

Patolojik Miyopi hastalığının tanısında VGG16 ve Resnet50 mimarilerinden esinlenerek oluşturulan yeni bir sinir ağı modeli

Fatma Akalın^{1*}

¹Bilişim Sistemleri Mühendisliği, / Bilgisayar ve Bilişim Bilimleri Fakültesi, Sakarya Üniversitesi, Sakarya, Türkiye

*(fatmaakalin@sakarya.edu.tr)

Özet – Miyop uzağı görme yetisinin azalması sonucunda oluşan bir göz rahatsızlığıdır. Tüm seviyelerindeki prevalansı son 30 yılda hızlı bir artış göstermiştir. Aynı zamanda 2050 yılına kadar tüm dünya nüfusunun %49.8’ini oluşturması beklenmektedir. Küresel nüfusun büyük bir kısmını oluşturan miyop hastalığına ilişkin vakalar, genellikle aşırı eksenel göz büyümesi ile ilişkilendirilmektedir. Buna ek olarak keratoconus ve nükleer katarakt miyopa neden olan nadir diğer rahatsızlıklardır. Miyopa neden olan olası bu durumların yanı sıra patolojik miyopi isimli özel bir miyop kategorisi de mevcuttur. Görme yetisinde hızlı değişiklikler oluşturan patolojik miyopi, körlüğe neden olabilme ihtimaline sahiptir. Yaşam kalitesini ve üretkenliği olumsuz etkileyen patolojik miyopinin tespitinde yüksek maliyet gerekirken doğru tanı için dünyada yeterli uzman yoktur. İvedi teşhis gerektiren patolojik miyopi hastalığında yapay zekanın entegrasyonu ile karar destek sistemi inşa etmek gereklidir. Böylece kişisel hassasiyetlere takılmaksızın standart bir doğruluk oranı ile insanlığın faydasına olacak önemli bir görev gerçekleştirilecektir. Bu hususta sunulan çalışmada fundus görüntüleri vasıtasıyla CNN tabanlı bir sistem önerilmiştir. VGG16 ve Resnet50 mimarilerinden esinlenerek oluşturulan bu sinir ağı modeli ile gerçekleştirilen eğitim sonucunda %100 başarı oranı ve 1.0119e-05 kayıp değeri elde edilmiştir. VGG 16 ve Resnet 50 transfer öğrenme mimarilerine kıyasla daha kararlı, istikrarlı ve başarılı sonuçlar üreten bu mimarinin tıp alanında verilmesi planlanan kritik kararlar için bir karar destek sistemi oluşturması hedeflenmektedir.

Anahtar Kelimeler – Patolojik Miyopi, transfer öğrenme, VGG 16, Resnet 50, önerilen sinir ağı mimarisi

I. GİRİŞ

Miyop, gözün uzağı görme yetisindeki zayıflama olarak nitelendirilen bir göz hastalığıdır. Bu hastalık ile uzak mesafedeki nesnelere ilişkin görüntülerin retinanın önünde odaklanması sonucunda bulanık bir görüş oluşmaktadır. Dünya çapında görülen en yaygın göz rahatsızlığıdır. Miyop hastalığına ilişkin vakaların çoğu, aşırı eksenel göz büyümesi ile ilişkilendirilmektedir. Keratoconus ve nükleer katarakt miyopa neden olan nadir diğer sebeplerdir. Keratoconus, korneada oluşan bir incelme sonucunda korneada meydana gelen bir çıkıntı olarak nitelendirilir. Prevalansı düşüktür. Bununla birlikte nükleer

katarakt 50 yaş ve üzerindeki bireylerde görülen bir kusurdur[1]. Ek olarak özel bir miyop kategorisinde patolojik miyopi (PM) yer almaktadır[2].

Patolojik miyopi, yüksek miyopi ya da dejeneratif miyopi olarak bilinir. Görmede hızlı değişiklikler oluşturur ve gözlük reçetelerinin 4 ila 6 ayda bir değiştirilmesine neden olur[3]. Patolojik miyopinin küresel nüfusun %3’ünü oluşturduğu tahmin edilmektedir[2]. Aynı zamanda Amerika Birleşik Devletinde erişkinlerde görülen körlüğün yedinci sebebi olarak Patolojik miyopi gösterilmiştir. Bununla birlikte Avrupada’ki genel popülasyonda

yaklaşık %0.5 oranında bir prevelans değerine sahip olduğu belirtilmektedir[4].

Miyopun tüm seviyelerindeki prevelansı, son 30 yılda hızlı bir artışa sahiptir. Bu durum miyop hastalığının salgın olarak ifade edilmesine neden olmuştur[1]. Miyop hastalığının 2050 yılına kadar dünya nüfusunun %49.8'ini oluşturması beklenmektedir[2]. Ek olarak miyop kusuru ile birlikte görme yetisinde bir zayıflık oluştuğu için yaşam kalitesi ile üretkenlik olumsuz etkilenmektedir[3]. Bu hususta çok disiplinli çalışmalar vasıtasıyla bir çözüm noktası oluşturulması gereklidir.

Genel olarak oftalmoloji alanında yapay zeka kullanımı genişleyen bir sirkülasyona sahiptir. Buna rağmen miyop hastalığına özgü çalışmalar yeterli değildir. Fakat erken tanı, hastalığın ilerleme durumu, risk sınıflandırması ve müdahale zamanlaması için yapay zekanın miyop alanındaki entegrasyonu önemli bir potansiyel barındırmaktadır. Bu potansiyelin ortaya çıkarılması için veri kümeleri kullanılmaktadır. Aynı zamanda veri kümeleri, uygun yapay zeka modelini seçmek ya da yeni bir algoritma geliştirmek için gerekli klinik girdilerdir[5].

Yapay zeka modellerinin ivedi teşhis gerektiren durumlara evrilmesi kritik bir çıktı sunmaktadır. Özellikle miyop hastalığının özel bir kategorisi olan Patolojik miyopinin saptanması için kullanılan yöntemler manuel ve özeldir[6]. Aynı zamanda dünya çapında PM'nin tespiti için yeterli sayıda uzman yoktur ve bu durum yüksek bir maliyet gerektirmektedir[7]. Bu nedenle patolojik miyopide yapay zekanın entegrasyonu ile karar destek sistemi inşa etmek önemlidir. Çünkü patolojik miyopun tam bir göz muayenesi 30 ile 60 dakika sürmektedir. Bu süre boyunca hasta üzerinde gerçekleştirilen klinik uygulamalar, klinisyenlerin manuel taramaları ve çabaları ile sonuçlanmaktadır. Teknolojinin ilerlemesi ile retinal fundus görüntülerinden patolojik miyopiyi tespit etmek için bilgisayar destekli tanı (CAD) sistemleri geliştirilmektedir[4]. Böylece kişisel hassasiyetlere takılmaksızın standart bir doğruluk oranı ile kararlı, istikrarlı ve başarılı sonuçlar üretmek insanlığın faydasına olacak önemli bir

görevdir. Bu hususta CAD sistemlerinin geliştirilmesine ilişkin literatürdeki çalışmalar derlenmiştir ve aşağıda sunulmuştur.

Retinal fundus görüntülerindeki patolojik miyopinin tanımlanması için [4] çalışmada bag-of-feature and sparse learning temelli çerçeveler önerilmiştir. Bu doğrultuda Bag-of-feature modeli ve sınıflandırma modeli için öğrenme aşamasında yerel görüntü özellikleri sözlüğü öğrenilir ve sparse learning ile önemli görsel özellikler keşfedilir. Test aşamasında hedef fundus görüntülerinden yerel özellikler çıkarılır ve yerel görüntü özellikleri sözlüğü ile genel özellikler nicelenir. Sınıflandırma modeli ile patolojik miyopinin tanısı için 2258 görüntünün yer aldığı veri kümesinde ulaşılan sonuçların umut verici çıktılar ürettiği ifade edilmiştir. [8] çalışmada patolojik miyopide risk sınıflandırması yapmak amacıyla derin evrimsel sinir ağı yapısı sunulmuştur. Normal düşük riskli ve yüksek miyopi olarak 3 ayrı kategoride sınıflandırılan yaklaşımın bir uzmanın ulaştığı başarı oranından daha iyi sonuçlar ürettiği ifade edilmiştir. Hastanın retina görüntülerinden PM teşhisi koyma olasılığını tahmin etmek için [6] çalışmada PM ve PM olmayan görüntüleri sınıflandırmak ve optik disk segmentasyonu sağlamak için CNN tabanlı bir yaklaşım kullanılmıştır. Bu yaklaşımın umut verici sonuçlar sunduğu belirtilmiştir. [7] çalışmada normal ve PM hastalığına sahip gözlerin ayırt edilmesi için farklı parametreler ile ince ayarı yapılan Resnet-50 ve DenseNet mimarileri kullanılmıştır. Modeller arasında ulaşılan maksimum doğruluğun %97 olarak elde edildiği ifade edilmiştir. Yüksek miyopi teşhisini sağlamak için [9] çalışmada VGG-16, VGG-19, ResNet-50, ResNet-101, Inception-V3, and EfficientNet-B0 transfer öğrenme modelleri kullanılmıştır. Sinir ağı tabanlı bu yaklaşımların sunduğu deneysel sonuçlar incelenmiştir ve ince ayarı yapılan Resnet-101 ağının maksimum performans gösterdiği ifade edilmiştir.


Genel olarak literatürdeki çalışmalar yapay zeka sistemlerinin tıp alanındaki hedef problem ile entegrasyonunda yoğunlaşmaktadır. Özellikle kritik çıktılara sahip olan patolojik miyopi için yeni

yaklaşımların geliştirilmesi büyük bir önem taşımaktadır. Bu çalışmada patolojik miyopinin tanısında transfer öğrenme mimarilerinden ilham alan yeni bir sinir ağı modeli önerilmiştir. Önerilen yaklaşım 200 görüntü içeren veri kümesinde %100 başarı oranı ve $1.0119e-05$ kayıp değeri üretmiştir.

II. MATERYAL VE YÖNTEM

Yapay zeka dijital sağlık verileri arasındaki ilişkileri, benzerlikleri ya da farklılıkları tespit etme potansiyeline sahip geniş bir çerçevedir. Bu çerçeveden doğru yöntemi seçmek ve seçilen yöntemi doğru parametreler ile veri kümesinin eğitiminde kullanmak hedef problemin tespitinde güvenilir sonuçlar üretmektedir. Bu çalışmada


görme yetisinde hızlı değişiklikler oluşturarak 4-6 ayda bir gözlük reçetesinin değiştirilmesine neden olma ihtimaline sahip patolojik miyopi hastalığı için VGG16 ve Resnet50 transfer öğrenme mimarilerinden esinlenerek yeni bir sinir ağı modeli önerilmiştir. Bu modelin performansını değerlendirmek için <https://www.kaggle.com/> linkinde yer alan "ODIR5K_Classification" isimli veri kümesinden 100 adet Pathological Myopia (M) ve 100 adet Normal (N) kategorisine sahip görüntü verileri tedarik edilmiştir. Bu görüntüler vasıtasıyla patolojik miyopinin tanısı için inşa edilen teşhis algoritmasının genel hiyerarşisi Şekil 1'de verilmiştir.



Şekil 1. Patolojik miyopinin tespiti için önerilen mimarinin genel çerçevesi

Bu hiyerarşide ilk olarak patolojik miyopun tespitinde bir karar destek sistemi oluşturmak için tedarik edilen görüntü verilerindeki kritik noktaların, ayrıntıların, kontrastı düşük özelliklerin ve insan gözü ile algılanamayan ilişkilerin netleştirilmesi için görüntü ön işleme aşaması kapsamında CLAHE yöntemi uygulanmıştır.

CLAHE, dijital görüntülerdeki kontrastın iyileştirilmesi için HE ve AHE yöntemlerinin görüntüler üzerinde oluşturduğu başarısızlıklar nedeniyle geliştirilen bir yöntemdir. Kontrast iyileştirmenin sınırlandırıldığı CLAHE yönteminde görüntü parçalara ayrılır. Ardından her bir parçanın histogramı histogram eşitleme yöntemi ile geliştirilir. Son aşamada tüm parçalar birleştirilir. Böylece görüntünün yerel kontrastı iyileştirilir[10]. Bu doğrultuda normal ve patolojik miyop girdi görüntüleri üzerinde uygulanan CLAHE yöntemi ile elde edilen çıktı görüntüleri Şekil 2'de verilmiştir.



Şekil 2. CLAHE yaklaşımı kullanılarak iyileştirilen normal ve patolojik miyop kategorisine ait fundus görüntü verileri

CLAHE yönteminin uygulandığı ön işleme aşaması ile belirginleştirilen biyolojik yapılar, sınıflandırma sürecinde hastalığın kategorisinin tespiti için faydalı bir girdi bilgisi oluşturacaktır. Bu önemli girdi bilgileri vasıtasıyla başarılı bir eğitim gerçekleştirmek için derin sinir ağı modelleri kullanılacaktır. Derin sinir ağı modelleri arasındaki popüler bir derin öğrenme yapısı evrimsel sinir ağı (CNN)'dir. 3 temel katmandan oluşan bu yapıda katmanlar, evrişim katmanı, alt örnekleme katmanı ve tamamen bağlı katmandır. Evrişim katmanı ile filtre yapıları vasıtasıyla görüntü verileri üzerinde 2 boyutlu evrişim işlemi gerçekleştirilir. Alt örnekleme katmanında uzamsal

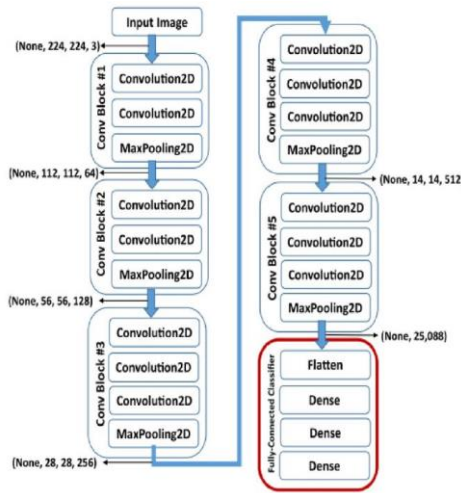
çözünürlük azaltılır ve ağırlık sağlam ve değişmez olması sağlanır. Tamamen bağlı katman ile nihai evrişim katmanını düzleştirilir ve sınıflandırma katmanına iletilir.

CNN yapıları, görüntü veri sayısının çok fazla olması durumunda mükemmel sonuçlar verir. Ancak böyle bir durumun gerçekleşmesi pratikte mümkün değildir. Bu nedenle önceden eğitilen ağırlıkların özel veri kümesine uyarlanması sonucunda geliştirilen modelin kullanılması sıfırdan yeni bir model geliştirmek ve eğitmek için harcanan zamanı azaltacaktır[11].

Bu çalışmada VGG16 ve Resnet-50 transfer öğrenme mimarilerinden esinlenerek geliştirilen yeni bir sinir ağı mimarisi önerilmiştir. VGG16, Resnet-50 ve önerilen mimarinin yapısı aşağıda açıklanmıştır.

A. VGG16 Sinir Ağı Mimarisi

16 evrişim katmanından oluşan VGG 16 ImageNet veri kümesi ile eğitilmiştir. 3x3'lük alıcı alanına ve 2x2 boyutunda maksimum havuzlama katmanına sahip birbirini takip eden 5 ayrı blok 3 tam bağlantılı katman ile bağlıdır[11]. VGG16 mimarisinin blok diyagramı Şekil 3'te verilmiştir.

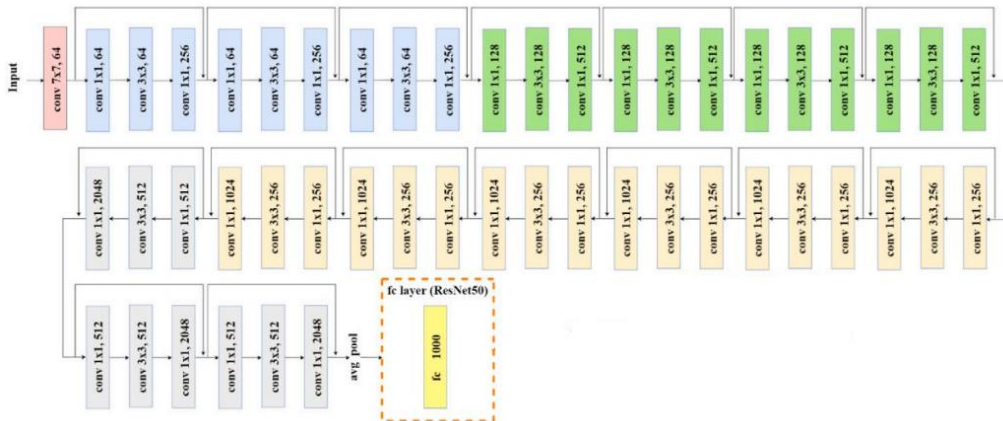


Şekil 3. VGG 16 sinir ağının mimarisi[11]

CLAHE yaklaşımı ile iyileştirilen görüntülere uygulanan VGG16 sinir ağı mimarisi ile görüntülerin hedef kategoriler ile ilişkilendirilmesi sağlanmıştır.

B. RESNET50 Sinir Ağı Mimarisi

50 katmana sahip bir sinir ağıdır. Bu mimari modele artık blokların eklenmesi ile oluşur. 4 farklı blok belirli oranlarda birbiri ile bağlantılıdır. Bu ilişkiyi tam bağlantılı katman takip eder. VGG16 mimarisinin blok diyagramı Şekil 4'te verilmiştir[12].



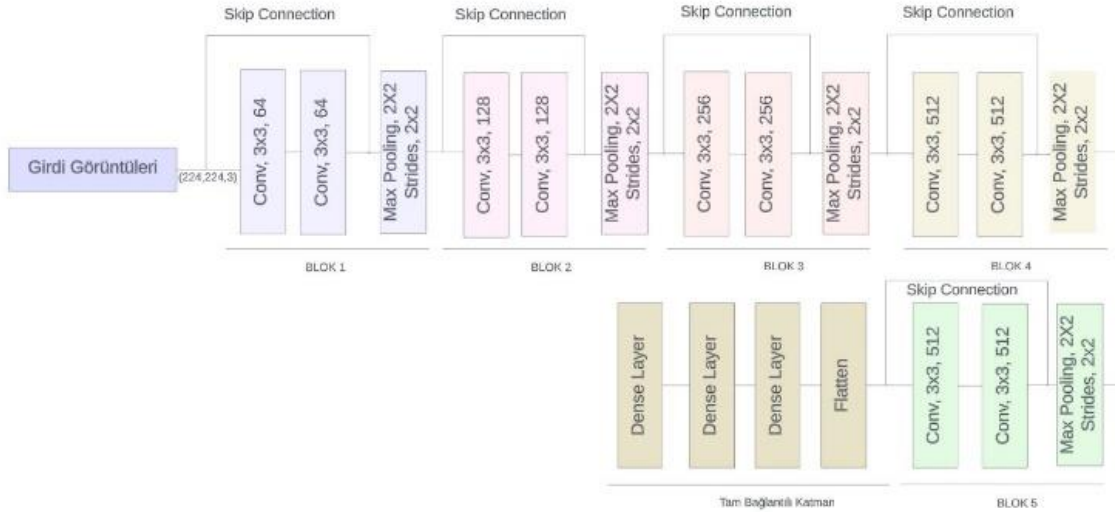
Şekil 4. Resnet 50 sinir ağının mimarisi[12]

CLAHE yaklaşımı ile iyileştirilen görüntülere uygulanan Resnet50 sinir ağı mimarisi ile görüntülerin hedef kategoriler ile ilişkilendirilmesi sağlanmıştır.

C. Önerilen Sinir Ağı Mimarisi

Önerilen sinir ağı mimarisi 13 evrişim katmanından oluşmaktadır. Önerilen bu mimarinin

genel yapısı hem VGG16 hem de Resnet50 mimarilerinden esinlenerek oluşturulmuştur. Artık blokların eklenmesi ile oluşan bu mimaride 5 farklı blok belirli oranlarda birbiri ile bağlantılıdır. Bu ilişkiyi tam bağlantılı katman takip eder. Önerilen mimarinin blok diyagramı Şekil 5'te verilmiştir.



Şekil 5. VGG16 ve Resnet 50 yapılarından esinlenerek oluşturulan sinir ağının mimarisi

CLAHE yaklaşımı ile iyileştirilen görüntülere uygulanan yeni sinir ağı mimarisi ile görüntülerin hedef kategoriler ile ilişkilendirilmesi sağlanmıştır.

III. BULGULAR VE TARTIŞMA

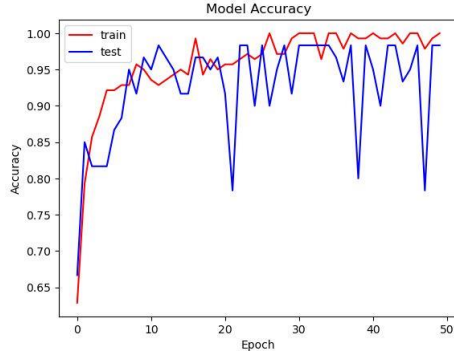
Yapay zeka, sağlıkta eşitliği yakalamak, sağlık hizmetlerinde teknolojiye yönelik bir dönüşüm sağlamak, tıp personelleri için iş akışını hızlandırmak ve üretkenliği arttırmak amacıyla büyük bir potansiyel barındırmaktadır[13].

Yapay zekanın alt alanlarından biri derin öğrenmedir. Derin öğrenme yaklaşımının özel bir türü olan CNN yapısı, nesnelere tespiti ve sınıflandırılması görevlerinde kullanılan popüler bir alandır. Aynı zamanda CNN yapıları ile devasa miktarda görüntü kullanılarak gerçekleştirilen eğitim sonucunda elde edilen ağırlıkların farklı bir modelin geliştirilmesi için kullanılması transfer öğrenme olarak nitelendirilmektedir.[12].


Transfer öğrenme başarılı çıktılarının üretilmesinde sıklıkla tercih edilmektedir. Fakat bir görevin

gerçekleştirilmesi için mevcut veri kümesi ile eğitilen ağın özellikleri spesifik veri kümesine aktarılırken hedef başarı eşğine ulaşamama ihtimaline de sahiptir. Çünkü özel bir amaç doğrultusunda oluşturulan veri kümesinde önceden eğitilmiş modellerden gelen bilgiler hedef görev kapsamında yetersiz kalabilir.


Bu nedenle bu çalışmada başarısı kanıtlanmış VGG16 ve Resnet 50 transfer öğrenme mimarilerinin yanı sıra bu mimarilerden esinlenerek oluşturulan yeni bir sinir ağı mimarisi önerilmiştir. Parametreleri fine tune edilen bu sinir ağı, PM ve normal görüntü verilerinden oluşan özel bir veri kümesi ile eğitilmiştir. Bu doğrultuda VGG16, Resnet 50 ve önerilen sinir ağı ile elde edilen değerlendirme oranları Şekil 6-11'de sunulmuştur.




Şekil 6. Eğitim ve test veri kümesi üzerinde VGG 16 mimarisi ile elde edilen başarı oranları




Şekil 10. Eğitim ve test veri kümesi üzerinde önerilen mimari ile elde edilen başarı oranları




Şekil 7. Eğitim ve test veri kümesi üzerinde VGG 16 mimarisi ile elde edilen kayıp değerleri



Şekil 11. Eğitim ve test veri kümesi üzerinde önerilen mimari ile elde edilen kayıp değerleri



Şekil 8. Eğitim ve test veri kümesi üzerinde Resnet 50 mimarisi ile elde edilen başarı oranları



Şekil 9. Eğitim ve test veri kümesi üzerinde Resnet 50 mimarisi ile elde edilen başarı oranları

Şekil 6-11 incelendiğinde VGG16 mimarisi ile elde edilen değerlendirme sonuçları kararsız bir tahmin işlevi sunarken Resnet 50 mimarisi ile elde edilen değerlendirme sonuçları VGG16 mimarisine göre daha kararlı bir tahmin süreci sunmaktadır. Fakat her iki mimari ile ulaşılan sonuçlar %100 doğruluk oranına ulaşmamıştır. Bununla birlikte Şekil 10-11'de sunulan değerlendirme sonuçları incelendiğinde önerilen yaklaşım %100 doğruluk oranına ulaşmıştır ve aynı zamanda daha kararlı, istikrarlı ve güvenilir sonuçlar üretmiştir. Önerilen hibrit yapının özellikle ayırt edilmesi zor problemler için karar destek sistemi olarak kullanılması hedeflenmektedir.

IV. SONUÇLAR

Son yıllarda gelişen teknoloji, hastalıklara ilişkin farklı tanı modellerinin önerilmesine ve tıp ile bilişim dünyasının çok disiplinli çalışmalar üretmesine doğru evrilmektedir. Bu süreçte, mevcut yöntemler kullanılmakta ya da yeni yöntemler geliştirilmektedir. Fakat hedef amaç çevresinde kullanılan yöntemin güncelliğinin ya da önerilen yöntemin içeriğinin yanı sıra probleme uygun yöntem tercihi de kritik bir husustur. Bu

nedenle sunulan çalışmada ilk olarak patolojik miyopun tespiti için fundus görüntülerindeki biyolojik yapıların CLAHE yöntemi kullanılarak netleştirilmesi sağlanmıştır. Ardından kritik ayrıntıları belirginleştirilen görüntüler, transfer öğrenme mimarileri ile sınıflandırılmıştır. Sınıflandırma sonucunda elde edilen başarı oranının iyileştirilmesi için VGG16 ve RESNET50 transfer öğrenme mimarilerinden esinlenerek yeni bir sinir ağı modeli geliştirilmiştir. Önerilen sinir ağı modelinin tıp alanında oluşturulacak karar destek sistemi için kararlı, istikrarlı ve başarılı sonuçlar üretmesi hedeflenmektedir.

Gelecekte önerilen hibrit yapıya çeşitli aktarım öğrenme mimarilerinden esinlenmek suretiyle farklı özelliklerin ve modüllerin eklenmesi planlanmaktadır. Böylece görüntülerden özellik çıkarma gücünün iyileştirilmesi hedeflenmektedir.

KAYNAKLAR

- [1] P. N. Baird et al., ‘Myopia’, *Nature Reviews Disease Primers*, vol. 6, no. 1, 2020, doi: 10.1038/s41572-020-00231-4.
- [2] Y. Zhang et al., ‘Performances of artificial intelligence in detecting pathologic myopia: a systematic review and meta-analysis’, *Eye*, pp. 1–9, 2023, doi: 10.1038/s41433-023-02551-7.
- [3] Z. Zhang, J. Cheng, J. Liu, Y. C. M. Sheri, C. C. Kong, and S. S. Mei, ‘Pathological myopia detection from selective fundus image features’, *Proc. 2012 7th IEEE Conf. Ind. Electron. Appl. ICIEA 2012*, pp. 1742–1745, 2012, doi: 10.1109/ICIEA.2012.6361007.
- [4] Y. Xu et al., ‘Learn to recognize pathological myopia in fundus images using bag-of-feature and sparse learning approach’, *Proc. - Int. Symp. Biomed. Imaging*, pp. 888–891, 2013, doi: 10.1109/ISBI.2013.6556618.
- [5] U. Ozkava, S. Ozturk, B. Akdemir & L. Sevfi, “An efficient retinal blood vessel segmentation using morphological operations”, 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) (pp. 1-7). IEEE.
- [6] U. Baid, B. Baheti, P. Dutande, and S. Talbar, ‘Detection of Pathological Myopia and Optic Disc Segmentation with Deep Convolutional Neural Networks’, *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON*, pp. 1345–1350, 2019, doi: 10.1109/TENCON.2019.8929252.
- [7] Z. R. Himami, A. Bustamam, and P. Anki, ‘Deep Learning in Image Classification using Dense Networks and Residual Networks for Pathologic Myopia Detection’, *2021 Int. Conf. Artif. Intell. Big Data Anal. ICAIBDA 2021*, pp. 191–196, 2021, doi: 10.1109/ICAIBDA53487.2021.9689744.
- [8] C. Wan, H. Li, G. F. Cao, Q. Jiang, and W. H. Yang, ‘An artificial intelligent risk classification method of high myopia based on fundus images’, *J. Clin. Med.*, vol. 10, no. 19, 2021, doi: 10.3390/jcm10194488.
- [9] B. Chen and C. Wan, ‘A diagnostic method of high myopia based on transfer learning’, *J. Phys. Conf. Ser.*, vol. 1976, no. 1, 2021, doi: 10.1088/1742-6596/1976/1/012031.
- [10] F. Akalın, ‘Sayısal haritalama teknikleri kullanılarak DNA dizilimleri üzerinden lösemi hastalığının temel türlerinin yapay zeka tabanlı algoritmalar ile sınıflandırılması’, *Doktora Tezi, Sakarya Üniversitesi, Sakarya, Mart. 2023.*
- [11] D. Theckedath and R. R. Sedamkar, ‘Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks’, *SN Comput. Sci.*, vol. 1, no. 2, pp. 1–7, 2020, doi: 10.1007/s42979-020-0114-9.
- [12] B. Hossain, S. M. H. Sazzad, M. Islam, N. Akhtar, and I. Sarker, ‘Transfer learning with fine-tuned deep CNN ResNet50 model for classifying COVID-19 from chest X-ray images’, *Informatics in Medicine Unlocked*, vol. 30, 2022.
- [13] Z. Li et al., ‘Artificial intelligence in ophthalmology: The path to the real-world clinic’, *Cell Reports Med.*, pp. 1–20, 2023, doi: 10.1016/j.xcrm.2023.101095.