



Hibrit Bir Model Oluşturarak Diyabetik Retinopati Sınıflandırılması

Kemal Ağca^{1*}, Hidayet Takcı²

^{1*} Sivas Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği ABD, Sivas, Türkiye, (ORCID: 0000-0001-5698-2208), kemalagca@gmail.com

² Sivas Cumhuriyet Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Sivas, Türkiye, (ORCID: 0000-0002-4448-4284), htakci@cumhuriyet.edu.tr

(1st International Conference on Engineering and Applied Natural Sciences ICEANS 2022, May 10-13, 2022)

(DOI: 10.31590/ejosat.1112980)

ATIF/REFERENCE: Ağca, K., Takcı, H. (2022). Hibrit Bir Model Oluşturarak Diyabetik Retinopati Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (36), 227-236.

Öz

Diyabetik Retinopati (DR), diyabet kaynaklı yüksek kan şekereinin retinadaki kan damarlarının geçirgenliğinde oluşturduğu hasar nedeniyle meydana gelen hastalıktır. Hastalığa erken tanı konmadığı ve tedavi edilmediği durumlarda ileri derecede göz bozukları ve görme kaybına neden olmaktadır. Komplikasyonların çoğu kan şekeri kontrolü ve erken tedavi ile önlenilmekte ancak DR'nin karmaşıklığı ve çeşitliliği nedeniyle manuel yöntemlerle tespiti zor olmaktadır. Uzmanlar tarafından tespiti zor olan hastalıkların teşhisinde bir derin öğrenme modeli olan Evrişimsel Sinir Ağı (ESA) ile günümüzde büyük başarı elde edilmiştir. Bu çalışmada DR'nin tespiti ve derecelendirilmesi için ESA ve makine öğrenmenin beraber kullanıldığı hibrit bir model önerilmektedir. Modelimizde ESA mimarisine sahip transfer öğrenme modeli otomatik özellik çıkarıcı olarak görev yapmakta ve ResNET-50 kullanılmaktadır. Makine öğrenme algoritmaları ise sınıflandırıcı olarak görev yapmakta ve K-En Yakın Komşu Algoritması, Rastgele Orman Algoritması ve Ekstra Ağaçlar Algoritması ayrı ayrı kullanılmaktadır. Çalışmada hastalığın şiddetine göre 'Proliferatif', 'Şiddetli', 'Orta', 'Hafif' ve 'Diyabetik retinopati yok' retina görüntülerinin yer aldığı Aptos 2019 veri seti kullanılmıştır. Veri setinde sınıf dengesizliği bulunduğundan sentetik veri artırma (SMOTE) tekniği kullanılarak sınıflar arasındaki dengesizlik giderilmiş ve veri artırımı sağlanmıştır. Eğitim ve test işlemi için veri setimize 10 kat çapraz doğrulama işlemi uygulanarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemi sonucunda %93 lük doğruluk ve %93 F1-skoru elde edilmiştir.

Anahtar Kelimeler: Evrişimsel Sinir Ağları, Görüntü İşleme, Diyabetik Retinopati, K-NN, Random Forest, Derin öğrenme, makine öğrenmesi, transfer öğrenme, resnet

Classification of Diabetic Retinopathy by Creating a Hybrid Model

Abstract

Diabetic Retinopathy (DR) is a disease that occurs due to the damage caused by high blood sugar caused by diabetes in the permeability of blood vessels in the retina. In cases where the disease is not diagnosed and treated early, it causes severe eye disorders and loss of vision. Most of the complications can be prevented with blood sugar control and early treatment, but due to the complexity and variety of DR, it is difficult to detect with manual methods. Today, great success has been achieved with the Convolutional Neural Network (ESA), which is a deep learning model in the diagnosis of diseases that are difficult to detect by experts. In this study, a hybrid model is proposed in which ESA and machine learning are used together for the detection and grading of DR. In our model, the transfer learning model with ESA architecture acts as an automatic feature extractor and ResNET-50 is used. K-Nearest Neighbor Algorithm, Random Forest Algorithm and Extra Trees Algorithm are used separately for classification. In the study, the Aptos 2019 dataset, which includes 'Proliferative', 'Severe', 'Moderate', 'Mild' and 'No diabetic retinopathy' retinal images, was used according to the severity of the disease. Since there is a class imbalance in the data set, the imbalance between the classes was eliminated and data augmentation was achieved by using the synthetic data augmentation (SMOTE) technique. Classification was carried out by applying 10-fold cross-validation to our data set for training and testing. As a result of the classification process, an accuracy of 93% and an F1-score of 93% were obtained.

Keywords: Convolutional Neural Networks, Image Processing, Diabetic Retinopathy, K-NN, Random Forest, Deep learning, machine learning, transfer learning, resnet

1. Giriş

Diyabet genel olarak; ağız kuruluğu, polifaji ya da iştahsızlık, polidipsi, poliüri, noktüri, bulanık görme, belirlenemeyen kilo kaybı, ayaklarda uyuşma, karıncalanma, yanma, idrar yolu enfeksiyonları, vulvovajinit, mantar enfeksiyonları, kaşıntı, ciltte kuruma, çabuk yorulma ve halsizlik şeklinde semptomlarını göstermektedir (TEMD, 2020; TÜRKDİAB, 2019)

Uluslararası Diyabet Federasyonu (IDF) diyabet atlası verilerine göre dünya genelinde 2021 yılı itibariyle; tahmini olarak 537 milyon yetişkinin (20-79 yaş) diyabet hastası olduğu ve bu rakamın dünya nüfusunun yaklaşık %10,5'ine denk geldiği vurgulanmaktadır. Diyabetin hızla büyüyen küresel bir sağlık sorunu olduğu, 2030 yılına kadar bu rakamın 643 milyona (%11,3) ve 2045'te 783 milyona (%12,2) çıkacağı tahmin edilmektedir (IDF, 2021; WHO, 2021).

Diyabetik retinopati (DR), diyabet komplikasyonuna bağlı olarak gözün arka kısmında yer alan ışığa duyarlı dokuda (retina) bulunan kan damarlarının zarar görmesinden kaynaklanan bir göz rahatsızlığı olarak tanımlanmaktadır. Diyabetik retinopati yavaş veya aniden ilerleyebilmekte ya da kendiliğinden iyileşebilmektedir. Ancak ilerlemesi halinde kısmi ya da kalıcı görme kaybına neden olabilmektedir. Uzun süre tip -1, tip-2 ve gestasyonel diyabet olan kişiler de dâhil olmak üzere diyabeti olan ve kan şekeri kontrolü düşük kişilerde diyabetik retinopati rahatsızlığı görülebilmektedir (NEI, 2021).

Diyabet belirtisine sahip hastalardan 20 yıllık süre sonunda tip-1 olanların büyük çoğunluğunda, tip-2 olanları ise yarıdan fazlasında diyabetik retinopati gelişimi olmaktadır. Diyabet süresi 15 yıla ulaşan ve diyabetik retinopati rahatsızlığı olan hastaların %2'sinde körlük ve %10'da ise ciddi görme kaybı yaşanmaktadır. DR rahatsızlığı diyabetli hastaların %25'inde hastalık gelişmeden önce görülmektedir. Bundan dolayı diyabete yakalanan kişilerin yılda en az bir kere göz muayenesi yaptırılması gerekmektedir (IDF, 2021).

Diyabetik Retinopati Erken Tedavi Çalışmasının kullandığı tanımlamalar, Amerikan Oftalmoloji Akademisi tarafından 2016'da yeniden düzenlenmiş ve DR şiddet ölçeğine göre nonproliferatif diyabetik retinopati (NPDR) ve proliferatif diyabetik retinopati (PDR) olmak üzere iki temel şekilde sınıflandırılmıştır.

Non-proliferatif Diyabetik Retinopati (NPDR): Hastalığın ilk dönemini ifade etmektedir. Bu dönemde bozuk damarlarda, retina kanamalarına neden olan sıvı sızması oluşmaktadır. Genel olarak hastanın görme yetisi bu dönemde etkilenmez. Bu evrede DR görülmekte olup hastalık şiddeti seviyesine göre hafif, orta ve şiddetli olarak kendi içerisinde üç gruba (Sibel, 2014) ayrılmaktadır.

Hafif proliferatif olmayan retinopati: Diyabetik retinopatinin ilk aşamasını oluşturmaktadır. Bu aşamada damarlardan retinaya çok az miktarda kan sızmaya başlamıştır. Bu aşamada görmeyle ilgili herhangi bir sorun oluşmadığından tedaviye ihtiyaç duyulmamaktadır. Ancak diyabetik retinopatinin ilerlemesini önlemeye yönelik olarak kan şekeri, kolesterol seviyesi ve kan basıncı takibinin yapılması gerekmektedir.

Orta derecede proliferatif olmayan retinopati: Diyabetik retinopatinin ikinci aşamasını oluşturmaktadır. Bu aşamada retinadaki küçük kan damarları şişmekte olup kan akışı bloke olmaktadır. Bundan dolayı retinada fiziksel değişiklikler meydana

gelmektedir. Yaşanan bu değişime bağlı olarak retinanın küçük orta kısmında (makula) kan ve diğer sıvıların birikmesi sonucu diyabetik makula ödemi oluşmaktadır. Diyabetik makula ödemiyle ilgili olarak bu aşamada görme problemleri görülmektedir.

Şiddetli proliferatif olmayan retinopati: Bu aşamada yeni kan damarları ve yara dokusu oluşmaktadır. Kan damarlarının belirli bir kısmı ya da tamamı tıkanmaktadır. Kan damarlarının tamamen tıkanmasına maküler iskemi denmektedir. Kan damarlarında oluşan bu durum sonucunda görme alanında koyu lekeler (uçan cisimler) oluşmakta ve bulanık görmeye neden olmaktadır. Bu aşamada uygulanan tedavi yöntemleri ile görme stabilize edilebilmekte ancak görmeye yaşanan kayıp telafi edilememektedir. Bu aşamada görme kaybı oluşma olasılığınız çok yüksek olmaktadır.

Proliferatif Diyabetik Retinopati (PDR): Bu dönemde retina tabakasında bulunan kan damarlarının ileri derecede bozulması sonucu beslenemeyen bölgeler oluşmakta ve oluşan bu bölgeler yeni damarların gelişmesine neden olmaktadır. Bu damarlar çok ince ve kırılabilir olduklarından dolayı göz içinde aniden kanamalara yol açmaktadır. Bu süreci yaşayan hasta gözünün önünde beliren ve gözü nereye çevirse o yönde hareket eden karartılar fark etmektedir. Daha yoğun kanama yaşayan hastalar ise ciddi görme kaybı ve körlük yaşamaktadır (Date vd., 2018).

Yapmış olduğumuz bu çalışmada, diyabetik retinopati hastalığının tespit ve sınıflandırılmasına yönelik olarak derin öğrenme ve makine öğrenme algoritmalarının bir arada kullanıldığı hibrit model kullanılmıştır. Ayrıca veri setinde yer alan sınıflar arasındaki veri dengesizliği probleminin çözümüne yönelik olarak sentetik veri artımı gerçekleştirilmiştir.

Yapmış olduğumuz çalışmada transfer öğrenme modeline uygulanan görüntülerden özellik çıkarma, buradan elde edilen verilerdeki sınıflar arasında yer alan dengesizlik sorununa çözüm sağlama, bu verilerin makine öğrenme algoritmalarına uygulanarak sınıflandırma yapması açısından özgün bir çalışma olmaktadır. Ayrıca diyabetik retinopatinin tespit ve sınıflandırılmasına yönelik yapılacak diğer çalışmalarda elde ettiği yüksek doğruluktan dolayı diğer çalışmalarda farklı bir bakış açısı kazandırarak bilime katkı sağlayacağı düşünülmektedir ve ilgili çalışma ile DR'nin erken tespit ve teşhis edilmesi amaçlanmaktadır.

1.1. İlgili Çalışmalar

Pratt vd. (2016) yapmış oldukları çalışmada, diyabetik retinopati sınıflandırmak için kaggle üzerinde yer alan 80.000 DR görüntüsünün bulunduğu EyePACS veri setini ESA tabanlı bir model oluşturularak beşli sınıflandırma gerçekleştirmişlerdir. Çalışma sonucunda %95 duyarlılık ve %75 doğruluk değeri elde edilmiştir.

Gulshan vd. (2016) yapmış oldukları çalışmada, diyabetik retinopati sınıflandırmak için Messidor-2 (1748 adet görüntü) ve EyePACS-1 (9963 adet görüntü) veri setini kullanmışlardır. Sınıflandırmada derin öğrenme modeli olarak transfer öğrenme modellerinden Inception-V3 kullanmışlardır. Çalışma sonucunda, EyePACS veri seti için %98,1 özgüllük ve %90,3 duyarlılık, Messidor-2 veri seti için %87 duyarlılık ve %98,5 özgüllük değeri elde etmişlerdir.

Abbas vd. (2017) yapmış oldukları çalışmada, diyabetik retinopati sınıflandırmak için farklı kaynaklardan elde edilen 750 DR görüntüsünün bulunduğu veri setini kullanmışlardır. DR'nin beş kategoride sınıflandırılması için gradyan lokasyon yönelimli

histogram teknikleri kullanarak çıkarılan derin görsel özelliklere dayalı bir yarı denetimli çok katmanlı derin öğrenme algoritması kullanmışlardır Çalışma sonucunda %92.4 AUC değeri elde edilmiştir .

Ghosh vd. (2017) yapmış oldukları çalışmada, diyabetik retinopayi sınıflandırmak için kaggle veri seti üzerinde yer alan 30.000 DR görüntü ile eğitim işlemi 3000 DR görüntüsü ile doğrulama işlemi yaptıkları veri seti kullanmışlardır. ESA tabanlı oluşturdukları model ile DR'yi ikili ve beşli olarak sınıflandırmışlardır Çalışma sonucunda ikili sınıflandırma için %95 beşli sınıflandırma için ise %85'lik bir doğruluk değerleri elde edilmiştir.

Masood vd. (2017) yapmış oldukları çalışmada, diyabetik retinopatiyi sınıflandırmak için EyePACS veri setini kullanmışlardır. Otomatik sınıflandırma için ESA tabanlı transfer öğrenme modeli olan Inception-V3 modelini kullanmışlardır. Beş kategorili sınıflandırma işlemine yönelik olarak yapmış oldukları çalışmada %48,2 doğruluk değeri elde etmişlerdir.

Yalçın vd. (2018) çalışmalarında, MESSIDOR, STARE, DIARETDB veri setlerinden elde ettikleri 500'ü hastalıklı ve diğer 500'ü hastaliksız olmak üzere 1000 adet renkli fundus görüntüsü kullanmışlardır (Yalcin vd., 2018). DR'nin erken tespitine yönelik yapmış oldukları ikili sınıflandırmada derin öğrenmeye dayalı bir yöntem önermişlerdir. Çalışma sonucunda %98,5 doğruluk değeri elde edilmiştir.

Kwasigroch vd. (2018) yapmış oldukları çalışmada, diyabetik Retinopatiyi sınıflandırmak için EyePACS veri setini kullanmışlardır. TR'yi tespit etmek, mevcut aşamasını belirlemek için ESA 'tabanlı VCC-D mimarisini ve sistemin performansını artırmak için özel bir sınıf kodlama tekniği kullanmışlardır. Kullanılan mimariyle değerlendirme aşamasında %51 ve DR'yi tespit etmede %82 doğruluk değerini elde etmişlerdir.

Qummar vd. (2019) yapmış oldukları çalışmada, diyabetik retinopatiyi sınıflandırmak için EyePACS veri setini kullanmışlardır . Çalışmada retina görüntülerinden DR'nin farklı aşamalarını otomatik olarak tespit etmek için ESA tabanlı Resnet-50, Inception-v3, Xception, Dense-121, Dense-169 transfer öğrenme modellerini kullanmışlardır. DR'nin beş kategorili sınıflandırma işlemine yönelik ilgili modellerinden; Resnet-50 (%48), Xception (%51), Dense-121 (%65), Inception-v3 (%69) ve Dense-169 (%84) hassasiyet değeri elde etmişlerdir.

Shanthi ve Sabeenian (2019) yapmış oldukları çalışmada, diyabetik retinopatiyi sınıflandırmak için Messidor veri setini kullanmışlardır. Çalışmada veri setindeki retina görüntülerinden DR'nin 4 kategorili sınıflandırma aşamalarını otomatik olarak tespit etmek için Alexnet tabanlı mimariyi kullanmışlardır Çalışma sonucunda sağlıklı kategorisi için %96.6, evre 1 kategorisi için %96.2, evre 2 kategorisi için %95.6 ve evre 3 kategorisi için %96.6 için doğruluk değeri elde edilmiştir.

Taufiqurrahman vd. (2020) yapmış oldukları çalışmada, diyabetik retinopatiyi sınıflandırmak için Aptos 2019 veri setini kullanmışlardır. Veri setine yönelik herhangi bir ön işlem yapmamışlardır. Çünkü yapmış oldukları araştırmada, ön işleme yapmanın bu veri kümesindeki nihai sınıflandırma sonucunu önemsiz şekilde etkilediğini veya hatta düşürdüğünü bulmuşlardır. Ayrıca veri setine yönelik olarak görüntü büyütme ve yeniden örnekleme uygulamışlardır. Derin öğrenme modeli olarak MobileNETV2-SVM den oluşan hibrit bir model kullanmışlardır. Çalışma sonucunda diyabetik retinopatinin normal, hafif, orta, şiddetli ve proliferatif DR sınıflandırmalarına e-ISSN: 2148-2683

yönelik olarak bu model, 0.925'lik QWK skoru ve 85%'lik doğruluk değeri elde etmişlerdir.

İslam vd. (2020) yapmış oldukları çalışmada, fundus görüntülerinin bulunduğu APTOS 2019 veri setini kullanmışlardır. ESA tabanlı VGG-16 mimarisine sahip transfer öğrenme ve ardından yeni bir renk versiyonu ön işleme tekniğine yönelik model geliştirmişlerdir. Önerilen model ile DR'nin 5 kategorili sınıflandırma işlemini yapmışlardır. Çalışma sonucunda 0,9132683 doğruluk değeri elde edilmiştir.

Shaban vd. (2020) yapmış oldukları çalışmada APTOS 2019 veri setini kullanmışlardır. Veri seti 0 ile 4 arasında etiket değeri (No DR-0, Mild NPDR-1, Moderate NPDR-2, Severe NPDR-3 ve PDR-4) bulunan fundus görüntülerinde etiketli veriler arasında dengesizlik bulunmaktadır. Veri seti içerisinde yer alan 1 ve 2 etiket değerine sahip (Mild NPDR-1, Moderate NPDR-2) ayrıca 3 ve 4 etiket değerine sahip (Severe NPDR-3 ve PDR-4) görüntüler kendi aralarında birleştirilerek 3 kategorili bir veri seti elde etmişlerdir. 0 etiket değeri DR yok, 1 etiket değeri orta derece DR ve 2 etiket değeri ise şiddetli DR'yi temsil edecek şekilde yeniden oluşturarak sınıflar arasındaki dengesizliğe çözüm sağlamışlardır. Çalışmalarında; DR yok, orta DR ve şiddetli DR olarak sınıflandırıldığı DR'yi sınıflandırmak için 18 evrimsel katman ve 3 tam bağlantılı katmandan oluşan derin bir ESA mimarisi kullanmışlardır. Eğitim ve test aşamasında 5 ve 10 kat çapraz doğrulama kullanarak sırasıyla %88-89 doğrulama doğruluğu, %87-89 duyarlılık, %94-95 özgüllük değerleri elde etmişlerdir.

Yaqoob vd. (2020) yapmış oldukları çalışmada, diyabetik retinopayi sınıflandırmak için Messidor-2 ve EyePACS veri setini kullanmışlardır. Messidor-2 veri setini ikili, EyePACS veri setini ise beşli sınıflandırma için kullanmışlardır. Her iki sınıflandırma için ResNET-50 ve Random Forest'den oluşan hibrit bir model kullanmışlardır. Önerilen modelin ilgili veri setlerine uygulanması sonucunda ikili sınıflandırmada %96 doğruluk ve beşli sınıflandırmada ise %75.09 doğruluk değeri elde edilmiştir.

Özçelik ve Altan (2021) yapmış oldukları çalışmada, DR'nin daha erken teşhis ve tedavisi için fundus görüntülerinin bulunduğu APTOS 2019 veri setini kullanmışlardır. Geliştirilen model iki aşamadan oluşmaktadır. İlk aşamada modelin aşırı öğrenmesinin önüne geçmek için iki boyutlu sinyal işleme tekniğini görüntülere uygulamışlardır. İkinci aşamada ise ESA tabanlı VGG-19 mimarisine sahip transfer öğrenme modelini kullanarak DR'nin 5 kategorili sınıflandırma işlemini yapmışlardır. Önerilen modele yönelik sınıflandırma işlemi sonucunda doğruluk, kesinlik, geri çağırma ve F1-skoru değerleri sırasıyla %97,8, %97,6, %97,7 ve %97,6 olarak elde etmişlerdir .


İlgili çalışmalar incelendiğinde, DR tespit ve derecelendirilmesine yönelik birçok çalışma yer almaktadır. Bu çalışmada, derin öğrenme ve makine öğrenme algoritmalarının bir arada kullanıldığı hibrit model kullanılmıştır. Ayrıca veri setinde yer alan sınıflar arasındaki veri dengesizliği probleminin çözümüne yönelik olarak sentetik veri artırımı gerçekleştirilmiştir. Önerilen çalışma ile Diyabetik Retinopatinin tespiti ve sınıflandırılması amaçlanmaktadır.

2. Materyal ve Metot

2.1. Veri Seti

Veri seti olarak Asya Pasifik Tele-oftalmoloji Derneğinin (APTOS) kaggle sitesi (APTOS2019, 2019) üzerinde körlük tespitine yönelik yapmış olduğu yarışmada halka açık olarak

sunduğu APTOS 2019 kullanılmıştır. İlgili veri seti fundus fotoğrafçılığı kullanılarak elde edilen toplamda 3.662 renkli retina görüntüsünden (PNG formatında) oluşmaktadır. Bu görüntüler; fundus fotoğrafçılığı kullanılarak çekilmiş 474 x 358 piksel ile 4288 x 2848 piksel çözünürlük arasında değişen normal retina ve diyabetik retinopatinin şiddet seviyelerine göre sınıflandırılarak oluşturulmuştur.



Şekil 1. APTOS 2019 veri setinden (0 ile 4 arasında etiketli) rastgele seçilmiş örnek görüntüler. (APTOS2019, 2019)

Uzmanlar tarafından her görüntü retinanın normal durumu ve diyabetik retinopatinin şiddeti açısından 0 ile 4 arasında derecelendirmiştir. Retinaya ait görüntülerin derecelendirme işlemi 5 sınıfa temsil edecek şekilde ayrılmıştır:

DR yok: Hastanın retinası normal.

Hafif DR: Hastanın hafif proliferatif olmayan retinopatisi vardır.

Orta DR: Hastanın orta derecede proliferatif olmayan retinopatisi var.


Şiddetli DR: Hastanın şiddetli proliferatif olmayan retinopatisi vardır.

Proliferatif DR: Hastada proliferatif retinopati var.

Normal, hafif, orta, şiddetli ve proliferatif DR sınıflarında sırasıyla toplam 1805, 370, 999, 193 ve 295 görüntü bulunmaktadır. Her bir sınıf içerisinde yer alan diyabetik retinopati görüntüne ait sayılar Tablo 1’de gösterilmektedir.

Tablo 1. Veri Setine ait sınıflar ve sınıflara ait görüntü sayıları.

Sınıf	Etiket	Adet	Yüzde %
DR yok	0	1805	49.290
Hafif DR	1	370	10.104
Orta DR	2	999	27.280
Şiddetli DR	3	193	5.270
Prolifere DR	4	295	8.056
Toplam		3.662	100 %



Şekil 2. APTOS 2019 veri seti etiket dağılımı

Modelimizde özellik çıkarma ve sınıflandırma işlemi için Aptos 2019 veri seti kullanılmıştır. Veri seti içerisinde yer alan sınıflardaki veri sayıları dengesiz bir dağılım göstermektedir. Şekil 2’de görüldüğü üzere veri setinde sınıf dengesizliği bulunduğundan SMOTE tekniği kullanılarak sınıflar arasındaki dengesizlik giderilmiştir.

2.2. Derin Öğrenme

Derin öğrenme, “yapay zekânın öğrenmeye dayalı alt çalışması olan makine öğrenmesine ait en yeni alt alanın adıdır” (Takcı, 2020). Derin öğrenme bilgi işleme konusunda canlıların sinir sistemlerinden esinlenerek kullanılan yapay sinir ağı algoritmaları kullanılmaktadır. Böylece, bilgi işlemeye yönelik olarak bilgisayarların her bir verinin neyi temsil ettiğini anlamasına ve kullanılan modellerin öğrenmesine imkân tanımaktadır (Daş vd., 2019).

Çoklu soyutlama yapısı ile derin öğrenme yaklaşımı, verinin belirgin özelliklerini öğrenmek için bir araya getirilmiş birden çok işleme katmanından oluşmaktadır. Ağdaki katman sayısının fazla olması o ağı derinliğini göstermektedir. Derin kavramı, ağda bulunan katmanların sayısını ifade etmektedir. Klasik yapay sinir ağları veya konvolüsyonel sinir ağları en fazla iki veya üç katmandan oluşmakta iken, derin sinir ağları ise yüzlerce alt katmandan oluşabilmektedir (Meltek & Halit, 2021; Şeker vd., 2017).

Derin öğrenme ağları, kullanılan alana göre çok katmanlı mimarinin yer aldığı modellerde tasarlanmaktadır. Bu ağların en önemli özelliği, derin yapıyı oluşturan katmanlar aracılığıyla probleme uygun öznelikleri ağı öğrenmesiyle ortaya çıkarmasıdır. Klasik öğrenme teknikleri, kendilerine verilen bilgiyi kullanmakta iken derin öğrenmede ise hangi bilgiyi kullanacağına kendisi karar vermektedir. Bu yüzden derin öğrenme klasik yöntemlere göre daha başarılı sonuçlar yansıtmaktadır (Kızrak & Bolat, 2018).

2.3. Evrişimsel Sinir Ağları

Evrişimsel sinir ağları (ESA), hayvanların görme sisteminden ilham alınarak oluşturulmuş; bilgisayarla görme ve görüntü işlemede en sık kullanılan derin öğrenme modelini oluşturmaktadır. Görüntülerin en düşük, en yüksek özelliklerini otomatik ve uyarlanabilir bir şekilde öğrenilmesi için tasarlanmıştır.

ESA’lar manuel olarak özellik çıkarma işlemi ortadan kaldırarak görüntüleri sınıflandırma için kullanılan özellikleri otomatik olarak tanımlayarak nasıl öğreneceğini kendi kendine yaparak çıkarmaktadır.

ESA’lar yapı olarak evrişim katmanı, havuzlama katmanı ve tam bağlı katman olarak üç tür katmandan (veya yapı taşlarından) oluşmaktadır. Evrişim ve havuzlama katmanı öznelik çıkarma işlemi gerçekleştirmek için tam bağlı katman ise sınıflandırma gibi nihai çıktıyı elde etmek için kullanılmaktadır (Yamashita vd., 2018).

2.4. Transfer öğrenimi

Transfer öğrenimi, bir görev için eğitilmiş bir modelin, benzer yapıdaki bir görevi gerçekleştirmek için kullanılan modelin başlangıç noktası olarak kullanıldığı bir derin öğrenme biçimini oluşturmaktadır. Transfer öğrenme ile oluşturulan bir model güncellemek ve yeniden eğitmek, çoğunlukla sıfırdan oluşturulmuş bir ağı eğitmekten daha kolay ve hızlı olmaktadır.

Önceden eğitilmiş bir model genellikle ImageNet gibi çok büyük veri setinde eğitilmekte ve eğitim sonucunda elde edilen ağırlıklar, oluşturulan yeni bir ağ yapısında kullanılmaktadır. Transfer Öğrenme modellerinin özellik çıkarımı için kullanılmasında son katman çıkarılarak kullanılmaktadır. Diğer katmanlar ile meydana gelen yeni model daha sonra diğer görevlerin gerçekleştirilmesi için sabit özelliklerin çıkarıcısı olarak işlem yapmaktadır (Ribani & Marengoni, 2019). Çalışmamızda ResNET-50 modeli veri setinde yer alan görüntülerden özellik çıkarma amaçlı kullanılmıştır.


2.4.1. Resnet-50

Derin sinir ağları yapı olarak daha az katmana sahip sinir ağlarından daha yüksek performansı göstermektedir. Ancak ağ derinliğinin artmasıyla derin ağların eğitilmesinde modellerin performans düşümüne neden olan kaybolan gradyan sorununu oluşturmaktadır. ResNet-50 mimarisi Şekil 3'te gösterildiği üzere diğer derin sinir ağları modellerinden farklı olarak ardışık ağ mimarisi yerine bünyesinde artık blok yapısı bulundurmaktadır.



Şekil 3. ResNet-50 mimarisi (Rastogi, 2022)

Bu yapının kullanılmasının nedeni, ağırlık yapısı derinleştiğçe başarımın düşmesine neden olan kaybolan gradyan sorununa engel olmak ve başarımın düşeceği durumlarda aynı kalmasını sağlamaktır. ResNet modelleri kimlik kısa yol bağlantıları kullanarak bu sorunu çözüm sağlayarak daha derin ağların eğitilmesini sağlamaktadır.



Şekil 4. ResNet-50 artık blok yapısı

Bu kısa yol bağlantıları gösterildiği üzere bir katmanın ağ katmanındaki çıktıyı (x) alıp mimari yapıya yönelik olarak kendinden sonra artık blok yapısı olarak kullanılan katmanları atlayarak ve artık blok katmanlarından elde edilen çıktı $F(x)$ ile toplanarak $F(x)+x$ şeklinde bir sonraki katmana girdi olarak kullanılmaktadır.

ResNet modelleri katman sayılarına göre birden çok yapıda bulunmaktadır. Çalışmamızda Şekil 4'te mimari yapısı gösterilen ve 50 katmana sahip ResNet-50 modeli giriş görüntülerinden özellik çıkarımı amaçlı kullanılmıştır (Veranyurt vd., 2020)

2.5. Sentetik Aşırı Örnekleme Yöntemi (SMOTE)

Örneklem sayılarında bulunan dengesizlik sınıflandırma işleminde kullanılan modelin performansına ve doğruluğuna

olumsuz yönde etki sağlamaktadır. Veri setlerinde yer alan ve sınıflar içerisinde dağılım gösteren verilerin, (He & Garcia, 2009) sayılarının eşit olmaması sınıf dengesizliği olarak ifade edilmektedir. Bu yöntemler, dengesiz örneklerin yer aldığı azınlık grubuna yönelik olarak yeniden örnek oluşturularak ilgili örneklemlerin dengeli hale getirilmesi işlemini oluşturmaktadır.

Bu çalışmada kullanılan veri setine, yapay veri artırma yöntemlerinden biri olan SMOTE yöntemi uygulanarak sınıflar arasındaki dengesizlik giderilmiştir.

Gerçek dünya problemlerini sınıflandırılmasına yönelik çalışmalarda veri dengesizliği sınıflandırma algoritmalarının performansını düşürmektedir. Veri setinde azınlık örnekleme olduğunda, veri dağılımı dengelemek için genellikle aşırı örnekleme yöntemleri uygulanmaktadır (He & Garcia, 2009). SMOTE algoritması, veri seti içerisinde yer alan orijinal örneklemlerin sayılarını birbirine dengelemek için azınlık örneklemleri kopyalayıp sayıyı eşitlemek yerine, sentetik olarak azınlık örneklemlerden yeni örneklemler oluşturularak aşırı örnekleme yaklaşımını ana fikir olarak sunmaktadır (Fernández vd., 2018). SMOTE algoritması, veri setleri içinde yaralan örneklerden her azınlık örneğini alarak azınlık sınıfın k-en yakın komşularını (Çavuşoğlu & Kaçar, 2019) birleştiren bir çizgi parçaları boyunca sentetik örnekler üretmektedir. Bu yöntem neticesine aşırı örneklemlenmiş sentetik veriler ile veri setinde bulunan sınıflar arasındaki dengesizlik soruna çözüm üretilmektedir (Zhou vd., 2017).

2.6 Makine Öğrenmesi

Makine öğrenmesi (ML), açık şekilde programlanmadığı halde veri ve bilgi arasındaki temel ilişkileri sentezlemeyi, oluşturulan algoritmalarla otomatik şekilde öğrenmeyi ve öğrendiklerini pekiştiren sistemler geliştirmeyi yerine getiren bir yapay zekâ alt dalı olarak tanımlanmaktadır (Takcı, 2020).

Denetimli öğrenme (supervised learning): Denetimli öğrenmede amaç, bir dizi bağımsız girdi değişkeni üzerinden tanımlanan göreve dayanarak çıktı değerini tahmin etmektir (Pulat & Kocakoç, 2021)

Denetimsiz Öğrenme (unsupervised learning): Denetimsiz öğrenmede amaç; bir dizi girdi verileri arasındaki ilişkileri ve gizli örüntüleri açığa çıkarmaktır.

Yarı Denetimli Öğrenme (semi-supervised learning): Denetimli ve denetimsiz öğrenme algoritmalarının dezavantajlarıyla baş edebilmek için oluşturulmuş öğrenme türünü oluşturmaktadır.

Takviyeli Öğrenme (reinforcement learning): Bu öğrenme türü davranışsal psikolojideki ödül ilkesine dayanmaktadır. Karar verme sistemi elde edilen sonuçlar içerinden en yüksek ödülü veren sonucu tercih ederek öğrenim işlemini gerçekleştirir (Takcı, 2020; Veranyurt vd., 2020).

2.6.1. K-En Yakın Komşu Algoritması(K-NN)

Parametrik olmayan yani temel veriler üzerinde herhangi bir varsayımda bulunmayan denetimli öğrenme algoritma türünü oluşturmaktadır. Sınıflandırılması yapılacak örneğin veri kümesi içerisindeki her bir örneğe olan mesafesi hesaplanmaktadır. Hesaplama sonucunda kendine en yakın k adet komşuların bulunduğu sınıfa göre yeni örneğin sınıfı belirlenmiş olmaktadır. Kullanılan k ifadesi sınıflandırması yapılacak örneğin veri kümesi içerisindeki en yakın komşu adedini seçmek için kullanılmaktadır.(Çavuşoğlu & Kaçar, 2019).

2.6.2. Rastgele Orman Algoritması (RF)

Karar ağacı algoritmasının yapısının baz alındığı bir denetimli öğrenme algoritmasını oluşturmaktadır. Orijinal veri kümesinden birden fazla ön yüklemeli eğitim veri kümesi oluşturmaktadır. Oluşturulan her bir ön yüklemeli veri kümesi için bir ağaç üretmektedir. Oluşturulan bu ağaçların çoğunluk oylamasıyla sınıflandırma işlemi yapmaktadır. Kullanılmış olduğu önyükleme yöntemiyle her bir karar ağacının benzersiz olmasını sağlamaktadır. Karar ağacı algoritması ile arasındaki temel fark düğüm seçimi ve bölümlerinin rastgele yapılmasıdır. Ayrıca Karar ağacı algoritmalarında yaşanan aşırı öğrenme sorunu bu algoritmada bulunmamaktadır

2.6.3. Ekstra Ağaçlar Algoritması (ET)

Rastgele orman algoritmasının farklı bir mimarisini oluşturmaktadır. Rastgele ağaç algoritmasından farklı oluşturulan düğümlerin dallara ayrılması aşamasında karar alma kriteri yerine rastgele dallanma yolunun seçilmesidir (Geurts vd., 2006).

2.7. Doğrulama

Sınıflandırma için kullanılan modeller ayrı ayrı çıktı sunmakta ve bu çıktılardan elde edilen metriklere ihtiyaç duyulmaktadır. Sınıflandırma metrikleri, bir modelin performansını değerlendirmek ve sınıflandırmanın ne kadar iyi veya ne kadar kötü olduğu hakkında bilgi elde edilmesini sağlamaktadır.

Tablo 2. Karmaşıklık Matrisi (Confusion Matrix)

Gerçek Değerler	Tahmin Edilen Değerler		
		Pozitif	Negatif
	Pozitif	(DP)	(YP)
Negatif	(YN)	(DN)	

Tablo 2’de gösterilen karmaşıklık matrisi modelin performansına yönelik kullanılmakta ve başarımlar değerlendirme metriklerine ait işlemler bu tablodan elde edilerek kullanılmaktadır.

Karmaşıklık matrisi, oluşturulan modellerin tahminlerinde elde edilen etiket değerine karşı gerçek etiketlerinin tablo halinde görselleştirilmesi olarak ifade edilmektedir. Tablo içerisinde yer alan kısaltmalar:

DP: Doğru Pozitif

YP: Yanlış Pozitif

YN: Yanlış Negatif

DN: Doğru Negatif

Literatürde hata matrisinde elde edilen değerlerin kullanılması sonucu modelin performansı ve başarısının değerlendirilmesinde kullanılan metriklerle ait denklemler:

Doğruluk (Accuracy) (A): Kullanılması ve uygulanması en basit metrik türünü oluşturmaktadır. Eğitim için kullanılan veri seti ile eğitilen modelin, test veri setindeki verileri doğru olarak sınıflandırma oranı olarak ifade edilmektedir.

$$\text{Doğruluk (A)} = \frac{|DP| + |DN|}{|DP| + |YP| + |DN| + |YN|}$$

Keskinlik (Precision) (P) : Doğru tahmin edilen pozitif örneklerin, toplam tahmin edilen pozitif örneklere oranı olarak ifade edilmektedir. Yani doğru pozitif değerlerin ne kadarını doğru tahmin ettiğini belirtmektedir.

$$\text{Keskinlik (P)} = \frac{|DP|}{|DP| + |YP|}$$

Duyarlılık (Recall) (R): Duyarlılık olarak da ifade edilen geri çağırma, sınıflandırma modelinin doğru pozitif sınıf etiketlerini yani incelenen olayın olma durumunu tahmin etmedeki performansını yansıtmaktadır. Dengesiz veri dağılımı bulunan veri setlerinin kullanıldığı sınıflandırma modellerinde önem arz etmektedir.

$$\text{Duyarlılık (R)} = \frac{|DP|}{|DP| + |YN|}$$

Duyarlılık ve özgüllük metriklerinden elde edilen değerlerinin harmonik ortalaması alınarak elde edilen metrik türünü oluşturmaktadır. Sınıflandırmada kullanılan veri setlerinde sınıflar arası dengesizlik var ise bu ölçüm metriği kullanılmaktadır.

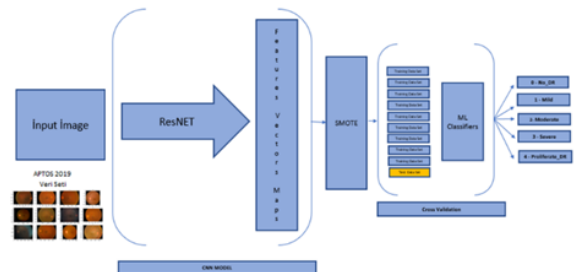
F-Ölçümü (F-Measure) (F): Duyarlılık ve özgüllük metriklerinden elde edilen değerlerinin harmonik ortalaması alınarak elde edilen metrik türünü oluşturmaktadır. Sınıflandırmada kullanılan veri setlerinde sınıflar arası dengesizlik var ise bu ölçüm metriği kullanılmaktadır.

$$\text{F-Ölçüm (F)} = \frac{2 * P * R}{P + R}$$

2.8 Metot

Diyabetik retinopatinin saptanması ve derecelendirilmesi için derin öğrenme ve makine öğrenmesinin birlikte kullanıldığı hibrit bir model kullanılmıştır. Hibrit modelde derin öğrenme modeli veri setindeki diyabetik retinopati görüntülerinden özellik çıkarımı olarak kullanılmaktadır.

Derin öğrenmede sınıflandırma işleminde kullanılan tam bağlı katman yerine derin öğrenme modelinden elde edilen özellikleri makine öğrenimi algoritmaları ile eğitim ve test işlemine tabi tutularak sınıflandırma işlemi gerçekleştirilmiştir.




Şekil 5. Önerilen çalışmanın şeması

Veri setinde sınıf dengesizliği bulunduğundan sentetik veri artırma yöntemi kullanılarak sınıflar arasındaki dengesizlik giderilmiştir. Dengeli hale getirilen veriler üzerinde algoritmalar çalıştırılmış ve model değerlendirme aşamasında 10 kat çapraz doğrulama (10-fold cross validation) kullanılmıştır. Şekil 3’te önerilen çalışmanın şeması yer almaktadır.

2.8.1 Özellik çıkarma

Ön işlem olarak veri setinde bulunan retinaya ait 3662 adet fundus görüntüsü Resnet-50 modeline uygulanmak için 128x128x3 boyutlarında standart hale getirilmiştir. Şekil 4'te görüldüğü üzere ResNET-50, veri setindeki diyabetik retinopati görüntülerinden özellik çıkarımı amacıyla kullanılmaktadır. ResNet-50 mimarisinden transfer öğrenme yöntemi ile elde edilen taban katmalarının ağırlık değerleri dondurulmuştur. Daha sonra ilgili veri seti ResNet-50 modeline uygulanmış ve Global ortalama havuzlama (global aware pool) katmanından bu görüntülere ait özellikler elde edilmiştir. Çalışma sonucunda 3662 adet görüntüye ait 2048 adet özellik elde edilmiştir.



Şekil 6. Özellik çıkarımı için kullanılan ResNet-50 mimarisini

2.8.2 Veri artırma


Elde edilen görüntüleri sınıflandırma işlemi için makine öğrenme algoritmaları uygulamadan önce SMOTE veri artırma tekniği kullanılarak sınıflar arasındaki dengesizlik giderilmiştir. SMOTE sentetik veri artırma tekniğinin bir türü olan aşırı örneklemeye yöntemi (over sampling) ile veri setindeki her bir sınıfa ait veriler 1.805 adede eşitlenmiştir.

Tablo 3. SMOTE işlemi sonrası veri seti sayısı ve sınıf dağılımı

Sınıf	Adet	Yüzde %
0	1805	20.00
1	1805	20.00
2	1805	20.00
3	1805	20.00
4	1805	20.00
Toplam	9.025	100 %

Bu eşitlemeyle veri setimizde yer alan dengesizlik sorunu çözülmüş ve Tablo 3'te görüldüğü üzere toplamda 9.025 adet görüntü ve her bir görüntüye ait 2048 adet özellik elde edilmiştir.

Böylece veri setinde yer alan 5 sınıf dağılımındaki görüntü sayıları eşitlenmiştir.



Şekil 7. SMOTE işlemi sonrası veri seti.

2.8.3 Sınıflandırma

Çalışmada performans karşılaştırması yapabilmek amacıyla; K En Yakın Komşu algoritması, Rastgele orman Algoritması ve

Ekstra Ağaçlar Algoritması ayrı ayrı uygulanmıştır. Sınıflandırma algoritmaları veri artırma yöntemiyle elde edilen veriler üzerinde çalıştırılarak model değerlendirme için 10 kat çapraz doğrulama işlemi yapılmıştır. Çalışma sonunda makine öğrenimi algoritmalarının başarı sonuçları kıyaslanarak çalışma tamamlanmıştır. 10-Katlamalı Çapraz Doğrulama (Stratified 10-Fold Cross Validation) tekniği kullanılarak doğruluk (accuracy), duyarlılık (recall), F1-Skoru (F1-Score) ve hesaplama zamanı metrikleri üzerinden değerlendirilmiştir.

3. Araştırma Sonuçları ve Tartışma

3.1. Sonuçlar

Sınıflandırma için kullanılan veri seti üzerinde veri artırma yöntemi kullanılarak sınıf sayıları eşitlenmiş ve ResNET-50 transfer öğrenme modeli yardımıyla veri işleme yapılmıştır. Daha sonra elde edilen 9.025 adet verinin yer aldığı yeni veri seti 10 kat çapraz doğrulama ile makine öğrenimi algoritmalarıyla eğitim ve test işlemine tabi tutularak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemine yönelik elde edilen bulgular Tablo 4'te gösterilmektedir.


Tablo 4. Sınıflandırma işlemi yapılan algoritmalara ait sonuçlar

Derin öğrenme Modeli	Makine Öğrenmesi Algoritması (Sınıflandırıcı)	Sonuçlar		
		Doğruluk	Duyarlılık	F1-Score
ResNET-50	K En Yakın Komşu algoritması	0.86	0.86	0.85
	Rastgele orman Algoritması	0.92	0.92	0.92
	Ekstra Ağaçlar Algoritması	0.93	0.93	0.93

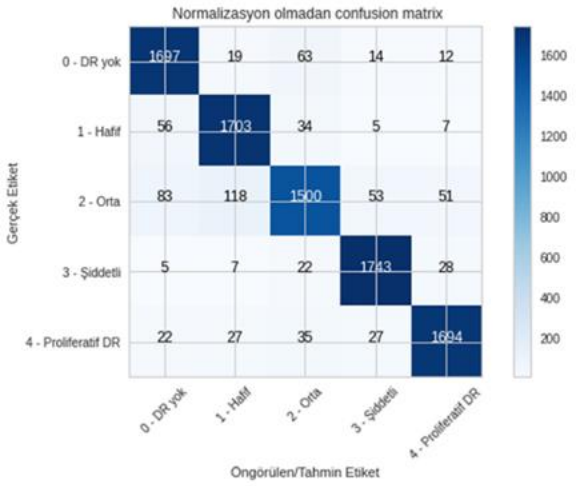
Tablo 4 incelendiğinde kullanılan yöntemler arasında yönelik olarak performans kıyaslaması yapabilmek amacıyla kullanılan makine öğrenme algoritmaları ve elde edilen sonuçları yer almaktadır.

Uygulanan algoritmalar içinde performans değerlendirme kriterlerine Ekstra Ağaçlar Algoritması %93'lük doğruluk, %93 duyarlılık ve %93'lük F1-skoru ile en başarılı sonucu yansıtmıştır.


Veri seti içinde yer alan gerçek etiket değerleri ile sınıflandırma işleminde kullanılan algoritmaların uygulanması sonucunda tahminlere yönelik elde edilen etiket değerlerin yer aldığı ve başarımlar değerlendirme metriklerinin hesaplandığı karmaşıklık matrisleri Şekil 8, Şekil 9 ve Şekil 10'da gösterilmektedir.



Şekil 8 K En yakın komşu algoritması ait karmaşıklık matrisi



Şekil 9. Rastgele orman Algoritmasına ait karmaşıklık matrisi



Şekil 10. Ekstra Ağaçlar Algoritmasına ait karmaşıklık matrisi

3.2. Tartışma

Diyabetik retinopati kan şekeriindeki dengesizliğe bağlı olarak meydana gelen görme bozukluğudur. Hastalığın tanısı manuel yöntemlerle doğru şekilde yapılamadığı için bu konuda derin öğrenme algoritmalarına ihtiyaç duyulmaktadır. Çalışmamızda görüntülere dayalı olarak hastalık teşhisi yapılmış ve sonuçlar raporlanmıştır. Sistemin eğitim ve test başarısını artırmak için bir transfer öğrenme modeli olan Resnet-50 e-ISSN: 2148-2683

kullanılmış olup model özellik çıkarımında destek olmuştur. Ayrıca, sınıf dengesizliği problemini ortadan kaldırmak için her bir sınıfta yer alan kayıtlar eşitlenmiş ve deneyler eşit sayıda elemanı olan sınıflar arasında yapılmıştır.

Yapılan çalışmanın sınıflandırma aşamasında üç farklı sınıflandırma algoritması kullanılarak sonuçlar 10-kat çapraz doğrulamaya göre elde edilmiştir.

Elde edilen sonuçlara göre; transfer öğrenme modelinin ve veri setindeki dengesizlik probleminin çözülmesinin sınıflandırma başarısına olumlu etki ettiği görülmüştür. Sınıflandırma sonuçlar literatür seviyesinde ve üstündedir. Dolayısıyla çalışmanın motivasyonuna uygun olarak derin öğrenme yöntemlerine dayalı hastalık teşhisi yüksek doğrulukla yerine getirilmiştir.

4. Sonuç

Bu çalışmada, diyabetik retinopati hastalığının derecelendirilmesine yönelik derin öğrenme ve makine öğreniminin birlikte kullanıldığı hibrit bir model önerilmiştir. Çalışmada kullanılan özellik çıkarımı için kullanılan ResNet-50 modeline retinaya ait 3662 adet renkli fundus görüntüsü uygulanmış ve bu görüntülere ait özellikler transfer öğrenme yöntemiyle elde edilmiştir. Çalışma sonucunda 3662 adet görüntü ve her bir görüntüye ait 2048 adet özellik elde edilmiştir. 3662 adet görüntü SMOTE yöntemi kullanarak sınıflar arasında dengesiz veri dağılımı sorunu giderilmiştir. SMOTE yönteminde yoğun olan sınıftaki eleman sayısına denk gelecek şekilde azınlık sınıftaki eleman sayısını artırma işlemi yapılmıştır. Bu teknik sonunda veri setimizdeki her bir sınıf için görüntü adedi yoğun olan sınıftaki eleman sayısı olan 1805 adet görüntüye eşitlenerek toplamda 9.025 adet veri ve her bir veriye ait 2048 adet özellik elde edilmiştir. Daha sonra bu veriler makine öğrenme algoritmalarından K en yakın komşu, Rastgele orman ve Ekstra ağaçlar Algoritmasına ayrı ayrı ait karmaşıklık matrisi ve 10 kat çapraz doğrulama işlemi uygulanarak eğitim ve test işlemi gerçekleştirilmiştir. Çalışma sonunda algoritmaların başarı sonuçları kıyaslanmıştır. Diyabetik retinopati hastalığının şiddetine göre beş kategori 'Proliferatif', 'Şiddetli', 'Orta', 'Hafif' ve 'Diyabetik retinopati yok' sınıflandırma işlemi sonucunda %93 lük doğruluk %93 lük F1-skoru elde edilmiştir.

*Bu çalışma; ikinci yazarın danışmanlığındaki birinci yazarın Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalı'nda yapmış olduğu "Evişimsel Sinir Ağları Kullanarak Diyabetik Retinopati Hastalığının Tespiti" başlıklı yüksek lisans tez çalışmasından üretilmiştir.

Kaynakça

- Abbas, Q., Fondon, I., Auxiliadora Sarmiento, S., Soledad Jiménez, S., & Alemany, P. (2017). Automatic recognition of severity level for diagnosis of diabetic retinopathy using deep visual features. *Med Biol Eng Comput*, 55, 1959–1974. <https://doi.org/10.1007/s11517-017-1638-6>
- APTOS2019. (2019). *Blindness Detection*. <https://www.kaggle.com/c/aptos2019-blindness-detection/overview/aptos-2019>.
- Çavuşoğlu, Ü., & Kaçar, S. (2019). Veri Madenciliği Algoritmaları ile Yeni Bir Saldırı Tespit Sistemi Tasarımı ve Performans Analizleri. *Academic Platform Journal of Engineering and Science*, 1–1.

- <https://doi.org/10.21541/apjes.418519>
- Coşansu, G. (2015). Diyabet: Küresel bir salgın hastalık. *Okmeydanı Tıp Dergisi*, 31(ek sayı), 1–6.
- Daş, R., Polat, B., & Tuna, G. (2019). Derin Öğrenme ile Resim ve Videolarda Nesnelerin Tanınması ve Takibi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(2), 571–581. <https://doi.org/10.35234/fumbd.608778>
- Date, R., Tarihi, K., & Date, A. (2018). *İzmir democracy university health sciences journal iduhs*. 13–22.
- Fernández, A., García, S., Herrera, F., & Chawla, N. V. (2018). SMOTE for Learning from Imbalanced Data: Progress and Challenges, Marking the 15-year Anniversary. *Journal of Artificial Intelligence Research*, 61, 863–905. <https://doi.org/10.1613/jair.1.11192>
- Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Mach Learn*, 63, 3–42. <https://doi.org/10.1007/s10994-006-6226-1>
- Ghosh, R., Ghosh, K., & Maitra, S. (2017). *Automatic Detection and Classification of Diabetic Retinopathy stages using CNN*. <https://www.kaggle.com/c/diabetic-retinopathy-detection/data>
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., Venugopalan, S., Widner, K., Madams, T., Cuadros, J., Kim, R., Raman, R., Nelson, P. C., Mega, J. L., & Webster, D. R. (2016). Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*, 316(22), 2402–2410. <https://doi.org/10.1001/jama.2016.17216>
- He, H., & Garcia, E. A. (2009). Learning from Imbalanced Data; Learning from Imbalanced Data. *IEEE Transactions on Knowledge and Data Engineering*, 21. <https://doi.org/10.1109/TKDE.2008.239>
- IDF. (2021). *IDF Diabetes Atlas | Tenth Edition*. <https://www.idf.org/news/240:diabetes-now-affects-one-in-10-adults-worldwide.html><https://diabetesatlas.org/atlas/tenth-edition/>
- Islam, M. R., Hasan, M. A. M., & Sayeed, A. (2020). Transfer Learning based Diabetic Retinopathy Detection with a Novel Preprocessed Layer. *2020 IEEE Region 10 Symposium, TENSYP 2020*, 888–891. <https://doi.org/10.1109/TENSYP50017.2020.9230648>
- Kashif Yaqoob, M., Farooq Ali, S., Bilal, M., Shehzad Hanif, M., Al-Saggaf, U. M., Kashif, M., Kareem, I., & Moazam Fraz, M. (2020). *ResNet Based Deep Features and Random Forest Classifier for Diabetic Retinopathy Detection † “Feature-based optimized deep residual network architecture for diabetic retinopathy detection”*. 1–6. <https://doi.org/10.3390/s21113883>
- Kızrak, M. A., & Bolat, B. (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 263–286. <https://doi.org/10.17671/gazibtd.419205>
- Kwasigroch, A., Jarzembinski, B., & Grochowski, M. (2018). Deep CNN based decision support system for detection and assessing the stage of diabetic retinopathy; Deep CNN based decision support system for detection and assessing the stage of diabetic retinopathy. *İçinde 2018 International Interdisciplinary PhD Workshop (IIPHDW)*. <https://doi.org/10.1109/IIPHDW.2018.8388337>
- Masood, S., Luthra, T., Sundriyal, H., & Ahmed, M. (2017). *Identification of Diabetic Retinopathy in Eye Images Using Transfer Learning*.
- Meltek, S., & Halit, Ç. (2021). *Matlab Ortamında Derin öğrenme Uygulamaları*. İksad Yayınevi.
- NEI. (2021). *Diabetic Retinopathy*. <https://www.nei.nih.gov/learn-about-eye-health/eye-conditions-and-diseases/diabetic-retinopathy>
- Özçelik, Y. B., & Altan, A. (2021). Diyabetik Retinopati Teşhisi için Fundus Görüntülerinin Derin Öğrenme Tabanlı Sınıflandırılması. *European Journal of Science and Technology*, 29, 156–167. <https://doi.org/10.31590/ejosat.1011806>
- Pratt, H., Coenen, F., Broadbent, D. M., Harding, S. P., & Zheng, Y. (2016). Convolutional Neural Networks for Diabetic Retinopathy. *Procedia Computer Science*, 90(July), 200–205. <https://doi.org/10.1016/j.procs.2016.07.014>
- Pulat, M., & Kocakoç, İ. D. (2021). Türkiye’de Makine Öğrenmesi ve Karar Ağaçları Alanında Yayınlanmış Tezlerin Bibliyometrik Analizi. *Manisa Celal Bayar Üniversitesi İ.İ.B.F YÖNETİM VE EKONOMİ*, 28(2), 287–308.
- Qummar, S., Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., Khan, I. A., & Jadoon, W. (2019). A Deep Learning Ensemble Approach for Diabetic Retinopathy Detection. *IEEE Access*, 7. <https://doi.org/10.1109/ACCESS.2019.2947484>
- Rastogi, A. (2022). *Resnet50*. <https://blog.devgenius.io/resnet50-6b42934db431>
- Ribani, R., & Marengoni, M. (2019). A Survey of Transfer Learning for Convolutional Neural Networks. *Proceedings - 32nd Conference on Graphics, Patterns and Images Tutorials, SIBGRABI-T 2019*, 47–57. <https://doi.org/10.1109/SIBGRABI-T.2019.00010>
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47–64. <http://dergipark.gov.tr/download/article-file/394923>
- Shaban, M., Ogur, Z., Mahmoud, A., Switala, A., Shalaby, A., Khalifeh, H. A., Ghazal, M., Fraiwani, L., Giridharan, G., Sandhu, H., & El-Bazid, A. S. (2020). *A convolutional neural network for the screening and staging of diabetic retinopathy*. <https://doi.org/10.1371/journal.pone.0233514>
- Shanthi, T., & Sabeenian, R. S. (2019). Modified Alexnet architecture for classification of diabetic retinopathy images. *Computers and Electrical Engineering*, 76. <https://doi.org/10.1016/j.compeleceng.2019.03.004>
- Sibel, İ. (2014). Diyabetik Retinopati ve Etiyopatogenezi. *Kocatepe Tıp Dergisi*, 15(2), 207–217.
- Takcı. (2020). *TEORİ VE UYGULAMADA VERİ MADENCİLİĞİ*. Nobel Akademik Yayıncılık.
- Taufiqurrahman, S., Handayani, A., Hermanto, B. R., & Mengko, T. L. E. R. (2020). Diabetic Retinopathy Classification Using A Hybrid and Efficient MobileNetV2-SVM Model. *IEEE Region 10 Annual International Conference, Proceedings/TENCON, 2020-Novem*, 235–240. <https://doi.org/10.1109/TENCON50793.2020.9293739>
- TEMED. (2020). *Diabetes Mellitus Ve Komplikasyonlarının Tanı, Tedavi Ve İzlem Kılavuzu (2020). 14. Baskı (Çevrimiçi Yayın) : 25 Haziran 2020*.
- TÜRKDİAB. (2019). *Diyabet Tanı ve Tedavi Rehberi*.
- Veranyurt, Ü., Deveci, A. F., & Esen, M. F. (2020). MAKİNE ÖĞRENMESİ TEKNİKLERİYLE HASTALIK SINIFLANDIRMASI: RANDOM FOREST, K-NEAREST NEIGHBOUR VE ADABOOST ALGORİTMALARI UYGULAMASI DISEASE CLASSIFICATION BY MACHINE LEARNING TECHNIQUES: RANDOM FOREST, K-NEAREST NEIGHBOR AND ADABOOST ALGORITHMS APPLICATIONS. *Usaysad Derg*, 6(2),

275–286. <http://dergipark.gov.tr/usaysad>

- WHO. (2021). *Diabetes*. World Health Organization. <https://www.who.int/news-room/fact-sheets/detail/diabetes>
- Yalcin, N., Alver, S., & Uluhatun, N. (2018). Classification of retinal images with deep learning for early detection of diabetic retinopathy disease. *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018*.