



T.C.
KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KORNEA ÜLSERİNİ TESPİTİNDE GENETİK
ALGORİTMA TEMELLİ ÖZNİTELİK SEÇİMİNİN
TRANSFER ÖĞRENME ÜZERİNDEKİ ETKİSİ**

TUĞBA İNNECİ

**YÜKSEK LİSANS TEZİ
ENFORMATİK ANABİLİM DALI**

KAHRAMANMARAŞ 2023

T.C.
KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KORNEA ÜLSERİNİ TESPİTİNDE GENETİK
ALGORİTMA TEMELLİ ÖZNİTELİK SEÇİMİNİN
TRANSFER ÖĞRENME ÜZERİNDEKİ ETKİSİ**

TUĞBA İNNECİ

YÜKSEK LİSANS TEZİ
Enformatik Ana Bilim Dalı

KAHRAMANMARAŞ 2023

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada, alıntı yapılan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

Tuğba İNNECİ

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

KORNEA ÜLSERİNİ TESPİTİNDE GENETİK ALGORİTMA TEMELLİ ÖZNİTELİK SEÇİMİNİN TRANSFER ÖĞRENME ÜZERİNDEKİ ETKİSİ (YÜKSEK LİSANS TEZİ)

TUĞBA İNNECİ

ÖZET

Kornea ülseri kalıcı hasar bırakan en önemli göz hastalıklarından biridir. Bu hastalığı tespit etmek için sınırlı sayıda hassas teknik mevcuttur. Son yıllarda, derin sinir ağları (DNN) çok sayıda sınıflandırma problemini önemli ölçüde çözmüştür. Bununla birlikte çok sayıda katman ve ağırlığa sahip bir DNN kullanarak makul sınıflandırma performansı elde etmek için çok sayıda örneğe ihtiyaç duyulmaktadır. Çok sayıda örnek içeren bir veri kümesi toplamak genellikle zor ve zaman alıcı bir süreç olduğundan, AlexNet, ResNet ve DenseNet gibi büyük ölçekli önceden eğitilmiş DNN'ler, transfer öğrenme tekniklerinden yararlanılarak az sayıda örnek içeren bir veri kümesini sınıflandırmak için kullanılabilir. Önceden eğitilmiş DNN'ler genel olarak başarılı sonuçlar sunmasına rağmen bazı durumlarda çok sayıda parametre, ağırlık ve katmanda bağlı olarak sürekli tekrar eden gereksiz özniteliklerin ortaya çıkması nedeniyle sınıflandırma performansları düşük kalabilmektedir. Önerilen teknik, genetik algoritma kullanarak katmanlardaki görüntüleri sistematik bir şekilde seçerek bu gereksiz öznitelikleri ortadan kaldırmaktadır. Önerilen yöntem ResNet üzerinde kornea ülserlerini sınıflandıran küçük ölçekli bir veri kümesi ile test edilmiştir. Sonuçlara göre, önerilen yöntem geleneksel yaklaşımlara kıyasla sınıflandırma performansını önemli ölçüde artırmıştır.

Anahtar Kelimeler: Kornea ülseri, Derin sinir ağları, Genetik algoritma, Transfer öğrenme

Kahramanmaraş Sütçü İmam Üniversitesi
Fen Bilimleri Enstitüsü
Enformatik Ana Bilim Dalı, Şubat/ 2023

Danışman: Dr. Öğr. Üyesi Hasan BADEM

Sayfa sayısı: 56

**THE EFFECT OF GENETIC ALGORITHM-BASED FEATURE SELECTION ON
TRANSFER LEARNING TO THE DETECTION OF CORNEAL ULCER
(M.Sc. THESIS)**

TUĞBA İNNECİ

ABSTRACT

Corneal ulcer is one of the most important eye diseases with permanent damage. There exist limited soft technique available for detecting this disease. In recent years, deep neural networks (DNN) have significantly solved numerous classification problems. However, many samples are needed to obtain reasonable classification performance using a DNN with a huge amount of layers and weights. Since collecting a data set with a large number of samples is usually a difficult and time-consuming process, very large-scale pre-trained DNNs such as AlexNet, ResNet and DenseNet, can be adapted to classify a dataset with a small number of samples thanks to the utility of transfer learning techniques. Although such pre-trained DNNs produce successful results in some cases, their classification performances can be low due to many parameters, weights and the emergence of redundancy features that repeat themselves in the many layers in some other cases. The proposed technique removes these unnecessary features by systematically selecting images in the layers using a genetic algorithm. The proposed method has been tested to classify corneal ulcers on ResNet with a small-scale dataset. According to the results, the proposed method significantly increased the classification performance compared to the conventional approaches.

Keywords: Corneal ulcer, Deep neural networks, Genetic algorithm, Transfer learning

Kahramanmaraş Sütçü İmam University
Graduate School of Natural and Applied Sciences
Department of Informatics, February / 2023

Supervisor: Assist. Prof. Dr. Hasan BADEM

Page number: 56

TEŞEKKÜR

Tez danışmanım Dr. Öğr. Üyesi Hasan BADEM'e bilimsel katkılarıyla beni aydınlattığı, ilgi ve desteğini esirgmeden akademik olarak gelişimime en büyük katkıyı sağladığı için teşekkür etmek isterim. Tez çalışmamda beni cesaretlendirmesi paha biçilemezdi.

Akademik gelişimime teşvik eden, her konuda beni destekleyen yöneticim Adam O'Rahilly'e teşekkürlerimi sunmak istiyorum. Bu çalışmayı onun desteği olmadan yapamazdım. En güzel anıları birlikte biriktirdiğimiz yakın arkadaşlarım Serpil Yücel ve Merve Acet'e yanımda oldukları için teşekkür ederim.

Teşekkürü borç bildiğim anneme bu satırlarda yer vermek istiyorum. Başarılarımın mimari, her zaman yanımda olan, yorulduğumda kalkmayı öğreten annem Eşe Ersin'e teşekkürlerimi sunmak istiyorum. Geleceğimizi emanet edeceğimiz yeğenlerim Tuğba İnneci ve Tülin İnneci'ye teşekkür ederim. Geleceğe dair umutlarımı yeşerttiğiniz için size minnettarım.

Tuğba İNNECİ

İÇİNDEKİLER

Sayfa No

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ	v
ÇİZELGELER DİZİNİ	vi
KISALTMALAR DİZİNİ	vii
1. GİRİŞ.....	1
2. GENEL BİLGİLER ve LİTERATÜR DERLEMESİ	4
2.1. Göz.....	4
2.2. Gözün Yapısı	4
2.3. Görme Süreci.....	7
2.4. Gözün önemi.....	8
2.5. Göz Hastalıklarının Teşhisi	8
3. MATERYAL ve METOT.....	11
3.1. Materyal	11
3.2. Evrişimli Sinir Ağları	11
3.2.1. Evrişimli sinir ağı(CNN) katmanları.....	12
3.2.2. Erişimsel sinir ağı mimarileri.....	16
3.3. Transfer Öğrenme	18
3.4. Artık Sinir Ağları (ResNet)	19
3.5. Genetik Algoritma (GA)	22
3.6. Destek Vektör Makineleri(SVM)	23
3.7. Önerilen Yöntem.....	24
3.7.1. Veri Seti	28
4. DENEYSEL SONUÇLAR VE TARTIŞMA	30
4.1. Deneysel Yapı	30
4.2. ResNet üzerinden Kornea Ülserinin Sınıflandırma Başarımı	32
4.3. Önerilen Yöntemin Sınıflandırma Başarımı.....	34
4.4. İstatistiksel Analiz.....	36
4.5. Sonuçların literatürle kıyaslanması ve zaman analizi	37
5. TARTIŞMA, SONUÇLAR VE ÖNERİLER.....	38
6. KAYNAKLAR.....	39
7. ÖZ GEÇMİŞ.....	46

ŞEKİLLER DİZİNİ

Şekil 2.1. Gözün yapısı [24]	4
Şekil 2.2. Kornea yapısı [29]	5
Şekil 2.3. İris yapısı [31]	6
Şekil 2.4. Gözde görme süreci [40]	8
Şekil 3.1. Örnek bir EK ile öznitelik çıkarımı [58]	12
Şekil 3.2. Genel CNN mimarisi [59]	13
Şekil 3.3. 3x3'lük filtrenin uygulandığı konvolüsyon işlemi [60]	13
Şekil 3.4. Aktivasyon haritası üretmek için evrişim işlemi [61]	14
Şekil 3.5. Maksimum havuzlama işlemi [63]	15
Şekil 3.6. Ortama havuzlama süreci [63]	15
Şekil 3.7. Tam bağlı katman yapısı [65]	16
Şekil 3.8. AlexNet mimarisi [67]	17
Şekil 3.9. Transfer öğrenme konsepti [84]	19
Şekil 3.10. Artık öğrenme bloğu	19
Şekil 3.11. ResNet 18 mimarisi	21
Şekil 3.12. Doğrusal destek vektör makinesi örneği [98]	23
Şekil 3.13. Önerilen yöntemin çerçevesi x :İlgili katmanın çıkışında elde edilen öznitelikler $\hat{x}$:GA tarafından elde edilen seçilmiş öznitelikler y :Gerçek etiket $\hat{y}$:Tahmin edilen etiket	25
Şekil 3.14. Önerilen yöntemin öznitelik seçim çerçevesi	26
Şekil 3.15. Seçili katmanın öznitelik haritası	27
Şekil 3.16. Verisetinden kornea ülseri imge örnekleri	29
Şekil 4.1. Her bir evrişimli katman üzerinde genel öznitelik haritalama analiz süreci	31
Şekil 4.2. Katmanların sınıflandırma başarımlar oranları	32
Şekil 4.3. En başarılı Her bir simülasyondan elde edilen sınıflandırma başarımlar oranları ..	35
Şekil 4.4. En iyi beş katmanın ortalama yakınsama grafikleri	36

ÇİZELGELER DİZİNİ

Tablo 3.1. Algoritma 1 Genetik Algoritma'nın temel adımları.....	22
Tablo 3.2. Önerilen yöntemin parametreleri	28
Tablo 4.1. Her bir katmandan elde edilen başarımlar oranları	33
Tablo 4.2. En iyi beş katman için temel istatistik tablosu	34
Tablo 4.3. Önerilen yöntemin kazanımları.....	35
Tablo 4.4. En iyi beş katmanın istatistiksel olarak karşılaştırma tablosu.....	36
Tablo 4.5. Önerilen metodun zaman karmaşıklığı	37



KISALTMALAR DİZİNİ

Kisaltmalar	Açıklama
KNN	: k-En Yakın Komşu Algoritması
SVM	: Destek Vektör Makinesi
DT	: Karar Ağacı
DSA	: Derin Sinir Ağı
CNN	: Evrişimli Sinir Ağı
GA	: Genetik Algoritma
NB	: Naive Bayes
RGB	: Kırmızı Yeşil Mavi
YCbCr	: Parlaklık Kroma-Mavi kroma-kırmızı
HSV	: Ton Doygunluk Değeri
PCA	: Temel Bileşen Analizi
MLE	: Maksimum Olabilirlik Tahmini
EA	: Evrimsel Algoritma
ResNet	: Artık Sinir Ağları
GAN	: Üretken Çekişmeli Ağlarda
GAP	: Global Ortalama Havuzlama
YSA	: Yapay Sinir Ağı
YZZ	: Tıpta Yapay Zeka
YZ	: Yapay Zeka
DR	: Diyabetik Retinopati
SFM	: Öznitelik Haritaları Üzerinden Sınıflandırma
YBMD	: Yaşa Bağlı Maküler Dejenerasyon
FMS	: Öznitelik Haritalarının Seçimi
CT	: Zaman Karmaşıklığı
BC	: Bipolar Hücreler
HK	: Havuzlama Katmanı
EK	: Evrişim Katmanı
TBK	: Tam Bağlı Katman

1. GİRİŞ

Korneal ülser, gözün kornea tabakasındaki açık yaralardır. Gözün epitel tabakasını veya kornea stromasını etkiler [1],[2]. Kornea ülserleri kontakt lensler, travma, adneksiyal hastalıklar, topikal steroid kullanımı, şiddetli zayıflama ve oküler yüzey bozukluklarına bağlı kornea hastalıklarında en sık görülen semptomlardır [3]. Floresein ile boyanmış gözün görüntüsü, iltihaplı yaranın konumunu ve şiddetini belirlemek için biyomikroskop üzerine monte edilmiş kamera tarafından kaydedilir [4]. Gözün korneasının boyanmasından sonra optometri ve oftalmoloji ile yapılan ölçümler kornea ülserlerini teşhis etmek için kullanılır. Temel çözüm, kornea ülserlerinin etkisini önlemek için çok önemli bir adım olan erken teşhistir [5]. Bununla birlikte, kornea ülserinin teşhisi, gelişmekte olan ülkelerde sınırlı olan yüksek teknolojiye sahip cihazlar ve eğitilmiş göz doktorları olmasını gerektirmektedir. Bu nedenle, kornea ülserlerinin teşhisinde göz doktorunu desteklemek için etkin alternatif makine öğrenimi teknikleri kullanılabilir [6],[7].

Bir görüntüden makine öğrenmesi ile kornea ülserinin tespiti, ön işleme, öznetelik çıkarma ve sınıflandırma olmak üzere üç temel adımdan oluşmaktadır. Etkili sınıflandırma sonuçları elde etmek için bu üç aşamanın etkin bir şekilde planlanması gerekmektedir [6],[8]. İlk adımda, görüntünün gürültü seviyesi azaltılır ve göz bölgelerini ayırmak için görüntü segmentasyonu uygulanır. Bu işlemlerden sonra öznetelikler görüntüden çıkartılmaktadır. Son adımda ise öznetelikler ve ilgili etiketleri eğitim ve test veri seti olmak üzere iki kısma ayrılır. Eğitim veri seti, sınıflandırıcının iç parametresini ayarlamak için kullanılmaktadır. Eğitim tamamlandığında, eğitilmiş sınıflandırıcı test verisi ile doğrulanmaktadır [6],[8].

Geleneksel sınıflandırıcılar olan Destek Vektör Makinesi (Support Vector Machine, SVM), k-En Yakın Komşu Algoritması (k-Nearest Neighbors Algorithm, KNN), Karar Ağacı (Decision Trees, DT) ve Naive Bayes (Naive Bayes, NB) makine öğrenimi tekniklerinin kullanıcı tarafından sağlanan parametreler gerektirmesi, sınır değerlere duyarlı olması, aşırı öğrenibilme gibi birçok dezavantajları bulunmaktadır [9],[10]. Ayrıca uygun öznetelik çıkarma ve sınıflandırma tekniklerini seçmek zahmetli ve zaman alıcıdır [11],[12]. Geleneksel algoritmaların sınıflandırma performansı da öznetelik ve örnek sayısı arttıkça önemli ölçüde düşmektedir [13]. Son zamanlarda geliştirilen Derin Sinir Ağı (Deep Neural Network, DSA) yapıları otomatik öznetelik çıkarma ve başarılı sınıflandırma sonuçları gibi yetenekleri sayesinde kısmen belirtilen dezavantajları üstesinden gelmektedir [14]. Bununla birlikte DSA çok fazla eğitim verisine ihtiyaç duyduğu gibi katman sayıları, nöron sayıları,

optimizasyon parametreleri olmak üzere etkin biçimde karar verilmesi gereken hiperparametre uzayını içermektedir [15]. Bu nedenle, sınırlı sayıda örnek içeren küçük ölçekli veri setlerini modellemek için DSA'nın kullanılması başarılı sonuçlar elde edilmesini engelleyebilmektedir [15].

Bu tezde kullanılan 720 örnekle kornea ülser veri seti [5] gibi küçük örneklemlili veri setleri için DSA'nın üstün başarımından faydalanmak amacıyla transfer öğrenme tekniği kullanılmaktadır. Transfer öğrenmede önceden eğitilen DSA'larının öznetelik çıkarma ve iyi biçimde ayarlanmış hiperparametrelerinden faydalanılmaktadır [16]. Literatürde öne çıkan Evrişimli Sinir Ağları (Convolutional Neural Network, CNN) tabanlı Alexnet, Resnet, Googlenet, Densenet vb. büyük ölçekli çok katmanlı DSA'ları, 1000 sınıflı 1 milyon görüntü içeren ImageNet [17] adlı büyük ölçekli bir veri seti ile eğitilmiştir. Açık erişimli eğitilmiş DSA'ların son katmanları değiştirilerek herhangi bir görüntü sınıflandırması için kullanılabilir. Tez çalışmamızda, ham kornea görüntülerini sınıflandırmak için önceden eğitilmiş Resnet-18 [18] modeli kullanılmıştır.

Literatürde kornea görüntülerini sınıflandırmak için önceden eğitilmiş CNN'ler kullanılmıştır [19],[20]. Bu çalışmaların en büyük dezavantajı karmaşık ön işleme adımları ve segmente edilmiş görüntüler gerektirmesidir. Çünkü önceden eğitilmiş ağların sınıflandırma performansı ham kornea görüntülerinin sınıflandırılması için yetersiz kalabilmektedir. Bu tezde bahsedilen sorunun üstesinden gelmek için, Resnet katmanlarından uygun görüntü alt kümelerini Genetik Algoritma (GA) ile seçerek ham kornea görüntülerini doğrudan sınıflandırmak için yeni bir yöntem önerilmiştir. GA öznetelik seçimi gibi karmaşık problemleri çözmek için uygulanan meta-sezgisel bir optimizasyon tekniğidir [21]. Klasik optimizasyon tekniği ile karşılaştırıldığında GA, birçok yerel minimuma sahip fonksiyonların optimizasyonunda küresele yakın çözüm vaat etmektedir [21].

Transfer öğrenmede genel olarak Resnet'in son üç katmanı değiştirilir ve son tam bağlı katman ve softmax katman ağırlıkları yeni veri seti için sınıflandırma elde etmek üzere ayarlanır. Bu tezde softmax katmanı yerine daha güçlü bir sınıflandırıcı olan SVM kullanılmıştır. Normal koşullarda sınıflandırma performansı Resnet in sondan 4. katmanı olan ve pool5 olarak adlandırılan çıkışından elde edilen özneteliklere bağlıdır. Ancak pool5'in yanı sıra kornea görüntülerini sınıflandırmak için kullanılabilecek farklı 67 katman daha vardır. Hangisinin en iyi olduğunu bulmak için bu katmanlar test edilmiştir.

Res5bbranch2b, res5arelu, bn5bbranch2a, res5bbranch2a ve res5abbranch2a gibi bazı katmanların çıkışından elde edilen özniteliklerin destek vektör algoritmasının sınıflandırma performansını önemli ölçüde artırdığını görülmüştür.

Daha fazla iyileştirme için GA kullanılarak yukarıda belirtilen katmanlardan bazı görüntü alt kümeleri seçilmiştir. Böylece görüntüden elde edilen gereksiz öznitelikler ortadan kaldırılmıştır.

Tezin 4 ana katkısı aşağıdaki gibi özetlenebilir:

- 1) Öznitelikleri çıkarmak için Resnet kullanılarak; ince ayar adımı ortadan kaldırılıp, zamandan ve enerjiden tasarruf edilmiştir.
- 2) Softmax yerine algoritmanın performansını artıran SVM kullanılmıştır.
- 3) GA, gereksiz öznitelikleri azaltmak için Resnet katmanlarından bazı görüntü alt kümelerini seçmek için kullanılmıştır.
- 4) DSA ve önceden eğitilmiş Resnet'in hiperparametre optimizasyonu, büyük veri seti gereksinimleri, zaman alan optimizasyon süreci vb. gibi başlıca dezavantajları kornea görüntü sınıflandırması için ortadan kaldırılmıştır.


2. GENEL BİLGİLER ve LİTERATÜR DERLEMESİ

2.1. Göz

İnsan gözü en dikkat çekici duyu sistemlerinden biridir. İnsan dış çevre hakkındaki bilgilerin çoğunu gözleri aracılığıyla edinir. Bu nedenle görme duyusuna diğer tüm duylardan daha fazla güvenir. Ayrıca göz sahip olduğumuz en hassas organdır. Kimlik belirleme teknolojisinin uygulanması için benzersiz özellikler sunar. Hem irisin son derece incelikli dokusu hem de fundus kan damarı deseni, her insan için eşsiz olup biyometrik tanıma için uygun özellikler sağlar [22].

2.2. Gözün Yapısı

Görmemizi sağlayan kısımlar kornea, iris, mercek, vitreus, retina, gözbebeği ve sklera'dır [23]. Gözün genel yapısı Şekil 2.1'de sunulmuştur.




Şekil 2.1. Gözün yapısı [24]

Kornea

Kornea, gözümüzün en önemli yapılarından biridir. Korneanın temel görevi, gözün optik sisteminin kırılma işlevini sağlayan hassas kavisli bir şekli korumaktır. Bunun yanında kornea, görünür dalga boylarında gelen ışığın %90'ından fazlasını iletmek için pürüzsüz yüzeyi korur [25], [26]. Kornea şeffaflığı önemli bir unsurdur. Korneanın şeffaflığı esas olarak kornea stromasındaki uygun su içeriği (yaklaşık %78 su) ile sağlanır. Bu durum epitelyal ve endotelyal pompaların doğru çalışmasına ve proteoglikanlar (bağlı

glikozaminoglikanlar ile), glikoproteinler, inorganik tuzlar ve sudan oluşan bir matriste kolajen liflerinin doğru organizasyonuna bağlıdır. Proteoglikanlar burada en büyük rolü oynar. Çünkü korneanın kuru ağırlığının %10'unu oluştururlar ve hücre dışı suyu bağlayarak kolajen fibrillerinin uygun dizilimini ve paketlenmesini sağlarlar [27].

Kornea'nın genel yapısı Şekil 2.2 de görülmektedir. Korneanın dış tabakadan iç tabakaya doğru yapısı beş bölümden oluşur: Epitel, bowman zarı, stroma, descemet zarı ve endotel [28]. Temel bileşen olan stroma, korneanın genel kalınlığının %90'ını oluşturur. Stromadaki tipik su içeriği % 75-80'dir ve bu oran diğer tüm bağ dokularındaki su içeriğinden fazladır. Bu durum, su molekülünün pozitif yüklü dipolünü çeken glikozaminoglikan zincirleri üzerindeki negatif yüklerin varlığı ile belirlenir. Glikozaminoglikan zincirlerinin hidrasyonunun bozulması boyutlarını azaltır, kolajen lifleri arasındaki mesafeyi değiştirir ve dolayısıyla kornea saydamlığının kaybolmasına yol açar ve gözün yapısını bozar. Korneadaki metabolik süreçler kornea dokusunun şeffaflığını korumalı ve bozulmasını önlemelidir [27].




Şekil 2.2. Kornea yapısı [29]

İris

Şekil 2.3 de irisin yapısı görülmektedir. İris önden arkaya doğru dört farklı tabakadan oluşmaktadır [23]: (1) Esas olarak fibroblastlar ve pigmentli melanositlerden oluşan, Fuchs kriptleri olarak adlandırılan büyük, çukur benzeri deliklerle kesintiye uğrayan ön sınır tabakası; (2) Kan damarları ve sinir lifleri etrafında yoğunlaşan lifler. Önceki katmanda bulunan fibroblastlar ve melanositlerin yanı sıra, iris stromasında topak hücreler ve mast hücreleri bulunur. Önceki katmanda bulunan fibroblastlar ve melanositlerin yanı sıra, iris stromasında yığın hücreler ve kök hücreler bulunur. İrisin rengini belirleyen melanositlerdeki pigmenttir. Kas lifleri pupiller marjini çevreleyen sfinkter pupillae kası, stromal tabakanın iç kısmında yer alır. Sfinkter kasılarak göz bebeğinin daralmasına neden

olur. Bu da iriste kasılma olukları olarak adlandırılan oluklara yol açar. Bu oluklar, (3) Anterior epitelin hücresel süreçleri tarafından oluşturulan dilatör kasın etkisiyle göz bebeğinin genişlemesiyle derinleşir. Dilatör pupilla kası, hücreleri miyoepitelyal olan ön epitel tabakasına aittir [30]. Sfinkter kasından farklı olarak, dilatör kasın kas lifleri radyal bir şekilde düzenlenir ve iris kökünde sonlanır; (4) Hücreleri kolumnar olan ve anterior epitel hücrelerine kıyasla daha yoğun pigmentli olan posterior pigmentli epitel. Arka epitel tabakası iris içinde ana ışık emici olarak işlev görür [22].



Şekil 2.3. İris yapısı [31]

Mercek

Yeterli miktarda ışık göz bebeğinden göze girdikten sonra mercek ile karşılaşır. Bir mercek lifi kütlesini kaplayan mercek epitel tabakasından oluşan mercek, esas olarak korneadan gelen görüntüyü daha da hassaslaştıran kristalin adı verilen proteinlerden oluşur. Kornea gibi, merceğin molekülleri de yoğun bir şekilde paketlenmiş ve eşit aralıklarla yerleştirilmiştir. Bu şeffaflık için gereklidir. Mercek, çevre ihtiyaçlarına bağlı olarak korneadan doğal olarak daha büyük bir kırılma indeksine sahiptir. Mercek aköz hümör ve vitröz hümör sıvısı ile çevrili olduğundan, görüntüyü daha fazla odaklamak ve optik sisteme katkıda bulunmak için merceğin indeksi daha da yüksek olmalıdır [32].

Vitreus

Vitreus, sağlıklı bir insan gözünün merkezinde yer alır. Vitreus jeli, lens, siliyer cisim ve retina arasında yer alan vitreus odasını doldurarak oküler hacim ve kütlenin en büyük kısmını oluşturur [33].

Retina

Retina, embriyolojik olarak merkezi sinir sisteminin bir parçasıdır [34],[35] . Retina, görme döngüsünde merkezi bir rol oynayan son derece özelleşmiş bir dokudur. Retinanın karmaşık yapılarından herhangi birinin hasar görmesi görme bozukluğuna ve körlüğe yol açabilir [36].

Gözbebeği


Gözbebeği anatomik olarak hafif yuvarlaktır ve irisin üst kısmında bulunmaktadır. Göz bebeği ortamdaki ışığa göre büyüüp küçülebilmektedir [37].

Sklera

Sklera, göze şeklini veren gözün beyaz dış kaplamasıdır. Işığı saçan kolajen demetlerinin yüksek oranda sıkıştırılmış düz bantlarından oluşmuştur. Sklera sert, lifli bir dokudur [38].

2.3. Görme Süreci

Şekil 2.4. de görme süreci sunulmuştur. Göz, duyuşal sinir sisteminin bir parçasıdır. Bununla birlikte, gözle birlikte çalışan bir dizi organ bulunmaktadır. Retina, memelilerde fotoreseptörlerin, çubukların ve konilerin varlığı nedeniyle fotoresepsiyonu düzenleyen tek dokudur. Hem görsel hem de görsel olmayan işlevleri yerine getirmektedir. Işık, neredeyse tüm organizmaların davranışlarında temel bir rol oynar. Görsel süreçlere ek olarak, ışık önemli fizyolojik tepkilere de neden olur. Oftalmik mutant sıçanlarla yapılan deneyler de görme kaybının fizyolojik faaliyetlerini de engellediğini ve ritim merkezlerinin de bozulduğunu göstermiştir [32]. İnsan gözü, vücutta ışığın dalga boylarını "görebilen" ve bunları görsel imgelere dönüştürebilen tek organdır. Gözler olmadan "göremeyiz" ya da beyne görsel bir imge gönderemeyiz. Fotoreseptörler, ışık çarptığında değişen kimyasallar içerir. Bu da bir elektrik sinyaline neden olur ve daha sonra bu sinyal optik sinir boyunca beyne gönderilir. Farklı fotoreseptör tipleri devasa bir ışık ve renk yelpazesini görmemizi sağlar. İnsan retinasında çubuklar ve koniler olmak üzere iki tür fotoreseptör vardır: Çubuklar düşük ışık seviyelerinde görmeden sorumludur (skotopik görme). Renkli görmeye aracılık etmezler ve düşük uzaysal keskinliğe sahiptirler [39].



Şekil 2.4. Gözde görme süreci [40]

2.4. Gözün önemi

Görmek hayatımızın vazgeçilmez bir parçasıdır. Yemek yapmak, dikiş dikmek, ders çalışmak, araba kullanmak gibi birçok işi gerçekleştirmek için iyi bir göz sağlığı gereklidir. Sosyal ve ekonomik hayatımızı etkiler. Görme aynı zamanda yaşam kalitesini ve kişinin fiziksel ve ruhsal durumunu da etkiler. Bağımsız bir yaşam sürmek için iyi bir görme duyusuna sahip olmamız gerekir bu da göz sağlığı bakımını öncelikli hale getirmektedir [41].

Görme, sağlığın ve yaşam kalitesinin önemli bir kaynağıdır. Görme bozukluğu olan bireylerde yaralanma riski artabilir. Araç kullanmayı azaltma veya bırakma olasılıkları daha yüksektir. Görme engelli olan yaşlılarda düşme, kırık ve depresyon riski daha yüksektir [42].

Görme bozukluğunun düşme ile ilişkili olduğunu gösteren çeşitli çalışmalarda bulunmaktadır [30]. Görsel risk faktörleri arasında azalmış görme keskinliği, azalmış kontrast duyarlılığı, zayıf derinlik algısı, zayıf görme ve zayıf görme alanı kaybı yer almaktadır. Ayrıca posterior subkapsüler katarakt ve glokom damlası olarak topikal uygulanan beta bloker kullanımının düşme için önemli risk faktörleri olduğu bulunmuştur [43],[44],[45].

2.5. Göz Hastalıklarının Teşhisi

Tıpta Yapay Zekâ (YZ) alanı, 1970'li yılların başında ortaya çıkmıştır [14]. Yüksek kaliteli tıbbi hizmetlere olan talebin artması ve tıbbi bilginin hızla büyümesi, doktorlara ve diğer sağlık hizmeti sağlayıcılarına tanı, tedavi ve teşhis konularındaki klinik rollerini yerine getirmelerinde yardımcı olabilecek bilgisayar programlarının kullanılmasına yol açmıştır [46].

YZ alanı, tiroid hastalıkları, meme hastalıkları, ilaç zehirlenmeleri, elektrolit bozuklukları, sarılık ve karaciğer fonksiyon bozuklukları, solunum fonksiyonları, hematoloji, göğüs ağrısı, oftalmoloji ve onkoloji gibi alanlarda tıbbi tanıda karar desteği vermek için uygulanmaktadır

[47] [48]. Bunların yanında bu tezin konusu olan göz hastalıklarıyla ilgili yapılan bazı çalışmalar aşağıda kısaca özetlenmiştir.

- ✓ Kornea ülserlerinin otomatik olarak segmentlere ayrılması ve sınıflandırılması için SUSTech-SYSU veri seti

Deng ve ark. 712 oküler boyama görüntüsü ve kornea ülserlerinin ilgili segmentasyon etiketlerini içeren bir veri kümesi hazırlamıştır. Bu veri setinde Kornea ülserleri için segmentasyon etiketlerine ek olarak, her görüntüye üç katlı sınıf etiketleri de sunulmuştur: ilk olarak, her görüntünün genel ülser modeli açısından bir etiketi vardır; ikinci olarak, her görüntünün spesifik ülser modeli açısından bir etiketi vardır; üçüncü olarak, her görüntünün ülser şiddet derecesini gösteren bir etiketi vardır. Bu veri seti, kornea ülserleri için farklı segmentasyon ve sınıflandırma algoritmalarının doğruluğunu ve güvenilirliğini araştırmak ve özellikle derin öğrenme çerçevesindeki yeni denetimli öğrenme tabanlı algoritmaların geliştirilmesi için imkan sunmaktadır [5].

- ✓ Kornea Ülseri Taraması İçin Derin Öğrenme Tabanlı Yaklaşım

Teepayan tarafından kornea ülseri tarama sürecini kolaylaştırmak için, semptomun iki şiddet seviyesini belirlemeye yardımcı olmak için çeşitli temel sinir ağlarına dayalı bir derin transfer öğrenme mimarisi sunmuştur [49]. Temel model olarak yaygın kabul gören toplam 15 derin evrişimli sinir ağı kullanılmıştır. Önerilen transfer öğrenme tabanlı mimariler, halka açık SUSTech-SYSU veri kümesinden 426, 143 ve 143 flöresein boyama yarık lamba görüntüsü üzerinde eğitilmiş, doğrulanmış ve test edilmiştir [49].

- ✓ Evrişimli Sinir Ağları ile Görüntü Sınıflandırması Kullanılarak Kornea Ülserasyonunun Yüksek Performanslı Tespiti

Jan ve ark. tarafından gerçekleştirilen çalışmada, flöresein boyama görüntülerine dayalı olarak farklı kornea ülseri türlerinin tanımlanmasına olanak tanıyan CNN tabanlı bir görüntü sınıflandırma yaklaşımı önermişlerdir. Önerilen yöntem kornea ülserlerini erken bir aşamada tespit ederek, ülserin şiddetinin azaltılmasına yardımcı olmayı amaçlamıştır [50].

- ✓ Keratitin Akıllı Teşhisi ve Sınıflandırılması

Arguran ve arkadaşlarının gerçekleştirdiği çalışmanın amacı, farklı ülser türleri ayırt etmek için otomatik bir sistem önermektir. SUSTech-SYSU veri kümesini kullanarak el ile ve otomatik öznitelik çıkarım yöntemlerini karşılaştırılmıştır. Önerilen yaklaşım, gri seviyeli ve renkli görüntülerden çıkarılan kullanıcı tarafından belirlenen öznitelikleri kullanarak

farklı kornea ülseri görüntüleri arasında seçim yapmaktadır. Renkli öznitelikler üç renk uzayından çıkarılmaktadır: kırmızı yeşil mavi (RGB), parlaklık kroma-mavi kroma-kırmızı (YCbCr) ve ton doygunluk değeri (HSV). Ayrıca bu çalışma, temel bileşen analizi (PCA), sonsuz gizli öznitelik seçimi gibi çeşitli öznitelik seçim yöntemlerinin performansını analiz etmektedir. Bu çalışma, flöresein boyama görüntüleri kullanılarak kornea ülserlerini tip derecelendirmesi ve genel örüntüsüne (ülser şekli ve dağılımı) göre ayırt etmeye çalışmıştır [51].

✓ Evrişimli Sinir Ağı Kullanarak Etkili Bir Otomatik Korneal Ülser Tespit Yöntemi

Akram ve Debnath'ın çalışmasında, genel amaçlı dijital kamera ile alınan yüz görüntüsünden gözdeki kornea ülseri hastalığını tespit etmek için CNN kullanan bir sistem önerilmiştir. Önerilen yöntem ilk olarak Haar Cascade Sınıflandırıcıları kullanılarak yüzün göz kısmını tespit etmekte ve segmentlere ayırmaktadır. Daha sonra yöntem, kornea hastalığının var olup olmadığını CNN ile tespit etmektedir. İlk olarak, GrabCut yöntemi kullanılarak gözün dış deri bölgesi çıkarılır ve Hough gradient ve aktif kontur teknikleri uygulanarak iris ve sklera bölgesi segmente edilir. Son olarak ülser bölgesini lokalize etmek ve kümelemek için aktif kontur tekniği kullanılarak ülser boyutunun oranı ölçülür. Burada kornea ülseri segmentasyon sonuçlarını iyileştirmek için iris görüntüsü üzerinde aşındırma ve genişletme işlemleri uygulanır. Eğitim için mevcut veri kümesinin boyutu sınırlıdır. Bu nedenle rastgele döndürme, çevirme, kaydırma, parlaklık, gürültü ve rastgele yakınlaştırma gibi çeşitli veri seti çoğaltma teknikleri uygulanmıştır [52].

✓ Keratit için Derin Öğrenmeye Dayalı Bir Görüntü Teşhis Algoritması

Ji ve arkadaşlarının önerdiği yöntemde, derin öğrenmeye dayalı bir keratit görüntüsü teşhis algoritması önerilmiştir. Görüntünün yorumlanabilirliğine dayalı olarak keratitin spesifik belirtileri analiz edilir ve keratit için teşhis temeli sağlanır. Sınıflandırmanın zorluğuna göre bir ağırlık cezası mekanizması getirilmiştir. Özniteliklerin ağırlıklı değeri, farklı öznitelikleri sınıflandırmak zor olduğu için ağ tarafından belirlenir ve çoklu görevlerin genel tanıma doğruluğunu artırmak için daha zor sınıflandırma görevleri için daha yüksek bir kayıp ağırlığı ayarlanır. Diğer keratit otomatik tanıma algoritmaları ile karşılaştırıldığında, algoritma sınıflandırması için yalnızca kornea fotoğraflarına ihtiyaç duyar ve pratik uygulamada daha yüksek fizibiliteye sahip olması amaçlanmıştır [7].

3. MATERYAL ve METOT

Bu bölümde; tezde kullanılan materyal, veri seti, derin öğrenme, transfer öğrenme ve önerilen yöntemlerine yer verilmiştir.

3.1. Materyal

Bu tezde kullanılan materyal olarak:

- MATLAB platformunda M-Script programlama dili,
- Modelleme sürecinde i3-7130U 2.7 GHz, 20 GB Ram sistem özelliklerine sahip PC kullanılmıştır.

3.2. Evrişimli Sinir Ağları


Evrişimli Sinir Ağları (Convolutional Neural Network- CNN) adını, iki veya daha fazla matematiksel işlemin birlikte kullanılması anlamına gelen bir matematiksel işlem olan konvolüsyon üzerinden almıştır [53].

CNN, görüntü tanıma ile ilgili çeşitli alanlarda son on yılda çığır açan başarılar sağlamıştır. CNN'lerin en önemli avantajı, Yapay Sinir Ağı (YSA)'daki parametre sayısını azaltmasıdır. Bu başarı, hem araştırmacıları hem de geliştiricileri, klasik YSA ile mümkün olmayan karmaşık görevleri çözmek için daha büyük modeller önermeye teşvik etmiştir. CNN tarafından çözülen problemlerle ilgili en önemli varsayım, uzamsal olarak bağımlı özniteliklere sahip olmamalarıdır. Örneğin bir yüz tanıma uygulamasında görüntülerde yüzlerin nerede olduğunun hesaplanması gerekmemektedir. Bu sayede, verilen görüntülerdeki konumlarından bağımsız olarak onları tespit edebilmektedir. CNN'nin bir diğer önemli avantajı, girdi daha derin katmanlara doğru yayıldığında soyut öznitelikler elde edebilmesidir. Şekil 3.1.'de görüldüğü gibi görüntü sınıflandırmada, ilk katmanlarda kenar, ardından ikinci katmanlarda daha basit şekiller ve ardından sonraki katmanlardaki yüzler gibi daha yüksek seviyeli öznitelikler çıkarılabilmektedir [54].

Evrişimli katman (EK), birden fazla derinliğe sahip bir görüntü olarak yapılandırılmış bir grup nöronuna sahiptir. EK'ler bir giriş görüntüsünden kenar, doku vb. öznitelikleri çıkarır [55]. Bu nedenle, EK'ler evrişim filtreleri veya evrişim çekirdekleri olarak adlandırılan ayarlanabilir filtreler olarak kabul edilir. Genel olarak, bir EK'nin boyutu $n \times m \times d$ 'dir; burada n , m , d giriş boyutlarıdır. Her EK çekirdeği, giriş görüntüsü ile evrişim işlemini hesaplar. Bu hesaplamada, filtre girdileri ve girdi arasında nokta çarpımı gerçekleştirilir [56].

Havuzlama katmanı (HK) her bir evrişimli özelliğin örneklemesini azaltmayı amaçlar. Böylece, boyutsallık azaltımı sayesinde ihtiyaç duyulan hesaplama maliyeti azaltılır. Sonuç olarak, EK'nin azaltılmış boyutu kullanılarak aşırı uyum probleminin kontrol edilmesi sağlanır [56]. Tam bağlı katman (TBK), son HK'den gelen öznitelikleri sınıflara eşler. TBK, geleneksel yapay sinir ağları gibi yapılandırılmıştır [57].


Ayarlanan tüm parametreler CNN modellerinde sonraki katmanlara tam olarak bağlanır [56]. Aslında, hesaplama maliyeti nedeniyle bu tam bağlantılı parametreler, özellikle çok sayıda piksel içeren görüntülerde problemleri sınıflandırmak için yetersizdir. Bu nedenle çok sayıda ağırlıktan oluşan nöronlar hızlı bir şekilde aşırı uyuma neden olur [57]. Aşırı uyum probleminin üstesinden gelmek için CNN modellerinde bazı bağlantılar bırakılır. Ayrıca, daha kararlı bir CNN modeli elde etmek için AlexNet, ResNet, GoogleNet, DenseNet gibi önceden eğitilmiş modeller kullanılabilir.



Şekil 3.1. Örnek bir EK ile öznitelik çıkarımı [58]

3.2.1. Evrişimli sinir ağı(CNN) katmanları


Derin evrişimli sinir ağı (CNN) evrişimli ve havuzlama katmanının yanı sıra tam bağlantılı bir katmandan oluşur [55]. Evrişimli ve tam bağlantılı katmanların parametreleri eğitim sürecinde ayarlanır. Ancak, havuzlama işleminde ayarlanması gereken bir parametre yoktur [55]. Genel bir CNN yapısı Şekil 3.2.'de gösterilmiştir.



Şekil 3.2. Genel CNN mimarisi [59]

3.2.1.1. Evrişim katmanı


Evrişim katmanı, yerel bağlantılara ve paylaşılan özniteliklerin ağırlıklarına sahip olan evrişimli sinir ağının temel parçasıdır. Evrişim katmanının amacı, girdilerin öznitelik temsillerini öğrenmektir. Şekil 3.3’de gösterildiği gibi, evrişim katmanı birkaç öznitelik haritasından oluşur. Aynı öznitelik haritasının her bir nöronu, önceki katmandaki farklı konumların yerel özniteliklerini çıkarmak için kullanılır. Sonra sonuçlar doğrusal olmayan bir aktivasyon fonksiyonuna geçirilir. Farklı çekirdekler uygulanarak farklı öznitelik haritaları elde edilir [59].



Şekil 3.3. 3x3'lük filtrenin uygulandığı konvolüsyon işlemi [60]

Evrişim katmanı CNN'deki en temel ama aynı zamanda en önemli katmandır. Temel olarak, verilen görüntü için bir aktivasyon haritası üretmek üzere verilen görüntü veya nesne için oluşturulan piksel matrisini konvolize eder. Aktivasyon haritasının ana avantajı, belirli bir görüntünün tüm ayırt edici özniteliklerini depolarken aynı zamanda işlenecek veri miktarını azaltmasıdır. Verilerin dönüştürüldüğü matris, temelde makinenin uyumlu olduğu bir değerler kümesi olan bir öznitelik detektörüdür. Öznitelik dedektörünün farklı değerleri

kullanılarak görüntünün farklı versiyonları oluşturulur. Konvolüsyonlu model ayrıca her katmanda minimum hatayı tespit etmek için geri yayılım ile eğitilir. En düşük hata setine göre, derinlik ve padding ayarlanır [61].



Şekil 3.4. Aktivasyon haritası üretmek için evrişim işlemi [61]



Şekil 3.4 de evrişimin nasıl çalıştığını gösterilmektedir. Bu adım, görüntü verilerini içeren matrisin evrişimini ve ardından bize bir aktivasyon haritası veya bir öznitelik haritası veren öznitelik algılayıcısını içerir. Evrişim işleminde, veri ve öznitelik haritasındaki aynı konumlardaki değerlerin, yani 1 veya 1'den fazla değere sahip değerlerin tutulurken geri kalanının çıkarılmasıdır. Görüntü verilerinden elde edilen matris her seferinde 3x3 matris ile işleme tabi tutulur. Öznitelik algılayıcısının boyutu kullanılan CNN türüne göre değişir. Örneğin, evrişim için 5x5 veya hatta 7x7 ölçekli filtreler kullanan CNN sürümleri de vardır [61].

3.2.1.2. Havuzlama katmanı

Havuzlama, öznitelik haritasının boyutlarını azaltmak için kullanılmaktadır. Havuzlama işleminde önemli öznitelikleri tutulurken aynı zamanda veri boyutu da azaltılır. Bu sayede aşırı uyum sorununun üstesinden gelinmesine katkı sağlanmaktadır. Havuzlama işlemi, CNN'in bir görüntüsünün tüm farklı boyutlarını birleştirmesini sağlar, böylece şekli çarpıtılmış olsa veya farklı bir açıdan görünse bile verilen nesneyi başarılı bir şekilde tespit edebilir. Maksimum havuzlama, ortalama havuzlama, stokastik havuzlama, uzamsal piramit havuzlama gibi çeşitli havuzlama türleri bulunmaktadır. Bunlardan en yaygın kullanılanı maksimum havuzlamadır [61].

Maksimum havuzlama, bir giriş öznitelik haritası üzerinde kayan bir filtre ile yapılır. Filtrenin boyutu ve üç katı herhangi bir pozitif tamsayı olarak ayarlanabilir. Genellikle 2x2 veya 3x3 olarak ayarlanır. Filtre kapsamındaki maksimum değeri çıkarılır. Bu sayede,


maksimum havuzlama öznitelik haritasındaki maksimum değer üzerinde yalnızca bir etkinleştirilmiş bağlantı nedeniyle hesaplama karmaşıklığını azaltır. Maksimum havuzlama süreci [62] Şekil 3.5'de gösterilmiştir [63].



Ortalama havuzlama, filtre kapsamındaki ortalama değeri hesaplar. Maksimum havuzlama ile karşılaştırıldığında, ortalama havuzlamanın katkısı çok fazla değildir, çünkü öznitelik haritasındaki her bağlantı etkinleştirilir. Bu nedenle öznitelik haritasındaki tüm bilgiler, geri yayılımdaki gradyan ile birlikte bir sonraki katmana taşınır. Bu durumda, ortalama havuzlama genellikle bir CNN modelinin sonunda Global Ortalama Havuzlama (GAP) olarak kullanılır veya Üretken Çekişmeli Ağlarda (GAN) aşağı örnekleme işlemi olarak kullanılır [64]. Ortalama havuzlama süreci Şekil 3.6'da gösterilmiştir [63].

3.2.1.3. Sınıflandırma (Tam bağlantılı katman) katmanı

Son evrişim veya havuzlama katmanının çıktı öznitelik haritaları tipik olarak düzleştirilir, yani tek boyutlu (1D) bir sayı (veya vektör) dizisine dönüştürülür. Her girdinin her çıktıya öğrenilebilir bir ağırlıkla bağlandığı yoğun katmanlar olarak da bilinen bir veya daha fazla tam bağlantılı katmana bağlanır. Konvolüsyon katmanları tarafından çıkarılan ve havuzlama katmanları tarafından boyutu düşürülen öznitelikler oluşturulduktan sonra, tam bağlı katmanların bir alt kümesi tarafından ağın son çıktılarına eşlenir, sınıflandırma görevlerinde her sınıf için olasılıklar gibi. Son tam bağlantılı katman tipik olarak sınıf sayısı ile aynı sayıda çıkış düğmesine sahiptir. Her tam bağlantılı katmanı, yukarıda açıklandığı gibi ReLU gibi doğrusal olmayan bir fonksiyon izlemektedir [55].




Şekil 3.7. Tam bağlı katman yapısı [65]

3.2.2. Erişimsel sinir ağı mimarileri

3.2.2.1. AlexNet

AlexNet mimarisi, 2012 yılında ImageNet yarışmasında adını duyuran, yaklaşık bir milyon görüntü ile eğitilme özelliğine sahip, görüntüleri sınıflandırmada son derece başarılı bir CNN modelidir. AlexNet mimarisi Şekil 3.8 de sunulmuştur. AlexNet, temel CNN

mimarisine kıyasla yığılmış konvolüsyon katmanları ile daha fazla filtre katmanına sahip daha derin bir mimari ile tasarlanmıştır. AlexNet, ilk üç katmanda evrişim ve maksimum havuzlamanın bir kombinasyonudur ve ardından dropout katmanı olarak da bilinen iki tek evrişim katmanı gelir. Bu tekli evrişim katmanının beşinci katmanı maksimum havuzlama katmanı ile sonlanır. Diğer üç katman tam bağlantılı katmanlardır. Tam bağlantılı katmanlardan elde edilen çıktılar softmax katmanına gönderilir ve burada 1000 sınıf etiketi için 1000 olasılık değeri üretilir [66].



Şekil 3.8. AlexNet mimarisi [67]

3.2.2.2. LeNet

1990 yılında LeCun ve arkadaşları tarafından Evrişimli Sinir Ağları alanındaki öncü çalışmalardan biriydi [68] ve daha sonra 1998 yılında geliştirildi [69]. Çalışmalarında, El Yazısı Rakam Tanıma görevi CNN kullanılarak gerçekleştirilmiştir ConvNets. Posta kodlarının, rakamların vb. okunmasında uygulama alanı bulmuştur. O dönemde yüksek bilgi işlem kapasiteli sistemlerin olmamasından dolayı CNN yaygın olarak kullanılamadı [70].

3.2.2.3. GoogleNet

Google araştırmacıları (birkaç üniversitenin yardımıyla) Google Net'i 2014 yılında yayınladıkları "Going Deeper with Convolutions" (ya da Inception V1) başlıklı araştırma makalesi ile tanıttılar. Bu tasarım 2014 ILSVRC fotoğraf sınıflandırma yarışmasını kazandı. Önceki şampiyonlar AlexNet ve ZF-Net'in yanı sıra VGG'den (2014 ikincisi) daha düşük bir hata oranına sahiptir. Tasarım aşaması boyunca 11 konvolüsyon ve küresel ortalama havuzlama kullanılmıştır. Tasarım 22 katmana sahiptir. Tasarımın sınırlı hesaplama kapasitesine sahip olsa bile tek bir cihaz üzerinde uygulanabilmesi öncelikli amaçlardan birisidir. Ayrıca sınıflandırıcı seviyeleri 4a ve 4d üzerinde Başlangıç katmanı 4'ün çıktısına bağlanan iki yardımcı sınıflandırıcı katmanı içermektedir [71].


3.3. Transfer Öğrenme

Önceden edinilmiş bir yeteneğin yeni bir görevde kullanılması transfer öğrenme olarak tanımlanmaktadır [72]. Son zamanlarda, makine öğrenimi veya veri madenciliği alanlarında transfer öğrenmenin birçok başarılı uygulaması bulunmaktadır. Genel bir görev için eğitilmiş CNN kullanılarak yeni bir görev için yeni verilerle yeniden eğitim verilmesi transfer öğrenme olarak kabul edilmiştir [73]. Transfer öğrenme sayesinde hesaplama maliyeti azalmakta ve büyük veri seti gereksinimi ortadan kalkmaktadır. Transfer öğrenme gerçekleştirmek için en başarılı uygulamalar, tıbbi görevlerde ImageNet [17], [74] ile eğitilen CNN modellerine dayanmaktadır [16],[75].

Geçtiğimiz birkaç yılda, video arama ve alma, gözetim, robotik ve benzeri alanlarda önemli miktarda çığır açan uygulamalar sunulmuştur. Normal makine öğrenimi yaklaşımları [76],[77] eğitim ve test verilerinin aynı öznitelik uzayında kaldığı veya aynı dağılımı paylaştığı ana varsayımı altında umut verici sonuçlar elde etmiştir. Ancak gerçek dünya uygulamalarında, insan eliyle etiketlemenin yüksek maliyeti ve çevresel kısıtlamalar nedeniyle, test verileriyle aynı öznitelik uzayına veya aynı dağılıma ait yeterli eğitim verisi her zaman mevcut olmayabilir. Örneğin; eğitim için her eylem sınıfı için yalnızca bir eylem şablonunun sağlandığı [78],[79] ve eğitim örneklerinin farklı bir bakış açısından kaydedildiği uygulamalardır [80]. Bu gibi durumlarda, normal makine öğrenimi tekniklerinin başarısız olma olasılığı bulunmaktadır. Nesnelerin devasa geometrik ve sınıf içi değişkenlikleri göz önüne alındığında, insanlar yaşamları boyunca on binlerce görsel kategori öğrenebilmektedir. İnsanların böyle bir yeteneği ön öğrenmelerin üzerine inşa ettiğini göstermektedir [81]. Dünyada yaklaşık 10-30 bin nesne sınıfı olduğu [82] ve çocukların günde 4-5 nesne sınıfı öğrenebildiği tahmin edilmektedir [81]. Bir çocuğun bir gün içinde görebileceği nesnelerin sınırlılığı nedeniyle, büyük miktarlardaki ilgili nesne verilerinden yeni nesne sınıflarının öğrenilmesi mümkün değildir. Bu nedenle daha önce bilinen nesnelerden edinilen mevcut bilginin, yeni nesne kategorileriyle olan bağlantıları aracılığıyla yeni öğrenme sürecine yardımcı olduğuna inanılmaktadır. Transfer öğrenme, belirli bir alanda yeni görevleri yerine getirirken diğer ilgili alanlardaki yeterli miktarda önceki bilgiyi kullanarak insan görme sistemini taklit edilmesi olarak tanımlanabilir [83].

Transfer öğrenmede mevcut eğitilmiş bir model ele alınır ve aynı model bazı yeni görevler için yeniden eğitilir. Önceden tüm modeli eğitmek ve yüksek doğruluk elde etmek için birçok epok gerekirdi. Transfer öğrenme kullanılarak, yüksek doğruluk elde etmek için


nispeten daha az iterasyon/epok çalıştırılır. Hem hesaplama zamanından hem de güçten tasarruf sağlar. Şekil 3.9’da transfer öğrenme konsepti gösterilmektedir [84].



Şekil 3.9. Transfer öğrenme konsepti [84]

3.4. Artık Sinir Ağları (ResNet)

DSA'ler optimum bir yerel çözüm noktasına yakınsamaya başladığında, büyük ölçekli ağlarda bir bozulma sorunu ortaya çıkabilir. Bir DSA'nin katmanları arttıkça, DSA'nin doğruluğu kötüleşir, doygunluğa ulaşır ve hızla bozulur [18]. Literatürde bu durum optimizasyon sürecinin durmasına neden olan bir bozulma problemi olarak tanımlanmaktadır. Bozulma sorununun üstesinden gelmek için, Imagenet [17] adlı büyük bir veri kümesini sınıflandırmak için Şekil 3.10 da görülen yeni bir DSA çerçevesi olarak Artık sinir ağı (ResNet) [18] önerilmiştir. Uygulanan teknik basittir ancak sonuçlar çok verimlidir. ResNet'te bazı bağlantılar ve katmanlar atlanmıştır. Böylece ResNet bozulma problemini çözebilir.



Şekil 3.10. Artık öğrenme bloğu

Artık öğrenme her birkaç yığılmış katmanda uygulanabilir. Artık yapı bloğu şu şekilde tanımlanır:


$$y = F(x, \{W_i\}) + x \quad (3.1)$$

Burada, giriş x ve çıkış y vektörleri, yanlılığı olmayan bir artık eşleme fonksiyonu olan $F(x, \{W_i\})$ fonksiyonu ile bağlanır. Şekil 3.10'da iki katman bulunmaktadır. Bağlantıları $F = W_2\sigma(W_1x)$, olarak hesaplanır, burada σ aktivasyon fonksiyonu olan ReLU fonksiyonudur. Eşitlik 3.1'de x ve F 'nin boyutları eşit olmalıdır [18],[85]. Bu sebepten dolayı Eşitlik 3.1 aşağıdaki gibi yeniden düzenlenmiştir:

$$y = F(x, \{W_i\}) + W_s x \quad (3.2)$$

Burada W_s , boyutları eşleştirmek için kısayol bağlantıları tarafından doğrusal bir yansıma kullanmak üzere bir kare matristir.

Derin sinir ağları çoğunlukla farklı soyutlama seviyelerinde uygun ayırt etme gerektiren karmaşık işlevleri temsil etmek için kullanılır. Ancak, DSA her zaman beklendiği gibi çalışmaz. Derin ağ parametrelerinin eğitimindeki engellerden biri kaybolan gradyanlardır. Bu nedenle gradyan inişi, öğrenmeyi engelleyici bir hale gelebilir. Artık Ağ (ResNet) bunun çözümlerinden biridir. Aktivasyonun birkaç ara katmanı atlmasına ve daha derin bir katmana katılmasına izin verir. Bir ResNet'te kullanılan iki ana blok türü vardır: “kimlik bloğu” ve “evrişimli blok”. Kimlik bloğu, ana sıralı akış yoluna paralel olarak atlanan bir yoldur ancak bölme ve birleştirme düğümlerinde aynı boyutu tutar. Öte yandan, atlama yollarındaki bir evrişimli blok, kimlik bloğu ile neredeyse aynıdır ancak bir evrişimli katman içerir. Atlama yolu evrişimli bloğunun rolü basit matris çarpımına benzer ve boyutta değişiklik yapar [86]. Bu tez çalışmasında kullanılan ResNet-18 mimarisi Şekil 3.11'de gösterilmiştir.



Şekil 3.11. ResNet 18 mimarisi

3.5. Genetik Algoritma (GA)

Genetik algoritma, evrimsel sürece dayanan uyarlanabilir bir sezgisel arama yöntemidir. Genetik algoritma 1970'lerin başında John Holland tarafından tanıtılmıştır [87]. Genetik algoritma, doğal seçim ve doğal genetik mekaniğine dayanan olasılıksal bir arama algoritmasıdır. Genetik algoritma, popülasyon adı verilen bir çözüm kümesi ile başlatılır. Genetik algoritmada her bir çözüm bir kromozom tarafından temsil edilir. Popülasyon büyüklüğü her nesil boyunca korunur. Her nesilde, her kromozomun uygunluğu değerlendirilir ve daha sonra bir sonraki nesil için kromozomlar uygunluk değerlerine göre olasılıksal olarak seçilir. Seçilen kromozomlardan bazıları rastgele eşlenir ve yeni nesil üretir. Yeni nesil üretilirken, çaprazlama ve mutasyon gerçekleşir. Yüksek uygunluk değerlerine sahip kromozomların seçilme olasılığı yüksek olduğundan, yeni neslin kromozomları eski neslin kromozomlarından daha yüksek ortalama uygunluk değerine sahip olabilir. Evrim süreci, son koşul sağlanana kadar tekrarlanır [88].

Genetik algoritmalar küresel arama yeteneğine sahiptir. Genetik algoritmalar biyoloji, mühendislik, bilgisayar bilimleri ve sosyal bilimler gibi çeşitli alanlardaki karmaşık problemlere en uygun çözümleri bulmak için kullanılmıştır. Genel algoritmalar, yerel arama yöntemlerinin aksine, olasılıksal bir strateji tarafından kontrol edilen bir dizi bağımsız hesaplamaya dayanır. Birbirini izleyen nesiller arasında en iyi bireylerin doğal seçiminin bir simülasyonudur [89]. GA 'nın temel adımlar Algoritma 1'de sunulmuştur.

Tablo 3.1. Algoritma 1 Genetik Algoritmanın temel adımları

1: Başlatma:

2: Rastgele başlangıç kromozomları oluştur ve değerlendir.

3: Çaprazlama Oranı (CR) ve Mutasyon Oranı (MR) kontrol parametrelerini tanımla.

4: Tekrarla

5: Seçim:

6: Seçim stratejisine göre olasılık değerlerine bağlı olarak kromozomları seçin (en uygun).

7: Çaprazlama:

8: CR üzerinden çaprazlama stratejisine bağlı olarak yeni yavruları üret.

9: Mutasyon:

10: Mutasyonu yeni yavrulara MR üzerinde rassal olarak uygulayın.

11: Yeni yavruları değerlendir.

12: En uygun popülasyonu yeni yavrularla değiştir.

13: En iyi yavruyu hafızada tut.


14: Olana kadar (Maksimum nesil sayısı)

3.6. Destek Vektör Makineleri(SVM)

Destek vektör makineleri (SVM) Vapnik ve arkadaşları tarafından önerilmiştir [90],[91]. SVM, herhangi bir sınıflandırma, kümeleme ve regresyon problemi için kullanılabilen bir makine öğrenme yöntemidir [92]. Çekirdek fonksiyonu SVM'deki ilgili problem için yüksek boyutlu öznelilikler olarak girdiden çıktıya eşlemek için kullanılır. SVM'nin başarısı sadece destek vektörlerinin ve ağırlıkların sayısına değil aynı zamanda çekirdek fonksiyonuna da bağlıdır [93]. Veri setlerinin doğasına göre doğrusal, Gauss, ikinci dereceden, kübik ve polinom çekirdekleri gibi farklı çekirdekler kullanılabilir. Bu tezde önerilen yöntemde doğrusal çekirdek kullanılmıştır.

SVM'ler denetimli, parametrik olmayan bir istatistiksel öğrenme tekniğidir. Temel yapısında [94] SVM bir dizi etiketli veri örneğiyle sunulur. SVM eğitim algoritması, veri kümesini eğitim örnekleriyle tutarlı bir şekilde önceden tanımlanmış ayrı bir sayıda sınıfa ayıran bir hiper düzlem bulmayı amaçlar. Optimal ayırma hiper düzlemi terimi, eğitim adımında elde edilen yanlış sınıflandırmaları en aza indiren karar sınırını ifade etmek için kullanılır. Öğrenme, eğitim modellerini (potansiyel olarak yüksek boyutlu uzayda) ayırmak ve daha sonra aynı konfigürasyonlar (boyutlar) altında simülasyon verilerini ayırmak için en uygun karar sınırına sahip bir sınıflandırıcı bulmanın yinelenmeli sürecini ifade eder [95].

Şekil 3.12'de, iki boyutlu bir girdi uzayında iki sınıflı ayrılabilir bir sınıflandırma probleminin basit bir senaryosu gösterilmektedir. SVM'lerin önemli bir özelliği, ayırıcı hiper düzlemin tanımlanmasında ve belirlenmesinde genellikle mevcut tüm eğitim örneklerinin kullanılmamasıdır. Kenar boşluğu üzerinde yer alan noktaların alt kümesi (destek vektörleri olarak adlandırılır), maksimum kenar boşluğu hiper düzlemini tanımlayan tek noktadır. [96].



Şekil 3.12. Doğrusal destek vektör makinesi örneği [96]


3.7. Önerilen Yöntem

Önceden eğitilmiş modeller, yeni görüntülerle model üzerinde yeni bir eğitim süreci gerçekleştirilmesi koşuluyla neredeyse tüm görüntü türlerini sınıflandırmak için kullanılabilir. Tıbbi görüntü sınıflandırmada, transfer öğrenme için en yaygın ön eğitim modelleri AlexNet, GoogleNet, DenseNet ve ResNet'tir. Transfer öğrenme kullanarak tıbbi görüntü sınıflandırmasını ele alan en yeni inceleme makalesi Kim ve arkadaşları [97] tarafından yayınlanmıştır. Bahsedilen çalışmada, tıbbi görüntü sınıflandırma problemlerinde transfer öğrenmenin kullanılabilmesi için 425 adet transfer öğrenme çalışması incelenmiştir [97]. ResNet modelinin, tıbbi görüntülerin özneteliklerini çıkarmada daha etkili olduğu belirtilmiştir. Ayrıca ResNet 18 modelinin ResNet'in diğer versiyonuna kıyasla hesaplama karmaşıklığı daha düşük olsa da ResNet modellerinin doğruluk oranları neredeyse aynıdır [57]. Ayrıca tez çalışmasında kornea ülseri tespit problemini çözmek için görüntü seçimi sayesinde ResNet 18 modelinin performansı artırılmıştır.


Bu tezde, GA, SVM ve ResNet ham görüntüleri kornea ülserini tespit etmek için birleştirilmiştir. Önerilen yöntem Şekil 3.13'de sunulmuştur. Önerilen yöntemde sırasıyla şu adımlar gerçekleştirilmektedir:

İlk olarak, ham görüntüler ResNet'in girişine uygulanır. Daha sonra, öznetelik haritaları (x) ResNet'in ilgili katmanının çıktısı üzerinden hesaplanır. Öznetelik haritası çıkarımına ilişkin bir örnek Şekil 3.15'te verilmiştir. Ardından, GA kullanılarak etkili öznetelik haritaları ($\hat{x}$) seçilir. Bundan sonra, seçilen her bir öznetelik haritasının ortalamaları havuzlama olarak hesaplanır. Son olarak, ($\hat{y}$) kornea ülserini sınıflandırmak için SVM kullanılır. Sonuç olarak, kornea ülserini tespit etmek için daha başarılı bir sınıflandırıcı yöntemi elde edilmiştir.


Önerilen yöntemin öznetelik seçim çerçevesi Şekil 3.14'de gösterilmektedir. Kornea ülseri için veri setinde tam 712 görüntü bulunduğundan, ResNet'in her katmanında aynı sayıda öznetelik haritası hesaplanabilir. Önerilen yöntemde en etkili 192 öznetelik haritasının seçilmesi amaçlanmıştır. Bu nedenle GA'da her kromozomun boyutluluğu 192'dir ve her gen rastgele olarak başlatılmıştır. Ebeveynler uygunluk değerlerine göre seçilir. Her kromozomun uygunluğu, ilgili kromozoma dayalı olarak seçilen öznetelik haritaları üzerinde SVM'nin doğruluğuna eşittir. GA'da uniform çaprazlama [98] uygulanmıştır. Uniform çaprazlamada her gen için $[0, 1]$ arasında rastgele bir değer üretilir. Rastgele üretilen değer $CR=0.5$ 'ten küçükse, Gen yavruya (Ch_1) atanır. Aksi takdirde gen yavruya (Ch_2) atanır.



Şekil 3.13. Önerilen yöntemin çerçevesi x :İlgili katmanın çıkışında elde edilen öznitelikler $\hat{x}$:GA tarafından elde edilen seçilmiş öznitelikler
 y :Gerçek etiket $\hat{y}$:Tahmin edilen etiket



Şekil 3.14. Önerilen yöntemin öznitelik seçim çerçevesi



Şekil 3.15. Seçili katmanın öznitelik haritası

Her bir yavru $MR=0.1$ ile mutasyona uğratılır. Mutasyonda her gen için $[0, 1]$ arasında rastgele bir değer üretilir. Rastgele üretilen değer $MR=0.1$ 'den küçükse, kromozomun genlerinden farklı olması gereken rastgele seçilen bir görüntü indeksi yavruya atanır. Aksi takdirde gen yavruya atanır. Her neslin en iyi kromozomu saklanır. Ebeveyn seçimi çaprazlama ve mutasyon işlemleri maksimum nesle kadar yürütülür.

Önerilen yöntemin kontrol parametreleri, Tablo 3.2'de sunulmuştur.


Tablo 3.2. Önerilen yöntemin parametreleri

	Parametre İsmi	Parametre Değeri
Öznitelik Çıkarma (Deep Model)	CNN Mimari	ResNet-18
	Yeniden eğitim	Hayır
	Giriş	İmgeler
	Çıkış	Öznitelik Haritası
Öznitelik Seçimi (GA)	Populasyon Sayısı	40
	CR	0.5
	MR	0.1
	Max Gen	1000
Sınıflandırıcı (SVM)	SVM - Kernel	Lineer -Kernel
Seçilmiş Öznitelik Haritaları	Giriş Sayısı	712
	Çıkış Sayısı	192

3.7.1. Veri Seti

Sun Yat-sen Üniversitesi Zhongshan Oftalmik Merkezi'nde çeşitli derecelerde kornea ülseri olan hastalardan oküler yüzeyleri tespit eden toplam 712 floresan boyama görüntüsü toplanmıştır. Toplanan 712 görüntünün 676 tanesi korneal ülsere sahip ve 36 tanesi korneal ülsere sahip olmayan bireylerden oluşmaktadır [5]. Beyaz ışık kaynağının maksimum genişliğine (30 mm) sahip yarık ışıklı aydınlatma, mavi uyarma filtresi, 10 veya 16 büyütme ve ışık kaynağı altta olacak şekilde 10 ila 308 eğik açıda bir difüzyon lensi ve muayene odasının parlaklığına bağlı olarak diyafram açıklığını, maruz kalma süresini ve deklanşör hızını ayarlamak için otomatik bir dijital kamera sistemi kullanılmıştır.

Görüntüler, bir Canon EOS 20D dijital fotoğraf makinesi (Canon, Tokyo, Japonya) ile birlikte bir Haag Streit BM 900 kesit lamba mikroskobu (Haag Streit AG, Bern, İsviçre) kullanılarak elde edilmiştir. Görüntüler 2592×1728 piksel çözünürlükte 24-bit RGB renk ile JPG formatında kaydedilmiştir. Her görüntü, görüntüde tamamen temsil edilen ve görüş alanında yaklaşık olarak ortalanmış olan yalnızca bir kornea içerir [99]. Veri setinden bazı kornea ülseri örnek görüntüleri Şekil 3.16'da sunulmuştur.



Şekil 3.16. Verisetinden kornea ülseri imge örnekleri

4. DENEYSEL SONUÇLAR VE TARTIŞMA

Bu bölümde elde edilen deneysel sonuçlar sunulmuştur. Elde edilen sonuçların istatistiksel olarak karşılaştırmasına yer verilmiştir. En sonda ise yürütme zamanı analizi sonuçları sunulmuştur.


4.1. Deneysel Yapı

ResNet-18 mimarisinde 71 katman bulunmaktadır. Bu katmanlar evrişim katmanı, ReLu katmanı ve havuzlama katmanlarından oluşmaktadır. DNN, bu temel katmanları tekrarlayarak verideki öznitelikleri girişten çıkışa doğru kademeli olarak ortaya çıkarmaktadır. Klasik derin sinir ağlarından farklı olarak ResNet'in her katmanında ekstra bir normalizasyon katmanı bulunmaktadır.

ResNet-18 toplamda 10 bloktan oluşmaktadır. Blok-1 giriş görüntüsü, konvolüsyon, normalizasyon, ReLu ve havuzlama katmanlarından oluşur. Blok-2a sırasıyla konvolüsyon, normalizasyon, ReLu, konvolüsyon, normalizasyon, toplama işlemi (Blok-1 çıkışı ve Blok-2a son normalizasyon katmanı çıkışı), ReLu (Blok2a çıkışı) katmanlarından oluşmaktadır. Sonraki 7 blok Blok-2a'ya benzer şekilde yapılandırılmıştır. Son blok sınıflandırma katmanı olarak tam bağlı bir katmana sahiptir.

Bu tez çalışmasında öncelikle, ResNet-18'in 67 katmanından elde edilen özniteliklerden hangilerinin sınıflandırma performansı için daha etkili olduğu incelenmiştir. Bu süreç, Şekil 4.1'de gösterilmiştir. ResNet katmanlarından 3 tanesi $112 \times 112 \times 64$ (2408448), ResNet katmanlarından 15 tanesi $56 \times 56 \times 64$ (3010560), ResNet katmanlarından 16 tanesi $28 \times 28 \times 128$ (1605632), ResNet katmanlarından 16 tanesi $14 \times 14 \times 256$ (802816), ResNet katmanlarından 16 tanesi $7 \times 7 \times 512$ (401408), ResNet katmanlarından 1 tanesi $1 \times 1 \times 512$ (512) özniteliğe sahiptir. Toplamda yaklaşık 8,2 milyon özniteliğe sahip olduğu görülmektedir. Yaklaşık 8,2 milyon öznitelik, sınıflandırma üzerinde dolaylı bir etkiye sahiptir.

Klasik yaklaşımda son katman olan pool5'te 512 öznitelik kullanılarak sınıflandırma yapılmaktadır. Ancak kornea ülserinin sınıflandırmasında pool5'teki öznitelikler ile sınıflandırma performansı 0,64 olduğu görülmüştür. Önerilen yöntem ile doğru bir katman seçim stratejisi üzerinde sınıflandırma başarısı 0,85 çıkarılabileceği görülmüştür.




Şekil 4.1. Her bir evrişimli katman üzerinde genel öznetelik haritalama analiz süreci

4.2. ResNet üzerinden Kornea Ülserinin Sınıflandırma Başarımı

Deneysel çalışmada öncelikle hangi katmanların sınıflandırma performansını etkilediği incelenmiştir. Bu amaçla her bir görüntünün 67 katmandan oluşan bir temsili hesaplanır. Bu temsil her bir görüntünün ortalaması alınarak elde edilir. Örneğin, i_{th} katmanının çıktısı $a^i * b^i * w^i$ ile gösterilebilir ve $a^i * b^i$ boyutunda bir $1 * w^i$ vektöre dönüştürülmüş w^i görüntü içerir. Burada $w^i = [w_1^i w_2^i \dots \dots \dots w_m^i]$, $a^i \times b^i$ boyutlarındaki her bir görüntünün ortalamasını içerir. Burada indeks $i=1,2,3,\dots,67$. Elde edilen veriler sınıflandırıcıda kullanılmak üzere %70 eğitim ve %30 test olarak ikiye ayrılmıştır.

Teknik olarak, her görüntünün çıktısı ortalama bir sayı olarak ifade edilir. Böylece öznetelik sayısı etkin bir şekilde azaltılmıştır. Her katmandan elde edilen veri ile 20 koşma gerçekleştirilmiştir. 20 farklı koşmanın minimum, maksimum, ortalama, medyan ve standart değerleri Tablo 4.1'de verilmiştir. Bu tablo incelendiğinde; res5b_branch2b, res5a_relu, bn5b_branch2a, res5b_branch2a ve res5a_branch2a katmanları en yüksek sınıflandırma performansına sahip olduğu anlaşılmaktadır. Ayrıca katmanların başarı oranları grafiksel olarak Şekil 4.2'de verilmiş olup, sonuçlar son katmanların başarısını göstermektedir. Klasik yaklaşımla ele alınan pool5 katmanının sonucunun 0,64 doğruluk değeri ile birçok katmanın gerisinde kaldığını belirtmek gerekir.



Şekil 4.2. Katmanların sınıflandırma başarı oranları

Tablo 4.1. Her bir katmandan elde edilen başarımlar oranları

Katman	Katman Adı	Ortalama	Max	Min	Ortanca	Katman	Katman Adı	Ortalama	Max	Min	Ortanca
63	res5b_branch2b	0,6923	0,723	0,6197	0,7042	16	bn2b_branch2b	0,6462	0,7042	0,5915	0,6408
59	res5a_relu	0,6887	0,7324	0,6432	0,6925	18	res2b_relu	0,6446	0,7089	0,5915	0,6455
61	bn5b_branch2a	0,6862	0,7418	0,6291	0,6831	66	res5b_relu	0,6432	0,6761	0,6009	0,6502
60	res5b_branch2a	0,685	0,7277	0,6197	0,6831	67	pool5	0,6432	0,6761	0,6009	0,6502
51	res5a_branch2a	0,6808	0,7559	0,6385	0,6761	34	res3b_relu	0,6432	0,6854	0,5728	0,6502
58	res5a	0,6775	0,7324	0,6432	0,6737	23	res3a_branch2a_relu	0,6415	0,6854	0,5728	0,6408
54	bn5a_branch2a	0,6758	0,7324	0,6197	0,6784	32	bn3b_branch2b	0,6411	0,6854	0,5728	0,6479
57	bn5a_branch2b	0,6725	0,723	0,6197	0,6761	24	res3a_branch2b	0,6401	0,6854	0,5915	0,6455
12	res2b_branch2a	0,6723	0,7183	0,615	0,6784	3	conv1_relu	0,639	0,6667	0,5869	0,6479
10	res2a	0,6704	0,7136	0,6056	0,6761	8	res2a_branch2b	0,6387	0,6854	0,5915	0,6432
11	res2a_relu	0,6688	0,7136	0,615	0,6737	25	bn3a_branch2b	0,6383	0,6854	0,5915	0,6432
42	res4a	0,6681	0,723	0,6009	0,6714	26	res3a	0,6383	0,6854	0,5681	0,6432
53	bn5a_branch1	0,6678	0,7136	0,6338	0,662	20	res3a_branch1	0,6373	0,6808	0,5915	0,6385
40	res4a_branch2b	0,6667	0,7183	0,6103	0,669	9	bn2a_branch2b	0,6369	0,6854	0,5915	0,6455
41	bn4a_branch2b	0,6664	0,723	0,5962	0,669	36	res4a_branch1	0,6362	0,6808	0,5634	0,6432
4	pool1	0,6643	0,7136	0,5915	0,6714	39	res4a_branch2a_relu	0,6359	0,6808	0,5681	0,6385
5	res2a_branch2a	0,6636	0,7042	0,5869	0,6667	28	res3b_branch2a	0,6354	0,6808	0,5822	0,6455
49	res4b	0,662	0,7136	0,5962	0,6714	7	res2a_branch2a_relu	0,635	0,6667	0,5869	0,6455
6	bn2a_branch2a	0,6613	0,7089	0,5822	0,6643	55	res5a_branch2a_relu	0,6345	0,6808	0,5728	0,6385
56	res5a_branch2b	0,661	0,7042	0,5915	0,6761	31	res3b_branch2b	0,6345	0,6854	0,5728	0,6338
35	res4a_branch2a	0,661	0,7183	0,6056	0,6549	37	bn4a_branch1	0,6343	0,6854	0,554	0,6362
38	bn4a_branch2a	0,6594	0,7136	0,6103	0,6596	27	res3a_relu	0,6333	0,6901	0,5775	0,6432
44	res4b_branch2a	0,6589	0,723	0,615	0,662	21	bn3a_branch1	0,6331	0,6714	0,5775	0,6432
19	res3a_branch2a	0,6582	0,6995	0,5869	0,6667	14	res2b_branch2a_relu	0,6317	0,6901	0,5681	0,6244
62	res5b_branch2a_relu	0,658	0,7089	0,5822	0,6667	48	bn4b_branch2b	0,6317	0,6901	0,5587	0,6362
17	res2b	0,6547	0,7136	0,5962	0,6526	29	bn3b_branch2a	0,63	0,6714	0,5681	0,6362
45	bn4b_branch2a	0,6521	0,6995	0,6056	0,6573	47	res4b_branch2b	0,6289	0,662	0,5634	0,6338
13	bn2b_branch2a	0,6519	0,6948	0,6056	0,662	65	res5b	0,6268	0,6854	0,5681	0,6197
52	res5a_branch1	0,6505	0,7183	0,5915	0,6549	64	bn5b_branch2b	0,6249	0,6761	0,5634	0,615
43	res4a_relu	0,6493	0,7089	0,6009	0,6549	46	res4b_branch2a_relu	0,5948	0,6197	0,5634	0,5962
50	res4b_relu	0,6491	0,6948	0,5869	0,6596	1	conv1	0,585	0,6385	0,5211	0,5892
33	res3b	0,6472	0,6995	0,5775	0,6502	2	bn_conv1	0,5704	0,615	0,5164	0,561
22	bn3a_branch2a	0,6465	0,6948	0,5915	0,6479	30	res3b_branch2a_relu	0,5688	0,6056	0,5164	0,5681
15	res2b_branch2b	0,6462	0,6948	0,6009	0,6385						

4.3. Önerilen Yöntemin Sınıflandırma Başarımı


Önerilen yöntemin başarımı, Tablo 4.1’de en iyi sınıflandırma başarısını sunan res5b_branch2b, res5a_relu, bn5b_branch2a, res5b_branch2a ve res5a_branch2a katmanları üzerinden değerlendirilecektir.

Önerilen yöntemde GA uygulanırken popülasyon büyüklüğü 40 ve kromozom sayısı (görüntü sayısı) 192 olarak seçilmiştir. Mutasyon oranı 0,1 olarak belirlenirken, iterasyon sayısı 1000 olarak seçilmiştir. Bu parametreleri seçmek için sistematik bir yöntem olmadığından parametreler deneme yanılma yoluyla seçilmiştir.

Önerilen yöntem ile 20 farklı koşma üzerinden res5b_branch2b, res5a_relu, bn5b_branch2a, res5b_branch2a ve res5a_branch2a katmanlarından seçilen görüntülerin sınıflandırma sonuçları Tablo 4.2.’de sunulmuştur. Ayrıca önerilen yöntemin Şekil 4.3’te res5b_branch2b, res5a_relu, bn5b_branch2a, res5b_branch2a ve res5a_branch2a katmanlarının her bir çalıştırmadan elde edilen başarı oranları sıralanmış olarak verilmiştir. Tablo 4.2 incelendiğinde ortalamada en yüksek doğruluk değeri 0,8582 ile res5a_branch2a katmanından elde edilen özniteliklerden sağlandığı görülmektedir. Aynı zamanda 0,8246 ile res5a_relu katmandan ortalama da en düşük değer elde edildiği görülmektedir. Bu durum Tablo 4.1 ile kıyaslandığında önerilen yöntemde anlamlı bir performans artışı sağlandığı anlaşılmaktadır.

Tablo 4.2. En iyi beş katman için temel istatistik tablosu

Katman	Ortalama	Max	Min	Ortanca	Std
res5a_branch2a	0,8423	0,8732	0,8028	0,8498	0,0215
res5a_relu	0,8246	0,8545	0,7887	0,8263	0,0212
res5b_branch2a	0,8582	0,8873	0,8169	0,8568	0,0204
bn5b_branch2a	0,8498	0,8826	0,8075	0,8521	0,0214
res5b_branch2b	0,8359	0,8732	0,8028	0,8357	0,0214




Şekil 4.3. Her bir simülasyondan elde edilen sınıflandırma başarımları

Önerilen yöntemin performans artışının daha anlaşılır olması için Tablo 4.3 de öznitelik seçimi olmadan elde edilen sonuçlar ile önerilen yöntemin sonuçları karşılaştırmalı olarak sunulmuştur. Bu tablo incelendiğinde önerilen yöntem ile en az %19,73, en çok %25,28 oranında performans artışı elde edilmiştir. Ayrıca 512 öznitelikten en etkili 192 öznitelik seçilmiştir. Böylece yaklaşık %37.5 oranında öznitelik azaltılmıştır.

Tablo 4.3. Önerilen yöntemin kazanımları

Katman	Önerilen Yöntem Ortalama DO	İleri Besleme Ortalama DO	Fark	Kazanım %
res5b_branch2a	0,8582	0,685	0,1732	25,28
bn5b_branch2a	0,8498	0,6862	0,1636	23,84
res5a_branch2a	0,8423	0,6808	0,1615	23,72
res5b_branch2b	0,8359	0,6923	0,1436	20,74
res5a_relu	0,8246	0,6887	0,1359	19,73

Önerilen yöntemde öznitelik seçim sürecinde kullanılan GA'nın res5b_branch2b, res5a_relu, bn5b_branch2a, res5b_branch2a ve res5a_branch2a katmanlarının yakınsama grafikleri Şekil 4.4'te verilmiştir. Burada tüm katmanlar için 400 iterasyona kadar kayda değer bir iyileşme gözlemlenebilmektedir



Şekil 4.4. En iyi beş katmanın ortalama yakınsama grafikleri

4.4. İstatiksel Analiz

Res5b_branch2b, res5a_relu, bn5b_branch2a, res5b_branch2a ve res5a_branch2a katmanlarından elde edilen sonuçlar da istatistiksel olarak birbirleriyle karşılaştırılmıştır. Wilcoxon işaretlenmiş sıralar testi temel istatistiki değerler üzerinden Tablo 4.4'te gösterilmiştir. Tablo 4.4'te sunulan sonuçlara göre, res5b_branch2b ve res5a_branch2a arasında anlamlı bir fark yoktur (p - değeri $> 0,05$). Fakat diğer tüm kombinasyonlarda istatistiksel olarak anlamlı bir fark vardır (p - değeri $< 0,05$).

Tablo 4.4. En iyi beş katmanın istatistiksel olarak karşılaştırma tablosu

Katmanlar	res5a_branch2a	res5a_relu	res5b_branch2a	bn5b_branch2a	res5b_branch2b
res5a_branch2a	1	0,0004	0,0002	0,0045	0,0555
res5a_relu	0,0004	1	0,0001	0,0001	0,0025
res5b_branch2a	0,0002	0,0001	1	0,0029	0,0003
bn5b_branch2a	0,0045	0,0001	0,0029	1	0,0014
res5b_branch2b	0,0555	0,0025	0,0003	0,0014	1

4.5. Sonuçların literatürle kıyaslanması ve zaman analizi

Bu tezde kullanılan veri setinin temel makalesi [97] paydaşları tarafından yayınlanmıştır. Önerilen yöntemin sonuçlarını literatürde aynı veri setini kullanan diğer yöntemlerin sonuçlarıyla karşılaştırmak için öncelikle [97] numaralı makaleye atıfta bulunan toplam 40 adet makale Web of Science (11), PubMed (7) ve Google Scholar (22) veri tabanlarından alınmıştır. Bunlardan 25'i birbirinin tekrarı olduğu için göz ardı edilmiştir. Kalan 15 makale özgündür ve karşılaştırma için değerlendirilmiştir. Segmentasyon (5) ve medikal (3) olmak üzere toplam 8 çalışma, sınıflandırmaya odaklanmadığı için hariç tutulmuştur. Kalan 5 çalışmada, kornea ülseri tipleri olan noktasal kornea, noktasal- pullu karışık kornea ve pullu kornea ülserleri, transfer öğrenme kullanılarak kornea ülseri tespit edilmeden sınıflandırılması amaçlanmıştır [100],[20]. Geriye kalan çalışmalarda, önerilen yöntemler uygulanmadan önce görüntüler maskelenmiştir. Sonuç olarak, bilğimiz dahilinde adil bir karşılaştırma için herhangi bir çalışma bulunamamıştır.

Hesaplama zamanı (HZ), bir algoritmanın verimliliğini değerlendirmek için önemli bir parametredir. Önerilen yöntemin HZ'sini hesaplamada metasezgisel yaklaşımlar için önerilen[49] yöntem kullanılmıştır. Önerilen yöntemin kontrol parametreleri, öznitelik haritaları seçimini (FMS) ve seçilen öznitelik haritaları üzerinden sınıflandırmayı (SFM) hesaplamak için Tablo 3.2'de sunulduğu gibi kullanılmıştır. Simülasyonlar i3-7130U 2.7 GHz, 20 GB RAM sahip bir PC üzerinden gerçekleştirilmiştir. Önerilen yöntemin hesaplanan HZ'leri Tablo 4.5'de verilmiştir. Bu tablo incelendiğinde, FMS işleminin her katmandaki HZ'lerinin yüksek hesaplama değerleri olduğu görülmektedir. Bununla birlikte SFM'ler üzerinden sınıflandırmanın her katmandaki HZ'leri kabul edilebilir hesaplama değerleridir. Ancak bu durum, elde edilen kazanç sayesinde göz ardı edilebilir düzeydedir.

Tablo 4.5.Önerilen metodun zaman karmaşıklığı

Katmanlar	FMS Hesaplama Zamanı			SFM Hesaplama Zamanı		
	Ort.	Std.	Karmaşıklık	Ort.	Std.	Karmaşıklık
res5b_branch2a	4,68E+03	1,84E+02	1,46E+04	6,80E-02	6,11E-03	2,12E-01
bn5b_branch2a	4,42E+03	1,26E+02	1,38E+04	6,27E-02	6,69E-03	1,95E-01
res5a_branch2a	4,46E+03	2,90E+02	1,39E+04	8,23E-02	5,44E-02	2,56E-01
res5b_branch2b	4,25E+03	1,22E+02	1,32E+04	6,71E-02	1,82E-02	2,09E-01
res5a_relu	4,36E+03	3,12E+02	1,36E+04	6,28E-02	9,09E-03	1,95E-01
Satır Ort.	4,44E+03	2,07E+02	1,38E+04	6,86E-02	1,89E-02	2,13E-01

5.TARTIřMA, SONUÇLAR VE ÖNERİLER

Bu tezde elde edilen sonuçlar ResNet derin sinir ağıının ara katmanlarında oluşan imgelerin öznitelik olarak klasik bir sınıflandırıcı olan SVM’de kullanıldığında ne kadar iyi sonuçlar elde edilebileceğini göstermiştir. Çalışmamızda 512 öznitelikten en etkili 192 öznitelik seçilmiştir. Böylece yaklaşık %37.5 oranında öznitelik azaltılmıştır Bu da çalışmamızda öncelikle ResNet gibi çok fazla katmana sahip bir ağ yapısının öznitelik çıkarıcı olarak kullanıldığında oluşan dezavantajların ortaya çıkarılıp analiz edilmesini sağlamıştır. Analiz sonuçları grafiksel ve tablo şeklinde sunulmuş olup, incelemeyi daha verimli hale getirmiştir. Bu tezde önerilen framework Resnet, GA ve SVM gibi ana yapılardan meydana gelmektedir. Çalışmamızda yapıların dezavantajları bertaraf edilerek avantajlı hale getirilmeye çalışılmıştır ve sunulduğu üzere büyük oranda performans artışı sağlanmıştır. İleriki çalışmalarda bu yapıların farklı versiyonları denenerek daha üstün başarımlar elde etmek mümkün olabilir. Çalışmamız ileriki çalışmalara ışık tutarak bu alanda daha önemli adımlar atılmasına olanak sağlayacaktır. Bu çalışmada karşılaşılan en önemli sorun GA ile Resnet gibi bir yapıdan imge seçimi işleminin hesaplama süresinin yüksek kalmasıdır. Bu problemin çözümü için popülasyon büyüklüğü azaltılabilir. Ancak bu durumda sınıflandırma başarımları düşmektedir. Optimum popülasyon büyüklüğü son derece kritiktir. İleriki çalışmalarda bu durum göz önünde bulundurulmalıdır. Ayrıca ileriki çalışmalarda GA yerine farklı optimizasyon algoritmaları, SVM yerine farklı sınıflandırıcılar, ResNet yerine farklı derin sinir ağı modeli farklı veri setleriyle daha geniş bir çalışma yapılabilir. Sonuçların umut vericidir bununla birlikte zaman alıcı olması en büyük dezavantajdır. Bu dezavantajı göz önünde bulundurarak deneylerin kapasitesi daha yüksek bilgisayarlarla yapılması gerekmektedir.

KAYNAKLAR

- [1] Methodologies to Diagnose and Monitor Dry Eye Disease: Report of the Diagnostic Methodology Subcommittee of the International Dry Eye WorkShop (2007). (2007). *The Ocular Surface*, 5(2), 108–152.
- [2] Diamond, J., Leeming, J., Coombs, G., Pearman, J., Sharma, A., Illingworth, C., ... Easty, D. (1999). Corneal biopsy with tissue micro homogenisation for isolation of organisms in bacterial keratitis. *Eye*, 13(4), 545–549.
- [3] Cohen, E. J., Laibson, P. R., Arentsen, J. J., & Clemons, C. S. (1987). Corneal Ulcers Associated with Cosmetic Extended Wear Soft Contact Lenses. *Ophthalmology*, 94(2), 109–114.
- [4] Morgan, P. B., & Maldonado-Codina, C. (2009). Corneal staining: Do we really understand what we are seeing? *Contact Lens and Anterior Eye*, 32(2), 48–54.
- [5] Deng, L., Lyu, J., Huang, H., Deng, Y., Yuan, J., & Tang, X. (2020). The SUSTech-SYSU dataset for automatically segmenting and classifying corneal ulcers. *Scientific Data*, 7(1), 23.
- [6] Sun, Q., Deng, L., Liu, J., Huang, H., Yuan, J., & Tang, X. (2017). Patch-Based Deep Convolutional Neural Network for Corneal Ulcer Area Segmentation. In M. J. Cardoso, T. Arbel, A. Melbourne, H. Bogunovic, P. Moeskops, X. Chen, ... T. Vercauteren (Eds.), *Fetal, Infant and Ophthalmic Medical Image Analysis* (pp. 101–108). Cham: Springer International Publishing.
- [7] Ji, Q., Jiang, Y., Qu, L., Yang, Q., & Zhang, H. (2022). An Image Diagnosis Algorithm for Keratitis Based on Deep Learning. *Neural Processing Letters*, 54(3), 2007–2024.
- [8] Rodriguez, J. D., Lane, K. J., Ousler, G. W., III, Angjeli, E., Smith, L. M., & Abelson, M. B. (2015). Automated Grading System for Evaluation of Superficial Punctate Keratitis Associated With Dry Eye. *Investigative Ophthalmology & Visual Science*, 56(4), 2340–2347.
- [9] Caliskan, A., Yuksel, M. E., Badem, H., & Basturk, A. (2018). Performance improvement of deep neural network classifiers by a simple training strategy. *Engineering Applications of Artificial Intelligence*, 67, 14–23.
- [10] Badem, H., Basturk, A., Caliskan, A., & Yuksel, M. E. (2017). A new efficient training strategy for deep neural networks by hybridization of artificial bee colony and limited-memory BFGS optimization algorithms. *Neurocomputing*, 266, 506–526.
- [11] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- [12] Kim, P. (2017). Deep Learning. In P. Kim (Ed.), *MATLAB Deep Learning: With Machine Learning, Neural Networks and Artificial Intelligence* (pp. 103–120). Berkeley, CA: Apress.

- [13] Hao, X., Zhang, G., & Ma, S. (2016). Deep Learning. *International Journal of Semantic Computing*, 10(03), 417–439.
- [14] Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27–48.
- [15] Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2018). A Survey on Deep Transfer Learning. In V. Kůrková, Y. Manolopoulos, B. Hammer, L. Iliadis, & I. Maglogiannis (Eds.), *Artificial Neural Networks and Machine Learning – ICANN 2018* (pp. 270–279). Cham: Springer International Publishing.
- [16] Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., ... He, Q. (2021). A Comprehensive Survey on Transfer Learning. *Proceedings of the IEEE*, 109(1), 43–76. Presented at the Proceedings of the IEEE.
- [17] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
- [18] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770–778). Presented at the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA: IEEE.
- [19] Tang, N., Liu, H., Yue, K., Li, W., & Yue, X. (2020). Automatic classification for corneal ulcer using a modified VGG network. In *2020 International Conference on Artificial Intelligence and Computer Engineering (ICAICE)* (pp. 120–123). Presented at the 2020 International Conference on Artificial Intelligence and Computer Engineering (ICAICE).
- [20] Cinar, I., Taspinar, Y. S., Kursun, R., & Koklu, M. (2022). Identification of Corneal Ulcers with Pre- Trained AlexNet Based on Transfer Learning. In *2022 11th Mediterranean Conference on Embedded Computing (MECO)* (pp. 1–4). Presented at the 2022 11th Mediterranean Conference on Embedded Computing (MECO).
- [21] Mirjalili, S. (2019). Genetic Algorithm. In S. Mirjalili (Ed.), *Evolutionary Algorithms and Neural Networks: Theory and Applications* (pp. 43–55). Cham: Springer International Publishing.
- [22] Irsch, K., & Guyton, D. (2009). Anatomy of Eyes.
- [23] Bron, A. J., Tripathi, R. C., Tripathi, B. J., & Wolff, E. (1997). *Wolff's anatomy of the eye and orbit* (8th ed.). London: Chapman & Hall Medical.
- [24] Willoughby, C. E., Ponzin, D., Ferrari, S., Lobo, A., Landau, K., & Omid, Y. (2010). Anatomy and physiology of the human eye: effects of mucopolysaccharidoses disease on structure and function – a review. *Clinical & Experimental Ophthalmology*, 38(s1), 2–11.
- [25] Ozheredov, I., Prokopchuk, M., Mischenko, M., Safonova, T., Solyankin, P., Larichev, A., ... Shkurinov, A. (2018). In vivo THz sensing of the cornea of the eye. *Laser Physics Letters*, 15(5), 055601.

- [26] Meek, K. M. (2008). The Cornea and Sclera. In P. Fratzl (Ed.), *Collagen: Structure and Mechanics* (pp. 359–396). Boston, MA: Springer US.
- [27] John, T. (2010). *Corneal Endothelial Transplant DSEAK, DMEK and DLEK*. Boydell & Brewer Ltd.
- [28] Maurice, D. M. (1984). Chapter 1 - The Cornea and Sclera. In H. Davson (Ed.), *The Eye (Third Edition)* (pp. 1–158). Academic Press.
- [29] Gandhi, S., & Jain, S. (2015). The Anatomy and Physiology of Cornea. *Keratoprotheses and Artificial Corneas*, 19–25.
- [30] Oyster, C. W. (1999). *The human eye: structure and function*. Sunderland (Ma): Sinauer Associates Inc.
- [31] Wildes, R. (2005). Iris Recognition. In J. Wayman, A. Jain, D. Maltoni, & D. Maio (Eds.), *Biometric Systems: Technology, Design and Performance Evaluation* (pp. 63–95). London: Springer.
- [32] Litzinger, T., & Rio-Tsonis, K. (2002). Eye Anatomy.
- [33] Rossi, T., & Ripandelli, G. (2020). Pars Plana Vitrectomy and the Risk of Ocular Hypertension and Glaucoma: Where Are We? *Journal of Clinical Medicine*, 9, 3994.
- [34] Robert, J. S. (2004). *Embryology, Epigenesis and Evolution: Taking Development Seriously*. Cambridge University Press.
- [35] Ali, W., Akram, M., Saleem, U., Salam, A., & abdul salam, A. (2021). Date of publication xxxx 00, 0000, date of current version xxxx 00, 0000. Deep Learning based Segmentation of Retinal Blood Vessels from Enhanced Fundus Images. *IEEE Access*.
- [36] Detrick, B., & Hooks, J. J. (2010). Immune regulation in the retina. *Immunologic Research*, 47(1), 153–161.
- [37] Hughes, M. O. (n.d.). Anatomy of the Anterior Eye for Ocularists, 11.
- [38] Francois, G., Gautron, P., Breton, G., & Bouatouch, K. (2009). Image-Based Modeling of the Human Eye. *IEEE Transactions on Visualization and Computer Graphics*, 15(5), 815–827. Presented at the IEEE Transactions on Visualization and Computer Graphics.
- [39] P D, G., & Pushkala, K. (2020). Extra Visual Function of the Human Eye.
- [40] Hayreh, S. S., Zimmerman, M. B., Kimura, A., & Sanon, A. (2004). Central retinal artery occlusion.: Retinal survival time. *Experimental Eye Research*, 78(3), 723–736.
- [41] Jan, N., Anjum, M., Faridi, T., Iqbal, S., Mujahid, M., & Hussain, A. (2022). Determination And Identification the Awareness of Primary Eye Care in Community: Awareness of Primary Eye Care in Health care worker of Community. *Pakistan BioMedical Journal*, 340–343.

- [42] Vitale, S., Cotch, M. F., & Sperduto, R. D. (2006). Prevalence of Visual Impairment in the United States. *JAMA*, 295(18), 2158–2163.
- [43] Ivers, R. Q., Norton, R., Cumming, R. G., Butler, M., & Campbell, A. J. (2000). Visual Impairment and Hip Fracture. *American Journal of Epidemiology*, 152(7), 633–639.
- [44] Wood, J. M. (2002). Age and Visual Impairment Decrease Driving Performance as Measured on a Closed-Road Circuit. *Human Factors*, 44(3), 482–494.
- [45] Rowe, F., Brand, D., Jackson, C. A., Price, A., Walker, L., Harrison, S., ... Freeman, C. (2009). Visual impairment following stroke: do stroke patients require vision assessment? *Age and Ageing*, 38(2), 188–193.
- [46] Scott, V. (1987). Computers in Medicine: Applications and Possibilities. *JAMA*, 257(9), 1248.
- [47] Ibrahim, F., Ali, J. B., Jaais, A. F., & Taib, M. N. (2001). Expert system for early diagnosis of eye diseases infecting the Malaysian population. In *Proceedings of IEEE Region 10 International Conference on Electrical and Electronic Technology. TENCON 2001 (Cat. No.01CH37239)* (Vol. 1, pp. 430–432 vol.1). Presented at the Proceedings of IEEE Region 10 International Conference on Electrical and Electronic Technology. TENCON 2001 (Cat. No.01CH37239).
- [48] Shortliffe, E. H. (1983). Artificial Intelligence in Medicine. *JAMA*, 250(6), 829–830.
- [49] Teeyapan, K. (2021). Deep learning-based approach for corneal ulcer screening. In *The 12th International Conference on Computational Systems-Biology and Bioinformatics* (pp. 27–36). Presented at the CSBio2021: The 12th International Conference on Computational Systems-Biology and Bioinformatics, Virtual (GMT+7 Bangkok Time) Thailand: ACM.
- [50] Gross, J., Breitenbach, J., Baumgartl, H., & Buettner, R. (2021). High-Performance Detection of Corneal Ulceration Using Image Classification with Convolutional Neural Networks. *Hawaii International Conference on System Sciences 2021 (HICSS-54)*. Retrieved from https://aisel.aisnet.org/hicss-54/hc/big_data_on_healthcare_app/5
- [51] Alquran, H., Al-Issa, Y., Alsalatie, M., Mustafa, W. A., Qasmieh, I. A., & Zyout, A. (2022). Intelligent Diagnosis and Classification of Keratitis. *Diagnostics*, 12(6), 1344.
- [52] Akram, A., & Debnath, R. (2019). An Efficient Automated Corneal Ulcer Detection Method using Convolutional Neural Network. In *2019 22nd International Conference on Computer and Information Technology (ICCIT)* (pp. 1–6). Presented at the 2019 22nd International Conference on Computer and Information Technology (ICCIT).
- [53] Arora, D., Garg, M., & Gupta, M. (2020). Diving deep in Deep Convolutional Neural Network. In *2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)* (pp. 749–751). Presented at the 2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN).

- [54] Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. In *2017 International Conference on Engineering and Technology (ICET)* (pp. 1–6). Presented at the 2017 International Conference on Engineering and Technology (ICET).
- [55] Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9(4), 611–629.
- [56] Sarvamangala, D. R., & Kulkarni, R. V. (2022). Convolutional neural networks in medical image understanding: a survey. *Evolutionary Intelligence*, 15(1), 1–22.
- [57] Caliskan, A., & Rencuzogullari, S. (2021). Transfer learning to detect neonatal seizure from electroencephalography signals. *Neural Computing and Applications*, 33(18), 12087–12101.
- [58] Siegel, C., Daily, J., & Vishnu, A. (2016). Adaptive Neuron Apoptosis for Accelerating Deep Learning on Large Scale Systems.
- [59] Guo, T., Dong, J., Li, H., & Gao, Y. (2017). Simple convolutional neural network on image classification. In *2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA)* (pp. 721–724). Presented at the 2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA).
- [60] İnik, Ö., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85–104.
- [61] Ajit, A., Acharya, K., & Samanta, A. (2020). A Review of Convolutional Neural Networks. In *2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)* (pp. 1–5). Presented at the 2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE).
- [62] Gholamalinejad, H., & Khosravi, H. (2020). *Pooling Methods in Deep Neural Networks, a Review*.
- [63] Sheng, M., Zeng, H., Li, J., & Sun, W. (2021). Pooling and Convolution Layer Strategy on CNN for Melanoma Detection. In *2021 3rd International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI)* (pp. 153–161). Presented at the 2021 3rd International Conference on Machine Learning, Big Data and Business Intelligence (MLBDBI).
- [64] Brock, A., Donahue, J., & Simonyan, K. (2019, February 25). Large Scale GAN Training for High Fidelity Natural Image Synthesis. arXiv.
- [65] Doğan, F., & Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*, 10(2), 409–445.
- [66] Sabri, N., Abd Aziz, Z., Ibrahim, Z., Rosni, M. A. R. B. M., & Ghapul, A. (2018). Comparing Convolution Neural Network Models for Leaf Recognition. *International Journal of Engineering and Technology(UAE)*, 7, 141–144.

- [67] Inik, Ö., & Turan, B. (2018). Classification of Animals with Different Deep Learning Models.
- [68] Cun, Y. L., Boser, B., Denker, J. S., Howard, R. E., Hubbard, W., Jackel, L. D., & Henderson, D. (1990). Handwritten digit recognition with a back-propagation network. In *Advances in neural information processing systems 2* (pp. 396–404). San Francisco, CA, USA: Morgan Kaufmann Publishers Inc.
- [69] Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. Presented at the Proceedings of the IEEE.
- [70] Aloysius, N., & Geetha, M. (2017). A review on deep convolutional neural networks. In *2017 International Conference on Communication and Signal Processing (ICCSP)* (pp. 0588–0592). Presented at the 2017 International Conference on Communication and Signal Processing (ICCSP).
- [71] Mohammed, A. H. M., & Çevik, M. (2022). GoogleNet CNN Classifications for Diabetics Retinopathy. In *2022 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)* (pp. 1–4). Presented at the 2022 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA).
- [72] Pan, S. J., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. Presented at the IEEE Transactions on Knowledge and Data Engineering.
- [73] Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning. *Journal of Big Data*, 3(1), 9.
- [74] Deng, J., Dong, W., Socher, R., Li, L., Kai Li, & Li Fei-Fei. (2009). ImageNet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition* (pp. 248–255). Presented at the 2009 IEEE Conference on Computer Vision and Pattern Recognition.
- [75] Apostolopoulos, I. D., & Mpesiana, T. A. (2020). Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, 43(2), 635–640.
- [76] Shao, L., Liu, L., & Li, X. (2014). Feature Learning for Image Classification Via Multiobjective Genetic Programming. *IEEE Transactions on Neural Networks and Learning Systems*, 25(7), 1359–1371. Presented at the IEEE Transactions on Neural Networks and Learning Systems.
- [77] Zhu, F., Shao, L., & Lin, M. (2013). Multi-view action recognition using local similarity random forests and sensor fusion. *Pattern Recognition Letters*, 34(1), 20–24.
- [78] Cao, X., Zhong, W., Yan, P., & Liu, W. (2013). Transfer learning for pedestrian detection. *Neurocomputing*, 100, 51–57.
- [79] Wu, D., Zhu, F., & Shao, L. (2012). One shot learning gesture recognition from RGBD images. In *2012 IEEE Computer Society Conference on Computer Vision and Pattern*

- Recognition Workshops* (pp. 7–12). Presented at the 2012 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops.
- [80] Liu, J., Shah, M., Kuipers, B., & Savarese, S. (2011). Cross-view action recognition via view knowledge transfer. In *CVPR 2011* (pp. 3209–3216). Presented at the CVPR 2011.
 - [81] Fei-Fei, L. (2010). Knowledge transfer in learning to recognize visual object classes.
 - [82] Biederman, I. (1987). Recognition-by-components: A theory of human image understanding. *Psychological Review*, 94, 115–147.
 - [83] Shao, L., Zhu, F., & Li, X. (2015). Transfer Learning for Visual Categorization: A Survey. *IEEE Transactions on Neural Networks and Learning Systems*, 26(5), 1019–1034. Presented at the IEEE Transactions on Neural Networks and Learning Systems.
 - [84] Kalita, A., Peesapati, R., & Ahamed, S. R. (2022). Detection of COVID-19 using a Deep Neural Network with Transfer Learning Approach. In *2022 International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN)* (pp. 1–5). Presented at the 2022 International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN).
 - [85] Ou, X., Yan, P., Zhang, Y., Tu, B., Zhang, G., Wu, J., & Li, W. (2019). Moving Object Detection Method via ResNet-18 With Encoder–Decoder Structure in Complex Scenes. *IEEE Access*, 7, 108152–108160. Presented at the IEEE Access.
 - [86] Patnaik, S., Kumari, S., & Das Mahapatra, S. (2020). Comparison of deep CNN and ResNet for Handwritten Devanagari Character Recognition. In *2020 IEEE 1st International Conference for Convergence in Engineering (ICCE)* (pp. 235–238). Presented at the 2020 IEEE 1st International Conference for Convergence in Engineering (ICCE).
 - [87] Tsoukalas, L. H., & Uhrig, R. E. (1996). *Fuzzy and Neural Approaches in Engineering* (1st ed.). USA: John Wiley & Sons, Inc.
 - [88] Lee, W., & Kim, H.-Y. (2005). Genetic algorithm implementation in Python. In *Fourth Annual ACIS International Conference on Computer and Information Science (ICIS'05)* (pp. 8–11). Presented at the Fourth Annual ACIS International Conference on Computer and Information Science (ICIS'05).
 - [89] Kumar, M., Husain, M., Upreti, N., & Gupta, D. (2010). Genetic Algorithm: Review and Application. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3529843>
 - [90] Vapnik, V. N. (2000). *The Nature of Statistical Learning Theory*. New York, NY: Springer.
 - [91] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297.
 - [92] Tanveer, M., Rajani, T., Rastogi, R., Shao, Y., & Ganaie, M. (2021). *Comprehensive Review On Twin Support Vector Machines*.

- [93] Zhang, L., Zhou, W., & Jiao, L. (2004). Wavelet Support Vector Machine. *IEEE transactions on systems, man, and cybernetics. Part B, Cybernetics : a publication of the IEEE Systems, Man, and Cybernetics Society*, 34, 34–9.
- [94] Vapnik, V. (2006). *Estimation of Dependences Based on Empirical Data*. New York, NY: Springer.
- [95] Zhu, G., & Blumberg, D. G. (2002). Classification using ASTER data and SVM algorithms;: The case study of Beer Sheva, Israel. *Remote Sensing of Environment*, 80(2), 233–240.
- [96] Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247–259.
- [97] Kim, H. E., Cosa-Linan, A., Santhanam, N., Jannesari, M., Maros, M. E., & Ganslandt, T. (2022). Transfer learning for medical image classification: a literature review. *BMC medical imaging*, 22(1), 69.
- [98] Syswerda, G. (1989). *Uniform Crossover in Genetic Algorithms*. *Proc. 3rd Intl Conference on Genetic Algorithms 1989*.
- [99] Deng, L., Lyu, J., Huang, H., Deng, Y., Yuan, J., & Tang, X. (2020). The SUSTech-SYSU dataset for automatically segmenting and classifying corneal ulcers. *Scientific Data*, 7(1), 23.
- [100] Daoud, A. A. R., Gusseinova, M., & Celebi, A. R. C. (2022). Augmentation of accuracy with the use of different datasets in Artificial Intelligence based corneal ulcer detectio.