

Diyabetik Retinopati Tespiti İçin Derin Öğrenmeye Dayalı Sınıflandırma

Deep Learning-Based Classification for Diabetic Retinopathy Detection

Seda Nur Polater^{1*} 
Ali Hakan Işık² 

^{1*} Burdur Mehmet Akif Ersoy
Üniversitesi, Mühendislik Fakültesi,
Bilgisayar Mühendisliği Bölümü,
Burdur, Türkiye.

² Burdur Mehmet Akif Ersoy
Üniversitesi, Mühendislik Fakültesi,
Bilgisayar Mühendisliği Bölümü,
Burdur, Türkiye.

*Sorumlu Yazar:
sedanurpolater7@gmail.com

Geliş/Received: 26.01.2024;
Kabul/Accepted: 29.05.2024

Atf/Citation: Polater, S; Işık, A.
H. (2024). Diyabetik Retinopati
Tespiti İçin Derin Öğrenmeye
Dayalı Sınıflandırma. UMBD,
7(2), 13-19

Öz

Diyabetik Retinopati (DR), yüksek kan şekeri seviyelerinin retinadaki kan damarlarında neden olduğu hasar sonucu oluşan bir göz hastalığıdır. Bu hastalık, erken teşhis edilmediği ve tedavi edilmediği durumlarda ciddi göz sorunlarına ve görme kaybına yol açabilir. Genellikle kan şekeri kontrolü ve erken tedavi ile bu komplikasyonlar önlenebilir, ancak DR'nin karmaşıklığı nedeniyle manuel teşhis zorlu olabilir. Uzmanlar, bu tür zorlu teşhislerde Evrişimsel Sinir Ağları (ESA) gibi derin öğrenme modellerinin başarılı bir şekilde kullanıldığını göstermişlerdir. Bu çalışma, DR'nin teşhisi ve sınıflandırılması üzerine makine öğrenme algoritmaları kullanılarak tamamlanmıştır. Araştırma, Aptos 2019 veri setini kullanarak gerçekleştirilmiştir. Bu veri seti, farklı DR şiddetlerine sahip retina görüntülerini içermektedir, bu da "Proliferatif," "Şiddetli," "Orta," "Hafif," ve "Diyabetik retinopati yok" gibi sınıflandırmaları içerir. Hastalığın teşhisi için DenseNet121, MobileNetV2, DenseNet169, InceptionV3, VGG16, MobileNet, VGG19, ResNet50, ResNet101 modelleri kullanılmıştır. DenseNet121 modelinde %97 doğruluk değeri hesaplanmıştır.

Anahtar Kelimeler: Diyabetik Retinopati (DR), Kan Şekeri, Retina, Göz Hastalığı, Görme Kaybı

Abstract

Retinopathy (DR) is an eye disease caused by damage to the blood vessels in the retina caused by high blood sugar levels. This disease can lead to serious eye problems and vision loss if not diagnosed and treated early. These complications can often be prevented with blood sugar control and early treatment, but manual diagnosis can be challenging due to the complexity of DR. Experts have demonstrated the successful use of deep learning models such as Convolutional Neural Networks (ESA) in such challenging diagnoses. This study was completed using machine learning algorithms on the diagnosis and classification of DR. The research was conducted using the Aptos 2019 dataset. This dataset contains retinal images with different DR severities, including classifications such as "Proliferative," "Severe," "Moderate," "Mild," and "No diabetic retinopathy." DenseNet121, MobileNetV2, DenseNet169, InceptionV3, VGG16, MobileNet, VGG19, ResNet50, ResNet101 models were used to diagnose the disease. 97% doğruluk value was calculated in the DenseNet121 model.

Keywords: Diabetic Retinopathy (DR), Blood Glucose, Retina, Eye Disease, Vision Loss

1. Giriş

Diyabet, pankreasın yetersiz insülin üretmesi veya vücudun insülini etkili bir şekilde kullanamaması sonucunda kan içindeki glikoz seviyelerinin arttığı kronik bir hastalıktır. Normalde insülin, vücut hücrelerinin glikozu enerji kaynağı olarak kullanmasına yardımcı olur ve kan şekerini dengelemeye yardımcı olur. İnsülin eksikliği veya etkisizliği durumunda, kan içindeki glikoz seviyeleri yükselir ve kişi diyabetik olabilir. Dünya genelinde diyabet, önemli bir sağlık sorunu haline gelmiştir. Uluslararası Diyabet Federasyonu'nun verilerine göre, 2017 yılında dünya genelinde yaklaşık 451 milyon yetişkinin diyabet ile mücadele ettiği tahmin edilmektedir. Çin, Hindistan ve ABD gibi ülkeler, diyabetin en yaygın olduğu ülkeler arasında yer almaktadır (Öcal ve Önsüz, 2018).

Diyabetin uzun süreli etkilerinden biri de diyabetik retinopati olarak adlandırılan göz hastalığıdır. Bu durum, diyabetin ileri evrelerinde görülebilir ve körlüğe neden olabilmektedir. Dünya genelindeki körlük vakalarının %2.6'sının sebebi diyabetik retinopatidir (Öcal ve Önsüz, 2018). Bu nedenle, diyabet hastalarının göz sağlığını korumak için düzenli retina taramaları yapılmalı ve olası riskler erken aşamada teşhis edilmelidir. Diyabet genellikle belirli semptomlarla ilişkilendirilir. Bunlar arasında ağız kuruluğu, aşırı veya az iştah, aşırı susama, sık idrara çıkma, gece sık idrara çıkma, bulanık görme, kilo kaybı, uyuşma ve karıncalanma hissi, idrar yolu enfeksiyonları, cilt sorunları, halsizlik gibi belirtiler yer alır. Uluslararası Diyabet Federasyonu'nun 2021 verilerine göre, dünya genelinde 20-79 yaş arasındaki yetişkinlerin yaklaşık %10,5'u diyabet hastasıdır (Tetik, 2023). Bu, yaklaşık 537 milyon yetişkinin diyabetle mücadele ettiği anlamına gelir. Federasyon, diyabetin hızla artan küresel bir sağlık sorunu olduğunu belirtmekte ve 2030 yılına kadar bu rakamın %11,3'e, 2045 yılında ise %12,2'ye yükselebileceğini tahmin etmektedir (Tetik, 2023). Bu veriler, diyabetin yaygınlığını ve küresel etkisini vurgulamaktadır.

Diyabetik retinopati (DR), şeker hastalığına bağlı olarak göz retinasındaki ışığa duyarlı dokuyu etkileyen kan damarlarının hasar görmesi sonucu gelişen bir göz hastalığıdır. DR, yavaşça ilerleyebilir veya ani bir şekilde ortaya çıkabilir. Aynı zamanda bazen kendiliğinden iyileşme gösterebilir, ancak ilerlerse kısmi veya kalıcı görme kaybına neden olabilmektedir. Diyabet hastaları arasında, tip 1, tip 2 ve gestasyonel diyabet dahil olmak üzere uzun süreli şeker hastalığına sahip kişilerde DR riski bulunmaktadır (Paydaş, 2019).

Bu araştırmada, DenseNet121, MobileNetV2, DenseNet169, InceptionV3, VGG16, MobileNet, VGG19, ResNet50, ResNet101 gibi farklı modeller kullanılmıştır. Diyabetik retinopati hastalığının teşhisi genellikle zor ve maliyetlidir. Bu çalışmanın hem hastalık teşhisinde hem de hastalığın evrelerinin belirlenmesinde faydalı olabileceği öngörülmektedir. Araştırma, bu modellerin retinopati hastalığıyla ilgili tanı ve evre belirleme süreçlerindeki etkinliğini değerlendirmeyi amaçlamaktadır.

1.1 Literatür Taraması

Gulshan ve diğerleri (2016) tarafından yürütülen çalışmada, diyabetik retinopatiyi sınıflandırmak için Messidor-2 (1748 görüntü) ve EyePACS-1 (9963 görüntü) veri kümesi kullanılmıştır. Sınıflandırmada transfer öğrenme modeli olarak Inception-V3 kullanılmıştır. Bu çalışmanın sonuçlarına göre, EyePACS veri seti için %98,1 özgüllük ve %90,3 duyarlılık elde edilmiş, Messidor-2 veri seti için ise %87 duyarlılık ve %98,5 özgüllük değerleri elde edilmiştir (Gulshan ve ark., 2016).

Shanthi ve Sabeenian (2019) tarafından yürütülen bir çalışmada, diyabetik retinopatiyi sınıflandırmak amacıyla Messidor veri seti kullanılmıştır. Bu çalışmada, veri setinde bulunan retina görüntülerini otomatik olarak dört farklı kategoriye ayırmak için AlexNet tabanlı bir mimari kullanılmıştır. Çalışmanın sonuçlarına göre, sağlıklı kategorisi için %96.6, evre 1 kategorisi için %96.2, evre 2 kategorisi için %95.6 ve evre 3 kategorisi için %96.6 doğruluk değerleri elde edilmiştir (Shanthi ve Sabeenian, 2019).

Özçelik ve Altan (2021) tarafından gerçekleştirilen bir çalışmada, diyabetik retinopatinin daha erken teşhis ve tedavisi için APTOS 2019 veri setini kullanmışlardır. Geliştirilen model iki aşamadan oluşmaktadır. İlk aşamada, modelin aşırı öğrenmesini engellemek için iki boyutlu sinyal işleme tekniğini görüntüleme

uygulamışlardır. İkinci aşamada ise ESA tabanlı VGG-19 mimarisi ile transfer öğrenme modelini kullanarak, diyabetik retinopatiyi 5 farklı kategoriye sınıflandırmışlardır. Bu önerilen modele yönelik yapılan sınıflandırma sonuçlarına göre, doğruluk %97,8, kesinlik %97,6, geri çağırma %97,7 ve F1-skoru %97,6 olarak elde edilmiştir (Özçelik ve Altan, 2021).

2. Materyal ve Metot


2.1 Veri Seti

Çalışmada kullanılan veri seti, Asya Pasifik Tele-oftalmoloji Derneği'nin (APTOS) halka açık olarak sunulan APTOS 2019 veri setidir (Blindness detection, 2019). Bu veri seti, göz sağlığı ile ilgili körlüğü belirlemeye yönelik bir yarışma sırasında oluşturulmuştur. APTOS 2019 veri seti, toplamda 3,662 renkli retina görüntüsünü içermektedir. Bu görüntüler, fundus fotoğrafçılığı kullanılarak elde edilmiştir ve farklı çözünürlüklerde çekilmiştir. Görüntüler, retina durumu ve diyabetik retinopatinin şiddet seviyelerine göre sınıflandırılmıştır.

Tablo 1. Veri setindeki hastalık şiddeti seviyelerinin dağılımı

Kriter	DR Durumu	Görüntü Sayısı
0	DR Yok	1805
1	Hafif	370
2	Orta Düzeyde	999
3	Şiddetli	193
4	Proliferatif DR	295

Uzmanlar, her görüntüyü retinanın normal durumu ve diyabetik retinopatinin şiddeti açısından 0 ila 4 arasında bir derecede değerlendirmiştir. Bu değerlendirme sonucunda görüntüler 5 sınıfa ayrılmıştır. Hastanın retinası normaldir (DR Yok), hastanın hafif proliferatif olmayan retinopatisi vardır (Hafif DR), hastanın orta derecede proliferatif olmayan retinopatisi vardır (Orta DR), hastanın şiddetli proliferatif olmayan retinopatisi vardır (Şiddetli DR) ve hastada proliferatif retinopati bulunmaktadır (Proliferatif DR) şeklindedir.



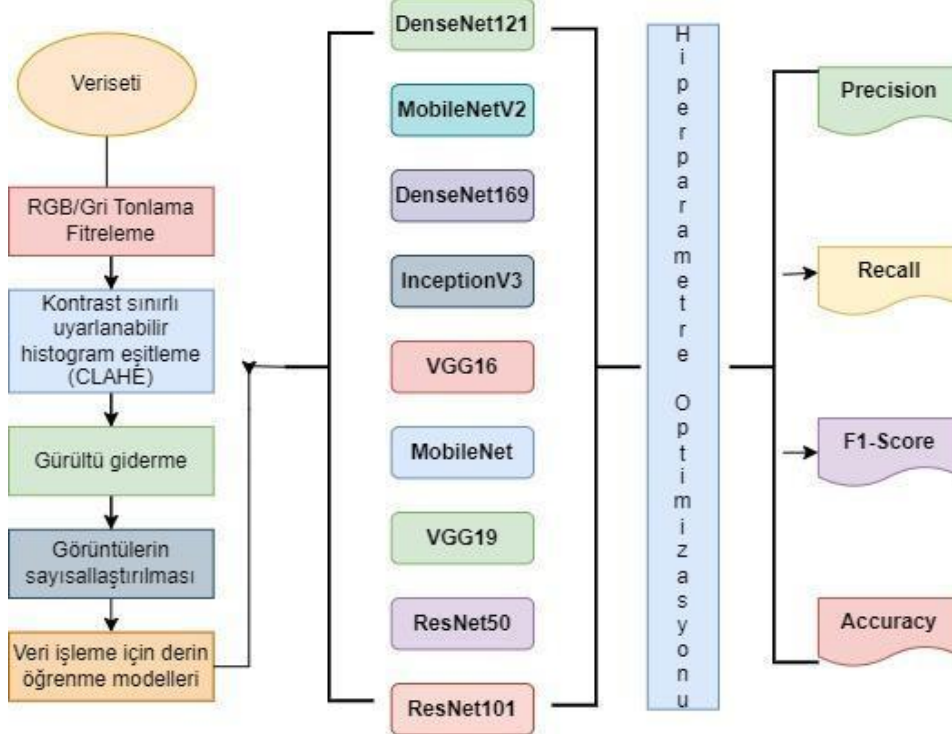
Şekil 1. APTOS veri kümesi sınıflarındaki görüntüler (Blindness detection, 2019)

2.2. Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (ESA), özellikle görüntü odaklı görevlerde kullanılan bir yapay sinir ağı türüdür. ESA, görüntü özelliklerini kodlarken daha az parametre kullanarak ağı daha uygun hale gelmesine olanak tanır. Ancak bazı durumlarda overfitting (aşırı uyum) yaşanabilir. Overfitting, ağı verilere aşırı uyum sağlayarak ezber yapmasıdır (Özsoy, 2022). Bu sorunu önlemek için daha az parametre kullanılabilir. ESA'da, giriş katmanına görüntü verisi eklenir ve evrişim katmanında özellik haritaları elde edilir. Evrişim katmanı, görüntüleri dönüştüren evrişim filtrelerini kullanarak özellik haritaları oluşturur. Bu katman, modelin karmaşıklığını azaltmak için depth (derinlik), stride (adım kaydırma) ve zero-padding (sıfır ekleme) gibi işlemleri uygular. ESA'nın performansını artırmak için uygun aktivasyon fonksiyonları seçilir, genellikle ReLU aktivasyon fonksiyonu tercih edilir (Njikam, 2022). Pooling katmanı boyut azaltmak için

kullanılırken, Dropout katmanı ezberlemenin önüne geçmek için bazı düğümleri geçici olarak kapatır (Cangöz, 2022). Tam bağlantılı katmanda önceki katmandaki nöronlar bu katmana bağlanır ve sınıflandırma işlemi için softmax sınıflandırıcısı kullanılabilir. Ayrıca, sınıflandırma için DVM gibi alternatif yöntemler de tercih edilebilir. Bu çalışmada DenseNet121, MobileNetV2, DenseNet169, InceptionV3, VGG16, MobileNet, VGG19, ResNet50, ResNet101 modelleri kullanılmıştır. ESA, verilen ham bir görüntünün sınıflandırılabilir temel özellikleri yüksek doğruluk oranında belirleyebilmeyi hedeflemektedir (Mustafa, 2022). İnsan soyutlama yeteneğini örnek alarak, ESA, bir görüntüyü incelediğimizde o görüntünün temel özelliklerini ortaya çıkartarak ve hangi nesneye ait olduğunu sınıflandırarak çalışır.

ESA, verilen ham görüntüyü parçalara ayırır ve her parçaya filtre uygulayarak bu parçalar arasında ilişki kurup tanıma işlemi gerçekleştirir. Evrişimsel katmanın dört temel bileşeni şunlardır: Evrişim katmanı (Convolution layer), Biriktirme katmanı (Pooling Layer), İletim sönümü katmanı (Dropout Layer) ve Düzleştirme katmanı (Flatten Layer). Evrişim (Convolution), girdi ve filtre matrisleri arasında matematiksel bir işlemdir ve çıktısı bir matristir (Metin ve Karasulu, 2022). Piksel ekleme (padding), evrişim işleminden sonra girdi ve çıktı matrisleri arasındaki boyut farkını kontrol etmek amacıyla uygulanır ve görüntünün daha doğru analiz edilmesine olanak tanır. Kaydırma adımı (stride), çekirdek (kernel) matrisinin girdi matrisi üzerinde kaç adımda taşınacağını belirler (Metin ve Karasulu, 2022). Örneğin, kaydırma adımı sayısının 1 olması durumunda filtreler 1 piksel ile taşınmaktadır. Biriktirme (Pooling), ESA'nın büyük görüntüler üzerinde parametre sayısını azaltarak küçültme işlemi yapmasını sağlayan önemli bir bileşendir. Maksimum ve ortalama biriktirme olmak üzere iki yöntemi bulunmaktadır. İletim sönümü (Dropout), uzun süren eğitim sürecine sahip karmaşık ağlarda aşırı öğrenmeyi önlemek amacıyla kullanılır. Bu katman, bazı sinir düğümlerinin eğitim sırasında unutulmasını sağlayarak aşırı öğrenmeyi engeller. Düzleştirme (Flattening), evrişimli veya havuzlama katmanlarından elde edilen veriyi tam bağlantı katmanında kullanılabilmesi için düzenleyen bir katmandır (Metin ve Karasulu, 2022).



Şekil 2. Diyabetik retinopati akış şeması

Şekil 2'de diyabetik retinopati teşhisinde kullanılan derin öğrenme modellerinin performansını değerlendirmek amacıyla tasarlanmış bir akış diyagramı ele alınmaktadır. Çalışma kapsamında kullanılan adımlar, filtreleme, ön işleme, model seçimi, eğitim, hiperparametre optimizasyonu ve sonuç değerlendirmesi gibi temel aşamaları içermektedir. Bu temel aşamalarda diyabetik retinopati teşhisi için

kullanılacak olan görüntü veri setini toplamaktadır. Bu veri seti, renkli (RGB) görüntüler içermektedir. Toplanan veri seti, gri tonlama filtrelemesi uygulanarak gri tonlamalı hale getirilmektedir. Kontrast sınırlı uyarlanabilir histogram eşitleme tekniği kullanılarak görüntülerin kontrastı artırılır ve anormallikler belirgin hale getirilmektedir. Gürültü giderme adımı, elde edilen görüntülerden istenmeyen gürültüleri temizlemektedir. Hazırlanan görüntüler, derin öğrenme modellerine uygun hale getirilmek üzere sayısallaştırılmaktadır. Çalışmada, DenseNet121, MobileNetV2, DenseNet169, InceptionV3, VGG16, MobileNet, VGG19, ResNet50, ResNet101 gibi popüler derin öğrenme modelleri seçilmektedir. Seçilen modeller, eğitim veri seti üzerinde eğitilir ve hiperparametre optimizasyonu gerçekleştirilmektedir. Bu aşama, modellerin genelleme yeteneklerini artırmak amacıyla yapılmaktadır. Eğitilen modeller, test veri seti üzerinde değerlendirilmektedir. Precision, recall, F1-score ve doğruluk gibi performans ölçütleri hesaplanarak her modelin teşhis başarısı değerlendirilmektedir. Elde edilen sonuçlar, her bir modelin diyabetik retinopati teşhisi konusundaki etkinliğini göstermektedir. Bu değerlendirmeler, her modelin güçlü ve zayıf yönlerini belirlemek için kullanılmaktadır. Bu akış diyagramı, diyabetik retinopati teşhisi sürecinde kullanılan adımları ayrıntılı bir şekilde açıklamaktadır. Her bir aşama, çalışmanın temel bulgularına ulaşmak için önemli bir taşıyıcıdır ve derin öğrenme modellerinin etkin bir şekilde kullanılmasını amaçlamaktadır.

3. Deneysel Çalışma ve Bulgular

Bu çalışma, çeşitli derin öğrenme modelleri ve farklı veri setleri üzerinde yürütülen araştırmaların diyabetik retinopati teşhisindeki etkinliği ve potansiyelini ortaya koymaktadır. Yapılan çalışmaların sınıflandırma sonuçlarının karşılaştırılmasıyla elde edilen Tablo 2'de çeşitli modellere göre precision, recall, F1-score ve doğruluk değerleri sunulmuştur. Precision, bir sınıflandırma modelinin pozitif olarak tahminlediği örneklerin gerçekte pozitif olan örnekler arasındaki oranı gösterir. Recall, gerçekte pozitif olan örneklerin model tarafından ne kadarının doğru bir şekilde tespit edildiğini ifade eder. F1-score, precision ve recall değerlerinin bir harmonik ortalamasıdır ve bu sayede her iki metriği dengelemeye çalışır. Doğruluk ise tüm sınıfların doğru bir şekilde tahmin edilme oranını ifade eder, yani doğru tahmin edilen örneklerin toplam örnek sayısına oranını gösterir (Özdemir, 2023). Bu metrikler, sınıflandırma modellerinin performansını değerlendirmek ve modelin ne kadar doğru tahmin yaptığını anlamak için kullanılır. DenseNet121 modelinde precision değeri %97, recall değeri %97, f1-score değeri %97 ve doğruluk değeri %97 olarak elde edilmiştir. MobileNetV2 modelinde precision değeri %96, recall değeri %96, f1-score değeri %96 ve doğruluk değeri %96 olarak elde edilmiştir. DenseNet169 modelinde precision değeri %96, recall değeri %96, f1-score değeri %96 ve doğruluk değeri %96 olarak elde edilmiştir. InceptionV3 modelinde precision değeri %96, recall değeri %96, f1-score değeri %96 ve doğruluk değeri %96 olarak elde edilmiştir. Vgg16 modelinde precision değeri %96, recall değeri %96, f1-score değeri %96 ve doğruluk değeri %96 olarak elde edilmiştir. MobileNet modelinde precision değeri %95, recall değeri %95, f1-score değeri %95 ve doğruluk değeri %95 olarak elde edilmiştir. VGG19 modelinde precision değeri %94, recall değeri %94, f1-score değeri %94 ve doğruluk değeri %94 olarak elde edilmiştir. ResNet50 modelinde precision değeri %91, recall değeri %91, f1-score değeri %91 ve doğruluk değeri %91 olarak elde edilmiştir. ResNet101 modelinde precision değeri %88, recall değeri %88, f1-score değeri %88 ve doğruluk değeri %88 olarak elde edilmiştir.

Tablo 2. Performans Metrikleri

Ölçüt	Formül
Precision	$TP/(TP+FP)$
Recall	$TP/(TP+FN)$
F1-Score	$2 * (Precision * Recall)/(Precision+Recall)$
Doğruluk	$(TP+TN)/(TP+TN +FP+FN)$

Tablo 3. Yapılan çalışmaların sonuçlarının karşılaştırılması

Model	Precision	Recall	F1-Score	Doğruluk
DenseNet121	0,97826	0,9782	0,9782	0,97
MobileNetV2	0,96735	0,9673	0,9673	0,96

DenseNet169	0,96577	0,96458	0,96459	0,96
InceptionV3	0,96244	0,96185	0,96189	0,96
VGG16	0,96185	0,96185	0,96186	0,96
MobileNet	0,95686	0,9564	0,95639	0,95
VGG19	0,94322	0,94278	0,94283	0,94
ResNet50	0,91912	0,91826	0,91825	0,91
ResNet101	0,88633	0,88556	0,88571	0,88

Bu arařtırmaların sonuçları, diyabetik retinopatinin erken teřhisi ve tedavisi iin yapay zekanın ve derin renmenin nemli bir potansiyele sahip olduėunu vurgulamaktadır. Farklı modellerin ve veri setlerinin kullanılmasıyla elde edilen sonuçlar, gelecekteki diyabetik retinopati teřhis ve tedavi yntemlerinin geliřtirilmesine ışık tutabilir. Bu alıřmalar, tıbbi grntleme alanında yapay zek tabanlı tekniklerin kullanımının nemini ve potansiyelini gstererek literatre katkı saėlamaktadır. Bu alanda yapılan alıřmalar, diyabetik retinopati teřhisinde derin renme modellerinin etkin bir biimde kullanılmasını ve hastalık ynetimindeki nemini vurgulamaktadır. Elde edilen bulgular, farklı derin renimi yaklařımlarının performansını lmek iin kullanılmıřtır. zellikle, DenseNet121 Modeli'nin yksek doėruluk deėeri dikkat kicidir ve bu yntemin diėerlerine gre daha iyi bir performans sergilediėi grlmektedir.

Literatr alıřmaları, derin renme tekniklerinin diyabetik retinopati hastalıėının teřhisinde, seyrinin takibinde ve hastalıkla iliřkili faktrlerin anlaşılmasında diėer geleneksel yntemlere gre daha yksek bařarı oranlarına sahip olduėunu gstermektedir (Gnay ve ark., 2022). Bu da derin renme tekniklerinin hastalıėın etkilerini azaltma, tedavi srelerini geliřtirme ve daha iyi bir hasta ynetimi iin nemli bir potansiyel sunduėunu ortaya koymaktadır.

4. Sonu

Bu alıřma, Diyabetik Retinopati hastalıėının tespit edilmesi amacıyla geliřtirilen derin renme modellerini incelemektedir. Toplamda dokuz farklı Evriřimli Sinir Aėı (CNN) mimarisi incelenmiřtir. Deneyler sonucunda, DenseNet121 mimarisi kullanılarak elde edilen en yksek bařarı oranı %97 olarak belirlenmiřtir. Bu sonuçlar, potansiyel bir retinopati tespit aracı olarak deėerlendirilebilir. Modelin eėitiminde kullanılan veri seti ve optimize edilmiř parametrelerin detaylı bir řekilde incelenmesinin bařarıyı artıracadıėı dřnlmektedir. Gelecekte yapılacak alıřmalar, modelin genelleme yeteneėini geliřtirmek ve daha geniř, genellenebilir sonuçlar elde etmek amacıyla yeni alıřmalar yapılması nerilmektedir. Bu arařtırma, diyabetik retinopati hastalıėının teřhisinde yeni bir bakıř aısı sunarken, ilerleyen alıřmalar iin nemli bir temel oluřturacadıėı dřnlmektedir. Geleneksel teřhis yntemlerinin sınırlılıklarına raėmen, yapay zeka byk veri analizi, derin renme algoritmaları ve grnt iřleme teknikleri kullanarak erken hastalık teřhisine destek olabileceėi dřnlmektedir. Ayrıca dzenli hasta muayeneleri ve takibinin gerekliliėini azaltarak, saėlık sistemleri zerindeki yk hafifletebileceėi ngrlmektedir.

Kaynaklar

Blindness detection. (2019, 25 Aralık). In Kaggle. <https://www.kaggle.com/competitions/aptos2019-blindness-detection>

Cangz, G. B. (2022). *Kpeklerin uzun kemiklerinin ve uzun kemiklerindeki kırıkların sınıflandırılması*. (Tez No. 718172) [Yksek Lisans Tezi, Bařkent niversitesi, Fen Bilimleri Enstits]. YK Ulusal Tez Merkezi.

Gulshan, V., Peng, L., Coram, M., Stumpe, C., Wu, M., Narayanaswamy, D., & 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://www.doi.org/10.1001/jama.2016.17216>

- Günay Şener, A. B., & Şener, H. (2022, 26 Ekim - 29 Kasım). Diyabetik Gözlerde Multifokal Elektoretinografide Halka Amplitüdünün ve Halka Amplitüdünü Etkileyen Faktörlerin Değerlendirilmesi [Bildiri sunumu]. 23. Ulusal ve 6. Uluslararası Biyoistatistik, Ankara. <https://www.medicine.ankara.edu.tr/2022/10/07/23-ulusal-ve-6-uluslararasi-biyoistatistik-kongresi-26-29-ekim-2022/>
- Metin, B., & Karasulu, B. (2022). Derin Öğrenme Modellerini Kullanarak İnsan Retinasının Optik Koherans Tomografi Görüntülerinden Hastalık Tespiti. *Veri Bilimi*, 5(2), 9-19. <https://dergipark.org.tr/en/pub/veri/issue/74116/1183777>
- Mustafa, G. (2022, 10 Kasım). Tokat Bölgesi Buğday Üretiminde Bazı Yabancı Otların Derin Öğrenme Yöntemi ile Tespit Edilmesi. <https://aperta.ulakbim.gov.tr/record/252241>
- Njikam, M. N. M. (2022). *Sefalometrik noktaların derin öğrenme kullanarak otomatik tespiti*. (Tez No. 715056) [Yüksek Lisans Tezi, Konya Teknik Üniversitesi, Fen Bilimleri Enstitüsü]. YÖK Ulusal Tez Merkezi.
- Öcal, E. E., & Önsüz, M. F. (2018). Diyabet hastalığının ekonomik yükü. *Estüdam Halk Sağlığı Dergisi*, 3(1), 24-41. <https://dergipark.org.tr/en/pub/estudamhsd/issue/39510/466120>
- Özbay, A. F., & Özbay, E. (2022). Diyabetik retinopati tespiti için atom arama optimizasyonu ile özellik seçimi yöntemi. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 9(16), 88-104. <https://www.doi.org/10.54365/adyumbd.1021738>
- Özçelik, B. Y., & Altan, A. (2021). Diyabetik retinopati teşhisi için fundus görüntülerinin derin öğrenme tabanlı sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, 9(29), 156-167. <https://www.doi.org/10.31590/ejosat.1011806>
- Özdemir, A. (2023). Makine Öğrenmesi Algoritmaları ile Aritmilerin Sınıflandırılması. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 39(3), 394-402. <https://dergipark.org.tr/en/pub/erciyesfen/issue/82292/1341157>
- Özsoy, Y. (2022). *Sağlık alanında derin öğrenme yöntemlerinin incelenmesi*. (Tez No. 739042) [Yüksek Lisans Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü]. YÖK Ulusal Tez Merkezi.
- Paydaş, Ü. (2019). *Gestasyonel diyabet riskinin belirlenmesinde tip 2 diyabet risk anketinin (findrisk) kullanımı*. (Tez No. 598892) [Yüksek Lisans Tezi, Adnan Menderes Üniversitesi, Sağlık Bilimleri Enstitüsü]. YÖK Ulusal Tez Merkezi.
- Shanthi, T., & Sabeenian, S., R. (2019). Modified alexnet architecture for classification of diabetic retinopathy images. *Computers & Electrical Engineering*, 76(1), 56-64. <https://www.doi.org/10.1016/j.compeleceng.2019.03.004>
- Tetik, R. F. (2023). *Tip 2 diyabetli bireylerde sağlık okuryazarlığının kardiyovasküler hastalık riski farkındalığı ve glisemik kontrol üzerine etkisi*. (Tez No. 808158) [Yüksek Lisans Tezi, Aksaray Üniversitesi Sağlık Bilimleri Enstitüsü]. YÖK Ulusal Tez Merkezi.