



Fundus Görüntülerinden Derin Öğrenme Teknikleri ile Glokom Hastalığının Tespiti

Özcan Yıldırım¹, Feyza Altunbey Özbay^{2*}

¹ Fırat Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Elazığ, Türkiye, (ORCID: 0000-0003-2776-5081), yldrmocn3@gmail.com

^{2*} Fırat Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Elazığ, Türkiye (ORCID: 0000-0003-0629-6888), faltunbey@firat.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1216404)

ATIF/REFERENCE: Yıldırım, Ö. & Altunbey Özbay, F. (2022). Fundus Görüntülerinden Derin Öğrenme Teknikleri ile Glokom Hastalığının Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 1-6.

Öz

Glokom optik siniri etkileyen ve erken teşhis edilmediği durumlarda kısmi ya da kalıcı körlüğe neden olan bir retina hastalığıdır. Zamanla görme kaybına neden olan glokomun teşhisi için doktorlar fundus görüntülerini kullanmaktadır. Glokomun etken teşhisi oldukça önemlidir. Bu çalışmada, fundus görüntülerinden glokom tespiti için Evrişimli Sinir Ağları (ESA) modellerinden olan AlexNet, ResNet-18, VGG16, SqueezeNet ve GoogleNet kullanılmıştır. Kullanılan mimariler için elde edilen sonuçlar doğruluk, duyarlılık, özgüllük ve f1-ölçütü değerleri olmak üzere farklı performans metriklerine göre değerlendirilmiştir. Sonuçlara göre test veri kümesinde en iyi duyarlılık değeri %97.96 ile VGG16 tarafından elde edildiği, özgüllük, doğruluk ve f1-ölçütü için en iyi değerlerin ise sırasıyla %98.97, %97.98 ve %98 ile GoogleNet olduğu tespit edilmiştir.

Anahtar Kelimeler: Evrişimsel Sinir Ağları, Fundus görüntüleri, Glokom, Yapay Zekâ.

Detection of Glaucoma Disease with Deep Learning Techniques from Fundus Images

Abstract

Glaucoma is a retinal disease that affects the optic nerve and causes partial or permanent blindness if not diagnosed early. To diagnose glaucoma, which causes vision loss over time, doctors use fundus images. The causative diagnosis of glaucoma is very important. In this study, Convolutional Neural Networks (CNN) models AlexNet, ResNet-18, VGG16, SqueezeNet, and GoogleNet were used for glaucoma detection from fundus images. The results obtained for the architectures used were evaluated according to different performance metrics such as accuracy, sensitivity, specificity, and f1-criterion values. According to the results, it was determined that the best sensitivity value in the test dataset was obtained by VGG16 with 97.96%, and the best values for specificity, accuracy, and f1-criterion were GoogleNet with 98.97%, 97.98%, and 98%, respectively.

Keywords: Convolutional Neural Networks, Fundus images, Glaucoma, Artificial Intelligence.

* Sorumlu Yazar: faltunbey@firat.edu.tr

1. Giriş

Glokom hastalığı genellikle göz için basıncının yükselmesinden kaynaklanmaktadır (Nayak vd., 2021). Optik sinire zarar veren bir hastalıktır. Dünya genelinde geri dönülemez körlüğün yaygın sebebidir. Ancak hastalık ilk evrede tespit edilebilirse görme kaybı önlenmektedir. Tahminlere göre, dünya genelinde 2013 yılında 40-80 yaş arası yaklaşık 64,3 milyon kişiye glokom teşhisi konduğu ve 2040 yılına kadar yaklaşık 112 milyon kişiyi etkilemesi beklenmektedir (Tham vd., 2014). Glokomun neden olduğu görme kaybı, erken teşhis ve tedavi ile önlenir. Bu nedenle glokomun erken bir aşamada tespit edilmesi önemlidir. Ancak, çoğu zaman şüpheli hastalar için manuel glokom taraması yapmak zordur. Bu nedenle, yüksek doğruluk ve verimlilik ile glokom tespiti yapabilen otomatik yöntemlerin geliştirilmesi gerekmektedir.

Glokom, optik diskin içinde ve dışında gözle görülür değişikliklerle yapısal optik sinir lifi hasarına neden olarak sonuçta fonksiyonel görme kaybına yol açmaktadır. Glokom, optik disk olarak da adlandırılan optik sinir başının (ONH) karakteristik değişiklikleri ile ilişkilidir (Weinreb vd., 2014). Klinik muayene ve optik disk fotoğraf analizi sırasında göz doktorları, genelleştirilmiş veya fokal nöral halka incelenmesi gibi tipik değişiklikleri arayarak ONH'yi değerlendirmektedir. Nöroretinal kenar incelenmesi, dikey çanak-disk oranı ölçülerek fundus fotoğraflarında ölçülebilir. Optik kap, ONH'nin orta kısmındaki ayırt edilebilir kazıdır. Normal gözlerde tipik olarak küçüktür, ancak nöroretinal halka kaybıyla artmaktadır. Bu nedenle, dikey çanak-disk oranının yüksek olması veya interoküler asimetri değerinin 0.2'den yüksek olması glokom için şüpheli kabul edilmektedir (Hemelings vd.,2021).

Derin öğrenme modelleri ve özellikle Evrişimli Sinir Ağları (ESA), tıbbi görüntü analizinde yeni ölçütler sunmakta ve her geçen popüler hale gelmektedir. Bu modeller ile cilt kanseri sınıflandırmasını araştırmak, otizmdeki karmaşık genetik etkileşimleri değerlendirmek ve yoğun bakım ünitesinde izleme gerçekleştirmek için makine öğrenmesi yöntemleri kullanılmıştır (Esteve vd., 2017, Uddin vd., 2014, Clifton vd., 2012). Derin makine öğrenimi kullanan diyabetik retinopati üzerine yakın tarihlili bir araştırma, makine öğreniminin diyabetik retinopatinin saptanmasında yüksek hassasiyet ve özgüllük sergilediğini ortaya koymuştur (Özbay, 2022).

Bu çalışma, fundus görüntülerinden glokom tespiti için AlexNet, ResNet-18, VGG16, SqueezeNet ve GoogleNet gibi önceden eğitilmiş ESA modellerini kullanımına dayanmaktadır. Makalenin ikinci bölümünde literatürde glokom tespiti ile ilgili yapılmış çalışmalar incelenmiştir. Kullanılan ESA modelleri ve yöntem üçüncü bölümde açıklanmıştır. Dördüncü bölümde ise deneysel sonuçları verilerek analiz edilmiş ve son bölümde makale sonlandırılmıştır.

2. İlgili Çalışmalar

Son yıllarda, evrimli sinir ağları araştırmacılar tarafından glokom tespiti için farklı birçok çalışmada kullanılmıştır. Alghamdi vd. retina görüntülerinden optik disk anormalliklerinin saptanması için uçtan uca denetimli bir model kullanmıştır. Modelde birbini izleyen iki derin öğrenme mimarisi kullanılmıştır. Dört genel ve dört özel veri kümesinden oluşan toplam sekiz veri kümesi kullanmışlardır. Önerilen model hızlı ve güçlü performans göstermiştir (Alghamdi vd., 2016).

Chen vd. Orica ve Sces veri kümeleri üzerinde altı katmanlı yapıya sahip ESA mimarisi kullanmışlardır. Veri arttırımı metotları ile veri kümelerini test ederek %88.70 başarı oranı yakalanmıştır (Chen vd., 2015). Bir başka çalışmada Orlando vd. halka açık Drishti-gsl veri kümesini ESA mimarisi ile eğitmişlerdir. Özellik vektörleri için overFeat ve VGG-S gibi ön işleme tekniklerini kullanarak oldukça başarılı sonuçlar elde edilmiştir (Orlando vd., 2017).

Hatanaka vd. glokom tespitinde kupa alanının zor tespit edilmesinden yola çalışmalarında optik disk üzerinde dikey bir profil kullanılarak çanak-disk oranını ölçmek için yeni bir yöntem önermiştir. Önerilen yöntemde ilk olarak kan damarları görüntüden temizlenmiş ve ardından canny kenar algılama filtresi kullanılarak disk kenar tespiti yapılmıştır. Daha sonra renkli görüntü verisi üzerinde kupa-disk oranı hesaplanmıştır. 25' i glokoma olan toplamda 79 adet görüntü verisinin kullanıldığı yöntemde %80 hassasiyet ve %85 özgüllük başarımları elde edilmiştir (Hatanaka vd., 2010).

Bir diğer çalışmada, Carrillo vd., Kolombiya özelinde yaygın görülen göz tansiyonu hastalığını ele almış ve bu hastalığın otomatik olarak tespiti ile ilgili yapay zekâ tabanlı yeni bir hesaplama yöntemi önermiştir. Önerilen yeni yöntemde kupa ve disk boyutu arasındaki eşik değere göre yapılan yeni ölçüm literatürdeki diğer disk segmentasyon yöntemlerine göre başarımları daha yüksektir. Yeni yöntem glokom tespitinde %85 başarı göstermiştir (Carrillo vd., 2019).

Bir diğer yapay zekâ tabanlı çalışmada, Almazroa vd. optik kabı iki boyutlu renkli bir fundus görüntüsünden ayırmak için yeni bir teknik geliştirilmiştir. Otsu fonksiyonu ve tip iki bulanık mantık entropi prosedürünün kullanıldığı yeni yöntem, RIGA veri tabanından alınan 100 fundus görüntü üzerinde uygulanmıştır. Önerilen yöntemin başarımları %72.5' tir (Almazroa vd., 2015).

Farklı bir çalışmada Dey ve Bandyopadhy, sayısal fundus görüntüleri üzerinde glokom tespiti için yeni bir yöntem önermiştir. Bu yöntemde gürültü giderme ve kontrast geliştirme gibi görüntü ön işleme teknikleri, özellik çıkarımı için Temel Bileşen Analizi (PCA) yöntemi ve görüntü sınıflandırması için Destek Vektör Makinesi (SVM) yöntemi kullanılmıştır. Önerilen SVM sınıflandırıcı için çapraz doğrulama sonucunda önerilen yöntem doğruluk, hassasiyet ve özgüllük başarımları sırasıyla %96, %100 ve %92' dir (Dey ve Bandyopadhy, 2016).

Sevastopolsky, çalışmasında optik disk kap segmentasyonu için U-Net konvolüsyonel sinir ağı tabanlı yeni bir evrensel yöntem sunmuştur. Önerilen yöntem, DRIONS-DB, RIM-ON VE DRISTHI-GS gibi açık veri tabanları üzerinde glokom tespitinde sık başvurulan yöntemlerle karşılaştırılmıştır. Aynı çalışmada önerilen yöntemin karşılaştırılan literatürdeki diğer yöntemlere oranla hesaplama tahmini açısından daha başarılı olduğu vurgulanmıştır (Sevastopolsky, 2017).


Cho vd. çalışmalarında erken ve geç glokom evrelerini otonom olarak sınıflandırabilen derin öğrenme tabanlı yeni bir yöntem geliştirmiştir. ESA mimarisi tabanlı bu yöntemde, eğitim aşamasında 3460 adet sayısal fundus görüntüsü içeren veri kümesi kullanılmıştır. Çalışma kapsamında elde edilen bulgular, önerilen yöntemin başarımları %88.1' dir (Cho vd., 2021).

Gheisari vd., çalışmalarında bir fundus görüntüsü üzerindeki uzamsal özelliklerin aksine, sıralı görüntüler (video) üzerinde gömülü geçici özellik çıkarımlarını da yapabilen ESA ve yinelemeli yapay sinir ağı tabanlı yeni bir yöntem önermiştir. Önerilen yöntemde 1810 fundus görüntüsü, 295 fundus videosu

veri kümesi olarak kullanılmıştır. Önerilen bu yöntemin f1-ölçütü değeri %96.2 iken tek başına ESA mimarisinde bu değer %79.2 olarak elde edilmiştir. Aynı çalışmada önerilen yöntemin fundus videolarından uzamsal ve zamansal özelliklerin çıkarılmasının glokom tespitinin doğruluğunu önemli ölçüde artırabileceğini göstermektedir (Gheisari vd., 2021).

3. Materyal ve Metot


Fundus görüntüleri glokom ve diyabetik retinopatiyi saptamak için kullanılmaktadır. Bu görüntülerin özellikleri kullanılarak optik sinir lifinde oluşan hasar saptanmaktadır. Ancak, glokomun erken bir aşamada teşhis edilememesi bu hastalık için önemli bir dezavantajdır. Bu çalışmada fundus görüntülerinden glokom teşhisi için ESA modellerinden AlexNet, ResNet-18, VGG16, SqueezeNet ve GoogleNet kullanılmıştır. Çalışmada öncelikle genel erişime açık glokom veri kümesinden 1000 görüntü alınmıştır. Ardından ön işlem adımında fundus görüntüleri, kullanılacak ESA mimarilerinin görüntü boyutuna dönüştürülmüştür. Daha sonra görüntüler AlexNet, ResNet-18, VGG16, SqueezeNet ve GoogleNet mimarileri ile eğitilmiştir. Tüm mimariler için eğitim oranları 0.005 olarak belirlenmiştir. Çalışmanın gerçekleştirim adımları Şekil 1’de gösterilmiştir.



Şekil 1. Önerilen yöntemin akış diyagramı

3.1. Veri Kümesi

Bu çalışmada, genel erişime açık fundus görüntülerinden oluşan Origa (-light) veri kümesi kullanılmıştır (Alsulami vd., 2022). Veri kümesinde 3000 adet glokom hastasına ve 3000 adet sağlıklı (normal) bireye ait olmak üzere toplam 6000 görüntü bulunmaktadır. Bu çalışmada veri kümesinden alınan 500 sağlıklı bireye ve 500 glokom hastasına toplam 1000 görüntü kullanılmıştır. Origa (-light) veri kümesinden sağlıklı ve hasta bireylere ait örnek görüntüler Şekil 2’de gösterilmiştir.



Şekil 2. a)glokom görüntüsü b)normal görüntü


Tablo 1 Origa-light veri kümesi dağılımı

Veri	Glokom görüntü	Normal Görüntü	Toplam
Eğitim veri kümesi	325	325	650
Doğrulama veri kümesi	76	76	152
Test veri kümesi	99	99	198

Çalışmada kullanılan dijital fundus görüntüleri %65 eğitim, %15 doğrulama, %20 test veri kümesi için ayrılmıştır. Tablo 1’de veri kümesinde bulunan normal ve glokom sayıları detaylı gösterilmektedir.

3.2. ESA Mimarileri

Günümüzde, ESA, segmentasyon, algılama, örüntü tanıma ve görüntü verileri gibi farklı birçok veri için kullanılmıştır. Son birkaç on yılda tıbbi görüntü analizinde yaygın olarak araştırmacılar tarafından kullanılmaktadır. Şekil 3, giriş katmanı, evrişim katmanı, havuzlama katmanı gibi ana öğeleri ve elde edilen sonucu temsil eden bilgilerin bir dizi yoğun katmana girdiği bir düzleştirme işlemi ile bir ESA’nın genel mimarisini grafiksel olarak göstermektedir. ESA, AlexNet, ResNet, GoogleNet ve diğerleri gibi farklı katman düzenlemelerine sahip birkaç mimariye sahiptir.




Şekil 3. ESA mimarisinin gösterimi

3.2.1. AlexNet

AlexNet, Alex Krizhevsky vd. tarafından önerilmiştir (Krizhevsky vd., 2012). Bu model 2012’de, ImageNet Büyük Ölçekli Görsel Tanıma’nın (ILSVRC) nesne algılama ve görüntü sınıflandırması için algoritmaları büyük ölçekte değerlendirdiği en zorlu mücadeleyi kazanmıştır. 60 milyon parametreye ve 650.000 nörona sahip olan AlexNet, beş konvolüsyonel katman ve üç tam bağlı katmandan oluşmaktadır. İlk iki evrişim katmanını normalleştirme ve bir maksimum havuzlama katmanı takip eder, üçüncü ve dördüncü doğrudan bağlanır ve beşinci evrişim katmanını bir maksimum havuzlama katmanı izler. Giriş görüntü boyutunu 227x227x3 pixel olarak almaktadır.

3.2.2. VGG16

Simonyan ve Zisserman tarafından önerilen VGG16 beş evrişimli ve havuzlama katmanı bloğundan oluşur, yani ilk iki bloğun her biri iki evrişimli katmana, ardından bir maksimum havuzlama katmanına sahipken, sonraki üç bloğun her biri üç evrişimli katmana ve ardından bir maksimum havuzlama katmanına sahiptir (Qassim vd., 2018). Şekil 4’te VGG16 mimarisinin görünümü verilmiştir. Giriş görüntü boyutunu 224x224x3 pixel olarak almaktadır.



Şekil 4. VGG16 mimarisi

3.2.3. ResNet18

İyi yakınsama davranışları ve zorlayıcı doğruluk gösteren derin mimarilere dayanan ResNet modelleri, He ve diğerleri tarafından geliştirilmiştir. Bu sayede, 2015 yılında ILSVRC ve Bağlamdaki Ortak Nesnelere (COCO) sınıflandırma yarışmasında birinci olmuşlardır. ResNet, birkaç yığılmış artık birim tarafından inşa edilmiştir ve birçok farklı sayıda katmanla geliştirilmiştir: 18, 34, 50, 101, 152 ve 1202. Ancak, farklı mimarilere bağlı olarak işlem sayısı değişebilir (Gómez-Ríos vd., 2019). Yukarıdakilerin tümü için artık birimler evrişimli, havuzlama ve katmanlardan oluşur. ResNet, VGG ağına benzemektedir ancak ResNet, VGG'den yaklaşık sekiz kat daha derindir. ResNet 18, derinlik ve performans arasında iyi bir dengelemeyi temsil eder ve bu ağ, beş evrişimli katmandan, bir ortalama havuzlamadan ve softmax ile tam bağlantılı bir katmandan oluşur. Giriş görüntü boyutunu 224x224x3 pixel olarak almaktadır.

3.2.4. GoogleNet

GoogleNet, Szegedy ve diğerlerinin çalışmasında sunulmuştur (Szegedy vd., 2015) ve 2014'te ILSVRC'nin galibi olmuştur. GoogleNet yedi milyon parametreye sahiptir ve dokuz başlangıç modülü, dört evrişimli katman, dört maksimum havuzlama katmanı, üç ortalama havuzlama katmanı, beş tam bağlı katman ve ağdaki ana yardımcı sınıflandırıcılar için üç softmax katmanı içermektedir. Ek olarak, tamamen bağlı katmanda bırakma düzenlemesini kullanır ve tüm evrişimli katmanlarda ReLU aktivasyonunu uygular. Bununla birlikte, bu ağ, toplam 22 katmanla çok daha derin ve geniştir, ancak AlexNet'e kıyasla çok daha düşük sayıda ağ parametresine sahiptir. Bu mimari görüntü boyutunu 224x224x3 pixel olarak almaktadır.

3.2.5. SqueezeNet

Bu mimari Landola ve diğerleri tarafından 2016 yılında önerilmiştir (Zavan vd., 2019). SqueezeNet, AlexNet'in 50 kat daha az parametreye ve 0,5 MB depolama alanına sahip sıkıştırılmış bir versiyonudur. SqueezeNet'te, AlexNet'teki kayan nokta işlemlerini azaltmaktan sorumlu olan sekiz ateş modülü bulunmaktadır.

3.3. Performans Değerlendirme Ölçütleri

Fundus görüntülerinden glokom tespiti için kullanılan modellerin performansını değerlendirmek için karmaşıklık matrisi kullanılmıştır. Tablo 2'de gösterilen karmaşıklık matrisi gerçek sınıf ve sınıflandırıcının tahmin ettiği sınıf olmak üzere iki boyuta sahiptir (Ahmad vd., 2022). Karmaşıklık matrisi sayesinde birçok sınıflandırma modelinin performansı değerlendirilebilmektedir.

Tablo 2 Karmaşıklık Matrisi

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Karmaşıklık matrisindeki terimler ve anlamları aşağıdaki gibidir:

- Doğru Pozitif (DP): Pozitif sınıfa ait olan ve sınıflandırıcı tarafından doğru şekilde sınıflandırılan verileri temsil etmektedir.
- Doğru Negatif (DN): Sınıflandırıcı tarafından doğru olarak sınıflandırılan negatif sınıfa ait verileri temsil etmektedir.
- Yanlış Pozitif (YP): Negatif sınıfa ait ifadeler yanlış sınıflandırılır ve pozitif sınıf olarak tanımlanır.
- Yanlış Negatif (YN): Gerçekte pozitif sınıfa ait olan bir örnek negatif sınıf olarak tanımlanır.

Doğruluk: Modelin performansının değerlendirilmesi için kullanılmaktadır. Modeldeki doğru tahminlerin sayısının tüm veri kümesine bölünmesiyle hesaplanmaktadır. Doğruluk değeri denklem 1'deki gibi hesaplanmaktadır.

$$\text{Doğruluk} = \frac{(DP+DN)}{(DP+DN+YP+YN)} \quad (1)$$

Duyarlılık: Pozitif örneklerin doğruluğuna karşılık gelir ve pozitif sınıfların kaç örneğinin doğru şekilde etiketlendiğini ifade etmektedir. Duyarlılık değeri denklem 2 ile hesaplanmaktadır.

$$\text{Duyarlılık} = \frac{DP}{(DP+YN)} \quad (2)$$

Özgüllük: Modelin, örneklerinin negatif sınıf etiketini tahmin etmedeki olasılığını ifade etmektedir. Denklem 3 ile hesaplanmaktadır.

$$\text{Özgüllük} = \frac{DN}{(DN+YP)} \quad (3)$$

F1-Ölçütü: Pozitif sınıfın analizine odaklanan bir metriktir. Bu metriğin değerinin yüksek olması, modelin pozitif sınıfta daha iyi performans gösterdiğini gösterir.

$$F1 - \text{Ölçütü} = \frac{2*DP}{(2*DP+YP+YN)} \quad (4)$$

4. Araştırma Sonuçları ve Tartışma

Bu çalışmada, fundus görüntülerinden glokom tespiti için ESA modelleri kullanılarak bir değerlendirme yapılmıştır. Bu çalışmanın amacı kullanılan ESA modellerinin performanslarını doğruluk, duyarlılık, özgüllük ve f1 ölçütü bakımından karşılaştırmaktır. Elde edilen sonuçlar Tablo 3'te verilmiştir.

Tablo 3 incelendiğinde, test veri kümesi için doğruluk değeri bakımından en iyi değer %97.98 ile GoogleNet tarafından elde edilirken en kötü değer %93.43 ile SqueezeNet tarafından elde edilmiştir. Duyarlılık bakımından en iyi değeri %97.96 ile


VGG16 vermiştir. En kötü değeri ise %91.35 ile SqueezeNet vermiştir. Özgüllük değeri incelendiğinde, %98.97 değeri ile GoogleNet en iyi performansı gösterirken, %92.63 değeri ile

AlexNet en kötü performansı göstermiştir. F1-ölçütü bakımından ise en iyi değer %98 ile yine GoogleNet ile elde edilmiştir. En kötü değeri ise SqueezeNet vermiştir.

Tablo 3. AlexNet, Rensnet-18, VGG16, SqueezeNet ve GoogleNet Performans Değerlendirme Ölçütleri


Model	Duyarlılık		Özgüllük		Doğruluk		F1-Ölçütü	
	Doğrulama	Test	Doğrulama	Test	Doğrulama	Test	Doğrulama	Test
AlexNet	91.57	94.74	94.20	92.63	92.76	93.68	93.25	93.75
ResNet-18	96.15	93.27	94.74	97.87	95.45	95.45	95.54	95.57
VGG16	94.87	97.96	98.65	97.00	96.71	96.47	96.73	97.46
SqueezeNet	91.14	91.35	93.15	95.74	92.11	93.43	92.31	93.60
GoogleNet	98.70	97.03	96.05	98.97	97.39	97.98	97.44	98.00

Derin öğrenme mimarileri ile test veri kümesi için elde edilen karmaşıklık matrisleri Şekil 5'te gösterilmiştir.



Şekil 5. Mimarilerin test veri kümesi karmaşıklık matrisi

Derin öğrenme mimarileri ile doğrulama veri kümesi için elde edilen karmaşıklık matrisleri Şekil 6'da gösterilmiştir.



Şekil 6. Mimarilerin doğrulama veri kümesi karmaşıklık matrisi

5. Sonuçlar

Bu çalışmada glokom hastalığının daha hızlı ve otomatik tespiti için ESA tabanlı derin öğrenme mimarileri kullanılmıştır. Çalışmada AlexNet, ResNet-18, VGG16, GoogleNet ve SqueezeNet mimarileri kullanılmıştır. Derin öğrenme mimarilerinin doğruluk, duyarlılık, özgüllük ve f1-ölçütü değerleri yönünden karşılaştırması yapılmıştır. Değerlendirme sonucunda doğrulama veri kümesinde duyarlılık için en iyi sonucun %98.70 ile GoogleNet, özgüllük için %98.65 ile VGG16, doğruluk için %97,39 ile GoogleNet ve f1-ölçütü için ise %97.44 ile GoogleNet olduğu görülmüştür. Deneysel sonuçlar değerlendirildiğinde, test veri kümesinde duyarlılık için en iyi sonucun %97.96 ile VGG16, özgüllük, doğruluk ve f-skör için en iyi sonucun sırasıyla %98.97, %97.98 ve %98 ile GoogleNet olduğu tespit edilmiştir.

Kaynakça

- Ahmad, S., Ansari, S. U., Haider, U., Javed, K., Rahman, J. U., & Anwar, S. (2022). Confusion matrix-based modularity induction into pretrained CNN. *Multimedia Tools and Applications*, 1-27.
- Alghamdi, H. S., Tang, H. L., Waheeb, S. A., & Peto, T. (2016, October). Automatic optic disc abnormality detection in fundus images: A deep learning approach. In *Ophthalmic Medical Image Analysis International Workshop (Vol. 3, No. 2016)*. University of Iowa.
- Almazroa, A., Alodhayb, S., Burman, R., Sun, W., Raahemifar, K., & Lakshminarayanan, V. (2015, October). Optic cup segmentation based on extracting blood vessel kinks and cup thresholding using Type-II fuzzy approach. In *2015 2nd International Conference on Opto-Electronics and Applied Optics (IEM OPTRONIX)* (pp. 1-3). IEEE.
- Alsulami, F., Alseleahbi, H., Alsaedi, R., Almaghdawi, R., Alafif, T., Ikram, M., ... & WeTeach, W. HiGANCNN: A Hybrid Generative Adversarial Network and Convolutional Neural Network for Glaucoma Detection.
- Carrillo, J., Bautista, L., Villamizar, J., Rueda, J., & Sanchez, M. (2019, April). Glaucoma detection using fundus images of the eye. In *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)* (pp. 1-4). IEEE.
- Chen, X., Xu, Y., Wong, D. W. K., Wong, T. Y., & Liu, J. (2015, August). Glaucoma detection based on deep convolutional neural network. In *2015 37th annual international conference*

- of the IEEE engineering in medicine and biology society (EMBC) (pp. 715-718). IEEE.
- Cho, H., Hwang, Y. H., Chung, J. K., Lee, K. B., Park, J. S., Kim, H. G., & Jeong, J. H. (2021). Deep learning ensemble method for classifying glaucoma stages using fundus photographs and convolutional neural networks. *Current eye research*, 46(10), 1516-1524.
- Clifton, L., Clifton, D. A., Pimentel, M. A., Watkinson, P. J., & Tarassenko, L. (2012). Gaussian processes for personalized e-health monitoring with wearable sensors. *IEEE Transactions on Biomedical Engineering*, 60(1), 193-197.
- Dey, A., & Bandyopadhyay, S. K. (2016). Automated glaucoma detection using support vector machine classification method. *British Journal of Medicine and Medical Research*, 11(12), 1.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *nature*, 542(7639), 115-118.
- Gheisari, S., Shariflou, S., Phu, J., Kennedy, P. J., Agar, A., Kalloniatis, M., & Golzan, S. M. (2021). A combined convolutional and recurrent neural network for enhanced glaucoma detection. *Scientific reports*, 11(1), 1-11.
- Gómez-Ríos, A., Tabik, S., Luengo, J., Shihavuddin, A. S. M., Krawczyk, B., & Herrera, F. (2019). Towards highly accurate coral texture images classification using deep convolutional neural networks and data augmentation. *Expert Systems with Applications*, 118, 315-328.
- Hatanaka, Y., Noudo, A., Muramatsu, C., Sawada, A., Hara, T., Yamamoto, T., & Fujita, H. (2010, March). Vertical cup-to-disc ratio measurement for diagnosis of glaucoma on fundus images. In *Medical Imaging 2010: Computer-Aided Diagnosis* (Vol. 7624, pp. 945-952). SPIE.
- Hemelings, R., Elen, B., Barbosa-Breda, J., Blaschko, M. B., De Boever, P., & Stalmans, I. (2021). Deep learning on fundus images detects glaucoma beyond the optic disc. *Scientific Reports*, 11(1), 1-12.
- Krizhevsky, A.; Sutskever, I.; Hinton, G.E. Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems*; Curran Associates, Inc.: New York, NY, USA, 2012;pp. 1097–1105.
- Nayak, D. R., Das, D., Majhi, B., Bhandary, S. V., & Acharya, U. R. (2021). ECNet: An evolutionary convolutional network for automated glaucoma detection using fundus images. *Biomedical Signal Processing and Control*, 67, 102559.
- Orlando, J. I., Prokofyeva, E., del Fresno, M., & Blaschko, M. B. (2017, January). Convolutional neural network transfer for automated glaucoma identification. In *12th international symposium on medical information processing and analysis* (Vol. 10160, pp. 241-250). SPIE.
- Özbay, E. (2022). An active deep learning method for diabetic retinopathy detection in segmented fundus images using artificial bee colony algorithm. *Artificial Intelligence Review*, 1-28.
- Qassim H, Verma A, Feinzimer D. Compressed residual-VGG16 CNN model for big data places image recognition. 8th Annual Computing and Communication Workshop and Conference. Las Vegas: IEEE;2018. p. 169-175
- Sevastopolsky, A. (2017). Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network. *Pattern Recognition and Image Analysis*, 27(3), 618-624.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Tham, Y. C., Li, X., Wong, T. Y., Quigley, H. A., Aung, T., & Cheng, C. Y. (2014). Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis. *Ophthalmology*, 121(11), 2081-2090.
- Uddin, M., Tammimies, K., Pellicchia, G., Alipanahi, B., Hu, P., Wang, Z., ... & Scherer, S. W. (2014). Brain-expressed exons under purifying selection are enriched for de novo mutations in autism spectrum disorder. *Nature genetics*, 46(7), 742-747.
- Weinreb, R. N., Aung, T., & Medeiros, F. A. (2014). The pathophysiology and treatment of glaucoma: a review. *Jama*, 311(18), 1901-1911.
- Zavan, F. H. D. B., Bellon, O. R., Silva, L., & Medioni, G. G. (2019). Benchmarking parts based face processing in-the-wild for gender recognition and head pose estimation. *Pattern Recognition Letters*, 123, 104-110