

Derin Öğrenme Algoritmaları ile OCT Görüntülerinden Retina Hastalıklarının Sınıflandırılması

Elif Işılay ÜNLÜ^{1*}, Ahmet ÇINAR²

¹ Bilgisayar Mühendisliği, Fırat Üniversitesi, TÜRKİYE

² Bilgisayar Mühendisliği, Fırat Üniversitesi, TÜRKİYE

*(eiunlu@firat.edu.tr)

Özet – Son yıllarda retina bozuklukları ciddi bir sağlık sorunu haline gelmiştir. Retina bozuklukları yavaş ve belirgin belirtiler olmadan gelişir. Her yıl dünya çapında milyonlarca kişiye retina hastalığı teşhisi konmaktadır. Optik Koherens Tomografi (OCT), hastalıklı retina katmanlarındaki nicel ayrımı analiz edebilen ve belirleyebilen yüksek çözünürlüklü bir tanı teknolojisidir. OCT - Işık dalgalarını kullanan optik koherens tomografi, retinanın enine kesit fotoğraflarını çeken invazif olmayan bir görüntüleme prosedürüdür. Bu çalışmada OCT taramalarını kullanarak retina anormalliklerini tespit etmek ve sınıflandırmak için bir çok katmanlı konvolüsyonel sinir ağı (CNN) olan EfficientNet kullanılmıştır. Önerilen yöntem, 84.484 görüntü içeren açık kaynaklı retinal OCT veri seti üzerinde uygulanmış ve %96, 8 test doğruluğu elde edilmiştir.

Anahtar Kelimeler –Konvolüsyonel Sinir Ağı(CNN), Biyomedikal Görüntü Sınıflandırması, Retina Hastalıkları, Retina OCT Görüntüleri, EfficientNet

1. GİRİŞ

Optik Koherens Tomografi (OCT), son on yılda en hızlı gelişen tıbbi görüntüleme modalitelerinden biridir. Biyolojik dokuların kan akışı, polarizasyon durumu, yapı verileri, elastik parametreler ve moleküler içerik gibi farklı yönlerini yakalayabilir[1]. Optik Koherens Tomografi (OCT), yüksek oranda saçılan dokuların invazif olmayan gerçek zamanlı, yüksek çözünürlüklü görüntülemesini sunan, gelişmekte olan bir biyomedikal görüntüleme teknolojisidir. Bu görüntüleme yöntemi, kullanım kolaylığı, düşük maliyeti, hasta konforu ve yüksek çözünürlüğü nedeniyle popüler hale gelmiştir [2]. Oftalmolojide, ön gözün ve retinanın yapısı üzerinde tanısal görüntüleme yapmak için yaygın olarak kullanılmaktadır. Bazı retina hastalıklarında OCT uygulamasını değerlendirmek için klinik çalışmalar yürütülmektedir. OCT, çeşitli hastalık türlerinin erken teşhisi için araçlar sağlayabilir, çünkü morfolojik değişiklikler sıklıkla bu hastalıkların fiziksel semptomlarından önce meydana gelir.

OCT, Koroidal NeoVaskülarizasyon (CNV) [3], Diyabetik Maküler Ödem (DME) [4], Drusen [5] gibi göz anormalliklerini teşhis ve tedavi etmek için kullanılmaktadır. Retina hastalıklarının teşhisi ve retina anormalliklerini tespit etmek amacı ile OCT görüntülerinin manuel olarak analizi eğitilmiş tıp uzmanları gerektirir. Bu manuel işlem karmaşıktır, zaman alıcıdır ve hataya açıktır. Bu nedenle, tıp uzmanlarına teşhislerinde yardımcı olmak için otomatik bir tespit ve sınıflandırma gereklidir.

Son yıllarda, derin konvolüsyonel sinir ağları, retina hastalıklarının tespiti ve teşhisi için etkin bir şekilde uygulanmaktadır ve yüksek performans elde etmektedir. Girard ve arkadaşları, fundus görüntülerinden derin öğrenme ve grafik yayılım yöntemlerini birleştirerek arter/ven sınıflandırması için yeni bir yöntem önerdi [6]. Yöntemleri, DRIVE veritabanında %93,3'lük bir doğruluk elde etti.

Sunija ve ark., hastaları Normal, DMD ve DME olarak doğru bir şekilde teşhis etmek ve sınıflandırmak için derin bir CNN mimarisi sundu[7]. Önerilen modelin sınıflandırma

doğruluğu %95,7'dir . Feng Li ve ark., retina OCT görüntülerini sınıflandırmak için artık sinir ağlarına dayanan dört sınıflandırma modeli örneğinden oluşan bir sınıflandırma modeli(ResNet50) önerdi [8]. Önerdikleri yaklaşım %97 sınıflandırma doğruluğuna ulaştı.

Subramanian ve ark., Retina OCT Görüntüleri veri setinde VGG16 ağı ile AMD, CNV, DRUSEN, DMR, DR, MH, CSR ve Normal Eye olarak sınıflandırdılar [9]. %97 civarında doğruluk elde ettiler. Najeeb ve ark., önerdikleri model ile retina görüntülerini NV, DME, DRUSEN ve NORMAL sınıflarına %95.66 doğrulukla sınıflandırdılar [10]. Kim ve ark., hastaların OCT görüntülerini Koroidal neovaskülarizasyon (CNV), Diyabetik maküler ödem (DME), Drusen ve Normal gibi dört sınıfa kategorize eden derin öğrenme modelleri önerdi. VGG16, VGG19, ResNet50, ResNet152, DenseNet121 ve InceptionV3 gibi çeşitli CNN'ler, ikili sınıflandırıcıları geliştirmek için özellik çıkarıcılar olarak uyarlanmıştır. Classifier-CNV için VGG16, Classifier-DME için VGG16, Classifier-Drusen için VGG19 ve Classifier-Normal için InceptionV3 model, 0.9870 doğruluk, 0.987 duyarlılık ve 0.996 özgüllük ile en iyi performansı göstermiştir [11].


II. MATERYAL VE YÖNTEM

A. Veri Seti

Bu çalışmada halka açık bir OCT görüntü veri seti kullanılmıştır [12]. Veri seti 83484 eğitim görüntüsü ve 1000 test görüntüsünden oluşmaktadır. Tablo 1'de gösterildiği gibi dört sınıf içerir; CNV sınıfında 37205, DME sınıfında 11348, Drusen sınıfında 8616 ve Normal sınıfta 26315 görüntü bulunmaktadır. Test veri setinde her sınıf 250 görüntüye sahiptir. Veri setindeki dört sınıfa ait görüntü örnekleri Şekil 1'de verilmiştir.

Tablo 1. Veri Setindeki Görüntülerin Dağılımı

Sınıf	Eğitim	Test
CNV	37,205	250
DME	11,348	250
DRUSEN	8616	250
NORMAL	26,315	250




Şekil 1. Veri Seti[12]


B. EfficientNet Mimarisi

EfficientNet, diğer konvolüsyonel sinir ağlarına kıyasla daha az veriyle daha fazla doğruluk elde etme imkânı sağlayan bir CNN mimarisidir. EfficientNet mimarisi, sabit bir bileşik katsayı kullanarak ağı derinlik, genişlik ve görüntü çözünürlüğü gibi farklı boyutlarını aynı anda eşit bir şekilde ölçeklendirme ilkesine dayanmaktadır [13]. Aslında, bu bileşik ölçeklendirme fikri mevcut MobileNet ve ResNet mimarilerinde de çalışır. Saniyedeki kayan nokta işlemleri (FLOPS) temelinde ölçülen doğruluğu ve verimliliği optimize eder. Bu geliştirilmiş mimari, mobil ters çevrilmiş darboğaz konvolüsyonunu (MBConv) kullanır. EfficientNet, diğer modern modellerin aksine, modeli küçültürken derinliği, genişliği ve çözünürlüğü eşit şekilde ölçeklendirerek daha verimli sonuçlar elde eder. EfficientNet ailesi EfficientNet-B0'dan EfficientNet-B7'ye 8 adet modelden oluşur. Sayı büyüdükçe hesaplanan parametre sayısı ve doğruluk artar. EfficientNet-B0 modelinin temel ağ yapısının blok gösterimi Şekil 2'de verilmiştir.

Derin öğrenme modellerini sıfırdan eğitmek, yoğun hesaplama ve büyük miktarda etiketli veri gerektirdiği için, bu problemlerin üstesinden gelmek amacı ile transfer öğrenme stratejisi önerilmiştir. Transfer öğrenme yeni bir modeli sıfırdan eğitmek yerine, son eğitim sürecinden mevcut olan bilgileri kullandığından, hesaplama süresinden tasarruf sağlar [14]. Önerilen yöntemde verilerin eğitimi aşamasında transfer öğrenme ile EfficientNet-B5 modeli kullanılmıştır. Önerilen yöntemin işleyişi Şekil 3'deki gibidir.




Şekil 2. EfficientNet B0 temel ağ yapısı blok gösterimi



Şekil 3.Önerilen Yöntem

III. BULGULAR


Eğitim veri setindeki 83434 görüntüye veri artırımı uygulandıktan sonra önceden eğitilmiş EfficientNet ağına beslenmiştir. Eğitim sırasında modelin doğrulanması için bu görüntülerin %20'lik rastgele bir seti bekleme olarak tutuldu. Ağ, birinci dereceden gradyan tabanlı stokastik optimizasyon prosedürü olan 'Adam' optimizer [15] kullanılarak eğitildi. Başlangıç öğrenme oranı 0.0001 olarak seçilmiş ve her 10 adım sonra öğrenme oranı 10 kat azaltılmıştır. Eğitim görüntülerinin sayısı yüksek olduğundan, model 10 adımda yakınsamıştır. Önerilen yöntem kullanılarak eğitim ve test verileri üzerinde elde edilen doğruluk değerleri Şekil 4'te verilmiştir. CNV, DME, DRUSEN, NORMAL sınıfları için test setindeki performans metrikleri Tablo 2'de ve karmaşıklık matrisi Şekil 5'te verilmiştir. Karışıklık matrisinin köşegen elemanları doğru sınıflandırmaları temsil etmektedir. Geri kalanlar ise yanlış sınıflandırmalardır. X eksenini tahmin edilen sınıfları gösterirken Y eksenini gerçek sınıfları gösterir. Doğruluk, kesinlik, hatırlama ve F1 puanı gibi bireysel sınıf ölçümleri, karmaşıklık matrisi kullanılarak belirlenir.



Şekil 4. Doğruluk ve kayıp değerleri

Tablo 2. Performans metrikleri

Sınıf	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
CNV	%98.2	0.99	0.94	0.97
DME	%97.7	0.92	0.99	0.95
DRUSEN	%98.9	0.92	0.99	0.95
NORMAL	%98.8	0.98	0.97	0.98



Şekil 5. Karmaşıklık matrisi

IV. SONUÇLAR VE TARTIŞMA

Optik Koherens Tomografi (OCT), gözün retina tabakasının enine kesit görüntülerini çeken ve oftalmologların retinanın tabakalarına dayalı olarak teşhis koymasına izin veren noninvaziv bir testtir. Bu nedenle, retina hastalıklarının ve retina anormalliklerinin tespiti ve miktar tayini için önemli bir yöntemdir. OCT her hasta için birkaç görüntü sağladığından, oftalmologların görüntüleri analiz etmesi zaman alan bir iştir. Derin öğrenme alanındaki teknolojilerdeki son gelişmeler, istenen sonuçlara ulaşmayı daha kolay ve daha etkili hale getirmiştir. Bu makale, hastaların OCT görüntülerini Koroidal neovaskülarizasyon (CNV), Diyabetik maküler ödem (DME), Drusen ve Normal gibi dört kategoride kategorize eden derin öğrenme modeli önermektedir. EfficientNet kullanılarak önerilen yöntemin yüksek bir tanıma oranına sahip olduğu ve %96.8 civarında bir ortalama doğruluk sağladığı gösterilmiştir. Sonuçlar, ilgili hastalık sınıfları için gerçek etiketlere karşı öngörülen etiketler üzerinde bir karışıklık matrisi oluşturularak daha da detaylandırılmıştır. Karmaşıklık matrisindeki en kötü sınıflandırma durumu, o sınıfa ait 250 görüntüden 11'ini DME ve 4'ünü DRUSEN olarak yanlış sınıflandırılan ve düşük hatırlama skoruna sahip olan CNV'dir. Bununla birlikte, diğer sınıflardan elde edilen sonuçlar oldukça ikna edicidir. Önerilen yöntemimiz, eğitimli bir tıp

uzmanınıninkiyle karşılaştırılabilir olan %96,88 doğrulukla retina hastalıklarını tespit edebilmektedir. Bu nedenle, önerilen metodoloji, tıp uzmanlarına teşhis tahminleri ve sınıflandırmalarında yardımcı olmak için destekleyici bir sistem olarak kullanılabilir. Ve böylece teşhis ve tedavi sürecinde kaynak ve zaman tasarrufu sağlanır. Gelecekteki çalışmalarda, sınıflandırma doğruluğunu iyileştirmek için yeni derin öğrenme mimarilerinin denenmesi ve handcrafted özellik çıkarma algoritmalarının uygulanması planlanmaktadır.

KAYNAKLAR

- [1] D. Huang, E. Swanson, C. Lin, J. Schuman, W. Stinson, W. Chang, M. Hee, T. Flotte, K. Gregory, C. Puliafito, and J. Fujimoto: Optical coherence tomography. *Science*, 254, 1178–1181 (1991) DOI: 10.1126/science.1957169
- [2] A. Lang, A. Carass, M. Hauser, E. S. Sotirchos, P. A. Calabresi, H. S. Ying, and J. L. Prince: Retinal layer segmentation of macular OCT images using boundary classification. *Biomed Opt Express*, 4, 1133–1152 (2013) DOI: 10.1364/BOE.4.001133
- [3] L. Jian, Y. Panpan, and X. Wen, "Current choroidal neovascularization treatment," *Ophthalmologica*, vol. 230, no. 2, pp. 55–61, 2013.
- [4] C. Wilkinson, F. L. Ferris III, R. E. Klein, P. P. Lee, C. D. Agardh, M. Davis, D. Dills, A. Kampik, R. Pararajasegaram, J. T. Verdager et al., "Proposed international clinical diabetic retinopathy and diabetic macular edema disease severity scales," *Ophthalmology*, vol. 110, no. 9, pp. 1677–1682, 2003.
- [5] R. L. Novack and R. Y. Foos, "Drusen of the optic disk in retinitis pigmentosa," *American journal of ophthalmology*, vol. 103, no. 1, pp. 44–47, 1987.
- [6] Girard and Cheriet, "Artery/vein classification in fundus images using CNN and likelihood score propagation," 2017 IEEE Global Conference on Signal and Information Processing (GlobalSIP), pp. 720–724.
- [7] Sunija A P, Saikat Kar, Gayathri S, Varun P. Gopi, P. Palanisamy, "A Lightweight CNN for Retinal Disease Classification from Optical Coherence Tomography Images", Volume 200, 2021, 105877, ISSN 0169- 2607. doi : <https://doi.org/10.1016/j.cmpb.2020.105877>
- [8] Feng Li, Hua Chen, Zheng Liu, Xue-dian Zhang, Min-shan Jiang, Zhi- zheng Wu, and Kai-qian Zhou, "Deep learning-based automated detection of retinal diseases using optical coherence tomography images," *Biomed. Opt. Express* 10, 6204–6226 (2019). doi : <https://doi.org/10.1364/BOE.10.006204>
- [9] M. Subramanian, K. Shanmugavadeivel, O. S. Naren, K. Premkumar and K. Rankish, "Classification of Retinal OCT Images Using Deep Learning," 2022 International Conference on Computer Communication and Informatics (ICCCI), 2022, pp. 1–7, doi: 10.1109/ICCCI54379.2022.9740985.

- [10] S. Najeeb, N. Sharmile, M. S. Khan, I. Sahin, M. T. Islam and M. I. Hassan Bhuiyan, "Classification of Retinal Diseases from OCT scans using Convolutional Neural Networks," 2018 10th International Conference on Electrical and Computer Engineering (ICECE), 2018, pp. 465-468, doi: 10.1109/ICECE.2018.8636699.
- [11] J. Kim and L. Tran, "Retinal Disease Classification from OCT Images Using Deep Learning Algorithms," 2021 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB), 2021, pp. 1-6, doi: 10.1109/CIBCB49929.2021.9562919.
- [12] Kermany, Daniel; Zhang, Kang; Goldbaum, Michael (2018), "Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification, Mendeley Data, v2
- [13] Tan, Mingxing and Quoc V. Le. "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks." ArXiv abs/1905.11946 (2019): n. pag
- [14] Torrey, L. & Shavlik, J.. (2009). Transfer learning. Handbook of Research on Machine Learning Applications. 10.4018/978-1-60566-766-9.ch011.
- [15] Kingma, Diederik and Ba, Jimmy, "Adam: A Method for Stochastic Optimization," International Conference on Learning Representations, 2014.