaktadır. Bu yapı, ağın her katmanının daha önceki katmanlardan gelen bilgiyi doğrudan kullanabilmesini sağlayarak öğrenme sürecini iyileştirerek ağın genel başarımını artırmaktadır [30]. Şekil 5'te DenseNet201 modeli gösterilmiştir.




Şekil 5. ESA mimarilerinden Densenet201 modeli

Bu çalışmada, ESA mimarisinde, önceden eğitilmiş DenseNet201 modeli kullanılarak toplamda 4217 görüntüden elde edilen 1000 öznitelikli bir çıktı elde edilmiştir.

ResNet101 Mimarisi

ResNet-101, görsel olarak Şekil 6'da tasvir edilen bir evrişimli sinir ağıdır ve toplamda 101 katmandan oluşmaktadır. Bu ağ, 1 milyondan fazla görüntüyü içeren ImageNet veri tabanında önceden eğitilmiştir. Eğitim

sürecinde, bu veri seti üzerinde bilgisayarlar, yazıcılar, çeşitli hayvan türleri ve daha fazlası gibi 1000'den fazla farklı sınıfa tanıma yeteneğine sahip olacak şekilde eğitilmiştir. ResNet101 modeli, 224x224 piksel çözünürlüğündeki görüntüleri giriş olarak kabul etmektedir. Bu boyut, girdi olarak alınan görüntülerin standart çözünürlüğünü temsil eder ve ağı görüntü verilerini işlemesi ve sınıflandırması için yeterli detayı sağlar. ResNet101, derin ağ mimarisi ve önceden eğitilmiş büyük bir veri tabanıyla geniş bir ölçekte sınıflandırma görevlerini başarılı bir şekilde gerçekleştirebilme kapasitesine sahiptir [31].




Şekil 6. ESA mimarilerinden ResNet101 modeli

Bu çalışmada, ESA mimarisi kullanılarak, önceden eğitilmiş ResNet101 modeli üzerinde 4217 görüntüden oluşan veri seti kullanılarak 1000 öznitelikli bir çıktı türetilmiştir. Bu süreçte, ResNet101 modeli üzerindeki özellik çıkarımıyla 4217 görüntünün analizi yapılarak, her görüntü için 1000 boyutlu öznitelik vektörleri elde edilmiştir.

DarkNet53 Mimarisi

Darknet53, YOLOv3 tarafından tercih edilen derin öğrenme modelidir ve genellikle nesne tanıma görevlerinde kullanılmaktadır. Bu ağ, görüntülerdeki nesnelere tanımlama ve konumlarını tahmin etme amacıyla kullanılır. Darknet53'ün kullanımı genellikle bir nesne tanıma veri kümesi oluşturularak başlar ve bu veri kümesi üzerinde ağın eğitilmesini içerir. Eğitim sürecinde, ağ veri kümesindeki nesnelere tanımlama yönelik örüntüler öğrenmektedir. Daha sonra, eğitilmiş modeli test etmek için yeni bir görüntü girdisi sağlanır ve ağ, bu görüntü üzerinde nesnelere tanımlamaya ve konumlarını tahmin etmeye çalışır. Bu aşamada, Darknet53 modeli, önceden tanımladığı nesnelere algılamak ve sınıflandırmak için öğrendiği desenleri kullanarak görüntüyü analiz eder. Şekil 7'de DarkNet53 modeli görülmektedir.



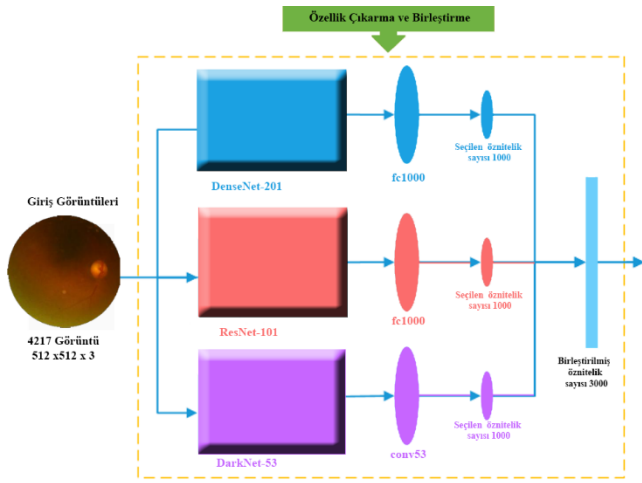
Şekil 7. ESA mimarilerinden DarkNet53 modeli

Bu çalışmada, ESA mimarisinde, 4217 görüntü kullanılarak önceden eğitilmiş DarkNet53 modeli üzerinde öznitelik

çıkarmı yapılmış ve her bir görüntü için 1000 boyutlu öznelik vektörleri oluşturulmuştur. DarkNet53 modeli sayesinde, veri setindeki her bir görüntüden gelen bilgilerin analizi sonucunda 1000 öznelikli çıktılar elde edilmiştir.

Mimari Birleştirme

Bu araştırmada, 4217 görüntü üzerinden DenseNet201, ResNet101 ve DarkNet53 mimarileri kullanılarak öznelikler çıkarılmıştır. Elde edilen öznelikler, MATLAB 2023a ortamında birleştirilerek hibrit bir model oluşturulmuştur. Bu hibrit model sayesinde, 4217 görüntüden toplamda 3000 öznelik elde edilmiştir. Şekil 8'de, bu birleştirilmiş modellerin görselleştirilmiş hali görülmektedir. Bu süreç, farklı ESA mimarilerinin öznelik çıkarımında bir araya getirilerek daha kapsamlı bir model oluşturulmasını ve veri setinden daha geniş öznelik yelpazesi elde edilmesini sağlamaktadır.



Şekil 8. ESA mimarilerinin birleşimi

Özellik Seçimi

Özellik seçimi, bir modelin performansını iyileştirmeyi ve gereksiz veya gürültülü verileri önlemeyi amaçlayan bir süreçtir. Başarılı bir özellik seçimi, modelin genelleme yeteneğini artırabilir ve aşırı uyum riskini azaltabilir. Özellik seçimi genellikle veri madenciliği, makine öğrenimi ve istatistik gibi alanlarda kullanılır ve doğru yapıldığında modelin verimliliğini ve performansını artırabilir.

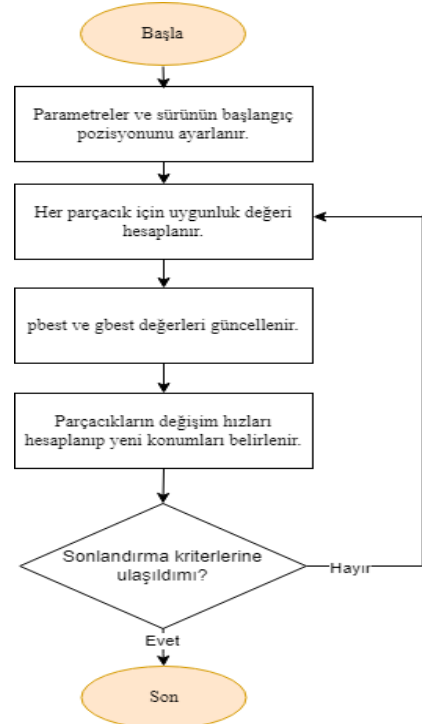
Literatürde metasezgisel yöntemler ile derin öğrenmenin birlikte kullanıldığı birçok çalışma mevcuttur [32-35]. Bu araştırmada, göz hastalıkları görüntülerinden elde edilen özneliklerin sayısını azaltmak amacıyla ön eğitilmiş ESA mimarilerinden elde edilen özneliklere PSO yöntemi uygulanmıştır. Bu süreç, öznelik seçiminde optimum çözümü bulmada PSO'nun etkinliğini göstermiş ve modelin performansında belirgin bir artış sağlamıştır. ESA mimarileri ile entegre edilen PSO, öznelik sayısının azaltılmasıyla birlikte modelin genelleme yeteneğini artırarak daha başarılı sonuçlar elde edilmesine yardımcı olmuştur.

Parçacık Sürü Optimizasyonu (PSO)

Dr. Eberhart ve Kennedy tarafından 1995 yılında önerilen bu meta-sezgisel yöntem, sürülerin davranışlarının gözlemlenmesine dayanmaktadır [36].

Bu algoritma, tehlikede olan kuş ve balık sürülerinin kolektif davranışlarını taklit ederek ilham almaktadır. Her bir parçacık, bir sürüdeki bir bireyi temsil eder ve en iyi performansı sergileyen bireyi taklit ederek hayatta kalmayı amaçlamaktadır. Parçacıklar, önceki hareketlerini hatırlar ve bu geçmiş deneyimlerini kullanarak gelecekteki hareketlerini belirlerler. Yeni adımlarını önceki adımlarla karşılaştırarak en uygun stratejiyi belirlemeye çalışırlar, böylece hayatta kalma ve optimal sonuçlar elde etme şanslarını artırırlar [37].

PSO algoritması, her parçacığın başlangıçta rastgele konumlarda yer aldığı bir başlangıç aşamasıyla işleyen bir optimizasyon algoritmasıdır. Bu aşamada, her parçacığın hızı ve konumu belirlenir ve başlangıç değerleri atanır. Her iterasyonda, parçacıkların çözümleri değerlendirilir ve en iyi çözümlerine göre hızları ve konumları güncellenir. Bu süreç, parçacıkların belirli bir problemin en iyi çözümünü bulmalarını sağlayacak şekilde optimize edilmesini amaçlamaktadır [38]. PSO'nun işleyişini gösteren akış diyagramı Şekil 9'da sunulmuştur.



Şekil 9. PSO'nun akış diyagramı

PSO algoritması, iterasyonlar boyunca en iyi çözümü bulmayı amaçlayan topluluk tabanlı bir iteratif algoritmadır. Parçacıkların güncellenen hız ve konum bilgileri, Denklem (1) ve Denklem (2) tarafından belirlenir [38].

$$V_i[t + 1] = wv_i[t] + c_1r_1(x_i, best[t] - x_i[t]) + c_2r_2(x_{gbest}[t] - x_i[t]) \quad (1)$$

$$X_i[t + 1] = x_i[t] + v_i[t + 1] \quad (2)$$

Denklemlerde kullanılan semboller aşağıda açıklanmıştır. Bu semboller, PSO algoritmasının iterasyonlarında parçacıkların güncellenen hız ve konum bilgilerini ifade etmek için kullanılır.

$V_i[t]$: Parçacığın anlık konumunu tanımlayan bir vektör olan hız vektörüdür.

w : Parçacığın kendi yönündeki hareketinin oranını belirleyen bir katsayıdır.

$x_i[t]$: Parçacığın mevcut konumunu belirten bir vektördür.

$x_i, best[t]$: Parçacığın geçmiş iterasyonlar boyunca ulaştığı en iyi konumu temsil eder.

$x_{gbest}[t]$: Tüm parçacıkların kapsamında bulunan en iyi konumu ifade etmektedir.

c_1 : Parçacığın kendi geçmiş deneyimlerinden elde ettiği öğrenme katsayısını ifade etmektedir.

c_2 : Parçacığın toplumun genel geçmiş deneyimlerinden aldığı öğrenme katsayısını tanımlar.

r_1 ve r_2 : (0,1) Aralığında rasgele olarak atanmış değerleri temsil eden değişkenlerdir.

Sınıflandırma

Sınıflandırma, denetimli bir makine öğrenimi yöntemidir ve temel amacı, belirli bir girdi verisine karşılık gelen doğru etiketi tahmin etmektir. Bu yöntemde, model, etiketlenmiş eğitim verileri üzerinde eğitilir ve daha sonra test verileriyle değerlendirilmektedir. Eğitim sürecinde, model, veri özelliklerini öğrenmektedir ve bu özelliklerden yola çıkarak verileri doğru sınıflara atamaktadır. Test aşamasında ise, modelin performansı test verisi üzerinde ölçülmektedir ve genellikle doğruluk, hassasiyet ve kesinlik gibi metriklerle değerlendirilmektedir. Bu değerlendirme sonucunda modelin başarımı değerlendirilmektedir ve yeni, görülmemiş veriler üzerinde tahminler yapmak için kullanılabilir [39].

Bu çalışmada, göz hastalıklarının tanısında kullanılan görüntülerin sınıflandırılması için SVM algoritması benimsenmiştir. Göz hastalıklarının tanısında kullanılan görüntülerin karmaşıklığını ele almak için bu algoritma seçilmiştir.


Destek Vektör Makineleri (SVM)

SVM, geniş bir alanda kullanılan ve sınıflandırma ile regresyon analizlerinde etkili sonuçlar veren bir denetimli öğrenme yöntemidir. Diğer sınıflandırma tekniklerine göre tercih edilme sebeplerinden biri, sınıflandırma problemlerini optimize etme kabiliyetleridir. Bu yöntemin belirgin avantajlarından biri, düzensiz veri kümeleriyle başa çıkabilme yeteneğidir. Ayrıca, uygun bir çekirdek seçimiyle karmaşık veri yapılarını sınıflandırabilirler ve büyük boyutlu veri kümeleriyle başarılı bir şekilde çalışabilirler. SVM'ler, genellikle optimum ayırım hiperdüzlemiyle veriler arasındaki maksimum marjı elde etmek için kullanılır ve doğrusal olmayan ilişkileri modelleme yeteneğiyle de dikkat çekerler.

Son yıllarda yaygın bir şekilde kullanılan SVM, sınıflandırma ve doğrusal olmayan işlev yaklaşımları için önerilen etkili bir denetimli öğrenme algoritmasıdır. SVM, yazı tanıma, nesne tanıma, ses tanıma, yüz tanıma gibi çeşitli örüntü tanıma uygulamalarında başarıyla uygulanmaktadır. Bu algoritmanın esas prensibi, farklı sınıflar arasındaki en geniş marjı olan bir hiperdüzlemi bulmaktır. Bu özelliği sayesinde veriler arasında en iyi ayrımı yaparak sınıflandırma konusunda yüksek doğruluk sağlar. SVM, verilerin doğrusal

olmayan ilişkilerini de modelleyebilen esnek bir yapıya sahip olduğundan geniş bir uygulama yelpazesine sahiptir ve pek çok alanda kullanım potansiyeline sahiptir [40].

Şekil 10'da daire ve kare sembolleriyle temsil edilen iki ayrı sınıfa ait veri noktalarının, belirgin bir marj ile ayrıldığı net bir ayırıcı hiperdüzlem gösterilmektedir. Bu hiperdüzlem, veri noktalarını maksimum marj ile böler ve farklı sınıflara doğru en iyi ayrımı sağlar.



Şekil 10. İki ayrı sınıfa ait veri noktalarının bir ayırıcı hiperdüzlemlerle ayrılışı

Hiper-parametre Seçimi

Hiperparametre seçimi, bir makine öğrenimi modelinin performansını etkileyen parametrelerin belirlenmesini referans alan bir süreçtir. Bu parametreler, modelin genel yapısı veya eğitim süreciyle ilişkili olmayıp, modelin başarısını doğrudan etkileyen düzenlemelerdir. Örneğin, hiperparametreler modelin karmaşıklığını, öğrenme hızını veya genelleme kabiliyetini yönlendirebilir. Hiperparametrelerin doğru seçimi kritik önem taşır çünkü yanlış değerler performansı olumsuz etkileyebilir. Genellikle hiperparametrelerin en iyi değerlerini tespit etmek için deneme yanılma yöntemleri kullanılır ve çapraz doğrulama gibi tekniklerle modelin performansı objektif bir şekilde değerlendirilir.

Bu araştırmada, SVM sınıflandırıcısının hiperparametrelerini optimize etmek için Bayesian optimizasyon yöntemi benimsenmiştir. Bu yöntem, SVM modelinin performansını artırmak ve en uygun hiperparametre değerlerini belirlemek için kullanılmıştır.

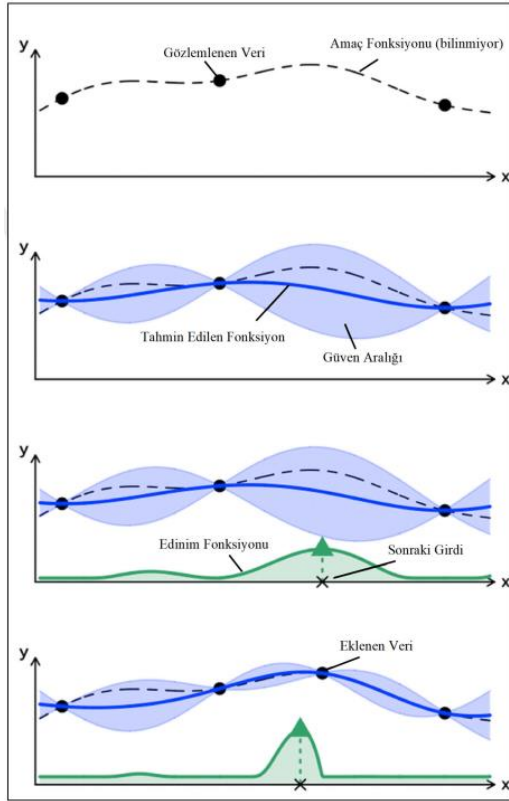
Bayesian Optimizasyon

Bayesian Optimizasyon, kompleks ve yüksek boyutlu uzaylarda en iyi çözümü etkili bir şekilde bulmayı hedefleyen bir optimizasyon yöntemidir. Bu yaklaşım genellikle maliyetli veya zaman alıcı gerçek deneyler veya simülasyonlar gerektiren problemlere odaklanır. Özellikle hiperparametre optimizasyonu, makine öğrenimi modeli yapılandırması ve endüstriyel tasarım gibi alanlarda yaygın olarak tercih edilmektedir. Bayesian Optimizasyon, verimli bir şekilde sonuca ulaşarak optimizasyon süreçlerini iyileştirmeyi amaçlar ve karmaşık problemleri çözmek için güçlü bir araçtır.

Temel prensip, geçmiş gözlemlere bağlı olarak gelecekteki en iyi noktayı tahmin etmek ve bu tahmini iyileştirmektir. Bu yaklaşım, modelin mevcut bilgi ve gerçek arasında denge kurarak en uygun noktayı belirlemesine odaklanır. Bu sayede, optimize edilmiş bir çözüm elde etmek için sürekli olarak

modelin tahminlerini güncelleyerek daha iyi sonuçlar elde edilmesi amaçlanır. Bu esnek ve verimli yöntem, mevcut bilgiyi efektif bir şekilde değerlendirerek en iyi çözümü bulmayı hedefler.

Başlangıçta, Bayesian optimizasyon sürecinde amaç fonksiyonu belirsizdir ancak birkaç başlangıç gözlem mevcuttur. İkinci adımda, gauss süreci kullanılarak amaç fonksiyonu ve belirsizliğini temsil eden standart sapma tahmin edilir. Üçüncü adımda, tahmin edilen fonksiyondan elde edilen en büyük kazançla yeni bir gözlem noktası belirlenir. Bu adımın ardından, tahmin ve kazanç fonksiyonları güncellenir ve süreç yeni verilere dayalı olarak devam etmektedir. Bayesian optimizasyon yöntemi, mevcut bilgileri kullanarak en iyi sonuçları elde etmeyi amaçlar ve iteratif bir şekilde yeni gözlemlerle modeli iyileştirir. Şekil 11'de Bayesian yönteminin işlem basamakları görülmektedir.



Şekil 11. Bayesian optimizasyonun tek boyutlu fonksiyonlar üzerindeki temsili [41]

Sınıflandırma Performans Metrikleri

Tablo 1. Karmaşıklık matrisi

	Tahmin Edilen Sınıf		
	Risk Var	Risk Yok	
Gerçek Sınıf	Risk Var	TP (True Positive)	FP (False Positive)
	Risk Yok	FN (False Negative)	TN (True Negative)

Bu çalışmada, sınıflandırma modellerinin etkinliğini değerlendirmek için yaygın olarak kullanılan metrikleri kullanılmıştır. Sınıflandırma problemlerinde modelin performansını değerlendirmek için doğruluk, hassasiyet,

duyarlılık ve F1 puanı gibi metrikler öne çıkmaktadır. Ayrıca, ROC eğrisi gibi grafiksel yöntemlerin kullanımı da detaylı olarak incelenmektedir. Karmaşıklık matrisi tabanlı metrikler, yanlış pozitiflerin ve yanlış negatiflerin modele etkisini ayrıntılı bir şekilde göstererek sınıflandırma performansını belirlemede önemli bir rol oynamaktadır. Bu metrikler, Tablo 1'de sunulan karmaşıklık matrisi üzerinden modelin performansını objektif bir şekilde değerlendirmeye olanak tanımaktadır.

Sınıflandırma algoritmalarının performansını değerlendirmek için sıklıkla kullanılan bir araç olan karmaşıklık matrisi, çeşitli temel terimler içermektedir:

True Positive (TP): Modelin doğru bir şekilde pozitif olarak tahmin ettiği gerçek pozitif örneklerin sayısı.

True Negative (TN): Modelin doğru bir şekilde negatif olarak tahmin ettiği gerçek negatif örneklerin sayısı.

False Positive (FP): Modelin yanlış bir şekilde negatif bir örneği pozitif olarak tahmin ettiği örneklerin sayısı.

False Negative (FN): Modelin yanlış bir şekilde pozitif bir örneği negatif olarak tahmin ettiği örneklerin sayısı.

Bu terimler kullanılarak, sınıflandırma performansı değerlendirilirken aşağıdaki metrikler belirlenmiştir [42]:

Doğruluk (Accuracy): Doğru tahmin edilen örneklerin toplam örnek sayısına oranı. Doğruluk Denklem 3'deki formülle hesaplanmaktadır.

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (3)$$

Hassasiyet (Precision): Pozitif olarak tahmin edilen örneklerin gerçek pozitif örneklerin oranı. Hassasiyet Denklem 4'teki gibi hesaplanır.

$$Precision = \frac{TP}{(TP + FP)} \quad (4)$$

F1 Skoru: Hassasiyet ve duyarlılık arasındaki dengeyi göz önünde bulunduran bir metriktir. Denklem 5'deki formülle F1 skoru hesaplanmaktadır.

$$F1\ score = 2 * \frac{(precision * recall)}{(precision + recall)} \quad (5)$$

ROC Eğrisi: sınıflandırma algoritmalarının performansını görsel olarak değerlendirmek amacıyla kullanılan etkili bir grafik aracıdır. AUC (Area Under Curve), ROC eğrisinin altında kalan alanı ifade eder ve bu değer modelin sınıflandırma yeteneğini yansıtır. AUC değeri ne kadar yüksekse, modelin performansı o kadar iyidir; 1'e yakın bir AUC değeri mükemmel bir sınıflandırıcıyı işaret ederken, 0.5'e yakın bir değer rasgele tahminin performansına eşittir. ROC eğrisi ve AUC, modelin başarısını belirlemede önemli bir gösterge olarak kullanılır ve modelin sınıflandırma becerilerini anlamak için değerli bir araçtır. Bu metrikler, karmaşıklık matrisi kullanılarak sınıflandırma performansının değerlendirilmesinde yaygın olarak kullanılmaktadır.

Deneysel Sonuçlar ve Tartışma

Bu çalışmada, göz hastalıklarının teşhisi için ESA mimarileri olan ResNet-101, DenseNet-201 ve DarkNet-53 modelleri kullanılarak özellik çıkarımı yapılmıştır. Bu modellerin kullanımı veri setindeki özelliklerin daha etkili bir şekilde tanımlanmasını sağlayarak göz hastalıklarının doğru teşhisi için önemli bir adım olmuştur. Ardından, modelin performansını artırmak ve sınıflandırmadaki gereksiz özellikleri elemek amacıyla PSO optimizasyon yöntemi gibi metasezgisel algoritmalar başarıyla uygulanmıştır. Bu optimizasyon süreci, modelin genel doğruluğunu ve sınıflandırma hassasiyetini artırmak için kritik bir rol oynamıştır.

Optimizasyon sürecinden sonra elde edilen özellikler, göz hastalıklarını sınıflandırmak için SVM sınıflandırıcısı ile entegre edilmiştir. SVM'nin doğruluk oranını en üst düzeye çıkarmak amacıyla hiperparametre iyileştirilmesi yapılmış ve bu sayede sınıflandırma performansı önemli ölçüde artırılmıştır. Ayrıca, sistem performansının objektif bir şekilde değerlendirilmesi için Bayesian optimizasyon yöntemi kullanılarak en uygun hiperparametreler belirlenmiştir.

Bu araştırmanın başlangıç aşamasında, göz hastalıklarının teşhisinde kullanılmak üzere fundus görüntülerinden çeşitli özelliklerin çıkarılması hedeflenmiştir. Bu amaçla, üç farklı güçlü ESA modeli tercih edilmiştir: ResNet-101, DenseNet-201 ve DarkNet-53. Her bir model için ayrı ayrı 1000 özellik çıkarılmış ve toplamda 3000 özellik içeren bir veri seti oluşturulmuştur. Bu veri seti, her modelin benzersiz mimarisinden kaynaklanan bilgiyi içermekte ve temel özellikleri yakalamak için kullanılmıştır.

Oluşturulan özellikli veri seti, Matlab R2023a yazılımı kullanılarak işlenmiş ve göz hastalıklarının sınıflandırılması amacıyla güçlü bir sınıflandırıcı olan SVM ile değerlendirilmiştir. Sınıflandırma işlemine başlamadan önce, SVM modeli "one-vs-All" stratejisi kullanılarak çoklu sınıf sınıflandırma yöntemi olarak yapılandırılmıştır.

Tablo 2. ResNet-101, DenseNet-201 ve DarkNet-53 ESA mimarilerinden çıkarılan özelliklerin SVM algoritması ile sınıflandırılması

Kullanılan Mimari	Sınıf Sayısı	Görüntü Sayısı	Özellik Sayısı	Sınıflandırıcı	Doğruluk Oranı (%)
ResNet-101	4	4217	1000	SVM	91.8
DenseNet-201	4	4217	1000	SVM	90.9
DarkNet-53	4	4217	1000	SVM	91.1


Elde edilen özellikler, ResNet-101, DenseNet-201 ve DarkNet-53 ESA mimarilerinden çıkarılan özellikler üzerinde çalışılarak elde edilmiş ve bu özellikler SVM kullanılarak sınıflandırılmıştır. Sonuçlar, sınıflandırma işlemi sonucunda elde edilen metrikler ve sınıflandırma

performansıyla birlikte Tablo 2'de detaylı bir şekilde sunulmuştur.


Daha sonra çalışmada kullanılan ön eğitilmiş mimarilerden elde edilen özellikler birleştirilerek 3000 özellikli yeni bir veri kümesi oluşturulmuş ve bu veri kümesi SVM algoritması ile sınıflandırılmıştır. Tablo 3'te sınıflandırma performansı gösterilmiştir.

Tablo 3. ResNet-101, DenseNet-201 ve DarkNet-53 mimarilerinin füzyonu ile elde edilen sonuçlar

Kullanılan Mimari	Sınıf Sayısı	Görüntü Sayısı	Özellik Sayısı	Sınıflandırıcı	Doğruluk Oranı (%)
ResNet-101 + DenseNet-201 + DarkNet-53	4	4217	3000	SVM	93.2



Şekil 12. ResNet-101, DenseNet-201 ve DarkNet-53 modelleri birleştirilerek özellik çıkarılmış görüntülerin sınıflandırılmasında SVM uygulandıktan sonraki karmaşıklık matrisi



Şekil 13. (1) Katarakt hastalığı için ROC eğrisi (2) Diyabetik retinopati hastalığı için ROC eğrisi (3) Glukom hastalığı için ROC eğrisi ve (4) Normal göz için ROC eğrisi

Elde edilen sonuçların daha detaylı bir şekilde analiz edilmesi ve karşılaştırılması için, karmaşıklık matrisi Şekil 12'de sunulmuştur. Bu matris, farklı sınıfların performansını ve sınıflandırıcının başarısını hangi koşullarda ne kadar gösterdiğini daha açık bir şekilde göstermektedir. Ayrıca, her bir sınıf için ROC eğrileri Şekil 13'te görselleştirilmiştir. Bu sayede, sınıfların tespit yetenekleri ve yanıt eğrileri daha net bir şekilde anlaşılabilir hale getirilmiştir.

Tablo 4. PSO optimizasyonu başlangıç parametreleri

Parametre	Değer
Veri doğrulama oranı	%20
Popülasyon boyutu	20
Yineleme sayısı	20
Bilişsel parametre	0,34
Sosyal parametre	0,33

Modelin performansını artırmak amacıyla 3000 özneliğin optimal kullanımı için PSO optimizasyon yöntemi WEKA 3.8.6 programı ile uygulanmıştır. Bu adımın hedefi, modeli daha etkili ve hassas hale getirmektir. Optimizasyon süreci sonrasında, modelin performansında belirgin bir iyileşme gözlenmiş ve daha üstün sonuçlar elde edilmiştir. PSO optimizasyonunun uygulandığı başlangıç parametreleri Tablo 4'te detaylı bir şekilde sunulurken, iyileştirme sonuçları SVM sınıflandırıcısının hiperparametrelerinin Bayesian ile optimizasyonu sonucu elde edilen performans değerleri Tablo 5'te gösterilmiştir.

Tablo 5. ResNet-101, DenseNet-201 ve DarkNet-53 mimarilerinin füzyonu ile elde edilen sonuçların PSO ile optimizasyon yapıp SVM sınıflandırmasının hiperparametrelerinin Bayesian ile optimizasyonu sonucu

Kullanılan Mimari	Sınıf Sayısı	Görüntü Sayısı	Özellik Sayısı	Sınıflandırıcı	Doğruluk Oranı (%)
ResNet-101 + DenseNet-201 + DarkNet-53 + PSO + SVM + Bayesian optimizasyon (Önerilen yöntem)	4	4217	1159	SVM	93.8

Bayesian optimizasyonun toplama fonksiyonu, saniyede beklenen iyileşme olarak, yineleme sayısı 30 olarak belirlenmiştir. Bu yapılandırılmalar sonucunda SVM için Box constrain level 5.147 ve standardize data true olarak en iyi hiperparametreler elde edilmiştir.

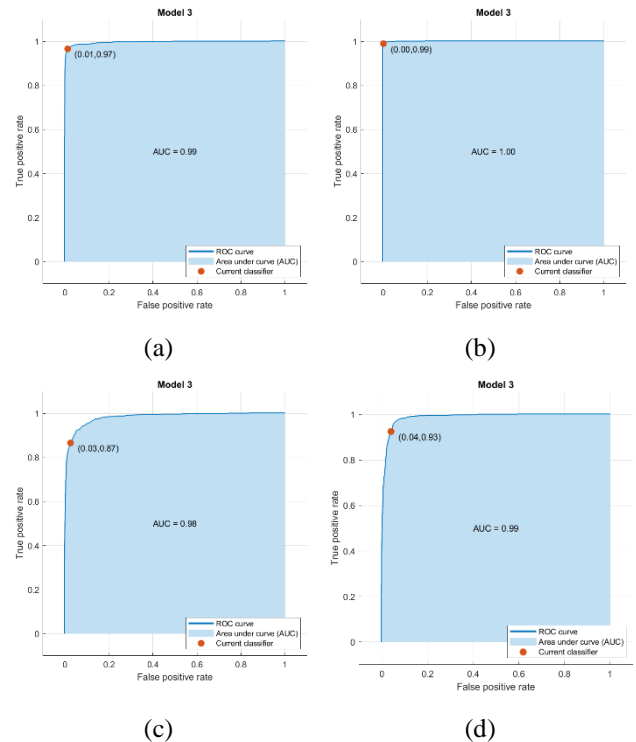
Önerilen metodolojide, özellik seçimi PSO optimizasyonu ile gerçekleştirilmiş ve sonrasında özellik sayısı 3000'den 1159'a düşürülmüştür. Ardından, SVM hiperparametrelerinin optimizasyonu için Bayesian optimizasyonu uygulanmış ve sistemin performansı yeniden test edilmiştir. Elde edilen sonuçlar, önerilen yöntemin sistem performansını artırdığını göstermektedir. Şekil 14'te önerilen yöntemin karmaşıklık

matrisi, Şekil 15'te ROC eğrisi ve Şekil 16'da önerilen yöntemin minimum sınıflandırma hatası grafiği görülmektedir.


Önerilen yöntemin, doğruluk performansı metriği aracılığıyla literatürdeki mevcut çalışmalarla karşılaştırılabilir olarak değerlendirilebilmesi için oluşturulan Tablo 6'da, göz hastalıklarının derin öğrenme yaklaşımlarıyla sınıflandırılmasına ait son yıllarda yapılmış çalışmalara yer verilmiştir.

		Model 3			
		1	2	3	4
True Class	1	1003		20	15
	2	1	1087	5	5
	3	23	3	873	108
	4	15	5	60	994
		Predicted Class			

Şekil 14. Önerilen yöntemin karmaşıklık matrisi



Şekil 15. (a) Katarakt hastalığı için ROC eğrisi (b) Diyabetik retinopati hastalığı için ROC eğrisi (c) Glukom hastalığı için ROC eğrisi ve (d) Normal göz için ROC eğrisi



Şekil 16. Önerilen yöntemin minimum sınıflandırma hatası

Tablo 6. Önerilen yöntemin mevcut çalışmalarla performans karşılaştırması

Yazar	Yöntem	Doğruluk
Carrillo vd. [20]	Segmentasyon	%88.5
Özbay [22]	ADL-ESA + ABC	%99.6
Metin ve Karasulu [25]	ResNet+MobileNet	%81.0
Topaloğlu [43]	VGG19	%88.0
Pan vd. [44]	Inception+ResNet	%93.8
Al-Fahdawi vd. [45]	DeepNet	%92.4
Sun vd. [46]	UWFIs	%93.0
Proposed method		%93.8

Önerilen yöntem, literatür bölümünde anlatılan benzer göz hastalıklarını sınıflandırma yaklaşımlarıyla karşılaştırılmıştır. Önerilen yöntemde, giriş görüntüsünün özellikleri farklı ön-eğitilmiş ESA mimarileri ile öğrenilebilmektedir. Özellik çıkarım yöntemleriyle elde edilen öznelik haritası PSO algoritması kullanılarak boyut indirgeme ile özellik seçimi gerçekleştirilmiştir. Ayrıca, model sağlamlığını artıran ve yakınsamayı hızlandıran ESA parametrelerini optimize etmek için Bayesian optimizasyon algoritması kullanılmıştır. Karşılaştırılan son yıllara ait mevcut çalışmalara ait yöntemler aynı veya benzer veri kümelerini kullanmışlardır. Bu bakımdan önerilen yöntem, Tablo 6’da verilen son yıllarda yapılan çalışmalarla kıyaslandığında geleneksel yöntemlere göre uygulama kolaylığı ve çok sınıflı varyansı işleme yeteneği ve yüksek sınıflandırma oranı nedeniyle mevcut yaklaşımlara göre daha büyük bir potansiyele sahip olduğu söylenebilir.

Sonuçlar

Bu çalışma, göz sağlığıyla ilgili önemli bir halk sağlığı sorununa odaklanarak, göz hastalıklarının erken teşhisi ve doğru tedavisi için gelişmiş bir yöntem geliştirmiştir. Çağdaş tıp ve teknolojinin sunduğu imkanlarla, derin öğrenme ve özellik seçimi tekniklerinin metasezgisel yaklaşımlarla birleştirilmesi suretiyle, göz hastalıklarının tanı süreci daha hassas ve etkili hale getirilmiştir.

Önceden eğitilmiş üç farklı derin öğrenme mimarisi olan ResNet101, DenseNet201 ve DarkNet53 kullanılarak elde

edilen özellikler, birleştirilerek kapsamlı bir özellik havuzu oluşturulmuştur. Bu havuz, görüntülerin daha iyi temsil edilmesini ve verimli bir analiz sürecini desteklemiştir. Daha da önemlisi, PSO gibi metasezgisel bir yöntem kullanılarak gereksiz özellikler elemine edilmiş ve modelin performansı iyileştirilmiştir.

Sınıflandırma amacıyla SVM tercih edilmiş ve hiperparametrelerin belirlenmesi için Bayesian optimizasyon yöntemi uygulanmıştır. Bu süreç, SVM’nin daha iyi ayarlanmasını ve veri setine uyum sağlamasını sağlayarak, sınıflandırma doğruluğunu %93.8 seviyesine yükseltmiştir. Elde edilen bu başarılar, önerilen metodolojinin göz hastalıklarının tespiti ve tedavisinde etkili bir araç olarak kullanılabileceğini göstermektedir.

Bu çalışmada, göz hastalıklarını sınıflandırmada ön-eğitilmiş modellerin ortalama %91 doğruluk performansı elde ettiği, bu modellerin birleştirilmesiyle birlikte bu oranın yaklaşık %93’e çıkarıldığı ve önerilen, PSO ile özellik seçimi sonrası Bayesian hiperparametre optimizasyonu yöntemiyle SVM sınıflandırıcısı kullanılarak %93.8 doğruluk elde edildiği gösterilmiştir. Bu bakımdan önerilen yöntemin mevcut ön-eğitilmiş ESA modellerine kıyasla yaklaşık %3 oranında bir iyileştirme sağladığı görülmektedir.

Sonuç olarak, yapay zeka tekniklerinin tıbbi görüntüleme alanında benzersiz bir potansiyele sahip olduğu ve göz hastalıklarının erken teşhisinde önemli bir rol oynayabileceği vurgulanmaktadır. Bu çalışma, bilimsel literatüre yeni bir katkı sunarken, göz sağlığının korunması ve görme kayıplarının en aza indirilmesi konularında umut vadeden bir yaklaşımı desteklemektedir.

Kaynaklar

- [1] V. Ayzenberg, F. S. Kamps, D. D. Dilks, ve S. F. Lourenco, “Skeletal representations of shape in the human visual cortex”, *Neuropsychologia*, c. 164, s. 108092, 2022.
- [2] R. R. A. Bourne vd., “Causes of vision loss worldwide, 1990–2010: a systematic analysis”, *The lancet global health*, c. 1, sayı 6, ss. e339–e349, 2013.
- [3] N. Congdon vd., “Causes and prevalence of visual impairment among adults in the United States.”, *Archives of Ophthalmology (Chicago, Ill.: 1960)*, c. 122, sayı 4, ss. 477–485, 2004.
- [4] T. Li vd., “Applications of deep learning in fundus images: A review”, *Medical Image Analysis*, c. 69, s. 101971, 2021.
- [5] H. Halıcı, “Yeni bir fakoemülsifikasyon cihazı tasarımı ve uygulaması”. Fen Bilimleri Enstitüsü, 2004.
- [6] S. H. Gözoğlu, “Mikroinsizyonel katarakt cerrahisi ile lens ekstraksiyonu ve arka kamara göz içi lensi yerleştirilmesi sonrası postoperatif sonuçların incelenmesi”, *TC Haseki Eğitim Araştırma Hastanesi Göz Hastalıkları Kliniği. Uzmanlık tezi, danışman: Doç. Dr. Feyza Önder*, 2006.

- [7] M. Duman, "Fakoemülsifikasyon sırasında arka kapsül yırtığı gelişmesi sonrası arka kamara göz içi lensi uygulanan olgularımızın klinik sonuçları", *TC Sağlık Bakanlığı İstanbul Eğitim ve Araştırma Hastanesi Göz Hastalıkları Kliniği. Uzmanlık tezi, danışman: Doç. Dr. Kadir Eltutar*, 2006.
- [8] M. Blair, "Diabetes mellitus review.", *Urologic nursing*, c. 36, sayı 1, 2016.
- [9] J. B. Cole ve J. C. Florez, "Genetics of diabetes mellitus and diabetes complications", *Nature reviews nephrology*, c. 16, sayı 7, ss. 377–390, 2020.
- [10] R. E. Washington, T. J. Orchard, V. C. Arena, R. E. LaPorte, A. M. Secrest, ve E. S. Tull, "All-cause mortality in a population-based type 1 diabetes cohort in the US Virgin Islands", *Diabetes research and clinical practice*, c. 103, sayı 3, ss. 504–509, 2014.
- [11] N. G. Congdon, D. S. Friedman, ve T. Lietman, "Important causes of visual impairment in the world today", *Jama*, c. 290, sayı 15, ss. 2057–2060, 2003.
- [12] A. Sinclair, P. Saeedi, A. Kaundal, S. Karuranga, B. Malanda, ve R. Williams, "Diabetes and global ageing among 65–99-year-old adults: Findings from the International Diabetes Federation Diabetes Atlas", *Diabetes research and clinical practice*, c. 162, s. 108078, 2020.
- [13] L. Zhou, Y. Zhao, J. Yang, Q. Yu, ve X. Xu, "Deep multiple instance learning for automatic detection of diabetic retinopathy in retinal images", *IET Image Processing*, c. 12, sayı 4, ss. 563–571, 2018.
- [14] D. R. Nayak, D. Das, B. Majhi, S. V Bhandary, ve U. R. Acharya, "ECNet: An evolutionary convolutional network for automated glaucoma detection using fundus images", *Biomedical Signal Processing and Control*, c. 67, s. 102559, 2021.
- [15] Y.-C. Tham, X. Li, T. Y. Wong, H. A. Quigley, T. Aung, ve C.-Y. Cheng, "Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis", *Ophthalmology*, c. 121, sayı 11, ss. 2081–2090, 2014.
- [16] A. Esteva *vd.*, "Dermatologist-level classification of skin cancer with deep neural networks", *nature*, c. 542, sayı 7639, ss. 115–118, 2017.
- [17] M. Uddin *vd.*, "Brain-expressed exons under purifying selection are enriched for de novo mutations in autism spectrum disorder", *Nature genetics*, c. 46, sayı 7, ss. 742–747, 2014.
- [18] L. Clifton, D. A. Clifton, M. A. F. Pimentel, P. J. Watkinson, ve L. Tarassenko, "Gaussian processes for personalized e-health monitoring with wearable sensors", *IEEE Transactions on Biomedical Engineering*, c. 60, sayı 1, ss. 193–197, 2012.
- [19] Y. Hatanaka *vd.*, "Vertical cup-to-disc ratio measurement for diagnosis of glaucoma on fundus images", içinde *Medical Imaging 2010: Computer-Aided Diagnosis*, SPIE, 2010, ss. 945–952.
- [20] J. Carrillo, L. Bautista, J. Villamizar, J. Rueda, ve M. Sanchez, "Glaucoma detection using fundus images of the eye", *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)*, IEEE, 2019, ss. 1–4.
- [21] H. Pratt, F. Coenen, D. M. Broadbent, S. P. Harding, ve Y. Zheng, "Convolutional neural networks for diabetic retinopathy", *Procedia computer science*, c. 90, ss. 200–205, 2016.
- [22] E. Özbay, "An active deep learning method for diabetic retinopathy detection in segmented fundus images using artificial bee colony algorithm", *Artificial Intelligence Review*, c. 56, sayı 4, ss. 3291–3318, 2023.
- [23] R. Asaoka, H. Murata, A. Iwase, ve M. Araie, "Detecting preperimetric glaucoma with standard automated perimetry using a deep learning classifier", *Ophthalmology*, c. 123, sayı 9, ss. 1974–1980, 2016.
- [24] F. Ağalday ve A. Çınar, "Derin Öğrenme Mimarilerini Kullanarak Katarakt Tespiti", *Avrupa Bilim ve Teknoloji Dergisi*, sayı 28, ss. 1428–1433, 2021.
- [25] B. Metin ve B. Karasulu, "Derin Öğrenme Modellerini Kullanarak İnsan Retinasının Optik Koherans Tomografi Görüntülerinden Hastalık Tespiti", *Veri Bilimi*, c. 5, sayı 2, ss. 9–19, 2022.
- [26] G. Venkat Doddi, "No Title", Kaggle. Erişim: 15 Mart 2024. [Çevrimiçi]. Available at: <https://www.kaggle.com/datasets/gunavenkatdoddi/eye-diseases-classification>
- [27] K. Fırıldak ve M. F. Talu, "Evrişimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi", *Computer Science*, c. 4, sayı 2, ss. 88–95, 2019.
- [28] Y. LeCun, Y. Bengio, ve G. Hinton, "Deep learning", *nature*, c. 521, sayı 7553, ss. 436–444, 2015.
- [29] H. Durmuş, E. O. Güneş, ve M. Kırıcı, "Disease detection on the leaves of the tomato plants by using deep learning", içinde *2017 6th International conference on agro-geoinformatics*, IEEE, 2017, ss. 1–5.
- [30] G. Huang, Z. Liu, L. Van Der Maaten, ve K. Q. Weinberger, "Densely connected convolutional networks", içinde *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, ss. 4700–4708.
- [31] D. Al-Rubaye ve S. Ayvaz, "Deep Transfer Learning and Data Augmentation for Food Image Classification", içinde *2022 Iraqi International Conference on Communication and Information Technologies (IICCIT)*, IEEE, 2022, ss. 125–130.
- [32] M. Yildirim, S. Kiziloluk, S. Aslan, E. Sert, "A new hybrid approach based on AOA, CNN and feature fusion that can automatically diagnose Parkinson's disease from sound signals: PDD-AOA-CNN", *Signal, Image and Video Processing*, 18(2), 1227–1240, 2024.

- [33] S. Kiziloluk, M. Yildirim, H. Bingol, B. Alatas, "Multi-feature fusion and dandelion optimizer based model for automatically diagnosing the gastrointestinal diseases", *PeerJ Computer Science*, 10, e1919, 2024.
- [34] S. Akyol, M. Yildirim, B. Alatas, "Multi-feature fusion and improved BO and IGWO metaheuristics based models for automatically diagnosing the sleep disorders from sleep sounds", *Computers in Biology and Medicine*, 157, 106768, 2023.
- [35] F. A. Özbay, "A modified seahorse optimization algorithm based on chaotic maps for solving global optimization and engineering problems", *Engineering Science and Technology, an International Journal*, 41, 101408, 2023.
- [36] R. Eberhart ve J. Kennedy, "A new optimizer using particle swarm theory", içinde *MHS'95. Proceedings of the sixth international symposium on micro machine and human science*, Ieee, 1995, ss. 39–43.
- [37] J. Kennedy ve R. Eberhart, "Particle swarm optimization", içinde *Proceedings of ICNN'95-international conference on neural networks*, Ieee, 1995, ss. 1942–1948.
- [38] E. H. Houssein, A. G. Gad, K. Hussain, ve P. N. Suganthan, "Major advances in particle swarm optimization: theory, analysis, and application", *Swarm and Evolutionary Computation*, c. 63, s. 100868, 2021.
- [39] Z. Keita, "Classification in Machine Learning: An Introduction", Datacamp. Erişim: 27 Mart 2024. [Çevrimiçi]. Available at: <https://www.datacamp.com/blog/classification-machine-learning>
- [40] A. U. Özkaya, M. E. Kaya, ve F. Gürgen, "Destek vektör makineleri kullanılarak aritmi sınıflandırması", *Biyomedikal Müh. Ulusal Toplantısı*, 2005.
- [41] R. Tanaka ve H. Iwata, "Bayesian optimization for genomic selection: a method for discovering the best genotype among a large number of candidates", *Theoretical and applied genetics*, c. 131, ss. 93–105, 2018.
- [42] E. Özbay ve F. A. Özbay, "Derin Öğrenme ve Sınıflandırma Yaklaşımları ile BT görüntülerinden Covid-19 Tespiti", *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(2), 211-219, 2021.
- [43] I. Topaloglu, "Deep learning based convolutional neural network structured new image classification approach for eye disease identification", *Scientia Iranica*, 30(5), 1731-1742, 2023.
- [44] Y. Pan, J. Liu, Y. Cai, X. Yang, Z. Zhang, H. Long, Z. Tan, "Fundus image classification using Inception V3 and ResNet-50 for the early diagnostics of fundus diseases", *Frontiers in Physiology*, 14, 1126780, 2023.
- [45] S. Al-Fahdawi, A.S. Al-Waisy, D.Q. Zeebaree, R. Qahwaji, H. Natiq, M.A. Mohammed, M. Deveci, "Fundus-deepnet: Multi-label deep learning classification system for enhanced detection of multiple ocular diseases through data fusion of fundus images", *Information Fusion*, 102, 102059, 2024
- [46] G. Sun, X. Wang, L. Xu, C. Li, W. Wang, Z. Yi, C. Chen, "Deep learning for the detection of multiple fundus diseases using ultra-widefield images", *Ophthalmology and Therapy*, 12(2), 895-907, 2023.