



## Yapay Zekâ Yaklaşımlarını Kullanarak Retinopati Hastalığının Tespiti

### Detection of Retinopathy Solutions Using Artificial Intelligence Approaches

<sup>1</sup>Abdulrahman ÇAVLI , <sup>2</sup>Mesut TOĞAÇAR 

<sup>1</sup>Teknoloji ve Bilgi Yönetimi, Sosyal Bilimler Enstitüsü, Fırat Üniversitesi, Elazığ, Türkiye

<sup>2</sup>Yönetim Bilişim Sistemleri, İktisadi ve İdari Bilimler Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

<sup>1</sup>acavli525@hotmail.com.tr, <sup>2</sup>mtogacar@firat.edu.tr

Araştırma Makalesi/Research Article

#### ARTICLE INFO

##### Article history

Received : 14 February 2023

Accepted : 24 March 2023

##### Keywords:

Artificial Intelligence, Machine Learning, Nasnet Mobile, Feature Extraction; Diabetic Retinopathy

#### ABSTRACT

Retinopathy is a disease that usually causes vision loss or blindness in diabetic patients. Diabetic retinopathy occurs as a result of damage to the blood vessels in the retina of the eye. This disease is one of the leading diseases that cause vision loss worldwide. Retinopathy is seen in 30% of diabetic patients. Early diagnosis of the disease is important to prevent vision loss in diabetic patients. In many studies carried out in the field of health recently, artificial intelligence approaches have been used for the diagnosis-treatment processes of diseases. In this study, a hybrid artificial intelligence model is proposed for the early diagnosis of retinopathy disease. The images in the dataset used in the study were created by fundus imaging technique and were graded in five stages according to the severity of the disease. In the proposed approach, using preprocessing step techniques, the unnecessary parts of the original images are left in the background and trained by the deep learning model (Nasnet mobile). Machine learning methods were used in the classification process of the proposed approach. In addition, feature selection algorithms were used to improve the time-performance process of model training. As a result of the experimental analysis, 100% overall accuracy was achieved with the proposed approach. It was observed that this study contributed to the diagnosis process of diabetic retinopathy patients.

© 2023 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

#### MAKALE BİLGİSİ

##### Makale Tarihleri

Gönderim : 14 Şubat 2023

Kabul : 24 Mart 2023

##### Anahtar Kelimeler:

Yapay Zekâ, Makine Öğrenmesi, Nasnet Mobil, Özellik Çıkarma, Diyabetik Retinopati

#### ÖZET

Retinopati, diyabet hastalarında görülen genelde görme kaybına veya körlüğe sebep olan hastalıktır. Bu hastalık dünya genelinde görme kaybına neden olan hastalıkların başında gelmektedir. Retinopati, diyabet hastalarının %30'unda görülmektedir. Hastalığın erken teşhisi diyabet hastalarının görme kaybını önlemek için önem arz etmektedir. Yakın zamanda sağlık alanında gerçekleştirilen birçok çalışmada hastalıkların tanı-tedavi süreçleri için yapay zekâ yaklaşımlarından faydalanılmıştır. Bu çalışmada retinopati hastalığının erken teşhisine yönelik hibrit bir yapay zekâ modeli önerilmiştir. Çalışmada kullanılan veri kümesindeki görüntüler fundus görüntüleme tekniği ile oluşturulmuş ve hastalığın ciddiyetine göre beş evrede basamaklandırılmıştır. Önerilen yaklaşımda ön işlem adımı teknikleri kullanılarak orijinal görüntülerin gereksiz görülen kısımları geri planda bırakılarak derin öğrenme modeli (Nasnet mobile) tarafından eğitilmesini sağlamaktadır. Önerilen yaklaşımın sınıflandırma sürecinde makine öğrenme yöntemleri kullanıldı. Ayrıca model eğitiminin zaman-performans sürecini iyileştirmek için özellik seçim algoritmaları kullanıldı. Deneysel analizlerin sonucunda önerilen yaklaşım ile %100 genel doğruluk başarısı elde edildi. Bu çalışma ile diyabetik retinopati hastalarının tanı sürecine katkı sağlandığı görülmüştür.

© 2023 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

## 1. GİRİŞ

Diyabet hastalığı, pankreasın insan vücudu için yeterli miktarda insülin salgılamaması veya salgılanan insülinin vücut tarafından etkin bir biçimde kullanılmaması sonucunda ortaya çıkan bir hastalıktır. Diyabet hastalığı dünya genelinde bireylerde sık görülmeye başlanmıştır. Uluslararası Diyabet Federasyonu (IDF) 2021 verilerine göre yaklaşık 537 milyon yetişkinde diyabet hastalığı görülmektedir ve bu sayı 2030 yılında 643 milyona ulaşması beklenmektedir [1]. Genel belirtileri; ağızda kuruluk, iştahsızlık, bulanık görme, ayaklarda uyuşma, idrar yollarında enfeksiyon, halsizlik ve yorgunluktur [2].

Diyabetes mellitus (DM) göz dışı kaslar, göz içi mercek, görme siniri ve retina dâhil olmak üzere göz yapısındaki birçok yapıyı etkilemektedir [3]. Diyabetik Retinopati (DR) dünya genelinde genellikle çalışma yaşındaki diyabet hastalarının görme kaybı ve körlükle sonuçlanan retinal bir hastalıktır. 2030 yılına kadar dünya genelinde DR'li hasta sayısının yaklaşık 130 milyon olacağı tahmin edilmektedir. Bu sayının 2045 yılına kadar 160 milyona yaklaşacağı ön görülmektedir [4]. DR klinik olarak erken evrede proliferatif olmayan DR (NPDR) ve ileri evrede proliferatif DR (PDR) olmak üzere iki grupta incelenir [3]. Hastalığın erken teşhisi ve tedavisi diyabet hastalarının görme kaybını veya körlüğü önleme açısından büyük önem arz etmektedir.

Yapay zekâ, canlılar ve insanların hal ve hareketlerinden yola çıkarak sistemlerin modelleme çalışmasına denir. Bu kavram ilk olarak 1950 yıllarında 'Artificial Intelligence' olarak ortaya çıkmıştır [5]. Yapay zekâ insanların iş yükünü azaltmanın yanında yapılan işlemi daha kısa sürede daha doğru bir sonuçla tamamlamasına imkân sunar. Yapay zekâ ve makine öğrenimi, sağlık alanında da günümüzde etkin bir şekilde kullanılmaktadır [6]. Özellikle hastalığın teşhisinde kullanılan bu yöntemler erken teşhis ve tedavi sürecini hızlandırmaktadır. Bu nedenle, diyabetik retinopati hastalığının semptomlarını belirleyerek erken müdahale imkânı sunan bilgisayar destekli bir yapay zekâ uygulaması geliştirmek gereklidir.

Literatürde DR hastalığının tespiti için birçok çalışma yer almaktadır. Bunlardan bazıları incelenirse; Özçelik ve arkadaşları [7] DR hastalığının erken tanı ve tedavisinde kullanılmak üzere fundus görüntülerini kullanarak derin öğrenme tabanlı bir model geliştirmişlerdir. Çalışmaları iki aşamadan oluşmaktadır. Birinci aşamada, fundus görüntülerine iki boyutlu sinyal işleme yöntemi uygulayarak modelin aşırı öğrenmesinin önüne geçmeye çalışmışlardır. İkinci aşamada, sınıflandırma yöntemi için Evrişimsel Sinir Ağı (ESA) ve transfer öğrenmesi yöntemleri oluşturulmuş. 5100 fundus görüntüsü ile modeli eğitmişlerdir. Bu model ile DR yok, hafif, orta, şiddetli ve çok şiddetli olarak sınıflandırılan 900 fundus görüntüsü ile test gerçekleştirmişlerdir. Doğrulama yöntemi olarak 10 kat çapraz doğrulama yöntemi kullanılarak analizler gerçekleştirilmiş. Hastalığın erken tanı ve tedavisi için önerdikleri modelin performansını %97,8 olarak ölçmüşlerdir. Yalçın ve arkadaşları [8] DR hastalığının erken teşhisi için retina görüntülerinden derin öğrenme tabanlı bir model geliştirmişlerdir. İki aşamalı bir yaklaşım önermişlerdir. Modelin birinci aşamasında veri kümesinden alınan retina görüntüleri ön işlemden geçirilerek görüntünün boyutu standart hale getirip görüntü gürültülerinden arındırılarak daha kesin sonuca ulaşmayı hedeflemişlerdir. İkinci aşamada derin öğrenme modellerinden olan ESA'yı kullanarak sınıflandırma yapılmış ve %98,5 başarıya ulaşmışlardır. Geleneksel yöntem yerine ESA modelini kullanılarak öznelik kümeleri eğitilmiştir. Ayrıca, grafiksel tabanlı ekran kartı kullanılarak karmaşık problemleri hızlı ve daha doğru bir şekilde çözümlenmişlerdir. Gulshan ve arkadaşları [9] derin sinir ağlarını kullanarak DR hastalığının derecesine göre sınıflandırmaya çalışmışlardır. Çalışmalarında büyük veri kümeleri kullanarak, lezyon bazlı özellikleri belirtmek zorunda kalmadan eğitilebileceğini göstermişlerdir. DR hastalığının tespitinde kullandıkları otomatik sistem, yorumladığı veriler tutarlı, yüksek hassasiyet, özgün sonuç vermesi ve hızlı raporlanma avantajı sunmuştur. Bu çalışma sonucunda geliştirdikleri modelin performansı %97,5 ve %96,1 olarak ölçülmüştür. Qummar ve arkadaşları [10] renkli fundus görüntülerinden DR hastalığının teşhisinde ESA topluluğu tabanlı bir model önermişlerdir. Araştırma sonucunda, önerdikleri topluluk modelinin diğer yöntemlerden daha iyi sonuç verdiği ve DR'nin tüm aşamalarını tespit edebildiği sonucuna ulaşmışlardır. Şen [11] yaptığı tez çalışmasında DR ve katarakt hastalıklarını tespit etmek için derin öğrenme modelleri kullanmışlardır. Hastalığın tespitinde kullanılan veri kümeleri ön işlem adımlarından geçmiş ve transfer öğrenme modeliyle eğitilmiştir. Veri kümesini sınıflandırmada %96,6 doğruluğa ulaşmıştır.

Bu makalede DR hastalığının erken teşhisi ve tedavisinde kullanılmak üzere yapay zekâ tabanlı hibrit bir model önerilmiştir. Önerilen yaklaşım;

- Uzman doktorların hastalığı erken teşhis etmelerine olanak sağlamayı,
- Objektif karar veren, hızlı ve doğru sonuçlar elde etmeyi amaçlamıştır.

Makalenin diğer bölümleri şu şekilde özetlenir; veri kümesi hakkında detaylı bilgiler ikinci bölümde verilmiştir. Önerilen yaklaşımda kullanılan yöntemler ve modeller hakkında detaylı bilgiler üçüncü bölümde değinilmiştir. Deneysel sonuçlar ve tartışma kısmına dördüncü bölümde yer verilmiştir. Makalenin son bölümünde sonuç yer almıştır.

## 2. VERİ KÜMESİ

Veri kümesi, fundus tabanlı görüntüleme yöntemi kullanılarak oluşturulmuştur. Fundus fotoğrafçılık, DR hastalığının tespiti için kullanılan bir görüntüleme yöntemidir. Düşük maliyet avantajına sahip olan bu görüntüleme yöntemi, fotoğrafları yüksek büyütme ile retinanın daha iyi incelenmesine olanak tanımıştır. [12].

Veri kümesi erişime açık, toplam 2111 fundus görüntüsünden oluşmaktadır. Bu görüntülerin her biri ortalama 512×510 piksel çözünürlüğe sahiptir ve dosya uzantısı JPG formatındadır. Veri kümesi DR hastalığının derecelendirilmesine göre toplam 5 sınıftan oluşmaktadır. Bu dereceler; 0-4 arasında kategorize edilmiştir. En çok fundus görüntüsü şiddet derecesi 2 olarak gösterilen orta proliferatif olmayan diyabetik retinopati (orta NPDR) hastalık türünde yer almaktadır. Görüntüler sınıf olarak dengeli dağıtılmamıştır. Veri kümesi sınıflandırmalarını gösteren örnek görüntüler Şekil 1’de verilmiştir.



**Şekil 1.** Veri kümesine ait örnek görüntüler;  
0: DR yok, 1: Hafif NPDR, 2: Orta NPDR, 3: Şiddetli NPDR, 4: PDR.

Veri kümesine ait istatistik bilgiler Tablo 1’de verilmiştir. Bu tabloya göre; (0: DR yok) görüntü sayısı 537, (1: Hafif NPDR) görüntü sayısı 537, (2: Orta NPDR) görüntü sayısı 559, (3: Şiddetli NDPR) görüntü sayısı 290, (4: PDR) görüntü sayısı 188 adettir [13].

**Tablo 1.** Veri kümesine ait görüntü sayıları

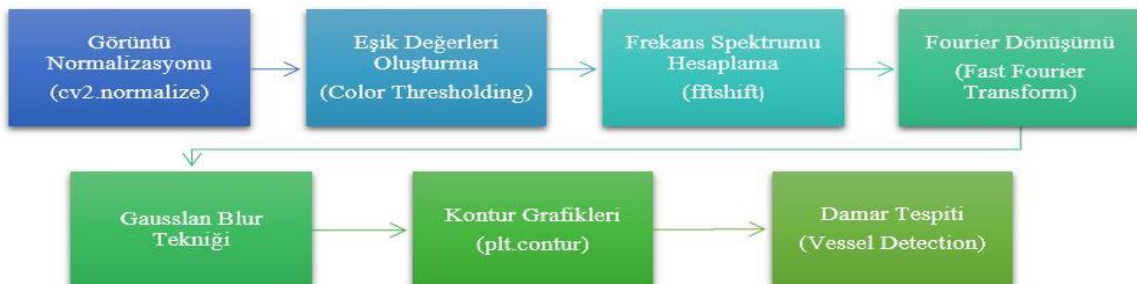
Sınıf / Derece	Görüntü Sayısı
0	537
1	537
2	559
3	290
4	188
<b>Toplam</b>	<b>2111</b>

### 3. YÖNTEM VE YAKLAŞIMLAR

#### 3.1. Ön İşlem Adımları

Önerilen yaklaşımda veri kümesindeki her bir görüntüyü iyileştirmek ve istenilen bölgeleri ön plana çıkarmak için ön işlem adımları uygulandı. Bu adımlarda kullanılan yöntem ve tekniklerin özeti Şekil 2’de gösterilmiştir. Kullanılan yöntem ve teknikler hakkında bilgiler aşağıda ifade edilmiştir;

- Görüntü Normalizasyonu (cv2.normalize): Görüntüde çekime bağlı olarak değişen renk değer dağılımı, aydınlatma şartları, kamera vb. varyasyonları telafi etmek amacıyla piksel yoğunluk değer aralığını değiştiren yöntemdir [14].
- Eşik Değerleri Oluşturma (Color Thresholding): Bir görüntüdeki nesnelere arka plandan ayırtmak için kullanılan yöntemdir [15].
- Frekans Spektrumu Hesaplama (fftshift): Görüntü küçük alanlara bölünerek sayısal değere haline dönüştürülmesi işlemi gerçekleştirir [16].
- Görüntü Bölütleme İçin Fourier Dönüşümü (Fast Fourier Transform): Görüntü pikselleri frekans alanına dönüştürülür, görüntüdeki önemli olan bilgiler çıkartılıp bunların analiz edilmesini sağlayan yöntemdir [17].
- Gausslan Blur Tekniği: Bulanık görüntü oluşturarak uzamsal ve frekans alanları açısından etkili geçiş filtreleri oluşturur [18].
- Kontur Grafikleri (plt.contour): Hazırda olan veya ölçümü yapılarak ulaşılan veri setindeki verilerin hangi değer çevresinde toplandığını gösterir [19].
- Damar Tespiti (Vessel Detection): Girdi görüntülerinde damar bölgelerinin ön plana çıkartılmasında eşik değeri aralıkları kullanarak, damarlı bölgelerin eşik değeri aralığında ise ön plana çıkartılmasını sağlar [19].



**Şekil 2.** Veri kümesine uygulanan ön işlem adımları.

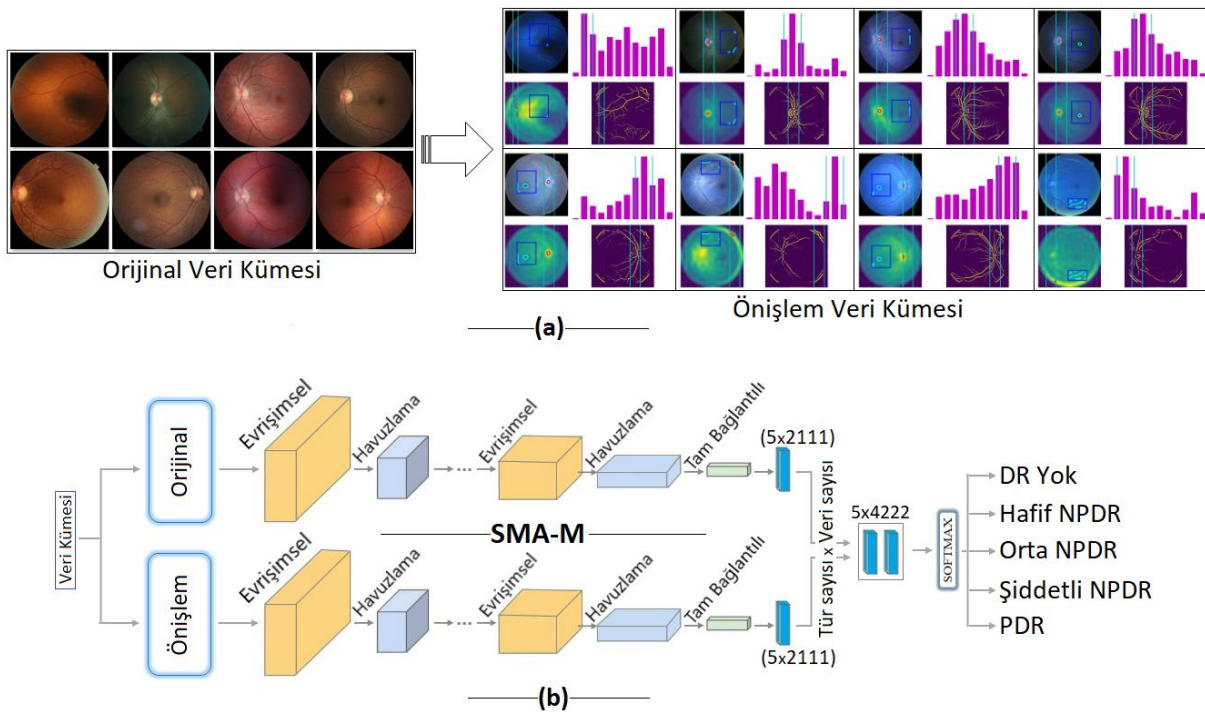




### 3.4. Önerilen Yaklaşım

Önerilen yaklaşım DR hastalığına ait fundus görüntülerini kullanarak, şiddet derecesine göre sınıflandırabilen ön işleme dayalı hibrit bir modelden oluşmaktadır. Fundus görüntülemeye hastalığın türünü daha belirgin hale getirmek için ön işlem adımları uygulanmıştır. Ön işlem adımları Şekil 2’de belirtilen teknikler ve yöntemlerden oluşmaktadır. Bu sayede Şekil 3’te gösterilen örnek görüntü kümeleri elde edilmiştir. İşlenmiş girdi verileri SMA-M modeli tarafından eğitilerek sınıflandırma süreci gerçekleştirilmiştir. Ön işlem adımlarının ESA modeline katkısı performans başarısını (hız, zaman, doğruluk, vs.) artırmaktır.

SMA-M modeli ile hem orijinal veri kümesi hem de ön işlem adımlarıyla işlenmiş veri kümesi eğitildi. SMA-M modelinin sınıflandırma sürecinde DSA, DVM, k-EYK, NB ve Softmax yöntemleri kullanıldı. İki veri kümesinin eğitilmesiyle ESA modelinin son katmanından öznelik setleri çıkartıldı. Öznelik setlerini birleştirme sürecinde uçtan uca bir ESA modelini sağlamak ve zamandan kazanç sağlamak için Softmax yöntemi tercih edildi. ESA modelinden çıkartılmış öznelikler makine öğrenme yöntemlerine el ile işlenerek girdi olarak verilmesi bir zaman kaybına yol açmıştır. Bu sebeple önerilen yaklaşımın son katmanında kullanılan Softmax yöntemi ile modele eğitilmesi için verilen girdi verileri son aşamada (sınıf sayısı x görüntü sayısı) boyutunda öznelik setlerine dönüştürüldü. Ardından iki öznelik seti birleştirilerek tekrardan Softmax yöntemi ile sınıflandırıldı. Öznelik birleştirilmesi sayesinde sınıflandırma performansının başarısı artırıldı. Önerilen yaklaşımın genel tasarımı Şekil 5’te gösterilmiştir.



Şekil 5. Önerilen yaklaşımın genel tasarımı; a) Ön işlem adımları örnek çıktıları, b) Tasarlanmış ESA mimarisi.

## 4. DENEYSEL ANALİZLER

Bu çalışmanın ön işlem adımları Python diliyle tasarlandı ve analizler Google Colab sunucusu kullanılarak gerçekleştirildi. Önerilen ESA modeli ve makine öğrenme yöntemleri Matlab 2022 yazılımı kullanılarak gerçekleştirildi. Matlab 2022 yazılımı için kullanılan donanım kaynakları şu şekildedir; geçici hafıza birimi 8 GB, işlemci birimi Intel® Xeon® CPU @3.20 GHz ve ekran kartı 4 GB GPU desteklidir. Analiz ölçümlerinde karmaşıklık matrisi kullanıldı. Karmaşıklık matrisinin hesaplanmasında kullanılan metrikler şunlardır; geri çağırma ( $G_{\text{çağ}}$ ), kesinlik (kes), f-skör (f-skr) ve doğruluk (doğ)[28],[29]. Metriklerin hesaplanma işlemleri için Denklem 1-4 kullanıldı. İlgili denklemlerde; (D): doğru, (Y): yanlış, (N): negatif, (P): pozitifdir[30]. Makine öğrenme yöntemleri ve SMA-M modeli için tercih edilen önemli parametreler Tablo 2’de gösterildi.

$$G_{\text{çağ}} = \frac{DP}{DP+YN} \quad (1)$$

$$\text{Kes} = \frac{DP}{DP+YP} \quad (2)$$


$$F\text{-skr} = \frac{2 \times DP}{2 \times DP + YP + YN} \quad (3)$$

$$\text{Doğ.} = \frac{DP+DN}{DP+DN+YP+YN} \quad (4)$$


**Tablo 2.** Önerilen yaklaşımda kullanılan model ve yöntemlerin parametreleri ve değerleri.

Model / Yöntem	Parametre	Tercih / Değer
SMA-M	İterasyon sayısı	4208
	Öğrenme oranı	1e-4
	Optimizasyon	SGD
	Sınıflandırıcı	Softmax
	Devir Sayısı	16
	Mini – topluluk (mini-batch)	8
	Eğitim oranı: test oranı	0.8:0.2
k-EYK	Komşu sayısı (k)	1
	Mesafe metriği	Öklid
	Mesafe ağırlığı	Eşit
NB	Sayısal Dağıtım fonksiyonu	Gauss
DVM	Kernel fonksiyon	Lineer
	Kutu kısıtlama düzeyi	1
	Çok sınıflı yöntem	Bire bir
DSA	Birinci katman boyutu	10
	Tam bağlantılı katman sayısı	1
	Aktivasyon	ReLU
	İterasyon sınırı	1000

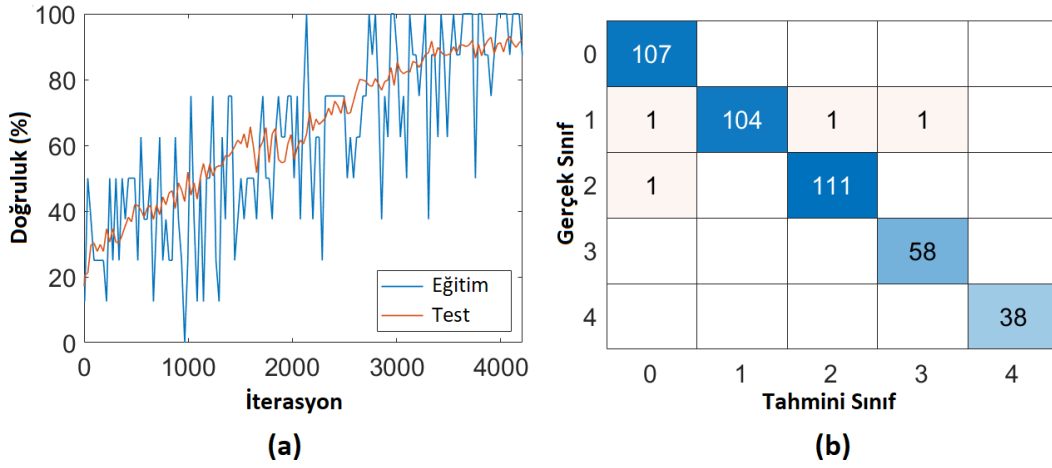
Bu çalışmanın tüm analizlerinde eğitim seti %80 olarak ayarlandı. Deneysel analizler 3 adımdan oluştu. Birinci adımda orijinal veri kümesi SMA-M modeli ile eğitildi. Bu analizden elde edilen eğitim-test başarı grafikleri ve karmaşıklık matrisi Şekil 6'da gösterilmiştir. Ardından SMA-M modelinin son katmanından çıkartılan özellik seti makine öğrenme yöntemlerine girdi olarak verildi. Bu yöntemlerden elde edilen karmaşıklık matrisleri Şekil 7'de gösterilmiştir. İkinci adımda önışlem veri kümesi SMA-M modeli ile eğitildi. İkinci adımın analizinden elde edilen eğitim-test başarı grafikleri ve karmaşıklık matrisi Şekil 8'de gösterilmiştir. Ardından SMA-M modelinin son katmanından çıkartılan özellik seti makine öğrenme yöntemlerine girdi olarak verildi. Bu yöntemlerden elde edilen karmaşıklık matrisleri Şekil 9'da gösterilmiştir.



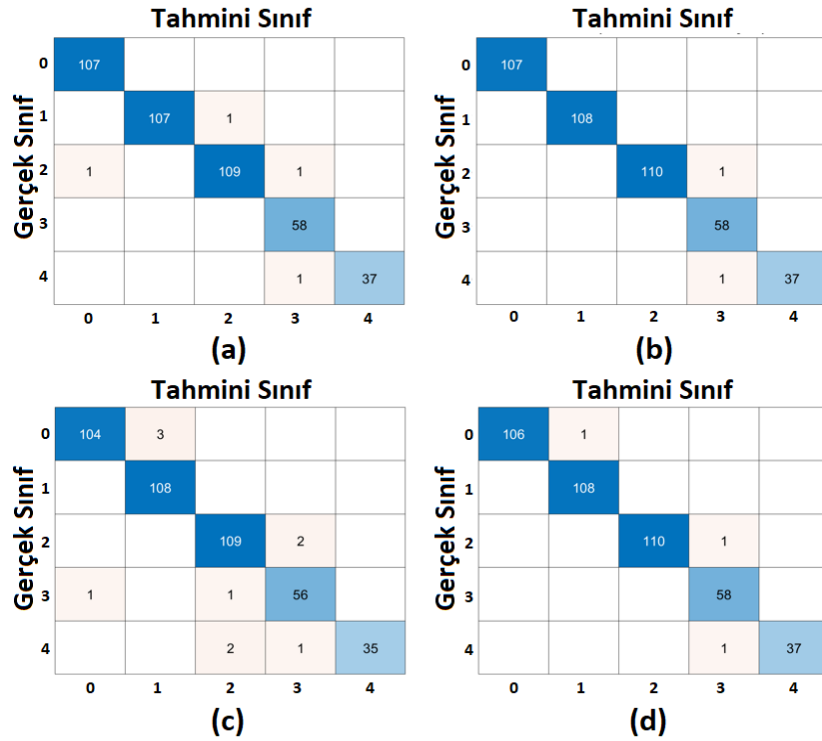
Şekil 6. Orijinal veri kümesinin SMA-M modeli ile eğitimi; a) Genel doğruluk başarısı, b) Karmaşıklık matrisi (Softmax).



Şekil 7. Orijinal veri kümesinin makine öğrenme yöntemleri ile elde edilmiş karmaşıklık matrisleri; a) k-EYK, b) NB, c) DSA, d) DVM.



Şekil 8. Önişlem veri kümesinin SMA-M modeli ile eğitimi; a) Genel doğruluk başarısı, b) Karmaşıklık matrisi (Softmax).




Şekil 9. Önişlem veri kümesinin makine öğrenme yöntemleri ile elde edilmiş karmaşıklık matrisleri; a) k-EYK, b) NB, c) DSA, d) DVM.

Tablo 3 incelendiğinde orijinal veri kümesiyle gerçekleştirilen analizler önişlem veri kümesine göre gerçekleştirilen analizlere göre ya eş değer olduğu ya da daha düşük performans gösterdiği gözlemlenmiştir. Orijinal veri kümesine göre en iyi performans NB yöntemi ile gerçekleşti ve bu yöntem %99,28 genel doğruluk başarısı verdi. Orijinal veri kümesiyle eğitilmiş SMA-M modelinin genel doğruluk başarısı %97,86'ydı. Önişlem veri kümesine göre en iyi performans NB yöntemi ile gerçekleşti. NB yöntemiyle %99,52 genel doğruluk başarısı sağlandı. Önişlem veri kümesiyle eğitilmiş SMA-M modelinin genel doğruluk başarısı %99,05'ti. Tüm bu analizlerde en iyi performansı NB yöntemi verdi. Ancak genel doğruluk performansındaki artış miktarı (%1,19) göz önüne alındığında en iyi performans SMA-M modeli vermiştir. SMA-M modeli ayrıca diğer yöntemlere göre uçtan uca bir modele sahiptir (Modelin son katmanında Softmax sınıflandırıcısı otomatik işlem yapmaktadır.). Diğer yöntemler ise ek maliyet (zaman kaybı, el ile gerçekleşen işlemler, vb.) gerektirmektedir. Dolayısıyla deneysel analizin üçüncü adımı SMA-M modeliyle gerçekleşti.

**Tablo 3.** Orijinal veri kümesi ile önışlem ile oluşturulmuş veri kümesinin analiz sonuçları.

Veri kümesi	Model / Yöntem	Genel Doğ. (%)
Orijinal	SMA-M (softmax)	97,86
	k-EYK	99,05
	NB	99,28
	DSA	97,63
	DVM	99,05
Önışlem	SMA-M (softmax)	99,05
	k-EYK	99,05
	NB	99,52
	DSA	97,63
	DVM	99,28

DeneySEL analizlerin son adımında amaç, SMA-M modelinden çıkartılmış iki özellik setini (orijinal veri kümesinden ve önışlem veri kümesinden) kullanarak özellik birleştirme yaklaşımını uygulamaktır. Özellik birleştirme yaklaşımı genel olarak başarı performansını artırabilmektedir. Bu amaç doğrultusunda, orijinal veri kümesiyle eğitilmiş modelin son katmanından çıkartılan (5x2111) boyutundaki özellik seti ile önışlem-veri kümesiyle eğitilmiş modelin son katmanından çıkartılan (5x2111) boyutundaki özellik seti birleştirildi ve iki özellik setinin birleştirilmesi ile (5x4222) boyutunda tek bir özellik seti elde edildi. Son aşamada birleştirilen tür/sınıf tabanlı özellik seti Softmax yöntemi ile yeniden sınıflandırıldı ve elde edilen genel doğruluk başarı %100'dü. Bu sonuç önerilen yaklaşımda kullanılan özellik birleştirme işleminin katkı sunduğunu göstermiştir. Önerilen yaklaşımda kullanılan Softmax yönteminin işleyiş yapısı ve son aşamadaki analizden elde edilmiş karmaşıklık matrisi Şekil 10'da gösterilmiştir. Şekil 10(b) 'de gösterilmiş karmaşıklık matrisinin metrik sonuçları Tablo 4'de verilmiştir.

**Şekil 10.** Birleştirilmiş özellik setinin Softmax yöntemi ile sınıflandırılması; a) Softmax'ın işlevi, b) Karmaşıklık matrisi.**Tablo 4.** Önerilen yaklaşım ile elde edilmiş karmaşıklık matrisinin metrik sonuçları.

Model	Sınıf	Kes	G_çağ	F-skr	Genel Doğ. (%)
Önerilen yaklaşım	DR yok	1,0	1,0	1,0	100
	Hafif NPDR	1,0	1,0	1,0	
	Orta NPDR	1,0	1,0	1,0	
	Şiddetli NDPR	1,0	1,0	1,0	
	PDR	1,0	1,0	1,0	

## 5. TARTIŞMA VE SONUÇ

DR hastalarının tedavisinde erken tanı önemlidir. Bu süreç teknolojik gelişmelere paralel olarak ilerlemektedir. Ayrıca bu hastalığın popülasyonu her geçen gün artmaktadır. Kişiyeye özel ekspertiz muayeneleri ile bu süreci doğru bir şekilde yürütmek mümkün olmayacaktır. Önerilen yaklaşım sayesinde sistem aynı anda gelen birçok görüntüyü işleyebilmekte ve görüntülerin analiz sonuçlarını kısa sürede verebilmektedir. Göz doktorlarının bu tür hastaları bire bir incelemesi zaman alıcıdır. Ayrıca uzman doktorlar aynı DR hastasının tanı-tedavi sürecini farklı zamanlarda farklı yorumlayabilir. Benzer şekilde DR hastasının tanı-tedavi süreçleri de diğer doktorlar tarafından



farklı yorumlanabilmektedir. Kısacası gözlemciler arası değişkenlik olabilir. Önerilen yaklaşım bir karar destek sistemine dayandığından, çoklu girdi görüntülerinin model tarafından işlenmesi çıktı sonucunu etkilemez. Önerilen yaklaşımın hesaplamalı ve nesnel bir değerlendirme gerçekleştirilmesi en önemli avantajıdır.

Görüntü kümesinin yeterli olmaması durumunda yapılması gereken adımlardan biri veri artırma tekniğidir. Makine öğrenme yöntemleri ve klasik yöntemler küçük veri kümelerinde iyi performans sergileyebilirler. Ancak derin öğrenme modelleri yeterli sayıda görüntü içeren veri kümesi olmadığı takdirde aynı performansı sergileyemeyebilirler. Veri artırma, ESA modellerinin eğitimi için ayrılan görüntü kümesine uygulanarak performans artırımı sağlayan, medikal imajlarda sıklıkla tercih edilen popüler bir tekniktir. Veri artırma tekniği sayesinde; geometrik dönüşümler, renk alanı dönüşümleri, filtreleme, vb. işlemler uygulanır [31]. Bu çalışmada orijinal görüntüler kullanılarak analizler gerçekleştirildi ve genel performans başarısı iyi sonuç verdiği için veri büyütme teknikleri kullanılmadı.

Önerilen yaklaşımda fundus görüntülerinin şiddet türleri, yapay zekâ tabanlı karar destek sistemi kullanılarak sınıflandırıldı. Bu yaklaşım; ön işleme adımları, ESA modeli, makine öğrenme yöntemleri ve özellik birleştirme yaklaşımından oluşmaktadır. Veri kümesi, ön işleme adımları ile işlenerek retinal bölgedeki damarların daha ön plana çıkarılması sağlandı. Özellik setleri, SMA-M modeli kullanılarak çıkarıldı ve veri kümelerinden çıkarılan özellik setleri birleştirilerek %100 genel doğruluk başarısı elde edildi. Makine öğrenme yöntemleri başarılı sonuçlar vermesine rağmen, el ile işlemlerin gerçekleşmesi hem zaman kaybına neden olmuş hem de önerilen yaklaşımın uçtan uca bir model olmasının önüne geçmiştir. Softmax yönteminin deneysel analizlerde gösterdiği performans artışı diğer sınıflandırıcılara göre daha iyi olduğu için deneysel analizin son adımında tercih edilmiştir. Gelecek çalışmada, veri kümesi sayısı artırılarak, DR hastalığına ait fundus görüntüler üzerinde farklı bölütleme yöntemleri denenecektir. ESA modelleri çeşitlendirilerek ve özellik birleştirme yaklaşımından sonra daha az özellik kullanma imkânı sunan ama daha verimli özellikleri ön plana çıkarabilecek meta-sezgisel yöntemler kullanılacaktır.

## Not

Bu makale, Fırat Üniversitesi Sosyal Bilimler Enstitüsü tarafından yürütülen “Diyabetik Retinopati Teşhisine Yönelik Yapay Zekâ Tabanlı Karar Destek Modeli” adlı yüksek lisans tezine dayanmaktadır.

## Yazar Katkıları

Abdulrahman ÇAVLI: Çalışmanın deneylerini gerçekleştirmiştir ve makaleyi yazmıştır.

Mesut TOĞAÇAR: Makalenin konusunun ve kapsamının belirlenmesine ve sonuçların yorumlanmasına katkı sunmuştur.

## Veri Kullanılabilirliği Bildirimi

Makalede özetlenen tüm veriler Kaggle Web Veri Havuzunda mevcuttur ve açık erişime sunulmuştur. Veri kümesi bağlantı linki: <https://www.kaggle.com/datasets/ahmedghazal54/diabetic-retinopathy-detection>

## Çıkar Çatışması

Makale yazarları, herhangi bir çıkar çatışması olmadığını beyan eder.

## KAYNAKÇA

- [1] URL-1 <https://idf.org/aboutdiabetes/what-is-diabetes/facts-figures.html> (Erişim Tarihi: 28.12.2022).
- [2] M. Balcı "Diyabet Tanı ve Tedavi Rehberi", Türkiye Diyabet Vakfı, İstanbul, 2019.
- [3] Ş. İmamoğlu and C. Özyardımcı Ersoy, Eds. "Diabetes Mellitusun Tanı, Tedavi ve İzleme", Uludağ Üniversitesi Tıp Fakültesi, Bursa, 2022.
- [4] Q. Jian, Y. Wu, and F. Zhang "Metabolomics in Diabetic Retinopathy: From Potential Biomarkers to Molecular Basis of Oxidative Stress", Cells, vol. 11, no. 19, p. 3005, 2022.
- [5] İ. Sucu and E. Ataman "Dijital Evrenin Yeni Dünyası Olarak Yapay Zeka Ve Her Filmi Üzerine Bir Çalışma", Electron. J. New Media, vol. 4, no. 1, pp. 40–52, 2017.
- [6] S. Subramanian, S. Mishra, S. Patil, K. Shaw and E. Aghajari "Machine Learning Styles for Diabetic Retinopathy Detection: A Review and Bibliometric Analysis", Big Data Cogn. Comput., vol. 6, no. 4, p. 154, 2022.
- [7] Y.B. Özçelik and A. Altan "Diyabetik Retinopati Teşhisi için Fundus Görüntülerinin Derin Öğrenme Tabanlı Sınıflandırılması", Eur. J. Sci. Technol., no. 29, pp. 156–167, 2021.
- [8] N. Yalcin, S. Alver, and N. Uluhatun "Classification of retinal images with deep learning for early detection of diabetic retinopathy disease", in 2018 26th Signal Processing and Communications Applications Conference (SIU), 2018.
- [9] V. Gulshan et al. "Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs", JAMA -

- J. Am. Med. Assoc., vol. 316, no. 22, pp. 2402–2410, 2016.
- [10] S. Qummar et al. “A Deep Learning Ensemble Approach for Diabetic Retinopathy Detection”, IEEE Access, vol. 7, pp. 150530–150539, 2019.
- [11] C. Şen “Derin Öğrenme Tabanlı Oftalmoloji Görüntülerinde Veri Analizi ve Güvenliği”, Yüksek Lisans Tezi, Bilgisayar Müh., Bursa Uludağ Üni., Türkiye, 2022.
- [12] J. Grauslund “Diabetic retinopathy screening in the emerging era of artificial intelligence”, Diabetologia, vol. 65, no. 9, pp. 1415–1423, 2022.
- [13] URL-2  
<https://www.kaggle.com/datasets/ahmedghazal54/diabetic-retinopathy-detection> (Erişim Tarihi: 17.01.2023).
- [14] B. Bakir Gungor, B. Adanur Dedeturk, and K. Taşdemir “Cilt Kanseri Görüntü Sınıflandırması için Görüntü Ön İşlemenin Evrimsel Sinir Ağları Performansı Üzerindeki Etkileri”, Erciyes Üniversitesi Fen Bilim. Enstitüsü Derg., vol. 38, no. 2, pp. 190–200, 2022.
- [15] T. Kurban, P. Civicioglu, R. Kurban, and E. Besdok “Comparison of evolutionary and swarm based computational techniques for multilevel color image thresholding”, Appl. Soft Comput. J., vol. 23, pp. 128–143, 2014.
- [16] T. Olğar “Mathematical Evaluation of Image Quality in Fluoroscopic Units”, Süleyman Demirel Üniversitesi Fen Bilim. Enstitüsü Derg., vol. 3, no. 2, pp. 201–207, 2008.
- [17] K. Hanbay “Görüntü Bölütleme için Fourier Dönüşümü, Hessian Matris ve Özdeğerler Kullanılarak Yeni bir Aktif Kontur Modeli”, Türk Doğa ve Fen Derg., vol. 10, no. 2, pp. 242–247, 2021.
- [18] A. İ. Öztürk, O. Yıldırım, A. Yavuz, and A. Kuru “Cyst Detection Using Filtering Technique in Kidney Images”, Eur. J. Sci. Technol., no. 38, pp. 198–204, 2022.
- [19] İ. Duman, R. Kara, and E. Çetiner “C # Kullanarak Mesafeye Bağlı Ters Ağırlık Yöntemi ile Gridleme ve Kontur Çizimi Gridding and Contouring with Inverse Distance Weight Method by C #”, Karaelmas Fen ve Mühendislik Derg., vol. 6, no. 1, pp. 16–21, 2016.
- [20] D. C. Samuk and F. M. Nuroğlu “A new wide area-based algorithm to determine faulted line in series-compensated grid using k-nearest neighbor (k-NN) classification method”, J. Fac. Eng. Archit. Gazi Univ., vol. 36, no. 2, pp. 871–882, 2021.
- [21] S. Tuzcu “Çevrimiçi Kullanıcı Yorumlarının Duygu Analizi ile Sınıflandırılması Classification of Online User Reviews with Sentiment Analysis”, Estud. Bilişim Derg., vol. 1, no. 2, pp. 1–5, 2020.
- [22] A.V. Setinde “Yüz Tanıma Sistemlerinde Kullanılan ESA , YGH-DVM ve DSA Algoritmalarının Performans Testleri Performance Tests of ESA , YGH-DVM and DSA Algorithms Used in Face Recognition Systems”, Fırat Üniversitesi Fen Bilim. Derg., vol. 34, no. 1, pp. 39–48, 2022.
- [23] T. Kavzoğlu and İ. Çölkesen “Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi”, Harit. Derg., vol. 144, no. 4, pp. 73–82, 2010.
- [24] F. Saxen, P. Werner, S. Handrich, E. Othman, L. Dinges and A. Al-Hamadi “Face attribute detection with mobilenetv2 and nasnet-mobile”, Int. Symp. Image Signal Process. Anal. ISPA, vol. 9, pp. 176–180, 2019.
- [25] A. Arı “Analysis of EEG signal for seizure detection based on WPT”, Electron. Lett., vol. 56, no. 25, pp. 1381–1383, 2020.
- [26] A. Arı, F. AYAZ and D. HANBAY “EMG Sinyallerinin Kısa Zamanlı Fourier Dönüşüm Özellikleri Kullanılarak Yapay Sinir Ağları ile Sınıflandırılması”, Fırat Üniversitesi Mühendislik Bilim. Derg., vol. 31, no. 2, pp. 443–451, 2019.
- [27] E. Şafak and N. Barışçı “Hafif Evrimsel Sinir Ağları Kullanılarak Sahte Yüz Görüntülerinin Tespiti”, El-Cezeri Fen ve Mühendislik Derg., vol. 2022, no. 4, pp. 1282–1289, 2022.
- [28] M.Z. Uzun, Y. Celik and E. Basaran “Micro-Expression Recognition by Using CNN Features with PSO Algorithm and SVM Methods”, Trait. du Signal, vol. 39, no. 5, pp. 1685–1693, 2022.
- [29] A. Çalışkan “Detecting human activity types from 3D posture data using deep learning models”, Biomed. Signal Process. Control, vol. 81, 2023.
- [30] A. Çalışkan “Diagnosis of malaria disease by integrating chi-square feature selection algorithm with convolutional neural networks and autoencoder network”, Trans. Inst. Meas. Control, vol. 45, no. 5, pp. 975–985, 2023.
- [31] P. Chlap, H. Min, N. Vandenberg, J. Dowling, L. Holloway and A. Haworth “A review of medical image data augmentation techniques for deep learning applications”, J Med Imaging Radiat Oncol, vol. 65, pp. 545-563, 2021.