



**GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİ İLE CİLT KANSERİ
TEŞHİSİ İÇİN KARAR DESTEK SİSTEMİNİN GELİŞTİRİLMESİ**

Cihan AKYEL

**DOKTORA TEZİ
YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI**

**GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ**

EKİM 2022

Cihan AKYEL tarafından hazırlanan “GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİ İLE CİLT KANSERİ TEŞHİSİ İÇİN KARAR DESTEK SİSTEMİNİN GELİŞTİRİLMESİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Yönetim Bilişim Sistemleri Ana Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Nursal ARICI

Yönetim Bilişim Sistemleri Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Başkan: Prof. Dr. Tunç Durmuş MEDENİ

Yönetim Bilişim Sistemleri Ana Bilim Dalı, Ankara Yıldırım Beyazıt

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Üye: Prof. Dr. Hasan Şakir BİLGE

Elektrik – Elektronik Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Üye: Doç. Dr. Tahsin ÇETİNYOKUŞ

Endüstri Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Üye: Prof. Dr. Pınar KARAGÖZ

Bilgisayar Mühendisliği Ana Bilim Dalı, Orta Doğu Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Tez Savunma Tarihi: 26 /10 / 2022

Jüri tarafından kabul edilen bu tezin Doktora Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Aslıhan TÜFEKÇİ

Bilişim Enstitüsü Müdürü

ETİK BEYAN

Gazi Üniversitesi Bilişim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Cihan AKYEL

26/10/2022

GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİ İLE CİLT KANSERİ TEŞHİSİ İÇİN KARAR DESTEK SİSTEMİNİN GELİŞTİRİLMESİ

(Doktora Tezi)

Cihan AKYEL

GAZİ ÜNİVERSİTESİ

BİLİŞİM ENSTİTÜSÜ

Ekim 2022

ÖZET

Gelişen bilgi ve iletişim teknolojileriyle birlikte ulaşılabilen veri miktarı çok büyük boyutlara ulaşmıştır. Özellikle tıp alanında verilerin artmasıyla birlikte verilerin toplanması, işlenmesi ve kanser teşhisi gibi süreçlerde karar desteği için kullanımı önemli hale gelmektedir. Kanser vakalarının erken teşhisi, tedavi için hayati önem taşımaktadır. Son zamanlarda kanser teşhisinde derin öğrenme ve görüntü işleme gibi bilgisayarlı yöntemler yaygın olarak kullanılmaktadır. Karar destek sistemleri (KDS) kanser teşhisi için model bileşeninde bu yöntemleri kullanırlar. Bu çalışma kapsamında model bileşeninde görüntü işleme ve derin öğrenme algoritmaları kullanılarak, cilt kanserinin teşhisi için bir KDS geliştirilmiştir. Bu sistemde cilt kanseri görüntülerindeki gürültülerin temizlenmesi, lezyon bölütleme (segmentasyon) ve lezyon sınıflandırma aşamaları yer almaktadır. Önerilen KDS ile karar vericilere cilt kanserinin teşhisinde hızlı ve düşük maliyetle karar desteği sağlanması amaçlanmıştır. Mevcut literatürde halka açık bir maske veri seti bulunmadığından derin öğrenmede kullanmak için ISIC2018 veri setinden seçilen görüntüleri kullanarak gürültü maskeleri oluşturulmuştur. Çalışma kapsamında LinkNet-RCB7, ResNetC, UNet-RCB7 modelleri önerilmiştir. LinkNet-RCB7 ile gürültü temizliği ve lezyon bölütlemeye sırasıyla %91,92, %96,85 ve önerilen sınıflama modeli ile lezyonun sınıflandırılmasında %97 zar doğruluğu elde edilmiştir. Bu sonuçlar karar vericilerin teşhis sürecine, katkısı açısından ümit vericidir.

Bilim Kodu : 114606

Anahtar Kelimeler : UNet, LinkNet, Görüntü işleme, Karar destek sistemi, Derin öğrenme.

Sayfa Adedi : 79

Danışman : Prof. Dr. Nursal ARICI

DEVELOPMENT OF DECISION SUPPORT SYSTEM FOR DIAGNOSIS OF SKIN
CANCER BY IMAGE PROCESSING AND DEEP LEARNING METHODS
(PHD Thesis)

Cihan AKYEL

GAZİ UNIVERSITY
INSTITUTE OF INFORMATICS

October 2022

ABSTRACT

With the development information and communication technologies, the amount of data that can be accessed has reached enormous dimensions. Especially with the increase in the amount of data in the field of medicine, the collection and processing of data and its use in decision support in processes such as cancer diagnosis have become important. Early detection of cancer cases is vital for treatment. Recently, computerized methods such as deep learning and image processing have been widely used in cancer diagnosis. Decision support systems (DSS) for cancer diagnosis use these methods in the model component. A DSS for the diagnosis of skin cancer has been developed within the scope of the study by using deep learning and image processing algorithms in the model component of DSSs. In this system, there are stages of removing noise in skin cancer images, lesion segmentation and lesion classification. With the proposed DDS, it is aimed to provide decision support to decision makers in the diagnosis of skin cancer quickly and with low cost. Noise masks were created to use for deep learning with image in ISIC2018 because there is no publicly available mask dataset in the available literature. In this study, LinkNet-RCB7, ResNetC, UNet-RCB7 were proposed. Using LinkNet-RCB7, 91,92%, 96,85% dice accuracy in noise removal, lesion segmentation respectively, and using proposed classification model, 97% dice accuracy were obtained in lesion classification. These results are promising in terms of its contribution to the diagnosis process of decision makers.

Science Code : 114606

Key Words : UNet, LinkNet, Image Processing, Decision support system, Deep learning.

Page Number : 79

Supervisor : Prof. Dr. Nursal ARICI

TEŞEKKÜR

Lisans, yüksek lisans ve doktora eğitimim boyunca desteklerinden dolayı danışmanım sayın Prof. Dr. Nursal ARICI'ya çok teşekkür ederim. Sayın hocam tez konumun belirlenmesi, araştırma süreci, makale aşamaları dâhil her aşamada her daim desteğinizi hissettim. Sizin öğrenciniz olmaktan daima gurur duyacağım.

Tez kapsamında modellerin geliştirilmesinde, çalışma sonuçlarının aktarılmasında değerli katkılarından dolayı hocam sayın Prof. Dr. Pınar KARAGÖZ'e çok teşekkür ederim. Çalışmanın gelişim aşamasında yeri doldurulamaz katkılarınız beni çok mutlu etti.

Tez konumun belirlenmesi sürecinden başlayarak tüm TİK sunumlarında değerli görüşleriyle bana katkı sağlayan hocam sayın Prof. Dr. Hasan Şakir BİLGE'ye teşekkürü borç bilirim. Sayın hocam yüksek lisans döneminden itibaren beni değerli bir öğrenci olarak görmenizden dolayı ayrıca gururluyum.

Bu uzun süreçte yeterince zaman ayıramadığım ama buna rağmen hep yanımda duran desteklerini hissettiğim ailem ve arkadaşlarıma da teşekkürü borç bilirim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ.....	xi
RESİMLERİN LİSTESİ	xii
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
2. KAVRAMSAL VE KURAMSAL TEMELLER.....	13
2.1. Cilt Kanseri	13
2.1.1. Melanom (Melanoma) cilt kanserleri	13
2.1.2. Melanom dışı (Non-melanoma) cilt kanserleri (MDCK)	13
2.2. Yapay Zekâ Yöntemleri	15
2.3. Derin Öğrenme	16
2.4. Yapay Sinir Ağları (YSA)	16
2.4.1. Kayıp fonksiyonu.....	18
2.4.2. Tek katmanlı ve çok katmanlı yapay sinir ağları	18
2.4.3. İleri ve geri beslemeli sinir ağları.....	19
2.4.5. Evrişimli sinir ağları.....	19
2.4.6. Tekrarlayan sinir ağları	21
2.4.7. Kodlayıcı - çözücü ağlar	21
2.4.8. Optimizasyon yöntemleri	21

	Sayfa
2.5. Derin Öğrenme Mimarileri.....	22
2.5.1. UNet, UNet++ ve EAR-UNet mimarileri	23
2.5.2. LinkNet mimarisi	24
2.5.3. FCN (Full convolutional network) mimarisi.....	26
2.5.4. SegNet mimarisi.....	26
2.5.5. ResNet (Residual network) ve ResNet50 mimarileri.....	26
2.5.6. EfficientNet mimarisi.....	27
2.5.7. VGG16, VGG19 ve XCEPTION mimarileri	28
3. MATERYAL VE METODOLOJİ.....	29
3.1. Veri Setleri.....	30
3.1.1. Veri artırma ve görüntü dilimleme.....	31
3.1.2. Temizleme veri seti	32
3.1.3. Bölütleme veri seti	34
3.1.4. Lezyon sınıflandırma veri seti.....	35
3.1.5. Veri setlerinin dağılımı	35
3.2. Önerilen Modeller	36
3.2.1. ResNetC	37
3.2.2. LinkNet-RCB7	39
3.2.3. UNet-RCB7	41
3.2.4. Lezyon sınıflandırma modeli	42
3.3. Modellerde Kullanılan Parametreler	43
3.4. Eğitim Aşamaları.....	44
3.4.1. Gürültü temizliği	44
3.4.2. Lezyon bölütleme.....	45

Sayfa

3.4.3. Lezyon sınıflandırma	46
4. ARAŞTIRMA BULGULARI	47
4.1. Gürültü Temizliği Aşaması.....	48
4.2. Lezyon Bölütleme Aşaması	50
4.3. Lezyon Sınıflandırma Aşaması.....	52
4.4. Ablasyon Çalışması (Ablation Study)	54
4.5. Karşılaştırma Sonuçları.....	56
5. ÖNERİLEN KARAR DESTEK SİSTEMİ.....	59
5.1. Önerilen KDS'nin Bileşenleri.....	59
5.1.1. Veri yönetimi	59
5.1.2. Model	59
5.1.3. Grafiksel kullanıcı arayüzü (GUI)	60
6. SONUÇ VE ÖNERİLER	67
KAYNAKLAR	71
ÖZGEÇMİŞ	79

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Temizleme veri seti ve bölütleme veri seti veri dağılımları	35
Çizelge 3.2. Lezyon sınıflandırma veri setinin türe göre dağılımı	36
Çizelge 3.3. Eğitim aşamalarında kullanılan parametreler	36
Çizelge 3.4. Kodlayıcı katmanları	39
Çizelge 4.1. Model bazında gürültü temizliği eğitim aşaması sonuçları.	49
Çizelge 4.2. Model bazında lezyon bölütleme eğitim aşaması sonuçları.	51
Çizelge 4.3. Model bazında lezyon sınıflandırma eğitim aşaması sonuçları.	53
Çizelge 4.4. Temel model bazında lezyon sınıflandırma sonuçları	54
Çizelge 4.5. Gürültü temizliği aşaması ablasyon çalışması.	55
Çizelge 4.6. Lezyon bölütleme aşaması ablasyon çalışması.	56
Çizelge 4.7. Gürültü temizliği aşamasında modellerin karşılaştırma sonuçları.	57
Çizelge 4.8. PH2 veri seti ile lezyon bölütleme sonuçları.	57
Çizelge 4.9. ISIC ve ISBI veri setleri ile lezyon bölütleme sonuçları.	58
Çizelge 4.10. ISIC ve ISBI veri setleri ile lezyon sınıflandırma sonuçları.	58

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Tek nöronlu yapay sinir ağı	16
Şekil 2.2. Derin öğrenme mimarisi.....	19
Şekil 2.3. UNet mimarisi.....	23
Şekil 2.4. LinkNet mimarisi.....	25
Şekil 2.5. ResNet mimarisi	27
Şekil 2.6. EfficientNetB7 mimarisi	28
Şekil 3.1. ResNetC Mimarisi	38
Şekil 3.2. LinkNet-RCB7 mimarisi	40
Şekil 3.3. UNet-RCB7 mimarisi	41
Şekil 3.4. Lezyon sınıflama modeli python kod yapısı	42
Şekil 4.1. EfficientNet türlerinin başarı grafiği	48
Şekil 4.2. Lezyon sınıflandırma aşaması karışıklık matrisi	53
Şekil 4.3. Test verisine ait duyarlılık, tahmin ve f1-skor değerleri	54
Şekil 6.1. Tüm aşamalar için eğitim grafikleri	70

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 3.1. Tez çalışmasının mantıksal tasarımı.....	30
Resim 3.2. Dilimleme sürecine ait örnek görüntüler.....	31
Resim 3.3. Gürültü maskelerinin oluşturulma süreci	32
Resim 3.4. Temizleme veri seti'ne ait örnek görüntü ve maskeler	33
Resim 3.5. Bölütleme veri seti'ne ait örnek görüntü ve maskeler.....	34
Resim 4.1. Görüntü işleme ile gürültü temizliği	49
Resim 4.2. Derin öğrenme ve görüntü işleme ile gürültü temizliği	50
Resim 4.3. Derin öğrenme ile lezyon bölütleme	51
Resim 4.4. Derin öğrenme ve görüntü işleme ile lezyon bölütleme	52
Resim 5.1. KDS başlangıç ekranı	61
Resim 5.2. KDS yükle işlevi.....	62
Resim 5.3. KDS seçilmiş görüntü	62
Resim 5.4. KDS ile temizlenmiş görüntü.....	63
Resim 5.5. KDS ile bölütlenmiş görüntü	64
Resim 5.6. KDS ile sınıflandırılmış görüntü	65
Resim 5.7. Rapor klasörü	66
Resim 6.1. Kıl gürültüsünün bölütlemeye etkisi	68
Resim 6.2. Başarısız bölütleme örnekleri A	68
Resim 6.3. Başarısız bölütleme örnekleri B.....	69

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

X	Yapay sinir ağı giriş değeri
y	Yapay sinir ağı çıkış değeri
W	Yapay sinir ağı ağırlık değeri
b	Bias değeri
$\hat{y}$	Tahmin edilen değer

Kısaltmalar

Açıklamalar

AK	Aktinik keratoz
AVD	Alternatif veri dağılımı
BHK	Bazal hücre karsinomu
BGVS	Bölütlenmemiş gürültülü veri seti
BVS	Bölütlenmemiş veri seti
CNN	Convolutional neural network
DF	Dermatofibrom
DB	Doğrulama başarısı
DK	Doğrulama kaybı
DN	Doğru negatif
DÖ	Derin öğrenme
DP	Doğru pozitif
DSS	Decision support system
DU	Duyarlılık
EB7	EfficientNetB7
EB	Eğitim başarısı
EK	Eğitim kaybı
ESA	Evrişimli sinir ağı

Kısaltmalar**Açıklamalar**

GUI	Graphical user interface
GVS	Gürültülü veri seti
KDS	Karar destek sistemi
KKDS	Klinik karar destek sistemi
İÇE	İkili çapraz entropi
MDCK	Melanom dışı cilt kanserleri
MHK	Merkel hücre karsinomu
MN	Melanositik nevüs
ÖM1	Önerilen model 1
ÖM2	Önerilen model 2
SHK	Skvamöz hücreli karsinom
TH	Tahmin
TM1	Temel model1
TM2	Temel model2
TN	Toplu normelleştirme
TVS	Test veri seti
VL	Vasküler lezyonlar
YBS	Yönetim bilişim sistemleri
YN	Yanlış negatif
YP	Yanlış pozitif
YSA	Yapay sinir ağı
ZD	Zar doğruluğu
ZK	Zar kaybı
ZKOHK	Zar kaybı ortalama hatalar karesi

1. GİRİŞ

Günümüzde gelişen bilgi ve iletişim teknolojileriyle birlikte toplanan verinin miktarı hızla artmaktadır. Ortaya çıkan büyük veriden faydalanabilmek için bu verilerin doğru şekilde toplanması ve anlamlı bilgilere dönüştürülmeleri gerekmektedir. Bu süreçte veri madenciliği, veri ambarı, yapay zekâ, görüntü işleme algoritmaları, karar destek sistemleri (KDS), yönetim bilişim sistemleri (YBS) gibi sistemlerin kullanımı önem kazanmaktadır. KDS'ler toplanan verileri, modelleri kullanarak bilgilere dönüştürür ve bunları karar verme süreçlerine destek sağlamak için kullanılırlar [1].

KDS'ler ile özellikle yarı yapısal ve yapısal olmayan kararlar için karar vericilere karar desteği sağlanmaktadır. KDS'ler verilerin toplanması, düzenlenmesi, saklanması aşamalarını içeren *veri yönetimi*, kararın hangi kriterlere göre alınacağı, şartlar ve yapıları içeren *model* ve kullanıcı ile etkileşimi sağlayan *GUI (Graphical user interface - Grafıksel Kullanıcı Arayüzü)* bileşenlerinden oluşur. Model bileşeninde çıkarım algoritmaları, what if yapıları, istatistiksel modeller, yapay zekâ ve görüntü işleme algoritmaları yer alabilmektedir. Son zamanlarda karar süreçlerinde kullanılacak nitelikli bilginin elde edilmesinde model olarak yapay zekâ yöntemlerinin kullanımı giderek artmaktadır [2].

KDS'lerin model tabanlı, veri tabanlı, iletişim ve grup tabanlı, bilgi tabanlı, belge tabanlı, coğrafi bilgi sistemleri tabanlı, organizasyon içi ve organizasyonlar arası, göreve özel ve genel amaçlı KDS'ler ve klinik karar destek sistemleri (KKDS) gibi birçok türü vardır [2]. Hekimler tıbbi alandaki bilgilerin çoğalmasıyla birlikte karar verme süreçlerinde zorlanmaktadırlar. Bu yüzden klinik konularda bir uzman gibi karar verme süreçlerine yardımcı olacak KDS'lere ihtiyaç duyulabilmektedir. Bu sistemlerde amaç karar vermekten çok, karar vericiye süreçte destek sağlamaktır.

KDS'lerin kullanımı tıp alanında giderek yaygınlaşmaktadır. KDS'lerin tıp alanında kullanımına ilişkin en eski örneklerden biri 1960 yılında ortaya konan “DeDombal'ın Leeds Abdominal Ağrı Sistemi” adlı çalışmadır. Bayesian olasılık teorisi ile hangi durumda hangi sonucun çıkacağı tahmin edilmeye çalışılmıştır. Yoğun bakım ünitelerinde bebeklerin beslenme planlanması, hava değişimi kontrolü için kullanılan NeoGanesh, ilaç dozajının belirlenmesiyle ilgili çalışmalar, hepatit testlerinin otomatik yorumlanması,

patolojik teşhislerde kullanılan PEIRS, erken teşhis sistemleri gibi birçok örnek uygulamada karar destek sistemleri kullanılmaktadır [3].

Kanser, çeşitli organlardaki hücrelerin kontrolsüz çoğalması sonucu ortaya çıkan bir hastalık olarak tanımlanabilir [4]. Günümüzde kanser vakaları giderek çoğalmaktadır. 2040 yılında yaklaşık 16 milyon insanın kanserden öleceği tahmin edilmektedir [5]. Cilt kanseri de sık görülen kanser türleri arasındadır. Güneş gibi çevresel etkilerle birlikte cilt kanserinin insidansı giderek artmaktadır. 2021 yılında sadece Amerika Birleşik Devletleri'nde 115320 yeni vaka sayıldı. Bu vakaların 11540'ı ölümle sonuçlandı. Cilt kanserinin birçok farklı türü olmakla birlikte melanom (melanoma) cilt kanserinin en ölümcül türünü temsil eder [6]. Erken teşhis diğer kanser türlerinde olduğu gibi cilt kanserinde de hayati öneme sahiptir. Melanom, erken tespit edilirse vakaların yaklaşık yüzde 95'i tedavi edilebilmektedir [7]. Dermoskopi gibi klasik yöntemler ile lezyonun görünümü üzerinden yapılan teşhis süreci, uzun sürmekte ve hastanın konforunu bozmaktadır [8]. Bu yöntemlerin başarı oranı uzmanların becerisine bağlı olmakla birlikte yaklaşık %75-84 arasında olmaktadır [9]. Özellikle gelişen teknolojiyle birlikte cilt kanseri teşhisinde, derin öğrenme ve görüntü işleme algoritmalarını kullanan yapılar ile hastalar için daha konforlu bir süreç mümkün olabilmektedir [10].

Cilt kanserinin görüntüler üzerinden teşhisinde temel olarak, görüntü üzerindeki gürültünün temizlenmesi, lezyonun bölütlenmesi ve sınıflandırılması aşamaları yer almaktadır. Gürültüden temizlenen görüntü doğru bölütlenebilirse, bölütlenen bu görüntü de doğru sınıflandırılabilir. Derin öğrenme ve görüntü işleme algoritmaları insan faktörünü ortadan kaldırdığı için cilt kanserinin sınıflandırılmasında geleneksel yöntemlere göre daha güvenilir ve başarılı sonuçlar verebilmektedirler. Klasik yöntemler zaman alıcıdır ve özellikle cerrahi temelli olanları hastalar için rahatsız edici olabilmektedir [11]. Hastalık teşhisinde görüntülerin görselleştirilmesi karar sürecinde karar vericilere katkı sağlayabilmektedir [12]. Özellikle derin öğrenme ve görüntü işleme desteği ile oluşturulan bir KDS uzmanlara karar verme sürecinde kolaylıklar sağlayacaktır. KDS ile hastalık teşhisinde teşhis süresi azalır ve teşhis doğruluğu artar [13].

Tez çalışmasının amacı; cilt kanseri görüntülerinde gürültü temizliği, lezyon bölütlemesi ve lezyonun sınıflandırılması aşamalarını içeren bir KDS tasarlamak ve geliştirmektir. Bu KDS ile cilt kanserinin teşhisinde karar vericilere destek sağlayacak hızlı ve uygun

maliyetli bir çözüm önerilmektedir. Bu süreçlerde tezin üçüncü bölümünde açıklanan modeller denenmiş ve en başarılı olanlar, önerilen KDS'nin model bileşenine dâhil edilmiştir. Sınıflamada iyi huylu ve kötü huylu olmak üzere iki sınıf kullanılmıştır. Burada amaç karar vericiye lezyonun teşhis sonucunda kötü huylu olup olmama durumu hakkında bilgi vererek, teşhis sürecine destek sağlamaktır.

Tez çalışması kapsamında geliştirilen KDS kullandığı büyük veri tabanı sebebiyle bilgi tabanlı, verilerin sınıflandırıldığını düşünürsek belge tabanlı, derin öğrenme içinde kullanılan optimizasyon aşamalarından dolayı model tabanlı KDS sınıfında değerlendirilebilir. Ayrıca çalışma kapsamında oluşturduğumuz KDS klinik kararlar için kullanılan klinik karar destek sistemleri (KKDS) olarak da kabul edilebilir. KKDS'ler klinik konularda karar vericilere destek sağlayan sistemlerdir.

Literatür taramasında derin öğrenme, görüntü işleme algoritmaları ve KDS'lerin tıp alanında kullanımı üzerine yoğunlaşıldı. Literatürde cilt kanseri teşhisiyle ilgili tezimize de konu olan derin öğrenme ve görüntü işleme algoritmalarının kullanıldığı güncel çalışmalar incelenmiştir. Çalışmalarda genellikle lezyon üzerindeki gürültü temizliği, lezyonun bölütlenmesi ve sınıflandırılması aşamaları birlikte ele alındığı için literatür çalışmalarının aktarılmasında kronolojik sıralama ya da konu bazında sınıflama yapılmamıştır.

Görüntüler üzerindeki gürültülerin giderilmesi konusunda en eski yöntemlerden biri DullRazor algoritmasıdır. Bu yöntemde açma, kapama gibi morfolojik işlemler gibi görüntü işleme yapıları kullanılarak, görüntülerdeki kıl gürültüsü giderilmiştir. Başarı oranı düşük olsa da kullanım kolaylığından dolayı günümüzde bilimsel makalelerde kullanılmaya devam etmektedir. Bir diğer çalışmada Şahin ve Alpaslan (2020) SegNet mimarisini kullanarak bölütleme çalışması yapmışlardır. Bu çalışma DullRazor algoritmasının ince telli kılları temizleme konusunda yetersiz olduğunu ortaya koymaktadır. Çalışmada %88,43'lük bir zar doğruluğu (dice accuracy) elde edilmiştir [14].

Gürültü temizliği yapılmış görüntüler, derin öğrenme ile eğitime alındığında lezyon bölütleme başarısını artırabilmektedir. Bu duruma örnek bir çalışmada Shaikh, Khana, Laghari ve Ali (2022) lezyon görüntülerindeki gürültülerin temizlenmesi ve bölütlenmesi aşamaları için bir çalışma önermişlerdir. Bu çalışmada gürültü temizliğinin bölütleme başarısı üzerine olan olumlu etkisi vurgulanmıştır. Sebep olarak, CNN (Convolutional

Neural Network) modelinin, gürültü ile hedef (cilt) arasındaki korelasyonları tespit edebilmesi ve bunun da bölütleme doğruluğunu etkilemesi gösterilmiştir [15].

Derin öğrenme ile yapılan eğitimlerde maske veya etiketleri olan veri setleri gerekmektedir. Literatüre bakıldığında cilt kanseri teşhisi için ISIC ve PH2 gibi halka açık veri setlerinin sıklıkla kullanıldığı görülmektedir [16]. Halka açık olan bu veri setleri bölütleme maskeleri ve lezyon sınıflarını içermektedir. Fakat literatürde halka açık gürültü maskesi içeren bir veri seti bulunmamaktadır. Bu yüzden mevcut veri setlerindeki görüntüler kullanılarak gürültü maskelerinin oluşturulduğu çalışmalar vardır. Bunun bir örneği Li, Raj, Tjahjadi ve Zhuang (2021)'in çalışmasında yer almaktadır. Bu çalışmada gürültü temizliği için ISIC2018 veri setine ait 306 görüntü içeren bir kıl veri seti oluşturulmuştur. UNet temelli bir algoritmanın kullanıldığı bu çalışma ile %96,88'lik bir zar doğruluğuna ulaşılmıştır. Bölütleme aşamasında ise %86,5 zar doğruluğu elde edilmiştir [17]. Talavera-Martínez, Bibiloni ve González-Hidalgo (2020) gürültü temizliği için kıl maskelerini içeren bir veri seti oluşturmuşlardır. Bu çalışmada veri kümeleri sadece simüle edilmiş kıl gürültülerini içermektedir (618 görüntü). Model olarak temel CNN modeli kullanılmıştır. Görüntü verileri 512×512 piksel boyutunda eğitime alınmıştır. Çalışmada simüle edilen kıl gürültüleri çok belirgin şekilde görülmektedir. Bu durum başarının yapay artışına neden olabilecektir. Çünkü gerçekte görüntüler daha farklı ve zor görülebilen kıl gürültüleri (farklı renkler, kontrast vb.) içerebilir [18].

Derin öğrenme yöntemini kullanan çalışmalarda hibrit modellerin kullanımı yaygındır. Bu tür hibrit kullanımlar eğitim başarısını artırmak için tercih edilmektedir. Bunun bir örneği Thapar, Rakhra, Cazzato ve Hossain (2022) tarafından yapılan çalışmadır. Bu çalışmada bölütleme için K-means ve Goa algoritmalarını kullanan hibrit bir model sunulmuştur. Bu modelde lezyon bölütleme aşamasında ISIC2018 veri seti kullanılarak %94,89 zar doğruluğu elde edilmiştir [5].

Derin öğrenme modelleri başarı oranını artırmak için kodlayıcı modellerle desteklenebilmektedir. Bu kodlayıcı modeller genellikle imageNet verileri ile eğitilmiş şekilde kullanıldığı için bu tür öğrenmeye öğrenme aktarımı denilmektedir. Öğrenme aktarımıyla birlikte eğitim başarısı artmakta, eğitim süresi ise azaltılmaktadır. Kodlayıcı modeller, kodlayıcı-çözücü mimarisine sahip modellerin kodlayıcı bloğu olarak kullanılabilir. Son zamanlarda önerilen kodlayıcı modellerden EfficentNetB7, kısa

eğitim süresine ve yüksek doğruluk oranlarına sahiptir [19]. Baheti, Innani, Gajre ve Talbar (2020) tarafından Eff-UNet adlı melez bir model ortaya konmuştur. EfficientNet farklı türlere sahiptir. Bu çalışmada bu türlerden imageNet ağırlıklarını kullanan EfficientNetB7 kodlayıcı olarak kullanılmıştır. EfficientNetB7'nin ResNet18, 34, 50, 101 arasında en yüksek doğruluğa sahip model olduğu ortaya konmuştur [20]. Wang, Zhang, Lv, Zhou ve Wang (2021) UNet modelini EfficientNet4 ve ResNet ile destekleyerek EAR-UNet adlı modeli önermişlerdir. Bu model görüntü ve video işleme amacıyla sunulmuştur. Karaciğer görüntülerinin bölütleme aşamasında %95,95 zar doğruluğu elde edilmiştir [21].

Gürültü temizliği yapılan görüntülerin kullanıldığı bölütleme eğitimlerinin daha başarılı olduğu görülmektedir. Zafar ve diğerleri (2020) tarafından yapılan çalışmada benzer bir durum vurgulanmış ve gürültüden temizlenen, normalize edilen ve boyutlanan görüntülerle yapılan bölütleme eğitiminde *başarının %0,9 arttığı* belirtilmiştir. Bu çalışmada UNet ile kodlayıcı olarak ResNet mimarisini kullandıkları görülmüştür. Görüntülerin kıl gürültüsünden temizlenmiş hallerini elde etmek için, gürültü içeren ve görüntüden kaldırılan piksellerin en yakın gürültüsüz piksellerin özelliklerini alması sağlanmıştır. Bu aşama Opencv kütüphanesinde yer INPAINT fonksiyonu ile de sağlanabilmektedir. UNet modeli ResNet50 kodlayıcı ile kullanılmış ve bölütleme aşamasında ISIC2017 veri seti ile %85,8, PH2 veri seti ile %92,4 zar doğruluğu elde edilmiştir [22].

Medikal görüntülerin bölütlenmesinde derin öğrenme ile birlikte görüntü işleme algoritmaları da başarı oranlarını artırmak için kullanılabilmektedir. Zhang ve diğerleri (2019) DSM adlı derin öğrenme modelini geliştirmişlerdir. Bu çalışmada bölütleme aşamasından önce görüntüler üzerinde gürültü temizliği yapılmıştır. Başarı oranlarını artırmak için kontrast iyileştirme tekniği uygulanmıştır. Çalışmada ISBI2017 veri seti ile %87,5, PH2 veri seti ile %92 zar doğruluğu elde edilmiştir [23].

Görüntü bölütlemesinde sıklıkla kullanılan modellerin başında UNet gelmektedir. Bu model gerek temel haliyle gerekse de değiştirilmiş versiyonları ile çalışmalarda sıklıkla tercih edilmektedir. Hasan, Dahal, Samarakoon, Tushar ve Marti (2020) UNet modelini kullanarak bölütleme aşamasında PH2 veri seti ile %87 mIoU başarı oranı elde etmişlerdir. Bu çalışmada başarının düşük olmasının nedenlerinden biri gürültü temizliğinin yapılmamış olmasıdır [24]. Akyel ve Arıcı (2020) tarafından yapılan başka bir çalışmada UNet tercih edilmiştir. Bu çalışmada gürültü temizlemede %88,58, bölütlemede %92,60

başarı oranları elde edilmiştir. 1534 görüntü ve kıl maskesi içeren bir veri seti oluşturarak bunu gürültü temizliği aşamasında kullanmışlardır [25].

UNet ile birlikte kodlayıcıların kullanıldığı çalışmalar vardır. Phan, Kim, Yang ve Lee (2021) çalışmalarında lezyon bölütleme aşamasında, UNet tabanlı algoritmaya DenseNet kodlayıcı olarak eklenmiştir. Çalışmada PH2 veri seti ile %94,04 zar doğruluğu elde edilmiştir [26]. Tang ve diğerleri (2019) UNet temelli bir bölütleme modeli önerdiler. ISIC2017 veri setinin kullanıldığı bu çalışmada %86,93 zar doğruluğu elde edilmiştir [27].

Modellere ResNet blokları eklenerek eğitim başarısının artırıldığı örnekler literatürde görülmektedir. Akyel ve Arıcı (2022) çalışmalarında ResNetC adlı algoritmayı geliştirmiş ve FCN8 algoritması ile birlikte hibrit bir model olarak kullanmışlardır. ResNetC'nin standart ResNet'e göre yaklaşık %3 daha başarılı olduğu belirtilmiştir. Ayrıca FCN8 gibi temel bir algoritmaya eklenerek standart FCN8'e göre yaklaşık %0,95 başarı artışı sağlanmıştır [28].

Görüntü bölütlemesinde yüksek başarı oranına sahip modellerden birisi de LinkNet'tir. Chaurasia ve Culurciello (2017) tarafından ortaya konulan LinkNet 11,5 M parametreye sahiptir. Bu model kısa epok (epoch) süresi ve yüksek başarı oranları vaat etmektedir. Bu çalışmaya göre LinkNet eski modellere göre (SegNet, Enet, Dilation10, Deep-Lab CRF (Vgg16), Deep-Lab CRF (ResNet101)) daha başarılıdır [29]. Mohamed, Kallam, Kumar, Natarajan ve Patan (2020) çalışmalarında LinkNet'in, UNet'ten daha yüksek doğruluğa sahip olduğunu ortaya koymuşlardır (UNet = 94,8 ve LinkNet = 97,2). Ayrıca bu çalışmada LinkNet34 adlı bir model ortaya konmuştur. Bu modelde standart LinkNet modelinde kodlayıcı olarak kullanılan ResNet18 yerine ResNet34 tercih edilmiştir. Bu tercih ile başarı oranının arttığı gözlemlenmiştir [30].

Literatürde LinkNet modelinin başarı artışı sağlanan farklı versiyonları görülmektedir. Değiştirilmiş LinkNet modellerine verilecek bir diğer örnek D-LinkNet'tir. Zhou, Zhang ve Wu (2018) tarafından geliştirilen bu modelde kodlayıcı olarak ResNet34 kullanılmış, ayrıca evrişim katmanları içeren bir orta blok eklenmiştir. Bu orta bloğun da katkısıyla LinkNet34'e kıyasla %1,12 daha yüksek başarı elde edilmiştir [31]. Xiong ve diğerlerinin (2021) çalışmasında Dp-LinkNet modeli önerilmiştir. Bu model D-LinkNet'e benzer olmakla birlikte farklı bir orta blok kullanmışlardır. D-LinkNet'ten f-skoru değerinde

%0,87 daha yüksek başarı elde edilmiştir. Burada bahsedilen orta blok kodlayıcı ve çözümleyici blokları arasına eklenmiştir. Bu durum başarı oranının yanı sıra, eğitim süresini de artırmaktadır [32].

Dong, Wang, Cheng ve Li (2021) tarafından geliştirilen FAC–Net isimli model ISIC2018 ile eğitilmiştir. Bu çalışmada bölütleme eğitim aşamasında %91,19 zar doğruluğu elde edilmiştir [33]. Brahmbhatt ve Rajan (2019) SegNet modelini kullanarak bölütleme aşamasında PH2 veri seti ile %85,16 zar doğruluğu elde etmişlerdir [34]. Bagheri, Tarokh ve Ziaratban (2021) çalışmalarında ise Maske R-CNN algoritmasını kullanılmıştır. Bu çalışmada %89,96 zar doğruluğu PH2 veri setinde gözlemlenmiştir [35].

Cilt kanserinin sınıflandırılmasında, lezyon üzerindeki renk geçişleri, parlamalar, lezyonun şekli gibi birçok zorluk vardır. Kaur, Gholamhosseini, Sinha ve Lindén (2022) tarafından sunulan çalışmada ISIC2020 veri seti üzerinde DCNN modeli ile %90,4'lük bir eğitim başarı değeri elde edilmiştir. Lezyonlar üzerinde herhangi bir gürültü temizliği ve bölütleme yapılmamıştır. Lezyon sınıflandırmada melanom ve normal olarak iki sınıf kullanılmıştır [36].

Suresh ve Seeja (2019) çalışmalarında bölütlenmiş görüntüler ile yapılan eğitimlerin daha başarılı olduğu vurgulanmıştır. Bölütlenmemiş görüntü ile yapılan sınıflandırmada başarının daha düşük olmasının nedeni; lezyonun görüntüdeki alanının küçülmesi ve temizlenememiş gürültüler olarak belirtilmiştir (parlaklık, kıl gürültüsü vb). SVM ile yapılan sınıflandırmada %85,19 zar doğruluğu elde edilmiştir [37].

Indraswari, Rokhana ve Herulambang (2022) MobileNetV2 modelini kullanarak cilt kanseri lezyonlarının sınıflandırmasını yapmışlardır. Çalışmada gürültü temizliği ve lezyon bölütlemesi yer almamıştır. ISIC-archive veri setinde %85'lik, ISBI2016 veri setinde %83'lük bir eğitim başarıları elde etmişlerdir. Bu çalışmada da lezyonlar için kötü (malignant) ve iyi (benign) olarak iki sınıf kullanılmıştır [38]. Ali, Islam, Haque, Miah ve Rahman (2021) tarafından sunulan DCNN tabanlı derin öğrenme modelinde % 92,69 eğitim başarıları elde edilmiştir. Lezyonlar iyi ve kötü huylu olarak sınıflandırılmıştır. Çalışmada görüntü işleme algoritmaları ile gürültü temizliği yapılmıştır [39].

Literatürde cilt kanseri görüntüleri genel olarak iyi huylu ve kötü huylu olarak ikiye ayrılmaktadır. Daha fazla sınıfa ayrıldığı örnekler de mevcuttur. Kausar ve diğerlerinin (2021) çalışmalarında cilt kanseri derin öğrenme ile sekiz sınıfa ayrılmıştır. Çalışmada ResNet, DenseNet, VGG16 ve Inception V3 modelleri kullanılmıştır. Bunlar arasında en yüksek başarı oranı ResNet ile elde edilmiştir (%92 eğitim başarısı). Literatüre bakıldığında genelde cilt kanserinin iyi ve kötü huylu olarak ikiye ayrıldığı görülmektedir. Bu çalışmada lezyonlar literatürde mevcut olan sekiz sınıfa ayrılmıştır. Bunlar; Bazal hücreli karsinom, iyi huylu, kötü huylu, dermatofibrom, aktinik keratoz (AK), melanositik nevüsler (MN), skuamöz hücre karsinoması (SHK), vasküler lezyonlar (VL)'dir [40].

Karar destek sistemleri, kullanıldıkları alanda, karar vericilerin karar sürecinde başarılı kararlar almasına yardımcı olurlar [13]. KDS'lerin daha çok yarı yapısal ve yapısal olmayan kararların alınma sürecine dâhil edildiği bilinmektedir. Kanser teşhisi için alınan kararlar da yarı yapısal olarak değerlendirilebilir. Bunun nedeni karar vermek için belirli kriterler olmasına rağmen, sonuca bu kriterleri gözleyerek varılmasının zorluğudur. Klinik karar destek sistemleri (KKDS) KDS türlerinden birisidir. Günümüzde klinik kararların alınmasında hekimler ve diğer sağlık profesyonelleri için KDS'ler önemli bir rol oynamaktadır. KKDS'ler, hastanın durumu hakkında metin, ses, video ve görüntü biçiminde veriler üzerinden raporlar sağlar. KKDS, seçenekler arasından en iyi olasılığı tahmin etmeye çalışarak karar vericilere yardımcı olur. KKDS'de makine öğrenimi ve derin öğrenme kullanılabilir. Son zamanlarda, CNN gibi derin öğrenme algoritmaları, mamogramlardan meme kanseri tespiti, bilgisayarlı tomografi ile karaciğer tümör segmentasyonu (bölütlemesi), rezonans görüntüleme ile beyin tümörü bölütlemesi gibi birçok hastalığın teşhisinde karar vericilere karar verme süreçlerinde fayda sağlamaktadırlar [41].

Bir çalışmada, Todd, Gepp, Vanstone ve Stern (2022) tarafından yeniden kabuller için bir karar destek sistemi geliştirildi. Hastaneye yeniden yatışların gerekli durumlar dışında olmasının maliyetinin yüksek olduğu belirtilmiştir. Bu çalışmadaki KDS yüksek riskli hastaları belirleyerek, yeniden yatış süreçlerine destek sağlamaktadır [42]. Kumar, Sathyadevi ve Sivanesh (2011) tarafından önerilen başka bir çalışmada veri madenciliği ile KDS üzerinde durulmuştur. Kalp, diyabet gibi hastalıkları sınıflandırmak için CART algoritması tercih edilmiştir. Bu çalışmada görüntülerle değil, hastalara ait sayısal ölçüm verileriyle çalışılmıştır [13].

Çakmak (2017) çalışmasında, tümör teşhisini tahmin etmek için SVM kullanarak bir KDS geliştirmiştir. Model kısmında yapay zeka kullanılan bu çalışmada herhangi bir rehberlikten (denetimli öğrenme) bahsedilmemiştir. SVM klinik verilerle birlikte kullanılmıştır [43]. Çorapçıoğlu (2006) tiroit hastalığının teşhisi için önerdiği KDS tasarımı kural tabanlı bir yöntem kullanmıştır. Bu çalışmada, RuleML adlı XML tabanlı bir kural depolama sistemi oluşturulmuştur. Hastanın yaşı, cinsiyeti ve TSH (tiroid stimüle edici hormon) gibi değerler arayüzden girdi olarak alınmıştır [44]. Medikal alanda KDS'lerin kullanımına bir örnek Tsoukalas, Albertson ve Tagkopoulos (2015) tarafından yapılan bir çalışma görülmektedir. Bu çalışmada sayısal verileri kullanarak sepsis durumlarında karar sürecine destek sağlayan grafiksel arayüze sahip bir KKDS geliştirilmiştir [45]. Derin öğrenme algoritmalarında kullanılan Python'da arayüz oluşturmak için Tkinter, PyQt, WxPython gibi kütüphaneler mevcuttur. Bu kütüphaneler ile kullanıcı etkileşimini sağlayabilecek arayüzler KDS'lere eklenebilmektedir [46].

Günümüzde KDS'lerin kullanımı özellikle kanser teşhisinde yaygınlaşmaktadır. Bunun temel nedeni KDS'ler ile teşhis sürecinin daha hızlı ve başarılı hale gelebilmesidir. Ayrıca bu tür bilgisayar destekli sistemler, teşhis sürecinde insan faktörünü azaltarak hataların düşürülmesinde de fayda sağlamaktadır. Demir ve Atay (2017) akciğer kanseri verilerinin toplanmasıyla ilgili bir çalışma yapmışlardır. Bu çalışmada doktorlara karar verme sürecinde destek sağlayacak bir KDS geliştirilmiştir. Akciğer kanseriyle ilgili gelen yoğun verilerin veri madenciliği ve veri ambarı teknikleriyle gereksiz ve tekrar eden verilerden arındırılması ve bu verilerin karar verme süreçlerinde destek sağlayacak bir KDS yapısında kullanılması sağlanmıştır. Burada hastaların önceki bilgilerinin veri ambarında tutulması ile hastanın kullandığı ilaçların dozajı da belirlenebilmektedir. Örneğin günde 3'ten fazla sigara içen hastaların kaçının ailesinde kansere rastlanmıştır sorusuna cevap bulunarak hasta ile ilgili tedavi süreci, yapılacak tetkikler gibi durumlar için karar desteği sağlanmaktadır [47].

Kuru ve Tunca (2011) genetik faktörlerden kaynaklanan dismorfik hastalıkların ön tanısı için bir KDS önermişlerdir. Bu KDS normal insan ölçülerini baz alarak görüntüler üzerinden anormal durumları bildiren bir yapıdadır. Sistemin doğum öncesi görüntüler ile down sendromu gibi genetik kaynaklı hastalıkların teşhisinde hekimlere yardımcı olması düşünülmüştür. Modelde karar vericilere kıyaslama yoluyla bilgi verilmiştir [48].

KDS'lerin temel bileşenlerinden biri olan arayüzler kullanıcı etkileşimi için önemlidir. Arayüzün kolay kullanılabilir ve basit yapıda olması bu sistemlerin karar süreçlerinde kolay ve hızlı kullanımına fayda sağlayacaktır. KDS'lerde kullanılacak arayüzler farklı platformlar ile modelin durumuna da bağlı olarak geliştirilebilmektedir. Karar destek sistemlerinde kullanılan arayüzleri web tabanlı veya exe uygulamalar şeklinde olabilmektedir. Web tabanlı arayüzler kullanım kolaylığı nedeniyle tercih edilmektedir. Özel (2010) çalışmasında web tabanlı bir KDS önermiştir. Bu çalışmada hasta bilgileri üzerinden hastanın yoğun bakıma ihtiyacı olup olmadığı gibi durumlara karar verilirken kara vericilere destek sağlanmaktadır. Önceden belirlenen senaryolar veri tabanına alınarak benzer durumlar için öneriler sağlanmaktadır [49].

Kahn, Akram, Sharif, Kadry ve Nam (2021) cilt kanserinin sınıflandırılması için bir KDS geliştirmişlerdir. Lezyonların sekiz sınıfa ayrıldığı çalışmada ISBI2019 veri seti %85,3 eğitim başarısı elde edilmiştir. Veri setinin %70'i eğitim kalanı test için ayrılmıştır. Çalışmada gürültü temizliği ve arayüzden bahsedilmemiştir [50].

KDS'lerde web tabanlı arayüz kullanımı görülmektedir. Bu tür KDS'lerin model yapıları genellikle sayısal verilen işlendiği ve sisteme çok yük getirmeyen yapıda olmaktadır. Model bileşeninde derin öğrenme yapılarını bulunduran KDS'lerin çalışma hızı modellerin yüklenme sürelerine ve kütüphanelere bağlı olarak azalmaktadır. Bu sebepten bu tür KDS'lerde web tabanlı arayüzler mevcut literatürde sık görülmemektedir. Web tabanlı arayüzler için yazılım ve kütüphanelerin hızlı sunuculara yüklenmesi gerekmektedir.

Genel olarak literatürde cilt kanseri teşhisi için derin öğrenme ve görüntü işleme algoritmalarının, bilgisayar destekli yöntemler olarak tercih edildiği görülmektedir. Derin öğrenme algoritmalarında kullanılacak veri setleri eğitim, doğrulama ve test kümelerine ayrılabilir. Bu ayrım genelde %70 eğitim, %20 doğrulama ve %10 test şeklinde olmaktadır. Veri setlerinin ayrılmasında literatürde net bir ayrım olmamasına rağmen veri setlerinin boyutunun küçük olduğu durumlarda, eğitim veri setinin yüzdesi %80'lerin üzerine çıktığında ezberleme (overfitting) sorunu ortaya çıkabilmektedir.

Literatür taramasında görülen temel eksiklikler;

- Gürültü temizliği aşamasında derin öğrenmenin kullanımını sağlayacak bir gürültü maske veri seti halka açık bulunmamaktadır. Kendi veri setlerini oluşturan bazı çalışmalar mevcuttur. Fakat bu veri setlerinde ya yapay simüle edilen maskeler kullanmakta ya da oluşturulan gürültü maskeleri sayı ve gürültü türü (sadece kıl gürültüsü) olarak yetersiz kalmaktadır.
- EfficientNetB7 kodlayıcı olarak kullanıldığında kodlayıcı çözücü mimarisine sahip LinkNet modelinin başarısını ciddi şekilde artırmaktadır. Buna rağmen cilt kanserinin teşhisiyle ilgili çalışmalarda şu ana kadar yer almamıştır.
- Derin öğrenme algoritmalarında genellikle maksimum 512*512 giriş çözünürlüğü kullanılmaktadır. Mevcut veri setlerindeki tüm görüntülerin bu çözünürlüğün üzerinde olduğu düşünüldüğünde, görüntülerde piksel kaybı kaçınılmaz olmaktadır. Bu durum başarı oranını düşürecektir.
- Mevcut literatürde cilt kanserinin teşhisinde gürültü temizliği, lezyon bölütleme ve lezyon sınıflandırma aşamalarını içeren, model bileşeninde LinkNet, EfficientNetB7 ve görüntü işleme algoritmaları yer alan bir karar destek sistemi bulunmamaktadır.

Bu tez çalışması; cilt kanseri görüntüleri üzerinden gürültü temizliği, lezyon bölütlemesi ve lezyon sınıflandırma olmak üzere üç aşamadan oluşmaktadır. Bu aşamaları içeren bir KDS çalışma kapsamında önerilmiştir. Tez çalışması kapsamında yukarıda açıklanan sorunlar doğrultusunda aşağıdaki çözümler geliştirilmiştir.

- KDS'nin veri yönetimi bileşeni için gürültü temizliği aşamasında kullanılmak üzere ISIC2018 veri setinde gürültü içeren 1500 görüntü seçilerek maskeleri oluşturulmuştur.
- KDS'nin model bileşeni için bölütleme ve gürültü temizliği aşamalarında kullanılmak üzere UNet ve LinkNet algoritmalarını temel alan toplam iki yeni model (UNet-RCB7, LinkNet-RCB7) geliştirilmiştir. Bu modellerin izlenen yöntem ile yüksek başarı oranlarına sahip olduğu belirlenmiştir. Bölütleme aşamasında gürültü temizliği yapılan veri setleri kullanıldığı için başarı oranları daha yüksek olmuştur.
- Ekran kartı kısıtı sonucu çalışmada görüntüler 256*256 olarak alınmıştır. Bu durumun piksel kaybına neden olmaması için görüntüler 16 dilime ayrılarak

toplamda 1024*1024 çözünürlüğe sahip bir görüntü kayıpsız eğitime alınabilmektedir. Bu teknik mevcut literatürde de sıkça kullanılmaktadır. Bu çözüm düşük donanım kaynakları ile de yüksek çözünürlüklü veri girişine izin verilebileceğini göstermiştir.

- Model bileşeninde LinkNet-RCB7 ve görüntü işleme algoritmaları kullanılan, gürültü temizliği, lezyon bölütleme ve lezyon sınıflandırma aşamalarını içeren bir karar destek sistemi çalışma kapsamında geliştirilmiştir.

Tez çalışmasında UNet-RCB7 ile gürültü temizliğinde %90,17, bölütleme aşamasında %93,20 zar doğruluğu gözlenmiştir. Bir diğer önerilen model LinkNet-RCB7 ile gürültü temizliğinde %91,92, bölütleme aşamasında %96,85 zar doğruluğu elde edilmiştir. Sınıflandırma aşamasında ise oluşturulan model ile yaklaşık %97 zar doğruluğuna ulaşılmıştır. Tezin ikinci bölümünde cilt kanseri ve derin öğrenme ile ilgili kavramsal ve kuramsal temeller, üçüncü bölümde kullanılan materyal ve yöntemler, dördüncü bölümde ulaşılan araştırma bulguları, beşinci bölümde önerilen KDS ve altıncı bölümde sonuç ve öneriler yer almaktadır. Eğitim ve test aşamalarında kullanılan ISIC veri setleri dünya üzerindeki uzmanlardan elde edilen verilerle oluşturulmuştur.

Tez çalışmasında bazı kısıtlar vardır. KDS ile sadece cilt kanserinin teşhisi için destek sağlanmıştır. Kullanılan veri setleri halka açık veri setleri arasından seçilmiştir. Eğitim aşamalarında kullanılan görüntü verileri ekran kartı kısıtından dolayı 256x256x3 boyutuyla girdi olarak alınabilmektedir. KDS’de arayüz olarak belirli kütüphanelerin yüklü olmasını gerektiren yerelde çalışan bir sistem geliştirilmiştir.

Tez çalışmasında cilt kanseri teşhisi için model bileşeninde derin öğrenme ve görüntü işleme algoritmalarını kullanan bir KDS önerilmiştir. Literatürde cilt kanseri teşhisi için model bileşeni olarak LinkNet, EfficientNetB7 modellerini ve görüntü işleme algoritmalarını birlikte kullanan, gürültü temizliği, lezyon bölütleme ve lezyon sınıflandırma aşamalarını barındıran bir çalışma yer almamaktadır. Önerilen KDS ile cilt kanseri teşhisinde karar vericilere karar sürecinde destek sağlanması beklenmektedir. Böylelikle teşhis süresinin kısalması, maliyetin düşmesi ve teşhis başarısının artması ön görülmektedir.

2. KAVRAMSAL VE KURAMSAL TEMELLER

Bu bölümde tez çalışmamıza konu olan kavramsal ve kuramsal temeller açıklanmıştır. Cilt kanseri ve türleri hakkında genel bilgi verilmiştir. Ayrıca kanser teşhisinde kullanılabilen yapay zekâ, görüntü işleme ve tezimize konu olan derin öğrenme algoritmaları güçlü ve zayıf yönleriyle birlikte aktarılmıştır.

2.1. Cilt Kanseri

Kanser çağımızın en ölümcül hastalıklarından biridir. Günümüzde kanser türleri arasında en yaygın olanlardan biri de cilt kanseridir [51]. Cilt kanseri temelde iyi huylu (non-melanom) ve kötü huylu (melanom – malign) olarak ikiye ayırabiliriz.

2.1.1. Melanom (Melanoma) cilt kanserleri

Melanom hızla çoğalan ve yayılan, kötü huylu kanser türüdür [52]. Melanom, cilt kanserleri, melanosit adı verilen hücrelerin aşırı çoğalması ve yayılmasıyla oluşur [53]. Melanom cilt kanserinin tedavisinde diğer kanser türlerinde olduğu gibi erken teşhis çok önemlidir. Ülkemizde bu konuda atılan adımlara rağmen melanom cilt kanserinde mortalite'nin yani cilt kanserine bağlı genel popülasyon içindeki ölüm sayısı oranının arttığı görülmektedir [54]. Melanom cilt kanserleri kan ve lenfatik sistemle diğer dokulara yayılabilirler. Bu sebeple melanom cilt kanserinin erken teşhisi çok önemlidir. Melanom tedavi edilmezse ölümcül olabilir [55].

2.1.2. Melanom dışı cilt kanserleri (MDCK)

MDCK'nin çoğunluğu ameliyatla etkin bir şekilde tedavi edilebilir. Ancak vakaların neredeyse %10'undan azı tedavi gerektirecek noktaya gelmektedir [53]. Bu kanser türleri kötü huylu olmamakla birlikte süreç içinde kötü huyluya dönüşebilirler.

Bazal hücre karsinomu (BHK – Basal cell carcinoma) yavaş ilerleyen ve çok yaygın görülen bir cilt kanseri türüdür. Yayılma eğilimi göstermezler. Genelde epidermisin altında görülmekle birlikte nadiren daha derinde kemiğe yakın yerlerde ortaya çıkabilmektedirler [56].

BHK için geleneksel cerrahi yöntemler geçerliliğini korumaktadır. Hastaların %30'unda kilo kaybı, yorgunluk gibi belirtiler görülebilmektedir. Histolojik yayılma özelliği göstererek komşu dokulara yayılabilirler. Komşu dokuların etkilenmesine neden olarak morbiditeye neden olur [53].

Skumöz hücreli karsinom (SHK – Squamous cell carcinoma) türünde lezyon pullu ve çıkıntılı bir yapıya sahiptir. SHK türü cilt kanserleri BHK'ye göre çok daha agresif şekilde yayılma eğilimindedirler. Lezyonlar üzerinde kanama görülebilir. SHK kanser türü yavaş gelişmesine rağmen tedavi edilmezse diğer dokulara yayılabilir [56].

SHK sık rastlanılan bir türdür. SHK diğer organlara yayılım göstermeden önce genellikle lenf düğümlerine yerleşirler. Metastaz başladığında hastaların iyileşme şansı düşmektedir. Bu durum bu kanserde erken teşhisin önemini göstermektedir [53].

Merkel hücre karsinomu (MHK – Merkel cell carcinoma) nadir görülmekle birlikte dünya nüfusunun yaşlanmasıyla birlikte yaygınlığı artmaktadır. 2000 yılında 200 bin kişide 1 görülürken, 2013 yılına gelindiğinde bu oran 200 binde 1.4'e çıkmıştır. Bu kanser türünün klinik olarak tespit edilmesi zor görülmektedir [53].

Aktinik keratos (AK – Actinic keratosis) ultraviyole ışınlarla cildin zarar görmesi sonucu ortaya çıkan kanser öncesi bir türdür [57].

Melanositik nevüs (MN – Melanocytic nevus) iyi huylu ve sık rastlanılan bir cilt kanseri türüdür. Güneşin etkisiyle görülme sıklığı artmaktadır. Özellikle çocuklarda güneşe karşı alınacak önlemler nevüs sayısını azaltabilmektedir. İyi huylu olmalarına karşın zamanla kötü huylu özellik gösterebilmektedirler [58].

Vasküler lezyonlar (VL – Vascular lesions) daha çok yüz ve boyunda görülürler. Damarsal genişlemelerdir Lazerle tedavileri mümkündür [59].

Dermatofibrom (DF – Dermatofibroma) iyi huylu lezyonlardır. Genellikle orta yaş insanlarda görülme eğilimindedir. Sert plaka şeklindedir [60].

2.2. Yapay Zekâ Yöntemleri

Yapay zekâ (AI), temel olarak bir makinenin zekâyı taklit etme yeteneği olarak tanımlanır. Başka bir ifadeyle AI insan davranışlarından ilham alan algoritmalarla oluşur [61]. İlerleyen başlıklarda yapay zekâ yöntemleri açıklanmaya çalışılmıştır. Yapay zekâ bir çatı kavram olarak düşünülebilir. Makine öğrenimi modeller genellikle bir dizi kural, prosedür veya ilginç veri kalıplarını keşfetmek veya davranışları tahmin etmek için kullanılabilen yapılardır. Makine öğrenimi, tahmine dayalı analitik olarak da bilinir. Makine öğrenimi ile var olan veriler üzerinden gelecekteki sonuçlar tahmin edilebilir. Temel olarak makine öğrenme teknikleri denetimli ve denetimsiz öğrenme olarak ikiye ayrılır. Denetimli ve denetimsiz öğrenme arasındaki temel fark süreçte bir denetmenin olup olmamasıdır [61].

Denetimli öğrenmede girdi verilerine karşılık gelen sonuç etiketleri önceden belirlidir. Bu şekilde verilerin belli sınıflara ayrılması sağlanır. Bu öğrenme türünde verileri ve etiketleri sisteme tanıtan bir yapı kurulmaktadır. Görüntülerden kanser teşhisi, görüntü bölütleme, spam benzeri e-postaları tespit etmek gibi örnekler denetimli öğrenmeye dâhildir. En yaygın kullanılan denetimli öğrenme görevi etiketli veriler üzerinden tahmin regresyon analizidir [62].

Denetimsiz öğrenmede birincil amaç verilerden desenler, yapılar veya bilgileri ortaya çıkarmaktır. Bu yöntemle “veri güdümlü yöntem” adı verilmektedir. Denetimli öğrenmeden temel farkı verilerin herhangi bir sınıfa ayrılmamış yani etiketlenmemiş olmasıdır. Bu yapıda büyük veri kavramı önemlidir. Bu öğrenme türünde sisteme önceden veriler girilirken herhangi bir sınıf etiketi verilmez. Sistem kümeleme ve benzeri yapılarla bu veriler arasındaki ilişkilere göre sınıflama yapmaya çalışır. Sınıf sayısı önceden belirlenmez süreç sonunda netleşir.

Büyük veriden öngörülemeyen yararlı bilgiler çıkarılabilir. Bu şekilde büyük veri yığınlarından faydalı bilgiler çıkarılması veri madenciliği olarak tanımlanmaktadır. Elde edilen verilerin yapısına göre farklı yöntemler kullanılarak kümelere ayrılır. Bu aşamada kümeleme, görselleştirme, boyut azaltma, birliktelik kuralları, anormallik algılama gibi yöntemler kullanılır [62].


2.3. Derin Öğrenme

Derin öğrenme (DÖ – Deep Learning), yapay sinir ağlarına dayalı bir yapay zekâ tekniği olarak bilinir. DÖ, günümüzde veriden katman bazında öğrenme yeteneği nedeniyle bilgi işlem dünyasında sıcak bir konu haline gelmiştir [63].

Derin öğrenmeyi anlayabilmek için yapay sinir ağlarının anlaşılması uygun olacaktır. Derin öğrenme de aslında bir yapay sinir ağıdır. Temel farklılık, derin öğrenmede birden çok gizil katmanın yer almasından kaynaklanmaktadır.

2.4. Yapay Sinir Ağları (YSA)

YSA canlıların sinir sisteminin matematiksel modeli olarak düşünülebilir. Bir nöronun çalışma mantığı kopyalanarak YSA oluşturulmaktadır. Derin öğrenme makine öğreniminin bir alt kümesidir. Çok katmanlı sinir ağlarından oluşan DÖ ile büyük miktarda veriden öğrenme işlemin gerçekleşir. Şekil 2.1’de tek bir nöronun tasvirinden oluşan YSA görülmektedir [64].



Şekil 2.1. Tek nöronlu yapay sinir ağı [64]

Girişler ($X_1, X_2, \dots, X_n$) kullanıcı tarafından belirlenen veriler ile oluşturulan katman.

Ağırlıklar ($W_1, W_2, \dots, W_n$) giriş verisinin oluşturacağı çıktının ne kadar olacağını belirler. Burada ağırlık (w) girdinin çıktıyı ne kadar etkileyeceğini göstermektedir. Bir girdiyle ilişkilenen ağırlık değişebilir. Bu değişim o girdinin önem derecesine göre artış ya da azalış şeklinde olabilir.

Toplama fonksiyonu bir hücredeki giriş toplamını hesap etmek için kullanılır. Farklı fonksiyonlar burada kullanılabilir. En sık tercih edilen ve bu tezde de kullanılmış olan fonksiyon ağırlıklı toplamdır. Bunun dışında çarpma, maksimum, minimum ve artan toplam gibi türler vardır. Ağırlıklı toplamda giriş ve ağırlık değerleri çarpılır ve elde edilen değerler birbirine eklenir. Eş. 2.1’de eşitlik görülmektedir (W_j =ağırlıklar, X_j =girişler) [65].

$$\text{Toplama: } \sum W_j X_j \quad (2.1)$$

Aktivasyon fonksiyonu çıkış değerini giriş değerine bağlı olarak hesaplamak için kullanılır. Aktivasyon fonksiyonları doğrusal, türevsel, hiperbolik tanjant gibi farklı türlerde olabilirler. Aktivasyon fonksiyonları bir algoritmada ara katmanların sonunda ve en son katmanda yer almaktadır. Algoritmanın bitişinde yer alan temel fonksiyonlar sigmoid ve softmax fonksiyonlarıdır. Sigmoid elemanların her biri için sıfır ile bir arasında bir değer üretmektedir. Softmax veriler üç veya daha fazla sınıfa ayrılacağı zaman tercih edilmektedir. Derin ağlarda en çok tercih edilen fonksiyonlardan biri de RELU fonksiyonudur. RELU algoritmanın bitişinde bulunmaz. Bu fonksiyonda giriş değerleri 0 ve 1 arasında çıkış değerlerine çevrilirler. Eğer giriş değeri sıfırın altında ise çıktı sıfırdır, değilse çıkış değeri giriş değerine eşit olur. Tanjant RELU’ya benzer amaçla kullanılır ve farkı çıkış değerlerinin -1 ve 1 arasında değerler olmasıdır [66].

Çıkış Fonksiyonu aktivasyon fonksiyonu ile belirlenir. Fonksiyon formülü Eş. 2.2’de görülmektedir. Son çıkış diğer hücrelerden gelen değerlerin birlikte üretilmesiyle bulunur (X_j =girişler, W_j =ağırlıklar, b_j =bias, y =gerçek çıkış). Bias verilere uyum sağlaması için fonksiyonun sağa veya sola kaydırılmasını sağlayan sabit bir değerdir [66].

$$\text{Çıkış} = \sum_j W_j X_j + b_j \quad (2.2)$$

2.4.1. Kayıp fonksiyonu

Kayıp fonksiyonu (Loss function) ağırlıkların artacağına ya da azalacağına karar vermek için kullanılır. İlk tahminden sonra ağırlık değerleri artırılarak ya da azaltılarak eğitim baştan yapılır. Yapılan her bir eğitim adımına epok (*epoch*) adı verilir. Kayıp fonksiyonu optimizasyon yöntemleriyle sıfıra yaklaşacak şekilde çalışmaktadır. Bazı temel kayıp fonksiyonlarını kısaca açıklarsak; [66]

İkili çapraz entropi (Binary cross entropy) çalışmalarda sıklıkla kullanılmaktadır. Çapraz entropi rastgele verilen bir değişken için iki muhtemel dağılım arasındaki farkın bir ölçüsüdür [67].

Eş. 2.3'te verilen İÇE (İkili Çapraz Entropi) fonksiyonu sıklıkla sınıflandırma ve bölütleme çalışmalarında kullanılmaktadır ($\hat{y}$ =tahmin edilen değer, y =gerçek çıkış) [67].

$$\text{İÇE}(y, \hat{y}) = -(y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})) \quad (2.3)$$

Zar Kaybı (ZK – Dice loss) zar doğruluğu parametresinin adaptasyonu ile oluşturulmuş bir kayıp fonksiyonudur. Eş. 2.4'de verilmiştir (y =gerçek çıkış, $\hat{p}$ =tahmin) [67].


$$ZK(y, \hat{p}) = 1 - \frac{2y\hat{p}+1}{y+\hat{p}+1} \quad (2.4)$$

Ortalama Hata Karesi (OHK – Mean Squared Error) hesap edilen ve gerçekte olan değerler arasındaki hata karelerinin ortalamasını bulur.

2.4.2. Tek katmanlı ve çok katmanlı yapay sinir ağları

Tek katmanlı sinir ağları sadece girdi ve çıktı birimlerinden oluşan yapay sinir ağı modelidir. Çok katmanlı sinir ağlarında, çoklu gizli katmanlar, girdi ve çıktı katmanları tipik bir derin sinir ağını oluşturur [65].

Şekil 2.2'de üç girişli tek gizli katmanlı bir derin öğrenme yapısı temsil edilmektedir.



Şekil 2.2. Derin öğrenme mimarisi [65]

2.4.3. İleri ve geri beslemeli sinir ağları

Yapay sinir ağı mimarileri ileri ve geri beslemeli olarak ikiye ayrılır. İleri beslemeli ağlarda veriler tek yönde düğümler üzerinden ilerler. Bir hücredeki çıkış değerleri ağırlıklar üstündeki girişler gibi takip eden katmana aktarılırlar. Bu ağ türünde veriler gizil katmana hiçbir değişikliğe uğramadan gönderilirler [65].

Geri beslemeli sinir ağlarının ileri beslemeli sinir ağlarından temel farkı nöronlarda elde edilen çıktıların sonraki nöronların yanı sıra kendinden önceki nöronlara da girdi olarak alınabilmesidir. Geri beslemede tercih edilen bu yöntem hataların azaltılmasına yardımcı olmaktadır [65].

2.4.4. Evrişimli sinir ağları (ESA)

Evrişim işlemi, bir evrişimli sinir ağının temel yapı taşlarından biridir. Evrişim katmanının parametreleri bir dizi öğrenilebilir filtre (çekirdek) içerir. Tipik filtre boyutları 3x3, 5x5, 7x7 boyutlarındadır. Filtrenin üçüncü boyutu girişteki kanal sayısına karşılık gelir. Bu gri tonlamalı görüntüde derinlik 1'dir ve renkli görüntüde 3'tür [68]. ESA girdi verisi olarak görüntüleri kullanan bir derin öğrenme algoritmasıdır. Görüntülerin özelliklerini (features) kullanarak görüntüleri birbirinden ayırt etmektedir. Diğer bir deyişle görüntülerden sınıflandırma işlemi gerçekleştirilmektedir. ESA mimarisi temel olarak üç katmandan oluşur. Bunlar Evrişimli Katman (Convolutional Layer), Havuzlama Katmanı (Pooling Layer) ve Tam Bağlantılı Katman (Fully Connected Layer)'dır. Bu katmanlardan geçen

görsel, farklı işlemlerden geçirilerek derin öğrenme modeline girecek hale gelir. Devam eden paragraflarda temel ESA parçaları aktarılacaktır [68].

Havuzlama katmanı algoritmalar için önemli bir katmandır. ESA'lar genellikle evrişim katmanlarından sonra havuzlama katmanı işlemini kullanır. Havuzlama işleminin işlevi boyutu küçültmek veya alt örnekleme olarak da adlandırılır. En yaygın olarak kullanılan havuzlama katmanının filtre boyutu 2'dir. En çok kullanılan havuzlama türleri maksimum havuzlama ve ortalama havuzlamadır. Bu işlemlerde sırasıyla maksimum ve ortalama değerler filtre boyutuna göre alınır [68].

Tamamen bağlı katman ağ bitişinde kullanılır. Birkaç evrişim ve havuzlama katmanından sonra, ESA genellikle tamamen bağlı birkaç katmanla biter. Bu katmanların çıktısında sahip olduğumuz tensör bir vektöre dönüştürülür ve sonra sinir ağı katmanları eklenir. Mimarideki son tam bağlı katman, tanınacak sınıf sayısı ile aynı miktarda çıktı nöronu içerir [68].

Aktivasyon katmanı (Activation layer) aktivasyon işleminin yapıldığı katmandır. Burada aktivasyon fonksiyonu kullanılarak yeni değerler elde edilir [69].

Toplu normalleştirme (TN – Batch normalization) özellik haritasıyla iç kovaryans kayması ile ilişkili sorunları adreslemek için kullanılır. İç kovaryans kayması gizli birimlerin dağıtımını, iç kovaryans kayması, yakınsamayı yavaşlatan ve parametrelerin dikkatli başlatılmasını gerektiren gizli birimlerin değerlerinin dağılımındaki bir değişiktir [68].

Toplu normalleştirme ağı performansını artırmaktadır. Katmanlara gelen verilen çok küçük ya da büyük olabilir. Bu durumda değerlerin belli aralıkta normalize edilmesi hem ağı performansını artıracak hem de verilerin belli aralıkta temsil edilmesini sağlayacaktır [68].

Bırakma (Dropout) kesinlik ihtimalli bağlantıları veya bazı birimleri rastgele göz ardı ederek genellemeyi geliştiren ağda düzenleme anlamına gelir. Bu işlem ile ağı ezberlemeye düşmesi önlenmeye çalışılır. Bu işlem ile ağda daha az etkin olan düğümlerin sayısı da azaltılmış olur [68].

Tekrarlayan sinir ağıları, derin inanç ağıları gibi farklı yapay sinir ağı türleri vardır. Fakat biz evrişimli sinir ağlarının yanında tez kapsamında kullanılan kodlayıcı – çözücü modeli ve tekrarlayan sinir ağılarını burada açıklayacağız.

2.4.5. Tekrarlayan sinir ağıları

Bu model Elman tarafından ortaya konulmuştur. Bu ağılar sadece ağı gelen giriş verilerini değil geçmiş giriş veri örneklerini de almaktadırlar. Geleneksel sinir ağlarından girişler birbirinden bağımsızdır. Tekrarlayan sinir ağlarında ise her verinin çıktısı önceki hesaplamalara bağlanır. Bu noktada tekrarlayan sinir ağlarının hem ileri hem de geri beslemeli olduğu görülmektedir [70].

2.4.6. Kodlayıcı – çözücü ağılar

Kodlayıcı – çözücü (Encoder – decoder) mimarisi giriş sekansında okunan verinin gizil ya da sonraki katmana sunuma hazırlanması için (boyut azaltma gibi) geliştirilmiştir. Bu yapıda giriş katmanı gizil katmana kodlanarak aktarılır. Kodlayıcı blokları evrişim katmanları, aktivasyon fonksiyonu (RELU vb) ve toplu normalleştirme içerebilmektedir. Kodlama kısmında temel amaç görüntüde özelliklerin boyut azaltarak çıkarılmasıdır. Giriş veri kümesi sıkıştırılarak en az kayıpla öğrenme sağlanır. Temel olarak giriş, çıkış ve gizil katmandan oluşur. Giriş ve çıkış katmanlarında nöron sayısı aynı, gizil katmandaki ise değişkendir [70]. Çözücü bloklar ise kodlama kısmının tersine yukarı örnekleme yaparak maske görüntüsünü (çıkış) elde etmeye çalışır [34].

Bu ağı türünden kodlayıcı bloklar için farklı derin öğrenme algoritmaları kullanılabilir. Sıklıkla kodlayıcı olarak kullanılan algoritmalar arasında ResNet, EfficientNetB1-B7, Inception V3, DenseNet, sayılabilir. Bunların içerisinde EfficientNetB7 en başarılı modeldir [19].

2.4.7. Optimizasyon yöntemleri

Kayıp fonksiyonu ile belirlenen hata değerlerinin mutlaka en aza indirilmesi gerekmektedir. Bu noktada optimizasyon algoritmaları kullanılmaktadır. Bu algoritmalar ağı içinde tahmin edilen çıktı değeri ile gerçek çıktı değeri arasındaki farkı, yani hatayı

minimize etmeye yarayan yöntemlerdir. Bu algoritmalarda öğrenme katsayısının (learning rate) doğru belirlenmesi son derece önemlidir. *Öğrenme katsayısı* optimizasyon algoritmasının hatayı azaltma sürecinde parametreleri yani modeli hangi ölçüde değiştireceğinin belirlenmesini sağlar. Bu katsayı genellikle 0,1 ile 0,2 aralığında alınır. Bu değer çok küçük alınırsa eğitim süresi uzayacak, çok büyük alınırsa ise ağırlıkların çok hızlı değişecek veya eğitim dengesiz olacaktır. Önemli bazı optimizasyon algoritmaları verilmiştir [66].

SGD optimizasyon algoritması tüm eğitim verisi yerine, seçilen bir örneklem üzerinden hesaplamalar yapılmaktadır. Burada amaç hafızanın tükenmesini önlemektir. Bu sorun özellikle görüntülerin girdi olarak kullanıldığı eğitimlerde sorun olarak ortaya çıkabilmektedir [66].

Adagrad her parametre için her adımda t farklı öğrenme katsayısı kullanılır ve her bir parametre için farklı güncellemeler yapılmaktadır. Bu sayede öğrenme katsayısının el ile ayarlanmasına gerek kalmamaktadır. Böylece, öğrenme katsayısının manuel olarak ayarlanma ihtiyacı ortadan kaldırılmaktadır. Bu yöntemin en büyük sorunu öğrenme katsayısının aşırı küçülmesidir. Bu durum eğitim sürecini uzatabilir hatta tı kayabilir [66].

Rmsprop adagrad'ta ortaya çıkan öğrenme katsayısının aşırı küçülmesi sorununa çözüm bulma amacıyla geliştirilmiştir. Adagrad'ın aksine tüm geçmiş parametreler kullanılmayarak sorun çözülmeye çalışılmaktadır [66].

Adam tıpkı *Rmsprop*'ta olduğu gibi geçmiş eğitimlerin karelerinin üssel olarak ağırlıklandırılmış ortalamaları kullanmaktadır. Ayrıca, momentum değişikliklerini de önbellekte saklanmaktadır. Bu yöntem tez çalışmamızda diğer yöntemlere olan üstünlüğünden dolayı tercih edilmiştir [66].

2.5. Derin Öğrenme Mimarileri


Bu başlık altında görüntü bölütleme amacıyla kullanılan önemli modeller ve tez çalışmasında yararlanılan derin öğrenme modelleri açıklanmıştır. Burada mimarilere geçmeden önce bilinmesi gereken bazı kavramlar kısaca açıklanacaktır. Derin öğrenme ile görüntü bölütleme temel olarak ikiye ayrılır.

Anlamsal (Semantic) bölütleme için kullanılan ağlarda girdi olarak RGB görüntüler kullanılır. Kaç tane nesne varsa o kadar etiket vardır. Piksel bazlı olarak her birinin hangi nesne etiketine ait olduğu bulunur. Aynı sınıfa ait iki nesne aynı renktedir [71].

Örnek (Instance) bölütleme ile her piksele belirli bir sınıf atanır. Farklı olarak aynı sınıftaki iki farklı nesne birbirlerinden farklı renklere sahiptir [71].

2.5.1. UNet, UNet++ ve EAR-UNet mimarileri

UNet, tıbbi görüntülerin bölütlenmesi için kullanılan modeller arasındadır. UNet, yüksek doğruluk oranına sahip bir derin öğrenme algoritmasıdır. UNet'te giriş görüntülerinde çıkış haritası elde edilir. Şekil 2.3 UNet'in yapısını göstermektedir. UNet'in kullandığı aktivasyon fonksiyonu 3x3 RELU evrişim katmanlarıdır. Son katmanda 1x1 evrişim kullanılır. Modelde toplam 23 evrişim katmanı kullanılmıştır [72].



Şekil 2.3. UNet mimarisi [72]

UNet mimarisi iki aşamadan oluşur. Bunlar şeklin sol tarafını temsil eden kodlayıcı ve sağ tarafını temsil eden kod çözücü bloklarıdır. Bağlantı atlama ifadesiyle temsil edilen işlem ile kod çözücü aşamasına özellik aktarımı sağlanır. Kodlayıcı aşamasında görüntülerdeki özellikler evrişim katmanları ile yakalanır. Her bloğun çıkışı bir maksimum havuz (max pool) katmanına bağlanmaktadır. Bu işlem sonucunda görüntü boyutu azalır. Kod çözücü aşaması ise görüntüde kesin lokalizasyonu yakalamaya çalışır. Bu aşamada yukarı örnekleme ile görüntü çözünürlüğü artırılarak nihai bölütleme sonucuna erişilmeye çalışılır. Her iki aşama şekilde görülen 4 bloktan oluşur ve TN ve RELU katmanları vardır. UNet ile RELU fonksiyonu tercih edilmektedir [72].

UNet ++ mimarisi temel olarak bir kodlayıcı alt ağıyla başlar. UNet'ten ayrılan özelliği iki alt ağı birbirine bağlamasıdır. UNet mimarisinde çözücü bloklarda elde edilen özellik haritaları çözücü bloklara direkt aktarılmıştır. UNet++'ta ise piramit seviyesine bağlı olarak evrişim katmanlarının sayısı ile orantılı olarak dense (yoğun) katmanına geçerler. UNet++ algoritmasının tanıtıldığı makale baz alındığında, UNet 'e göre yaklaşık %4 daha başarılı bir model olduğu görülmektedir [73]. EAR-UNet çözücü blok olarak EfficientNetB4 kullanan bir UNet türüdür. UNet ve UNet++ algoritmalarından daha başarılı olduğu görülmektedir [21].

2.5.2. LinkNet mimarisi

LinkNet mimarisi Şekil 2.5'te görülmektedir. /2 alt örneklemenin adım (stride) 2 değeriyle yapıldığını gösterir. Aynı şekilde *2 üst örneklemenin 2 değeriyle yapıldığını ifade etmektedir. Bu modelde her evrişim katmanı arasında toplu normalleştirme kullanılmıştır. Mimari UNet te olduğu gibi kodlayıcı ve çözücü mantığıyla çalışmaktadır. Kodlayıcı ve çözücü bloklarının içeriği şekilde görülmektedir. Mimari 7*7 çekirdek boyutuna sahip bir evrişim katmanı ile (adım 2) başlar. Ardından 3*3'lük bir maksimum havuzlama işlemi gelmektedir. Kodlayıcı ve çözücü bloklarının bitiminde tam evrişimli katmanla mimari sonlanmaktadır.

LinkNet kısa epok zamanı ve yüksek başarı değerleri sunmaktadır. LinkNet kodlayıcı bloklarında ResNet18'i hızlı ve sade ağ yapısını korumak adına tercih etmektedir [29]. Şekil 2.4'de LinkNet mimarisi görülmektedir. Tam evrişimli katman bu mimaride yukarı örnekleme görevini yerine getirir.



2.5.3. FCN (Full convolutional network) mimarisi

En temel ve eski derin öğrenme algoritmalarından biridir. FCN8, 16 ve 32 olmak üzere üç farklı türü vardır. Bu türler arasında en başarılı modeli FCN8'dir. FCN modellerinin temel farkı havuzlama ve yukarı örnekleme işlemlerinden kaynaklanmaktadır. Adlarını da aslında bu farklılıktan almaktadırlar. FCN8 8x yukarı örnekleme yaparken, FCN32 32x yukarı örnekleme yapar. Bu durum FCN32'nin eğitim süresini ve başarısını aynı anda düşürür. FCN temel olarak evrişim katmanları, havuzlama ve aktivasyon fonksiyonlarından oluşur. Mimaride ortalama havuzlama ve 1*1 evrişim katmanları ve RELU aktivasyon fonksiyonu tercih edilmiştir. Ayrıca model önceden eğitilmiş VGG19 gibi modellerle adapte edilerek başarı artırılabilir [74].

2.5.4. SegNet mimarisi


SegNet, kodlayıcı ve kod çözücü olarak adlandırılan katmanlardan oluşur. Her kodlayıcı, bir adet evrişim bir adet TN ve RELU adımlarını içerir. Kodlayıcı adımlarından çıkan değerler, daha sonra bir maksimum havuzlama katmanında işlenir. Kod çözücüler temel olarak kodlayıcılara benzer. Farkları doğrusal olmaları ve kodlama aşamasından saklanan endeksleri kullanarak girdilerini örneklendirmeleridir. Son kod çözücünden alınan çıktı daha sonra bir SoftMax sınıflandırıcısına verilerek bölütleme işlemi gerçekleştirilir [14, 75].

2.5.5. ResNet (Residual network) ve ResNet50 mimarileri

ResNet Şekil 2.5'te gösterilen bloktan oluşmaktadır. Her blok periyodik olarak, filtre sayısı ve alt örnekleme (stride 2 ile) içeren 3x3 evrişim katmanına sahiptir. ResNet özel atlama bağlantılarına sahiptir ve her evrişimden sonra toplu normalleştirme kullanılır.

Daha derin modellerin optimize edilmesi daha zordur. Çözüm olarak ResNet mimarisinde bu bloklar paralel kullanılarak ya da yapıları değiştirilerek başarı artışı sağlanabilir. Ama blok sayısını artırmak eğitim süresini artıracak ve optimizasyonu zorlaştıracaktır [69].

Şekil 2.6'da ResNet mimarisinin yapısı görülmektedir.




Şekil 2.5. ResNet mimarisi [69]

ResNet50 7x7 evrişim katmanı ile başlar ve bu katmanı 3x3'lük bir havuzlama takip eder. Sonrasında sırasıyla 1x1, 3x3 ve 1x1 evrişim katmanlarından oluşan 16 blok yer almaktadır. Ortalama havuzlama işlemi ve tam bağlı katman softmax fonksiyonu ile tamamlanır. ResNet50 temel ResNet'e göre başarı oranı yüksek fakat eğitim süresi de fazla olan bir mimaridir [76]. ResNet daha çok diğer modeller içinde kullanılırken ResNet50 başlı başına bir model olarak tercih edilebilir.

2.5.6. EfficientNet mimarisi

EfficientNet B1, B2, B3, B4, B5, B6, B7 olmak üzere yedi alt türe sahiptir. MBConv bu modeldeki ana bloktur. EfficientNet'in alt türlerinde B1'den B7'ye bu bloktan artan sayılarda yer almaktadır. Blok sayısının artması eğitim başarısını ve süresini artırmaktadır [77].

EfficientNet türleri arasındaki en başarılı model EfficientNetB7'dir. Bunun yanında eğitim süresi olarak en uzun süreye sahip olan model yine EfficientNetB7'dir. Bu modelin yapısı Şekil 2.7'da görülmektedir.



Şekil 2.6. EfficientNetB7 mimarisi

2.5.7. VGG16, VGG19 ve XCEPTION mimarileri

VGG mimarisi daha küçük filtre boyutları (11x11 ve 5x5 yerine 3x3) kullanmaktadır. Bu sayede daha az hesaplama maliyeti gerekmektedir. VGG16 arka arkaya bağlı üç tam katman içerir. Çıkış katmanında softmax fonksiyonu kullanılmaktadır. VGG19 temelde VGG16 ile aynıdır. Farklılık kullanılan evrişim katmanı sayısının fazla olmasından kaynaklanmaktadır [78].

Xception toplam 22.8M parametreye sahiptir. 3x3 evrişim katmanları ve 1 adet 1x1 evrişim katmanı kullanır. Toplamda 71 katmana sahiptir. Genellikle yüksek sayıda sınıflama işlemlerinde kullanılmaktadır. Genel olarak VGG16 ve VGG19'a göre başarısı düşüktür. Burada temel neden parametre sayısının VGG versiyonlarında olan 138M'a göre oldukça düşük kalması sayılabilir [68].

3. MATERYAL VE METODOLOJİ

Bu bölümde kullanılan veri setleri, yöntemler, kullanılan parametreler ve önerilen modeller açıklanmıştır.

Çalışmamızda gürültü temizliği, lezyon bölütleme ve lezyon sınıflandırma olmak üzere üç aşama yer almaktadır. Gürültü temizliği ve bölütleme aşamalarında derin öğrenme ve görüntü işleme algoritmaları ile iki farklı yaklaşım kullanılarak maske tahmini yapılmıştır. Lezyon bölütleme aşamasında, gürültüden arındırılmış görüntüler ile lezyon bölütlemesi yapılmaktadır. Son olarak lezyon sınıflandırma aşamasında, bölütlü ya da bölütsüz seçenekleri ile görüntü iyi huylu ve kötü huylu (melanom) olarak sınıflandırılmaktadır. Cilt kanserinin birçok alt türü bulunmaktadır. Bu türlerden melanom kötü huylu, diğerleri iyi huylu kabul edilebilir. Diğer türlerden bazıları zamanla kötü huylu tümörlere dönüşebilmektedirler. Tez çalışmasında karar vericilere cilt kanserinin teşhis sürecinde destek sağlamak amacıyla görüntüler, iyi huylu ve kötü huylu olarak ikiye ayrılmıştır.

Çalışmamızda karar vericilere karar verme aşamasında yardımcı olmak üzere bir KDS geliştirilmiştir. Bu KDS bahsedilen üç aşamayı içermekte ve karar verici her bir aşamada istediği görüntüyü gürültülü/gürültüsüz, bölütlü/bölütsüz şeklinde seçebilmektedir. Gürültü temizliği ve lezyon bölütleme aşamalarında olası bir hata oluşma durumunda, hatalı görüntüler seçilerek sınıflama yapıldığında sınıflama başarısı düşecektir. Bu yüzden karar vericiye bir KDS'den beklendiği gibi seçimler sunularak hatalı olan sürecin geçilebilmesi sağlanmıştır.


Literatürde genel olarak veri setleri sırasıyla eğitim, doğrulama ve test kümeleri olmak üzere; (%80, %10, %10); (%70, %15, %15); (%70, %20, %10) şeklinde ayrılmaktadır. Bazı çalışmalarda veri seti ilk etapta %80 eğitim, %20 test olarak ayrılmaktadır. Daha sonra eğitim verisi kendi içinde %80 eğitim, %20 doğrulama olacak şekilde yeniden ayrılmaktadırlar. Doğrulama veri setinin oranları değişebilmekle birlikte, tüm veri setinin %80'inden fazlasını eğitime ayırmak özellikle veri seti boyutunun küçük olduğu durumlarda ezberleme sorununa neden olabilmektedir. *Aşırı öğrenme (Overfitting)* veri kümesine modelin aşırı uyum göstermesi sonucunda sistem dışından gelen bir veri ile test edildiğinde başarının düşmesi olarak düşünülebilir. Eğitim veri seti eğitim aşamasında kullanılır. Doğrulama veri seti eğitim aşamasında kullanılan parametrelerin

sağlanması etkili olmuştur. Sınıflama aşaması için ISIC2019 ve ISIC2020'e ait veri setlerinden yararlanılmıştır. Veri setleri 3.1.2, 3.1.3 ve 3.1.4 başlıklı bölümlerde detaylandırılmıştır. Çalışmada veri setlerinin güncel versiyonları tercih edilmiştir.

3.1.1. Veri artırma ve görüntü dilimleme

Gürültü temizliği ve lezyon bölütleme aşamalarında kullanılacak veri setleri görüntü artırma yöntemleriyle (yatay/dikey kaydırma ve yatay/dikey çevirme) 4 katına çıkarılmıştır. Bu şekilde eğitim aşamalarındaki olası ezberleme (overfitting) önlenmeye çalışılmıştır. Tüm veri setlerinde *görüntü keskinleştirme* uygulanmıştır.


Kullanılan veri setleri arasında minimum görüntü boyutu 600*450'dir. Bu durumda bu çözünürlüğün altında bir girdi boyutunda piksel kayıpları yaşanacaktır. 16'lık dilimleme işlemi ile toplamda 1024*1024*3 boyutları girdi olarak alınmış, olası piksel kayıpları en aza indirgenmeye çalışılmıştır. Resim 3.2'de dilimleme sürecine örnek görüntüler görülmektedir. Bu yöntemle toplam veri sayısı veri artırma sonucu oluşan verilerin 16 katına çıkmaktadır.



Resim 3.2. Dilimleme sürecine ait örnek görüntüler

3.1.2. Temizleme veri seti

Jpeg formatında lezyonlu 10015 RGB görüntüden oluşan ISIC 2018'e ait bir veri seti bu aşamada tercih edilmiştir. Bu veri setinde bölütleme maskeleri yer almamaktadır [79]. Dolayısıyla bu veri setini sadece gürültü giderme ve sınıflandırma aşamalarında kullanabiliriz. Literatürde gürültü maskelerini içeren erişime açık herhangi bir veri seti bulunmamaktadır. Bu yüzden tez çalışması kapsamında bu veri setinden kıl ve cetvel gürültüsü içeren 1500 görüntü seçilmiş ve gürültü maskeleri oluşturulmuştur. Veri artırma ile gürültü giderme aşamasında bu veri setinin boyutu 6000 görüntü ve maskeye çıkarılmıştır. Veri seti 16'lık dilimlere ayrılarak toplam 96000 görüntü ve maskeye çıkmıştır. Bu veri kümesi *temizleme veri seti* olarak adlandırılmıştır. Bu veri setinin oluşturulma süreci Resim 3.3'te gösterilmektedir.



Resim 3.3. Gürültü maskelerinin oluşturulma süreci [77]


Seçilen görüntüler ile öncelikle adaptif eşikleme (adaptive thresholding) işlemi ile maske tahmini yapılmıştır. Daha sonra ortanca filtresi (median filter) ve morfolojik operasyonlar (morphological operations) ile maske üzerindeki gürültüler temizlenmiştir. Son aşamada ise görüntü manipülasyon yazılımı ile maskeler son hallerine getirilmiştir. Gürültü maskesi oluşturma aşamasında opencv kütüphanesi ve adobe fireworks yazılımından faydalanıldı. Bu aşamada kullanılan parametre ve yöntemler aşağıda açıklanmıştır.

Adaptif eşikleme (Adaptive Thresholding) piksel değeri eşikten küçükse 0 olarak ayarlanır. Aksi takdirde, maksimum bir değere ayarlanır. Algoritma pikselin etrafındaki küçük bir alana dayalı bir piksel için eşik değerini belirler. Böylece, aynı görüntünün diğer bölgeleri

için farklı eşikler elde edilmiş olur. Bu sayede düzensiz parlaklıklardan muzdarip görüntüler için daha iyi sonuçlar elde edilebilir [80].

Ortanca filtresi (median filter) ortanca piksel değeriyle yer değiştiren merkez piksel ve çekirdek altındaki tüm piksellerin ortasını hesaplar. Bu yolla görüntüdeki gürültüler temizlenebilir [80].


Morfolojik operasyonlar (morphological operations) arasında açma (opening), kapama (closing), erozyon (erosion) ve genişletme (dilation) işlemleri yer alır. *Açma (opening)* ile görüntü önce erozyona (erosion) uğrattılır sonra genişletilir (dilation). Erozyon, ön plan nesnesinin sınırlarını aşındırır ve genişletme ile görüntüdeki bölge veya ön plan nesnesindeki beyaz bölge artar. Bu yöntem küçük bölgelerin görüntüden çıkarılmasında kullanışlıdır. Çekirdek (kernel) farklı komşu pikselleriyle kombine edilen herhangi bir pikselin değerini nasıl değiştireceğimizi gösterir. *Kapama (Closing)* açmanın tersidir, genişleme ve ardından erozyon işlemleri yapılır. Ön plan nesnelerinin içindeki küçük deliklerin veya nesne üzerindeki küçük siyah noktaların kapatılmasında kullanışlıdır [80]. Oluşturulan temizleme veri seti'ne ait görsel Resim 3.4'de görülmektedir.



Resim 3.4. Temizleme veri seti'ne ait örnek görüntü ve maskeler [77]

3.1.3. Bölütleme veri seti

ISIC 2018'e ait bir veri seti (jpeg formatında 2594 görüntü ve png formatında maske) [81] ve PH2 [82] veri seti tercih edilmiştir (.bmp formatında 200 görüntü ve maske). Veri genişletme ile veri kümesi 11176'ya yükseltilmiştir. Bu veri seti *bölütleme veri seti* olarak adlandırılmıştır. Seçilen ISIC2018 güncel versiyon olup, veri setinin maske görüntülerinde uzman (expert), dikkat (notice) gibi ibareler yer almamaktadır. Bu veri seti lezyon bölütleme aşamasında kullanılmıştır. Bu veri seti 16'lık dilimlere ayrılarak 178816 görüntü ve maskeye ulaşmıştır. Bölütleme veri seti'ne ait dört örnek görüntü ve maskeler Resim 3.5'te görülmektedir.



Resim 3.5. Bölütleme veri seti'ne ait örnek görüntü ve maskeler

3.1.4. Lezyon sınıflandırma veri seti

Bu aşamada iyi huylu ve kötü olarak iki sınıf etiketine sahip ISIC2020 veri seti kullanılmıştır. Bu veri setinde bulunan kötü huylu lezyon sayısı iyi huylu lezyon sayısından çok daha düşüktür (iyi huylu: 32542, kötü huylu:584). Sınıf dağılımının normalleştirilmesi için ISIC2020 veri setinden 5106 iyi huylu ve 584 kötü huylu görüntü, ISIC2019'a ait etiketli veri setinden kötü huylu (melanom) 4522 görüntü ile birleştirilmiştir. Sonuç olarak 5106 iyi huylu ve 5106 kötü huylu lezyondan oluşan bir veri seti elde edilmiştir. Bu veri seti *lezyon sınıflandırma veri seti* olarak adlandırılmıştır.

Eğitim ve test verisinde sınıfların dağılımı veri setindeki dağılımla orantılı yapılmaya çalışılmıştır. Az sayıda veri içeren veri setlerinde ezberleme durumu ortaya çıkabilmektedir. Veri artırma bu duruma çözüm getirebilmektedir. Sınıflama veri setindeki görüntü sayısının fazla olmasından dolayı veri artırma işlemine ihtiyaç duyulmamıştır [83].

Lezyon sınıflandırma aşamasında herhangi bir görüntü dilimleme işlemi uygulanmamıştır. Bunun sebebi sınıflama için kullanılan sınıf bilgilerinin tüm görüntüye bakılarak belirlenebiliyor olmasındandır. Dilimli her bir görüntünün sınıflandırılması mümkün olmamaktadır. Veri setinde toplam iki sınıfa ait görüntüler yer almaktadır.

3.1.5. Veri setlerinin dağılımı

Veri setleri üzerinde veri artırma ve dilimleme işlemleri uygulanmış olup veri setleri üzerinde süreçlerin etkileri Çizelge 3.1 ve Çizelge 3.2'de verilmiştir.

Çizelge 3.1. Temizleme veri seti ve bölütleme veri seti veri dağılımları

Veri Seti Adı	Kullanılan Veri Seti	Görüntü Sayısı	Veri Artırma	Görüntü Dilimleme	Eğitim Veri Seti (%70)	Doğrulama Veri Seti (%20)	Test Veri Seti (%10)
Temizleme Veri Seti	ISIC 2018	1500	6000	96000	67200	19200	9600
TOPLAM				96000	67200	19200	9600
Bölütleme Veri Seti	ISIC 2018	2594	10376	166016	116211	33205	16600
	PH2	200	800	12800	8960	2560	1280
TOPLAM				178816	125171	35765	17880

Çizelge 3.2. Lezyon sınıflandırma veri setinin türe göre dağılımı

Kullanılan Veri Seti	Tür	Görüntü Sayısı	Eğitim Veri Seti (%70)	Doğrulama Veri Seti (%20)	Test Veri Seti (%10)
ISIC 2019	Kötü Huylu (Melanom)	4522	3166	904	452
ISIC 2020	Kötü Huylu (Melanom)	584	410	116	58
ISIC 2020	İyi Huylu	5106	3575	1021	510
TOPLAM		10212	7151	2041	1020

3.2. Önerilen Modeller

En iyileyici olarak Adam belirlenmiştir. Çıkış fonksiyonu olarak, çıkış sınıfı iki olduğu için gürültü temizliği ve lezyon bölütleme aşamalarında softmax yerine sigmoid kullanılmıştır. Softmax fonksiyonu çıkış üç veya daha fazla sınıf içerdiğinde tercih edilmektedir [84]. Modellerde imageNet ağırlıklarını kullanan ön eğitilmiş kodlayıcılar tercih edilmiştir. Transfer öğrenme olarak adlandırılan bu yöntemle eğitim süresi kısaltmakta ve başarı artışı sağlanmaktadır.

Kullanılan tüm modellerde ezberlemeyi önlemek için bırakma ve toplu normalleştirme katmanları eklenmiştir. Gürültü temizliği, lezyon bölütleme ve lezyonun sınıflandırılması için eğitim aşamalarında kullanılan temel parametreler Çizelge 3.3'te yer almaktadır.

Çizelge 3.3. Eğitim aşamalarında kullanılan parametreler

Parametre	Gürültü Temizliği Aşaması	Bölütleme Aşaması	Lezyon Sınıflandırma Aşaması
Yığın Boyutu (Batch Size)	8	8	16
Öğrenme Katsayısı (Learning Rate)	0.001	0.001	0.001
Epok Sayısı (Epoch)	5000	5000	250
Giriş Boyutu (Input Size)	256x256	256x256	256x256
En İyileyici (Optimizer)	Adam	Adam	Adam
Kayıp Fonksiyonu (Loss Function)	ZKOHK	ZKOHK	İÇE
Çıkış Fonksiyonu (Output Function)	Sigmoid	Sigmoid	Sigmoid


Görüntüler üzerinden yapay sinir ağları ile bölütleme yapan bir çalışmada Adam Adadelta, SGD gibi en iyileyiciler (optimizer) arasında en yüksek başarı oranına sahip olmuştur [85]. Tez çalışmasında üç aşamada da adam tercih edilmiştir.

3.2.1. ResNetC

Derin öğrenme algoritmalarında katman sayısını artırmak bir noktadan sonra başarı artışı yerine başarı düşüşüne neden olur. Bu düşüşün nedeni gradyan problemidir. Gradyan temel olarak girişe bağlı fonksiyondaki değişimin çıkışa etkisini ölçer. Ağdaki her bir ağırlığa göre kayıp fonksiyonunun gradyanı hesaplanır. Amaç kayıp fonksiyonu değerinin sıfıra olabildiğince yaklaştırılmasıdır. ResNet mimarisi bu soruna çözüm olarak daha fazla katman yerine “Identity connection (Kimlik bağlama)” yöntemini kullanmaktadır. Kullanılan kısa yol bağlantıları ile giriş ve çıkış katmanlarının boyutlarının aynı kalması sağlanmaktadır [86].

Çalışmada ResNetC adlı yeni bir ResNet modeli önerilmiştir [28]. C complex (karmaşık) kelimesinin ilk harfi olarak model ismine eklenmiştir. 2’şer adet ResNet bloğu paralel olarak kullanılarak, modelde başarı artışı sağlanmıştır. Olası bir gradyan probleminin önüne geçmek ve ağırlık yükünü çok artırmamak adına daha fazla ResNet katmanı eklemesi yapılmamıştır. Bu kullanıma bir örnek Fan ve diğerlerinin (2021) çalışmalarında paralel ResNet modeli önerilmiştir. Buna göre ResNet bloklarının paralel olarak kullanılması ile bilgi çıkarımı yapamayan ağırlıklar olduğunda paralel ResNet bloğu bunu tolere edilebilir. Ayrıca paralel ResNet modelleri daha fazla yararlı bilgi öğrenilebilir ve çıkış değerinin belirlenmesinde daha hassas davranarak, ağırlıkların ayarlanmasını kolaylaştırabilmektedir [87].

ResNetC modeli önerilen UNet-RCB7 ve LinkNet-RCB7 algoritmalarında son katmandan önce kullanılmıştır. Sadece son katmandan önce kullanılmasının sebebi kodlayıcı bloklarından dolayı hâlihazırda ağır olan algoritmaların yükünü artırmamaktır. ResNetC Şekil 3.1’de görülebilir.



Şekil 3.1. ResNetC mimarisi [28]

3.2.2. LinkNet-RCB7

LinkNet-RCB7 modeli LinkNet-B7 modeli ile geliştirilmiştir [77]. LinkNet-RCB7 bu modelden farklı olarak ResNet bloğu yerine, önerilen ResNetC bloğunu kullanmıştır. B7 EfficientNetB7 modelini temsilen isme eklenmiştir.


Model isminde RC ResNetC kullanımını belirtmek için eklenmiştir. Modelde 4 kodlayıcı bloğu ve 4 kod çözücü bloğu vardır. Çalışmada kodlayıcı olarak imageNet ile eğitilmiş EfficientNetB7 ön eğitilmiş modeli kullanılmıştır. Bunun nedeni, B7'nin diğer EfficientNet türleri arasında en yüksek başarı değerlerine sahip olmasındandır.

Son katmandan önce modelimize tek bir ResNetC bloğu eklenmiş ve kod çözücü bloklardan önce bir orta blok kullanılmıştır. Kodlayıcı ve çözücü bloklar arasında kullanılan bu tür yapıların daha fazla özellik yakalanmasına yardım ettiği Xiong ve diğerlerinin (2021) çalışmalarında belirtilmiştir [32]. Bu şekilde kod çözücü bloklardan önce daha fazla özellik elde edilmek istenmiştir. Kodlayıcı bloğun katmanları Çizelge 3.4'de görülmektedir.

Çizelge 3.4. Kodlayıcı katmanları

Faz	Operatör	Çözünürlük	Kanallar	Katmanlar
1	conv 7x7, /2	128x128	64	1
2	conv 3x3	128x128	64	1
3	Blok 1 – Mbconv1 3x3	128x128	32	3
4	Blok 2 – Mbconv6 3x3	64x64	48	7
5	Blok 3 – Mbconv6 5x5	64x64	80	7
6	Blok 4 – Mbconv6 3x3	32x32	80	10
7	Blok 5 – Mbconv6 5x5	32x32	224	10
8	Blok 6 – Mbconv6 5x5	16x16	384	13
9	Blok 7 – Mbconv6 3x3	16x16	640	4


Şekil 3.2'de oluşturulan LinkNet-RCB7 algoritmasının mimarisi görülmektedir. Çözücü (decoder) bloklarının açılımı şekle eklenmiştir. Transposed conv giriş özellik haritasından daha büyük uzaysal boyutta çıkış özellik haritasını oluşturur.



Şekil 3.2. LinkNet-RCB7 mimarisi

3.2.3. UNet-RCB7

Tez çalışması kapsamında UNet-RCB7 modeli geliştirilmiştir. Kodlayıcı olarak imageNet ile eğitilmiş EfficientNetB7'yi seçilmiştir. Modelimizde önceki modelde olduğu gibi son katmandan önce yine tek bir ResNetC katmanı ve kodlayıcı ile çözücü bloklar arasında bir orta blok kullanılmıştır. Orta blok 3ç conv3x3 katmanı içermektedir. Şekil 3.3'te UNet-RCB7'nin yapısı görülebilir. Orta blok ile çözücü blok öncesi elde edilen özellik sayısı artırılarak başarı artışı hedeflenmiştir.



Şekil 3.3. UNet-RCB7 mimarisi

3.2.4. Lezyon sınıflandırma modeli

Lezyon sınıflandırma aşaması için imageNet ile eğitilmiş ResNet50 modeli algoritmanın başlangıcını oluşturmaktadır. Daha sonra sırasıyla düzleştirme (flatten) katmanı, yoğun (dense) katman, bırakma (dropout) katmanı, toplu normalleştirme (batch normalization) ve RELU aktivasyon fonksiyonu kullanılmıştır. *Düzleştirme katmanı* matris formundaki veriyi düzleştirir. Çıkış sınıfı kötü huylu (melanom – malign) ve normal olmak üzere ikiye ayrılmıştır. Şekil 3.4’de lezyon sınıflandırma modelinin python kodları görülmektedir.

Lezyon sınıflandırma aşamasında modelin başlangıcına ResNet dışında Xception ve VGG16 modelleri de eklenmiştir. Bu modellerle elde edilen sonuçlar dördüncü bölümde verilmiştir. Sonuçlardan da görüleceği gibi ResNet50 en yüksek başarı değerini göstermiş ve bu sebepten model bileşeninde tercih edilmiştir.

```
from keras.callbacks import CSVLogger, ModelCheckpoint
csv_logger = CSVLogger('log.csv', append=True, separator=';')

filepath = "best_model.hdf5"
checkpoint = ModelCheckpoint(filepath, monitor='val_acc', verbose=1, save_best_only=True, mode='max')
callback_list = [csv_logger, checkpoint]

def cihan():

    training_shape = (256,256,3)
    base_model = ResNet50(include_top=False,weights='imagenet',input_shape = training_shape)
    for layer in base_model.layers:
        layer.trainable = True

    n_classes = 2

    model = Flatten()(model)
    model = Dense(128)(model)
    model = Dropout(0.5)(model)
    model = BatchNormalization()(model)
    model = Activation('relu')(model)
    output = Dense(n_classes, activation='softmax')(model)
    model = Model(inputs=base_model.input, outputs=output)

    skip=d4
    x = Conv2D(64, 3, padding="same")(d4)
    x = BatchNormalization()(x)
    x = Activation("relu")(x)
    x = Conv2D(64, 3, padding="same")(inputs)
    x = BatchNormalization()(x)
    x = Activation("relu")(x)
    x = Concatenate()([x, skip])
    outputs = Conv2D(1, 1, padding="same", activation="sigmoid")(x)

    return model
```

Şekil 3.4. Lezyon sınıflandırma modeli python kod yapısı

3.3. Modellerde Kullanılan Parametreler

Zar doğruluğu (ZD- Dice coefficient) gerçek (Y) ve tahmin edilen (X) bölütleme arasında piksel bazında eşleşmeyi hesaplar. Formül Eş. 3.1’de verilmiştir [88].

$$ZD = (2 * |X \cap Y|) / (|X| + |Y|) \quad (3.1)$$

Kayıp fonksiyonu (Loss function) olarak çalışmada ZK ve OHK birlikte kullanılmıştır (ZKOHK). OHK, hata karelerinin ortalamasını ölçer [89]. Zar Kaybı aşırı bölütleme hatalarını ve OHK genel görüntü ayrıntılarını azaltır. ZKOHK formülü Eş. 3.2’de görülmektedir [90].

$$ZKOHK = OHK + ZK \quad (3.2)$$

En iyileyici (optimizer) olarak keras kütüphanesinde yer alan adam seçilmiştir. Adam eniyileyici stokastik bir gradyan iniş yöntemidir [91].

mIoU (Intersection Over Union) görüntüde bulunan bir nesne için tahmin edilen bölge ile gerçek bölge arasındaki benzerliği verir. Her bir sınıf için elde edilen IoU değerlerinin ortalamasını alınır [92]. DP: Doğru Pozitif, DN: Doğru Negatif, YP: Yanlış Pozitif, YN: Yanlış Negatif. Denklemin formatı Eş. 3.3’te görülmektedir.

$$IoU = DP / (YP + DP + YN) \quad (3.3)$$

Duyarlılık (DU – Recall) Eş. 3.4’de verilen formüle göre test veri setindeki pozitiflerin verilerin, gerçekte pozitif olarak bulunmasının doğruluk oranını belirler [92].

$$DU = DP / (DP + YN) \quad (3.4)$$

F1-Skoru (F1-Score) uç değerleri de göz ardı etmeyerek tahmin ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir. Formül Eş. 3.5’te verilmiştir [11].

$$F1-Skoru = 2 \frac{TH * DU}{TH + DU} \quad (3.5)$$

Tahmin (TH – Precision) pozitif olarak belirlenen değerlerin gerçekte pozitif olma durumlarının bir ölçüsüdür. Eş. 3.6’da tahmin değerinin hesaplanmasına ait eşitlik verilmiştir [5].

$$TH = DP / (DP + YP) \quad (3.6)$$

3.4. Eğitim Aşamaları

Hem gürültü temizliği hem de lezyon bölütleme aşamalarında iki farklı yaklaşım uygulanmıştır. İlk yaklaşımda derin öğrenme ve görüntü işleme algoritmaları birlikte kullanılmıştır. Önerilen derin öğrenme modelleri, belirtilen epok sayıları kadar koşturulmuştur. Çizelge 3.3’te modeller için kullanılan parametreler görülmektedir. İkinci yaklaşımda ise sadece görüntü işleme algoritmaları tercih edilmiştir.

3.4.1. Gürültü temizliği

Her iki yaklaşımla da tahmin edilen maskeler kullanılarak renkli (rgb) görüntüler üzerindeki gürültüler INPAINT fonksiyonu yardımı ile görüntüden temizlenmiştir.

Derin öğrenme ve görüntü işleme ile gürültü temizliği

Adım 1: Temizleme veri seti eğitim: 67200, doğrulama: 19200, test: 9600 şeklinde ayrılmıştır.

Adım 2: Modeller 5000 epok çalıştırılmıştır.

Adım 3: Test verisi kullanılarak modelden tahminler yapılmıştır.

Adım 4: Tahmin edilen maskelerin üzerindeki gürültüler, sırasıyla görüntü işleme algoritmaları olan ortanca filtresi ve morfolojik operasyonlar (açma, kapama) ile temizlenmiştir.

Adım 5: Opencv kütüphanesinde bulunan INPAINT fonksiyonu ile maskeler ve rgb görüntüler üzerinden gürültü temizliği yapılmıştır.

Görüntü işleme ile gürültü temizliği

Adım 1: Görüntüler gri seviyeye dönüştürülmüştür.

Adım 2: Adaptif eşikleme ile maske tahmini yapılmıştır.

Adım 3: Ortanca filtresi ile maskeler gürültülerden arındırılmıştır.

Adım 4: Maskeler üzerinde, açma ve kapama işlemleriyle hatalar azaltılmıştır. Gürültü temizliğinin etkisini artırmak için genişletme ile kıl maskesinin alanı artırılmıştır.

Adım 5: Son olarak tahmin edilen maskeler ile rgb görüntü üzerindeki gürültü INPAINT fonksiyonu ile temizlenmiştir.

3.4.2. Lezyon bölütleme

Bu aşamada yine iki farklı yaklaşımla elde edilen lezyon bölütleme maskeleri kullanılarak renkli görüntüler bölütlenmiştir. Her iki yaklaşımda da kullanılacak veri setinde, gürültü temizliği aşamasında eğitilen LinkNet-RCB7 modeli kullanılarak görüntülerdeki gürültüler INPAINT fonksiyonu ile temizlenmiştir.

Derin öğrenme ve görüntü işleme ile lezyon bölütleme

Adım 1: Temizlenen bölütleme veri seti eğitim: 125171, doğrulama: 35765, test: 17880 şeklinde ayrılmıştır.

Adım 2: Modeller 5000 epok çalıştırılmıştır.

Adım 3: Test verisi kullanılarak modelden tahminler yapılmıştır.

Adım 4: Son işlem (Post-process) adımı, tahmin edilen maskeler üzerindeki gürültüler, ortanca filtresi ve morfolojik operasyonlar (açma, kapama) ile temizlenmiştir.

Adım 5: Elde edilen maskeler ile renkli görüntülerdeki lezyonlar bölütlenmiştir.

Görüntü işleme ile lezyon bölütleme

Adım 1: Görüntüler gri seviyeye dönüştürülmüştür.

Adım 2: Görüntü üzerinde otsu eşikleme (otsu thresholding) ile maske tahmini yapılmıştır.

Adım 3: Tahmin edilen maskelerde, açma ve kapama işlemleriyle hatalar azaltılmıştır.

Adım 4: Son adımda tahmin edilen maskeler ile renkli görüntüler üzerinde bölütleme yapılmıştır.

Görüntü işleme yöntemleri derin öğrenme algoritmaları olmaksızın tek başlarına kullanıldıklarında, gürültü temizliği ve bölütleme aşamalarında yeterli olmamaktadırlar. Dördüncü bölümde bu durum örneklerle açıklanmıştır. Bu yöntem önerilen KDS ile karar vericilere seçenek olarak, gürültü temizliği ve lezyon bölütleme aşamalarında sunulmuştur. Bu şekilde karar vericiler iki yaklaşımın sonuçlarını karşılaştırabilecekler ve seçimlerini tekrar düzenleyebileceklerdir.

3.4.3. Lezyon sınıflandırma

Lezyon sınıflandırma aşamasında karar vericilere “bölütlü ve “bölütsüz” adlı iki seçenek sunulmuştur. Bölütlü seçeneği seçildiğinde sınıflandırma işleminde, önceki aşamalarda eğitilen LinkNet-RCB7 modeli ile temizlenen ve bölütlenen görüntüler kullanılmıştır. Bölütsüz seçeneğinde ise yine LinkNet-RCB7 ile gürültüsü temizlenmiş fakat bölütlenmemiş görüntülerle eğitilen sınıflama modeli kullanılmaktadır.

Bölütlü seçeneği ile sınıflandırma

Adım 1: Lezyon sınıflandırma veri seti gürültü temizliği ve lezyon bölütleme aşamalarında eğitilen LinkNet-RCB7 modeli kullanılarak gürültülerden temizlenmiş ve bölütlenmiştir.

Adım 2: Sınıflama veri seti eğitim: 7151 ve doğrulama: 2041, test: 1020 olarak bölünmüştür.

Adım 3: Model 250 epok çalıştırılmıştır.

Adım 4: Eğitilen modeller ile test verisi üzerinde tahminler yapılmıştır.

Bölütsüz seçeneği ile sınıflandırma

Adım 1: Lezyon sınıflandırma veri seti gürültü aşamasında eğitilen LinkNet-RCB7 modeli kullanılarak gürültülerden temizlenmiştir.

Adım 2: Sınıflama veri seti eğitim: 7151 ve doğrulama: 2041, test: 1020 olarak bölünmüştür.

Adım 3: Model 250 epok çalıştırılmıştır.

Adım 4: Eğitilen modeller ile test verisi üzerinde tahminler yapılmıştır.

4. ARAŞTIRMA BULGULARI


Bu bölümde gürültü temizliği, lezyon bölütleme ve lezyon sınıflandırma aşamalarında LinkNet-RCB7 ve UNet-RCB modelleri ve görüntü işleme algoritmaları ile elde edilen sonuçlar yer almaktadır. Ayrıca sonuçlarda farklı modellerin karşılaştırması da yapılmıştır. Bu karşılaştırmalarda karşılaştırmanın daha sağlıklı yapılabilmesi için aynı veri setine ait aynı sayıda görüntüler kullanılmaya çalışılmıştır.

Literatürde gürültü temizliği aşamasında kullanılabilecek, yayınlanan gürültü veri seti bulunmamaktadır. Bu yüzden gürültü temizliği aşamasında derin öğrenme kullanan az sayıda çalışma vardır. Sadece görüntü işleme ile yapılan gürültü temizliğinde bir başarı yüzdesinden söz edilememektedir. Bu sebepten bu aşamadaki karşılaştırmalar çalışma sayısı daha sınırlıdır.

Tez çalışmamızda geliştirdiğimiz iki model için de EfficientNetB7 kodlayıcı olarak tercih edilmiştir. Bunun temel sebebi EfficientNetB7'nin hem kendi içinde hem de diğer kodlayıcılar arasında en yüksek başarı oranına sahip olmasıdır. Şekil 4.1 EfficientNet türleri arasındaki karşılaştırma yer almaktadır.

Çizelgelerde yer alan sonuçlar için eğitim aşamalarında veri seti %70 eğitim, %20 doğrulama, %10 test şeklinde bölünerek elde edilen sonuçlar paylaşılmıştır. Ayrıca çizelgelerde en başarılı model olan LinkNet-RCB7 için, veri seti %80 eğitim ve %10 doğrulama, %10 test şeklinde bölünerek alternatif veri dağıtımı (AVD) ile karşılaştırma yapılmıştır.


Çizelgelerde kullanılan kısaltmalar; Eğitim Başarısı: EB, Eğitim Kaybı: EK, Doğrulama Başarısı: DB, Doğrulama Kaybı: DK, Zar Doğruluğu: ZD, Test veri seti: TVS, Gürültülü Veri Seti: GVS, Bölütlenmemiş Veri Seti: BVS, BGVS: Bölütlenmemiş Gürültülü Veri Seti, Alternatif veri dağıtımı: AVD.



Şekil 4.1. EfficientNet türlerinin başarı grafiği

4.1. Gürültü Temizliği Aşaması

Sadece görüntü işleme algoritmaları kullanılarak yapılan gürültü maskesi tahmini ve gürültü temizliği işlemine ait örnek görüntüler Resim 4.1’de görülmektedir. Gürültü tahmini yapılırken aslında lezyon üzerindeki piksellerin de gürültü olarak seçildiği görülmüştür. Bu durumda gürültü lezyondan temizlenmiş olsa dahi, bu durum beraberinde lezyon piksellerinin kaybını da getirecektir. Tahmin edilen maske üzerinde kalan ve tuz ve biber (salt and pepper) adı verilen gürültüler farklı yöntemlerle giderilebilir. Fakat bu düzeltme işleminde kıl maskesi üzerinde de kayıplar kaçınılmaz hale gelmektedir. Ayrıca görüldüğü gibi bazı görüntülerde iyi sonuç veren görüntü işleme algoritması farklı kontrast, parlaklık ve gürültü içeren görüntülerde de aynı sonucu vermeyebilmektedir. Maske düzeltme ile birbiriyle bağlantısız gürültü alanları maskelerden kaldırılmıştır. Bu durumda kırmızı ile işaretlenen bölgelerdeki kıl gürültüsünde kayıplar olduğu görülmüştür. Resim 4.1’de yer alan 3 numaralı görüntüdeki maske tahmininde, lezyon da gürültü olarak belirlenmiştir. Yanlış maske tahmini ile yapılan gürültü temizliği sonucu lezyon piksellerinde de kayıplar oluşmuştur. Bu gibi nedenler gözetilerek “Açma, kapama ve genişletme işlemleri” ile elde edilen maske gürültü temizliğinde kullanılmıştır. Açma işlemi ile kıl maskeleri dışında kalan beyaz piksel gürültüleri, kapama işlemi ile de maske içindeki siyah piksel gürültüleri görüntüden kaldırılmaya çalışılmıştır. Genişletme (dilation) ile incelen kıl maskeleri genişletilmiştir.




Resim 4.1. Görüntü işleme ile gürültü temizliği

Çizelge 4.1’de gürültü temizliği aşamasının eğitim sürecinde farklı modeller ile elde edilen sonuçlar paylaşılmıştır. Bu modeller arasında LinkNet-RCB7 en başarılı değerlere sahip model olarak görülmektedir.

Çizelge 4.1. Model bazında gürültü temizliği eğitim aşaması sonuçları

Parametre	UNet	LinkNet	EAR-UNet	UNet-RCB7	LinkNet-B7	LinkNet-RCB7	LinkNet-RCB7 AVD
EB (%)	86,44	89,24	91,31	93,91	95,82	95,88	94,83
EK	0,27	0,219	0,169	0,088	0,076	0,075	0,079
DB (%)	81,28	84,47	86,36	88,76	90,28	90,43	89,53
DK	0,429	0,362	0,332	0,254	0,242	0,237	0,249
meanIoU (%)	84,04	86,33	89,98	89,88	91,03	91,22	90,41
ZD (%)	83,58	86,24	89,71	90,17	91,42	91,92	90,82
TVS Başarı (%)	81,26	86,11	85,12	85,96	87,39	87,89	86,88
TVS ZD (%)	80,44	81,76	84,61	83,35	85,28	85,85	84,73

Çizelge 4.1’de görüldüğü gibi LinkNet-RCB7 modelimiz diğer modellerden daha başarılıdır. Resim 4.2’de örnek görüntülerin toplamda altı model (derin öğrenme + görüntü işleme) ve görüntü işleme ile test edilen sonuçlar yer almaktadır.




Resim 4.2. Derin öğrenme ve görüntü işleme ile gürültü temizliği

4.2. Lezyon Bölütleme Aşaması

Yöntem olarak sadece görüntü işleme algoritmaları kullanılarak yapılan lezyon bölütleme işlemine ait örnek sonuçlar Resim 4.3'te yer almaktadır. Lezyon maskeleri otsu eşikleme ile tahmin edilmiş, sonrasında açma ve kapama işlemleriyle maskedeki gürültüler temizlenmeye çalışılmıştır. Açma işlemi beyaz (255) piksel değerleriyle ifade edilen maskenin bölütlenmiş alanı dışında kalan bölümlerdeki beyaz pikselleri kaldırmaya çalışır. Kapama işlemi ise bölütlenmiş alan içindeki siyah (0) pikselleri görüntüden kaldırma işleminde kullanılmıştır. Maske düzeltme işleminde küçük alanlar maskeden kaldırılmıştır. Fakat lezyon görüntü boyunca küçük parçalardan da oluşabilmektedir. Uygulanan bu teknik optimal bir çözüm olmayacaktır. Özellikle Resim 4.3'te yer alan 2 numaralı görüntüde bölüt maskesi, lezyonu doğru temsil etmekten uzak kalmıştır. Bu sebeplerden dolayı bölütleme işlemi “Açma ve kapama işlemleri ile elde edilen maskeler kullanılarak yapılmıştır.

Görüntü işleme ile gürültü temizliği ve lezyon bölütleme aşamalarında maske düzeltme işlemleri karşılaştırma açısından farklı tekniklerle yapılmıştır. Her iki durum da, görüntü işleme ile yapılan gürültü temizliği ve lezyon bölütleme işlemlerinde optimal bir çözümün bulunmasının zorluğunu göstermiştir.




Resim 4.3. Derin öğrenme ile lezyon bölütleme

Bölütleme aşamasında toplam altı farklı model kullanılarak eğitim süreci tamamlanmıştır. Bu modellerden ikisi tez çalışmamız kapsamında geliştirilen UNet-RCB7 ve LinkNet-RCB7 modelleridir. Çizelge 4.2’de bu altı model ile elde edilen sonuçlar görülmektedir. LinkNet-RCB7 en yüksek başarı değerlerine sahip model olmuştur. Son iki satırda görülen değerler gürültülü veri setiyle yapılan eğitim sonuçlarıdır.

Çizelge 4.2. Model bazında lezyon bölütleme eğitim aşaması sonuçları

Parametre	UNet	LinkNet	EAR-UNet	UNet-RCB7	LinkNet-B7	LinkNet-RCB7	LinkNet-RCB7 AVD
EB (%)	87,28	91,18	94,02	95,76	97,50	98,10	97,38
EK	0,263	0,180	0,172	0,102	0,060	0,053	0,058
DB (%)	86,40	89,62	91,64	93,24	95,20	95,62	94,45
DK	0,354	0,293	0,285	0,253	0,245	0,232	0,245
meanIoU	85,20	89,41	92,26	93,42	96,11	96,42	95,71
ZD (%)	84,27	89,73	91,97	93,20	96,33	96,85	95,65
GVS Başarı (%)	84,85	90,75	92,82	93,30	96,34	96,97	95,78
GVS ZD (%)	81,45	90,58	91,63	92,84	93,88	94,45	93,24
TVS Başarı (%)	83,32	90,51	91,32	92,10	93,85	94,41	93,60
TVS ZD (%)	81,37	88,43	89,23	90,12	91,72	92,25	91,44

Resim 4.4’de örnek görüntülerin farklı modeller (derin öğrenme + görüntü işleme) ve görüntü işleme ile test edilen sonuçları yer almaktadır.



Resim 4.4. Derin öğrenme ve görüntü işleme ile lezyon bölütleme

4.3. Lezyon Sınıflandırma Aşaması


Literatür incelendiğinde cilt kanseri görüntülerinin sınıflandırılmasında ardışık (sequential) tabanlı modellerin yanında UNet, MobileNetV2 gibi modellerin de kullanıldığı görülmektedir. Bu aşamada tez kapsamında geliştirilen model yüksek başarı oranları elde etmiştir.

Önerilen KDS ile lezyonlar iyi huylu ve kötü huylu olmak üzere iki sınıfa ayrılmıştır. Çizelge 4.3’te lezyon sınıflandırma aşamasında elde edilen sonuçlar görülmektedir. Bu sonuçlar, gürültü temizliği yapılmış ve bölütlenmiş görüntüleri içeren veri setiyle elde edilmiştir. Ayrıca BVS (Bölütlenmemiş veri seti) ve GVS (Gürültülü veri seti) kullanılarak elde edilen başarı değerleri de çizelgede yer almaktadır. BVS’de bölütlenmemiş fakat gürültüsüz veriler yer almaktadır. Bu iki veri setiyle yapılan eğitimlerin daha düşük başarı değerleri gösterdiği görülmüştür.

Çizelge 4.3. Model bazında lezyon sınıflandırma eğitim aşaması sonuçları

Parametre	UNet	MobileNetV2	Önerilen Model	Önerilen Model AVD
EB (%)	97,78	99,00	99,93	99,40
EK	0,006	0,004	0,002	0,002
DB (%)	94,81	96,15	97,28	96,88
DK	0,241	0,212	0,199	0,201
ZD (%)	95,13	95,28	97,00	96,80
BVS Başarı (%)	96,40	97,03	98,00	97,65
BVS ZD (%)	93,11	94,10	95,28	95,00
GVS Başarı (%)	96,05	97,22	98,34	98,00
GVS ZD (%)	93,48	94,93	96,10	95,95
BGVS Başarı (%)	95,93	97,00	97,72	97,21
BGVS ZD (%)	93,80	94,78	95,67	95,30

Çizelge 4.4’te farklı temel modeller kullanılarak elde edilen sonuçlar görülmektedir. Lezyon sınıflandırma algoritmasında ResNet50 ile elde edilen sonuçlar, kullanılan diğer temel modellere göre daha yüksek olmuştur. ResNet50, VGG16 ve VGG19 modellerini görüntü sınıflama amacıyla karşılaştıran Macarenhas ve Agarwa (2021) çalışmalarında sırasıyla ResNet50 %97,33, VGG16 %96,67 ve VGG19 %97,07 eğitim başarısı elde etmişlerdir [93]. Gürültülü ve/veya bölütsüz görüntüler eğitim seti olarak tercih edildiğinde başarının düştüğü görülmüştür. Şekil 4.2’de gürültüsüz ve bölütlü test veri setine ait karışıklık matrisi sunulmuştur (0: İyi Huylu, 1: Kötü Huylu).



Şekil 4.2. Lezyon sınıflandırma aşaması karışıklık matrisi

Test veri setine ait duyarlılık (recall), tahmin (precision) ve F1-Skoru (F1-Score) başarı değerleri Şekil 4.3'te görülmektedir. Kötü huylu lezyonlarda duyarlılık (recall) değerinin yüksek olması kötü huylu olarak tahmin edilen değerlerin %89'unun gerçekten pozitif olduğunu göstermektedir.

Şekil 4.2 ve Şekil 4.3 modelimizin gerçek iyi huylu ve kötü huylu lezyonların tespitinde başarılı olduğu görülmektedir. Ağırlıklı ortalama değerleri tahmin %95, duyarlılık %94 ve f1-skoru %94 olarak elde edilmiştir.

	precision	recall	f1-score	support
0	0.90	1.00	0.94	510
1	1.00	0.89	0.94	510
accuracy			0.94	1020
macro avg	0.95	0.94	0.94	1020
weighted avg	0.95	0.94	0.94	1020

Şekil 4.3. Test verisine ait duyarlılık, tahmin ve f1-skoru değerleri

Çizelge 4.4. Temel model bazında lezyon sınıflandırma sonuçları

Parametre	ResNet	Xception	VGG16	ResNetC	VGG19	ResNet50
EB (%)	95,89	96,31	97,45	98,11	98,62	99,93
EK	0,004	0,004	0,003	0,003	0,003	0,002
DB (%)	93,20	93,9	95,04	95,64	96,42	97,28
DK	0,28	0,262	0,246	0,208	0,205	0,199
ZD	93,45	95,2	96,25	95,27	96,32	97
TVS Başarı	93,13	94,48	95,21	95,54	96,31	97,3
TVS ZD	90,08	90,47	91,62	93,37	93,83	95,06

4.4. Ablasyon Çalışması (Ablation Study)

Gürültü temizliği ve görüntü bölütleme aşamalarında geliştirdiğimiz LinkNet-RCB7 ve UNet-RCB7 modelleri için ablasyon çalışmaları yapılmıştır. Çizelge 4.5'te gürültü temizliği aşaması için, Çizelge 4.6'da ise lezyon bölütleme aşaması için yapılan ablasyon

çalışmasına ait sonuçlar yer almaktadır. Bu çizelgeler önerilen yaklaşımın başarıyı artırdığını göstermektedir.

Lezyon sınıflandırma aşaması için Çizelge 4.4'te verilen karşılaştırmalar göz önüne alınarak ablasyon çalışmasına gerek duyulmamıştır. Temel modellere orta bloğun etkisi ile başarı artışı sağlamıştır. Çizelgelerde orta blok ile ilgili olası diğer kombinasyonlar modeller arasında yapılacak olan karşılaştırma sayısını artıracak için eklenmemiştir. Karşılaştırmalarda parametreler kısaltmalarla verilmiştir (Temel Model1 (TM1): UNet, TMO1: TM1 + Orta Blok, Temel Model2 (TM2) :LinkNet, TMO2: TM2 + Orta Blok, EfficientNetB7: EB7).

Çizelge 4.5. Gürültü temizliği aşaması ablasyon çalışması

Parametre (%)	Başarı	DB	meanIoU	ZD
TM1	86,44	81,28	84,04	83,58
TMO1	87,42	83,30	84,75	84,43
TMO1+ ResNet	88,40	84,22	85,82	85,22
TMO1 + ResNetC	89,75	85,67	86,95	86,56
TMO1+ EB7	91,74	87,51	88,88	88,95
TMO1 + EB7 + ResNet	92,60	88,35	89,30	89,80
TMO1 + EB7 + ResNetC	93,91	88,76	89,88	90,17
TM2	89,24	84,47	86,33	86,24
TMO2	90,10	84,90	86,80	86,84
TMO2 + ResNet	91,05	85,61	87,40	87,50
TMO2 + ResNetC	91,94	86,02	88,30	88,05
TMO2 + EB7	93,96	88,15	89,05	90,30
TMO2 + EB7 + ResNet	94,80	89,87	90,00	91,25
TMO2 + EB7 + ResNetC	95,88	90,43	91,22	91,92

Çizelge 4.5'te ve Çizelge 4.6'da eklenen katmanlar göz önüne alındığında, en fazla başarı artışının EB7 kodlayıcısının eklenmesi ile elde edildiği görülmektedir. ResNetC ve ResNet modellerinin son katmandan önce algoritmaya eklenmesiyle oluşan başarı değerleri yine bu çizelgelerde verilmiştir. ResNetC modelinin algoritmaya eklenmesi, ResNet'e göre daha yüksek başarı artışı sağlamıştır.

Çizelge 4.6. Lezyon bölütleme aşaması ablasyon çalışması

Parametre	Başarı	DB	meanIoU	ZD
TM1	87,28	86,40	85,20	84,27
TMO1	88,30	87,55	86,25	85,30
TMO1 + ResNet	89,25	88,40	87,10	86,48
TMO1 + ResNetC	90,80	89,85	88,32	87,77
TMO1 + EB7	92,95	91,92	90,25	89,80
TMO1 + EB7 + ResNet	93,90	92,85	91,10	90,77
TMO1 + EB7 + ResNetC	95,76	93,24	93,42	93,20
TM2	91,18	89,62	89,41	89,73
TMO2	92,00	90,57	90,50	90,60
TMO2 + ResNet	92,90	91,45	91,40	91,40
TMO2 + ResNetC	94,10	92,80	92,70	92,58
TMO2+ EB7	96,05	94,77	94,65	94,65
TMO2 + EB7 + ResNet	96,94	95,25	95,40	95,35
TMO2 + EB7 + ResNetC	98,10	95,62	96,42	96,85

4.5. Karşılaştırma Sonuçları

Farklı modeller aynı veri setleri ve görüntü sayılarıyla karşılaştırıldı. Karşılaştırmalardaki veri setlerindeki görüntü ve maske sayıları veri artırma ve dilimleme olmaksızın belirtilmiştir. Sonuçlar Çizelge 4.7’de, Çizelge 4.8’de, Çizelge 4.9’da ve Çizelge 4.10’da görülmektedir. Gürültü temizliği aşamasında mevcut literatürde kullanılmış olan FCN8, UNet ve LinkNet temelli çalışmalar ile önerilen LinkNet-RCB7 ve UNet-RCB7 modelleri karşılaştırılmıştır.

Çizelge 4.7’de görüldüğü gibi 17 no’lu kaynakta belirtilen çalışma %96,88 zar doğruluğu ile önerilen modele (LinkNet-RCB7) kıyasla az farkla en başarılı model olmuştur. Fakat oluşturdukları veri seti sadece kıl gürültüsü içeren az sayıda görüntüden oluşmaktadır. Bu çalışmada gürültü temizliğinin bölütleme başarısını artırdığı belirtilmiş olup, bölütleme aşamasında %86,5 zar doğruluğu elde edilmiştir. Önerilen model ile bölütleme başarısı %96,85 zar doğruluğuna sahiptir (ÖM1: UNet-RCB7, ÖM2: LinkNet-RCB7).

ISBI International Symposium Biomedical Imaging adlı sempozyumun kısaltmasıdır. Bu sempozyumda sunulan ISIC verisetleri ISBI adıyla da kullanılabilir.

Çizelge 4.7. Gürültü temizliği aşamasında modellerin karşılaştırma sonuçları

Çalışma	Yöntem	Veri Seti	Görüntü Sayısı	ZD	Başarı
[17]	UNet	ISIC-archive	306	96,88	99,08
[25]	UNet	ISIC2018	1534	-	88,58
[28]	FCN8-ResNetC	ISIC2018	3000	-	90,30
[77]	LinkNet-B7	ISIC2018	160000	-	95,72
ÖM 1	UNet-RCB7	ISIC2018	306	94,11	95,08
ÖM 1	UNet-RCB7	ISIC2018	1500	90,17	93,91
ÖM 2	LinkNet-RCB7	ISIC2018	306	96,25	98,20
ÖM 2	LinkNet-RCB7	ISIC2018	1500	91,92	95,88

Çizelge 4.8’de ve Çizelge 4.9’da sırasıyla PH2, ISIC, ISBI veri setlerini kullanan farklı çalışmalarla önerilen modeller, lezyon bölütleme aşaması için karşılaştırılmışlardır. Çizelgelerde de görüldüğü gibi önerilen LinkNet-RCB7 diğer modellerden daha yüksek başarı değerlerine sahiptir.

Çizelge 4.8. PH2 veri seti ile lezyon bölütleme sonuçları

Çalışma	Yöntem	Veri seti	Görüntü Sayısı	ZD
[5]	K Means with Goa	PH2	2000	93,07
[22]	UNet	PH2	200	92,4
[23]	DSM	PH2	200	92,00
[26]	UNet	PH2	200	94,04
[28]	FCN8-ResNetC	PH2	200	97,10
[34]	SegNet	PH2	200	85,16
[35]	CNN	PH2	200	89,83
[77]	LinkNet-B7	PH2	200	97,42
ÖM 1	UNet-RCB7	PH2	200	95,34
ÖM 2	LinkNet-RCB7	PH2	200	97,55

Çizelge 4.9. ISIC ve ISBI veri setleri ile lezyon bölütleme sonuçları

Çalışma	Yöntem	Veri seti	Görüntü Sayısı	ZD
[5]	K Means with Goa	ISIC2018	3200	94,89
[14]	SegNet	ISBI2016	900	88,43
[22]	UNet	ISIC2017	Belirsiz	85,8
[23]	DSM	ISBI2017	2750	87,5
[25]	UNet	ISIC2018	13000	92,6
[27]	UNet	ISIC2017	Belirsiz	86,93
[28]	FCN8-ResNetC	ISIC2018	13200	96,50
[33]	FAC-Net	ISIC2018	2594	91,19
[77]	LinkNet-B7	ISIC2018	844800	96,75
ÖM 1	UNet-RCB7	ISIC2018	2594	93,25
ÖM 2	LinkNet-RCB7	ISIC2018	2594	96,87

Çizelge 4.10 sınıflandırma modelimizin diğer modellerle ISIC ve ISBI veri setleri üzerinden karşılaştırılmasına ait sonuçları içermektedir. Çalışma kapsamında geliştirilen lezyon sınıflandırma modeli yüksek başarı değerlerine sahiptir.

Çizelge 4.10. ISIC ve ISBI veri setleri ile lezyon sınıflandırma sonuçları

Çalışma	Yöntem	Veri seti	Görüntü Sayısı	Eğitim Başarısı (%)	Zar Doğruluğu (%)
[36]	DCNN	ISIC2020	10070	90,40	-
[37]	SVM	ISBI2016	900	85,19	-
[38]	MobileNetV2	ISBI2016	1279	-	83,00
[39]	DCNN	ISIC2018	10015	92,69	-
[50]	CNN-Temelli	ISIC2019	-	85,3	-
Önerilen model	ResNet50	ISIC2018	10015	95,40	93,65
Önerilen Model	ResNet50	ISIC2016	900	85,65	82,30
Önerilen Model	ResNet50	ISIC2020	10212	99,93	97,00

5. ÖNERİLEN KARAR DESTEK SİSTEMİ

Cilt kanseri görüntülerindeki gürültünün temizlenmesi, lezyonun bölütlenmesi ve sınıflandırılması için bir KDS tez çalışması kapsamında geliştirildi. Bu KDS'nin karar vericilere cilt kanseri teşhisinin karar sürecinde yardımcı olması ve teşhis süresi ve maliyeti ciddi şekilde azaltması beklenmektedir.

Bu KDS ile amacımız karar vericiler yerine karar vermek değil sadece teşhis sürecinde karar vericilere yardımcı olmaktır. KDS'nin model kısmında gürültü temizliği ve bölütleme aşamaları için en başarılı model olmasından dolayı LinkNet-RCB7, sınıflandırma aşaması için ise önerilen sınıflandırma modeli kullanılmıştır. Bu bölümde çalışma kapsamında önerilen KDS'nin temel bileşenleri açıklanmış olup, kullanımına dair detaylar verilmiştir.

5.1. Önerilen KDS'nin Bileşenleri

Önerilen KDS'de bulunan veri yönetimi, model ve arayüz bileşenleri kullanılan veri setleri ve önerilen modeller doğrultusunda bu başlık altında aktarılmıştır. Arayüz'e ait kullanım örnekleri verilmiştir.

5.1.1. Veri yönetimi

Tüm aşamalarda ISIC ve PH2'ye ait veri setleri kullanılmıştır. Bu veri kümeleri veri yönetimi bileşenini oluşturmaktadır. Gürültü temizliği, lezyon bölütleme ve lezyon sınıflandırma test veri setlerinin, önerilen KDS klasörüne eklenerek, sistemin test sürecinde karar vericiler tarafından kullanılması öngörülmüştür.

5.1.2. Model

KDS'de model bileşeninde gürültü temizliği ve lezyon bölütlemesi için geliştirilen LinkNet-RCB7 ve görüntü işleme algoritmaları, sınıflama için önerilen sınıflandırma modeli ve görüntü işleme algoritmaları yer almaktadır. Bu yapılar ile sisteme alınan görüntüler gürültülerden temizlenmekte, bölütlenmekte ve sınıflandırılmaktadır. Sınıflama iyi huylu ve kötü huylu olarak yapılmaktadır.


Önerilen KDS ile karar vericilere temizleme, bölütleme ve sınıflandırma aşamalarında seçenekler sunulmaktadır. Temizle düğmesi ile karar verici derin öğrenme ya da görüntü işleme yöntemlerini tercih edebilmektedir. Sınıflama aşamasında ise bölütlü ve bölütsüz verilerle eğitilmiş iki ayrı model kullanılmaktadır. Karar vericinin tercihinine göre bölütlü ya da bölütsüz seçimi yapılarak sınıflama sonucu öğrenilebilmektedir.

Önerilen KDS’de karar verici seçenek üzerinde değişiklik yapmadığı takdirde varsayılan senaryoda temizleme ve bölütleme aşamaları “Derin Öğrenme ile”, sınıflama aşaması ise bölütlü model ile gerçekleştirilmektedir. KDS’nin gürültü temizliği ve bölütleme aşamalarında model bileşeninde LinkNet-RCB7 yer almaktadır. Sınıflandırma aşamasında ise önerilen sınıflama modeli kullanılmıştır.

5.1.3. Grafiksel kullanıcı arayüzü (GUI)


Modelimizde kullanıcı arayüzü geliştirmek için Tkinter üçüncü parti yazılımını kullandık. Python kullanıcılara hali hazırda arayüz desteği sunmamaktadır. Bu noktada üçüncü parti yazılımların desteğiyle arayüzler oluşturulabilmektedir. Fakat bazı kısıtlar söz konusudur. Derin öğrenme ve görüntü işleme algoritmaları çok sayıda model ve kütüphanenin yüklü olmasını gerektirmekte, bu durum da oluşturulan arayüzün hem boyutunu artırmakta hem de platform bağımsız çalışabilmesini zorlaştırmaktadır.

Önerilen KDS’nin model bileşeninde toplam 3 adet model ve ağırlıkları yer almaktadır. Sistem, kullanıcı kullanımını kolaylaştırmak için basit bir arayüz tasarımına sahiptir. Beş düğme ile tüm aşamalar kontrol edilebilmektedir. KDS’ye ait genel görünüm Resim 5.1’de görülmektedir.




Resim 5.1. KDS başlangıç ekranı

Önerilen KDS için kullanılan düğmeler işlevleriyle birlikte örnek bir senaryo üzerinden verilmiştir. *YÜKLE* düğmesi karar vericilerin jpeg, jpg, bmp ve png gibi farklı formatlardaki görüntüleri seçmesine olanak tanır. Burada okunan görüntüdeki dosya uzantısı kaldırılmıştır. Daha sonra pillow kütüphanesinde yer alan Image.open fonksiyonu ile görüntüler okunmuştur. Bu sayede görüntü formatından bağımsız olarak görüntülerin sisteme alınması sağlanabilmektedir. Resim 5.2’de “YÜKLE” düğmesinin çalışması görülmektedir.




Resim 5.2. KDS YÜKLE işlevi

Seçim işleminden sonra seçilen görüntü sistemde gösterilmektedir. Resim 5.3'te kıl gürültüsü içeren bir görüntü seçildikten sonra oluşan KDS ekranı görülmektedir.




Resim 5.3. KDS seçilmiş görüntü

TEMİZLE düğmesi ile karar verici lezyon görüntülerindeki gürültüyü kaldırabilecektir. Bu aşamada karar verici açılır menü üzerinden “Derin Öğrenme ile” ve “Görüntü İşleme ile” seçeneklerini seçerek işlem yapabilmektedir. Resim 5.4’te “Derin Öğrenme ile” seçeneği seçilmiş ve gürültü temizliği yapılmıştır. Sonuç yine sistem üzerinde ve “Rapor” klasörü altında karar vericiye sunulmaktadır. Rapor klasörü altında seçilen görüntünün adıyla yeni bir klasör oluşturulmaktadır. Burada seçilen orijinal görüntünün yanında karar vericinin yaptığı işleme ait sonuçlar yer almaktadır.




Resim 5.4. KDS ile temizlenmiş görüntü

BÖLÜTLE düğmesi ile karar verici temizlenmiş bir görüntüyü “YÜKLE” düğmesiyle seçtikten sonra “BÖLÜTLE” düğmesine basarak bölütleme işlemini gerçekleştirmektedir. Bu senaryoda “Derin Öğrenme ile” seçeneği seçilerek bölütleme işlemi yapılmıştır. Elde edilen sonuç Resim 5.5’te görülmektedir.



Resim 5.5. KDS ile bölütlenmiş görüntü

SINIFLA düğmesi bölütlü/bölütsüz bir görüntünün “YÜKLE” düğmesiyle seçilmesinde sonra lezyon sınıflandırma işlemini gerçekleştirmektedir. Karar vericilere bu aşamada bölütlü ya da bölütsüz seçenekleri açılır menü üzerinden sunulmaktadır. Kullanıcı bölütlü seçeneğini seçtiğinde bölütlü ve gürültüsüz görüntülerle eğitimi tamamlanmış model kullanılmaktadır. Aynı şekilde bölütsüz seçeneği seçildiğinde bölütsüz ve gürültüsüz görüntülerle eğitilmiş model KDS’nin model bileşeninde kullanılmış olmaktadır. Örnek sınıflama sonucu Resim 5.6’da görülmektedir.




Resim 5.6. KDS ile sınıflandırılmış görüntü

TÜM_AŞAMA düğmesi işlevini kullanabilmek için karar vericinin gürültülü bir görüntü seçmesi beklenmektedir. “YÜKLE” düğmesiyle görüntü seçildikten sonra bu düğmeye basılabilir. Bu düğmeye basıldığında görüntü üzerindeki gürültü temizlenecek, temizlenen görüntü bölütlenecek ve bölütlenmiş görüntü sınıflandırılacaktır. Bu işlevde karar vericiden tek tek “derin öğrenme ile”, “görüntü işleme ile”, “bölütlü”, “bölütsüz” seçeneklerini seçmesi beklenmemekte ve bu seçimler sunulmamaktadır. Karar vericilere gürültü temizliği ve bölütleme aşamalarında “Derin Öğrenme ile”, “Görüntü işleme ile”, sınıflama aşamasında “Bölütlü”, “Bölütsüz” seçeneklerini seçme olanağı sunulmaktadır. Ayrıca karar verici isterse her aşamada gürültülü/gürültüsüz, bölütülü/bölütsüz görüntüleri de seçebilmektedir. Çünkü gürültü temizliği ve/veya bölütleme aşamalarında hatalı sonuçlar oluşabilir ve bu durum lezyon sınıflandırma başarısını olumsuz etkileyebilir. Karar vericilere, önceki aşamaların hatalı olduğunu düşünmeleri durumunda seçim şansı sunulmaktadır. Bu durum aslında KDS’lerin temel özelliğidir. KDS’ler karar vericilere

mevcut seçenekler arasında seçim imkânı sunulmaktadır. Özetle, bir karar verici şunları yapabilir:

1. YÜKLE düğmesiyle, gürültülü/gürültüsüz ve/veya bölütlü/bölütsüz görüntü seçilebilir.
2. TEMİZLE düğmesiyle görüntüdeki gürültüler temizlenebilir.
3. BÖLÜTLE düğmesiyle gürültülü/gürültüsüz görüntüler seçilerek bölütlenebilir.
4. SINIFLA düğmesiyle gürültülü/gürültüsüz ve/veya bölütlü/bölütsüz lezyonlar sınıflandırılabilir.
5. Karar vericiler görüntüyü seçip herhangi bir aşama için işlem yaptığında, görüntü adıyla aynı isimde bir klasör rapor klasörü altında oluşturulmaktadır.

Karar vericiler KDS üzerinden görüntü temizliği, lezyon bölütleme veya tüm aşama işlemlerinden herhangi birini gerçekleştirdiğinde, seçilmiş görüntüyle aynı isimli klasörde üç adet görüntüyü ve bir adet csv dosyasını rapor halinde bulabilirler. Bu görüntüler; orijinal görüntü, gürültüsüz görüntü ve bölütlenmiş görüntü şeklindedir. Karar vericilere sunulan sınıflama sonucuyla birlikte, bu görüntüler üzerinden karar desteği sağlanmıştır. Seçilen görüntüye ait dosya ismi ve lezyon sınıflandırma sonucu csv uzantılı bir dosyaya atılmakta ve bu şekilde sonuçları içeren bir veri tabanı da oluşturulmuş olmaktadır. KDS’de hasta mahremiyeti düşünülerek isimler alınmamaktadır. Karar vericiler için bu veri tabanı bir rapor olarak işlev görecektir. Resim 5.7’de Rapor klasöründen bir görüntü yer almaktadır.




Resim 5.7. Rapor klasörü

6. SONUÇ VE ÖNERİLER

Cilt kanseri teşhisi için mevcut literatürde derin öğrenme ve görüntü işleme algoritmalarını içeren bir KDS olmadığı görülmüştür. Çalışma kapsamında gürültü giderme, lezyon bölütleme ve sınıflandırma aşamalarını içeren bir KDS geliştirilmiştir. Önerilen KDS ile gürültüsü temizlenmiş ve bölütlenmiş görüntüler üzerinden karar vericiler daha doğru sınıflama yapabilirler. KDS'nin gürültü temizleme ve lezyon bölütleme aşamalarında önerilen LinkNet-RCB7 en yüksek başarı değerlerine sahip model olduğu için tercih edilmiştir. Bu modelin yüksek başarı göstermesinde EfficientNetB7'nin kodlayıcı olarak kullanılması etkili olmuştur. EfficientNet türevlerinin kodlayıcı olarak kullanıldığı modeller mevcut olmakla birlikte cilt kanseri teşhisi çalışmalarında LinkNet ile EfficientNetB7'nin kodlayıcı olarak kullanıldığı bir KDS'nin henüz yer almadığı görülmüştür.


Önerilen KDS ile kullanıcılara gürültü temizliği, lezyon bölütleme ve lezyon sınıflandırma aşamalarında farklı yöntem seçenekleri sunulmuştur. Kullanıcıya varsayılan olarak sunulan ilk seçenekler en yüksek başarıyı göstermektedirler. Bu noktada amaç karar vericiler tarafından bu seçenekler denenerek sonuçların karşılaştırılabilmesidir. Çalışma sonucunda gürültü temizliği ve lezyon bölütleme aşamalarında görüntü işleme algoritmalarının tek başına yeterli olmadığı görülmüştür.

Literatür çalışmalarında da görüldüğü gibi özellikle gürültü temizliği aşamasının, lezyonun doğru bölütlenmesinin başarısında etkili olduğu görülmüştür. Gürültülü verilerle yapılan eğitimde başarının yaklaşık %1 oranında düştüğü literatür taramasında ve elde edilen sonuçlarda yer almaktadır. Bölütleme modeline, gürültülü görüntüler verildiğinde bölütleme başarısının düştüğü Resim 6.1'de görülmektedir ((a) gürültülü görüntü, (b), (d) tahmin edilen maske, (c) temizlenmiş görüntü). Gürültü temizliğinin başarısız olması durumunda lezyon görüntülerinde veri kayıpları yaşanabilir. Bu durum bölütleme ve sınıflama başarısını olumsuz etkileyecektir. Bu yüzden karar verici gürültü temizliğinin hatalı olması durumunda bölütleme ve sınıflama aşamalarında gürültülü görüntüyü seçebilecektir.



Resim 6.1. Kıl gürültüsünün bölütlemeye etkisi


Bölütlenmemiş görüntüler eğitimde kullanıldığında başarının düştüğü görülmektedir. Bölütlenmemiş görüntü ile yapılan sınıflandırmada başarının daha düşük olmasının nedeni; lezyonun görüntüdeki alanının küçülmesi ve temizlenememiş gürültülerdir (parlaklık, kıl gürültüsü vb) [37]. Bölütleme işleminde Resim 6.2’de görüldüğü gibi tahmin edilen alanın doğru olmamasından kaynaklı hatalar ortaya çıkabilir. Bu durum bölütleme ve sınıflama işlemlerinin başarısını düşürecektir. Bu aşamada karar verici isteğe bağlı olarak bölütleme işlemini geçerek, gürültüsüz görüntü ve bu görüntü ile yapılacak sınıflandırma sonucuna göre karar verebilir ((a) orijinal görüntü, (b) maske, (c) tahmin edilen maske).



Resim 6.2. Başarısız bölütleme örnekleri A

Bölütleme aşamasında esas sorun bölütlemenin Resim 6.3’te görüldüğü gibi yanlış yapıldığı örneklerdir. Birinci örnekte parlaklık, ikincide lezyon üzerinde kontrast farkı, üçüncüde ise kontrast farkının az oluşu hatanın olası nedenleridir. Bu durumda eğer karar

vericiye yanlış bölütlenmiş görüntü üzerinden sınıflama sonucunu sunmuş olsaydık muhtemeldir ki kararı olumsuz etkilemiş olacaktık. Bu yüzden önerilen KDS’de bölütlü ve bölütsüz görüntülerin sınıflama aşamasında seçilmesi önem teşkil etmektedir ((a) orijinal görüntü, (b) maske, (c) tahmin edilen maske). Gürültü temizliği ve bölütleme aşamaları doğru olduğunda karar vericinin gürültüsüz ve bölütlenmiş verileri seçmesi başarıyı artırmaktadır. Buna karşın bu aşamalarda hata görüldüğünde gürültüsüz veya bölütlü görüntüleri seçmek sonucun tamamen yanlış olmasıyla sonuçlanabilmektedir. Bu yüzden karar vericilere seçimler sunulması önemli hale gelmektedir. KDS’lerin temelinde karar verici yerine karar vermek yoktur. Bu durum düşünüldüğünde karar vericiye sunulan gürültülü/gürültüsüz, bölütlü/bölütsüz görüntüler sınıflama sonucunun verilmesinden daha fazla öneme sahip olacaktır.




Resim 6.3. Başarısız bölütleme örnekleri B

Sınıflama aşaması için ResNet50 ile desteklenen bir model önerilmiştir. Literatüre bakıldığında bazı cilt kanseri türlerinin zamanla kötü huylu olabildiği görülmektedir. Karar vericilere daha net ve sade bir destek sağlanması adına sınıflama işleminde lezyonlar iyi huylu ve kötü huylu olmak üzere iki sınıfa ayrılmışlardır. Önerilen KDS ile önemli olan lezyonu gürültüden temizleyerek, görüntüden ayırıp hekimlere yardımcı olmaktır. Sınıflandırma aşamasındaki başarının farklı algoritmalar denenerek artırılabilmesi olasıdır. KDS için kullanılan arayüz, Tkinter kütüphanesi kullanılarak tasarlanmıştır. KDS’nin çalışabilmesi için kullanılacağı sistemde bütün kütüphanelerin ve model yapılarının

yüklenmiş olması, ayrıca donanım seviyesinin yüksek olması (özellikle ekran kartı ve ram) gerekmektedir. Web tabanlı arayüz kullanan KDS'lerdeki temel avantaj verilerin sayısal olması ve sade model yapılarından kaynaklanmaktadır. İleriki çalışmalarda modeller ve kullanılan kütüphaneleri destekleyen hızlı sunucular üzerinden KDS için web tabanlı bir arayüz oluşturulabilir.

Çalışma sürecinde karşılaşılan en büyük kısıt ekran kartı başta olmak üzere donanımsal düzeyde yaşanmıştır. Örneğin lezyon sınıflandırmada Çizelge 4.4'de görülen modeller kullanıldığında epok zamanları sırasıyla ResNet ile 52 sn, ResNetC ile 93 sn, ResNet50 ile 213 sn, Xceptiton ile 340 sn, VGG16 ile 194 sn, VGG19 ile 198 sn olmaktadır. Modelin katman ve parametre sayısı arttıkça eğitim süresi de uzamaktadır. Bu durum KDS'nin kullanımında tepki süresini olumsuz etkilemektedir. Bu yüzden daha iyi bir donanım kombinasyonu ile KDS'nin hızı artırılabilir.

Gürültü temizliği, lezyon bölütleme ve lezyonun sınıflandırılması aşamalarındaki eğitim başarıları ve eğitim kaybının epoklar boyunca değişimini görebilmek için tüm aşamalarda modeller 250 epok koşturulmuştur. En hızlı öğrenme sınıflama aşamasında görülmüştür. Bu durumun temel sebebi modelin daha sade oluşu ve bu aşamada diğer aşamaların aksine hem gürültüsüz hem de bölütlenmiş verilerin kullanılıyor olmasıdır. Modellerdeki parametre ve epok sayıları artırılarak başarı artışı sağlanabilir. Ayrıca gürültü temizliği aşaması için daha farklı gürültü türlerini içeren daha büyük bir veri setiyle çalışılabilir. Şekil 6.1'de eğitim aşamalarına ait grafikler yer almaktadır. KDS'nin model bileşeninde gürültü temizliği için kullanılan LinkNet-RCB7, gürültüsüz verilerle eğitilen bölütleme modeli LinkNet-RCB7 ve gürültüsüz ve bölütlü verilerle eğitilen önerilen sınıflandırma modeli olmak üzere üç model yer almaktadır. Gürültülü ve bölütsüz verilerle yapılan eğitimlere dördüncü bölümde verilmiştir. Bu modeller çok fazla kombinasyona yol açacağı ve sistemi yavaşlatacağı için KDS'ye eklenmemiştir.



Şekil 6.1. Tüm aşamalar için eğitim grafikleri

KAYNAKLAR

1. Sucu, M. (2020). Karar Destek Sistemleri ve İş Zekası Uygulamalarının İşletmeler Açısından Önemi: Bir Literatür Araştırması, *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 44, 261-283.
2. Dönerçark, M. ve Tecim, V. (2020), Kurumsal Karar Destek Sistemlerinde Yapay Zekâ Kullanımı: Tasarım ve Uygulama. *Yönetim Bilişim Sistemleri Dergisi*, 6(2), 77-103.
3. Özata, M. ve Aslan, Ş. (2004), Klinik Karar Destek Sistemleri ve Örnek Uygulamalar. *Kocatepe Tıp Dergisi*, 5, 11-17.
4. Baykara, O. T. (2016). Current Modalities in Treatment of Cancer. *Balıkesir Health Sci. Journal*, 5, 154–165.
5. Thapar, P., Rakhra, M., Cazzato, G., and Hossain, S. (2022). A Novel Hybrid Deep Learning Approach for Skin Lesion Segmentation and Classification. *Hindawi Journal of Healthcare Engineering*, 2022, 1-21.
6. Siegel, R. L., Miller, K. D., Fuchs, H. E., and Jemal, A. (2021). *Cancer statistics. CA: A Cancer Journal of Clinicians*, 71(1), 7-33.
7. Ünver, H. M. and Ayan, E. (2019). Skin Lesion Segmentation in Dermoscopic Images with Combination of YOLO and GrabCut Algorithm. *Diagnostics Journal*, 9(3), 1-21.
8. Kumar, A. and Vatsa, A. (2022). Untangling Classification Methods for Melanom Skin Cancer. *Front. Big Data*, 5, 1-11.
9. Kahia, M., Echtioui, A., Kallel, F., and Hamida, A. B. (2022, October). *Skin Cancer Classification using Deep Learning Models*. Paper presented at International Conference on Agents and Artificial Intelligence, Vienna, Austria.
10. Alfi, I. A., Rahman, M., Shorfuzzaman, M., and Nazir, A. (2022). A Non-Invasive Interpretable Diagnosis of Melanom Skin Cancer Using Deep Learning and Ensemble Stacking of Machine Learning Models. *MDPI Diagnostic*, 12(3), 1-18.
11. Arif, M., Philip, F. M., Ajesh, F., Izdrui, D., Craciun, M. D., and Geman, O. (2022). Automated Detection of Nonmelanom Skin Cancer Based on Deep Convolutional Neural Network. *Hindawi Journal of Healthcare Engineering*, 2022, 1-15.
12. Gillmann, C. Saur, D., Wischgoll, T., and Scheuermann, G, (2021). Uncertainty-aware Visualization in Medical Imaging A Survey. *Computer Graphics Forum*, 40(3), 665–689.
13. Kumar, S., Sathyadevi, G., and Sivanesh, S. (2011). Decision Support System for Medical Diagnosis Using Data Mining. *IJCSI International Journal of Computer Science Issues*, 8(3), 147-153.

14. Şahin, N. ve Alpaslan, N. (2020). Seg-Net Mimarisi Kullanılarak Cilt Lezyon Bölütleme Performansının İyileştirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, special issue, 40-45.
15. Ali, K., Shaikh, Z. A., Khan, A. A., and Laghari, A. A. (2022). Multiclass skin cancer classification using EfficientNets—A first step towards preventing skin cancer. *Artif. Intell. Brain Inform.* 2(4), 1–10.
16. Cassidy, B., Kendrick, C., Brodzicki, A., Jaworek-Korjakowska, J., and Yap, M. H. (2022). Analysis of the ISIC image datasets: Usage benchmarks and recommendations. *Med. Image Anal.*, 75, 1–15.
17. Li, W., Raj, A. N. J., Tjahjadi, T., and Zhuang, Z. (2021). Digital hair removal by deep learning for skin lesion segmentation. *Pattern Recognition*, 117, 1-15.
18. Talavera-Martínez, L., Bibiloni, P., and González-Hidalgo, M. (2020). Hair Segmentation and Removal in Dermoscopic Images Using Deep Learning. *IEEE Access*, 9, 2694–2704.
19. Tan, M. and Le, Q. V. (2019, June). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks*. Paper presented at the 36th International Conference on Machine Learning, California, USA.
20. Baheti, B., Innani, S., Gajre, S., and Talbar, S. (2020, June). *Eff-U-Net: A Novel Architecture for Semantic Segmentation in Unstructured Environment*. Paper presented at IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, Seattle, USA.
21. Wang, J., Zhang, X., Lv, P., Zhou, L., and Wang, H. (2021). EAR-U-Net: EfficientNet and attention-based residual U-Net for automatic liver segmentation in CT. *ArXiv Journal*, abs/2110.01014, 1-26.
22. Zafar, K., Gilani, S.O., Waris, A., Ahmed, A., Jamil, M., Khan, M. N., and Kashif, A. S. (2020). Skin Lesion Segmentation from Dermoscopic Images Using Convolutional Neural Network. *Sensor Journal*, 20(6), 1-14.
23. Zhang, G., Shen, X., Chen, S., Liang, L., Luo, Y., Yu, J., and Lu, J. (2019). DSM: A Deep Supervised Multi-Scale Network Learning for Skin Cancer Segmentation. *IEEE Access*, 7, 1-10.
24. Hasan, K., Dahal, L., Samarakoon, P. N., Tushara, F. I., and Marti, M. R. (2020). DSNet: Automatic Dermoscopic Skin Lesion Segmentation. *Computers in biology and medicine*, 120, 426-434.
25. Akyel, C. and Arıcı, N. (2020). A New Approach to Hair Noise Cleaning and Lesion Segmentation in Images of Skin Cancer. *Journal of Polytechnic*, 23(3), 821-828.
26. Phan, T., Kim, S., Yang, H., and Lee, G. (2021). Skin Lesion Segmentation by U-Net with Adaptive Skip Connection and Structural Awareness. *Applied sciences*, 11(10), 1-14.

27. Tang, P., Liang, Q., Xintong, Y., Xiang, S., Sun, W., Coppola, G., and Zhang, D. (2019). Efficient skin lesion segmentation using separable-U-Net with stochastic weight averaging. *ELSEIVER Computer Methods and Programs in Biomedicine*, 178, 289–301.
28. Akyel, C. and Arıcı, N. (2022). Hair Removal and Lesion Segmentation with FCN8-ResNetC and Image Processing in Images of Skin Cancer. *Journal of Information Technologies*, 15(2), 231-238.
29. Chaurasia, A. and Culurciello, E. (2017, December). *LinkNet: Exploiting The encoder Representations for Efficient Semantic Segmentation*. Paper presented at the IEEE Visual Communications and Image Processing (VCIP), St. Petersburg, FL, USA.
30. Mohamed, M. Y. N., Kallam, S., Kumar, M. S., Natarajan, V. A., and Patan, R. (2020, November). *Segmentation of Nuclei in Histopathology Images Using Fully Convolutional Deep Neural Architecture*. Paper presented at the 2020 International Conference on Computing and Information Technology (ICCIT-1441), Tabuk, Saudi Arabia.
31. Zhou, L., Zhang, C., and Wu, M. (2018, June). *D-LinkNet with Pretrained The encoder and Dilated Convolution for Resolution Satellite Imagery Road Extraction*. Paper presented at the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Salt Lake City, UT, USA.
32. Xiong, W., Jia, X., Yang, D., Ai, M., Li, L., and Wang, S. (2021). DP-LinkNet: A convolutional network for historical document image binarization. *Ksii Trans. Internet Inf. Syst.* 15(5), 1778–1797.
33. Dong, Y., Wang, L., Cheng, S., and Li, Y. (2021). FAC-Net: Feedback Attention Network Based on Context Encoder Network for Skin Lesion Segmentation. *Sensor Journal*, 21(15), 1-17.
34. Brahmbhatt, P. and Rajan, S. N. (2019). Skin Lesion Segmentation using Seg-Net with Binary CrossEntropy. *Vivechan International Journal of Research*, 10(2), 22-31.
35. Bagheri, F., Tarokh, M. J., and Ziaratban, M. (2021). Skin lesion segmentation based on mask RCNN, Multi Atrous Full-CNN and A Geodesic Method. *International Journal of Imaging Systems and Technology*, 31(3), 1609-1624.
36. Kaur, R., Gholamhosseini, H., Sinha, R., and Lindén, M. (2022). Melanom Classification Using a Novel Deep Convolutional Neural Network with Dermoscopic Images. *Sensors*, 22(3), 1-15.
37. Suresh, A. and Seeja, R. (2019). Deep Learning Based Skin Lesion Segmentation and Classification of Melanom Using Support Vector Machine (SVM). *Asian Pacific Journal of Cancer Prevention*, 20(5), 1555-1561.
38. Indraswari, R., Rokhana, R., and Herulambang, W. (2022). Melanom image classification based on MobileNetV2 network. *Procedia Computer Science*, 197, 198–207.

39. Ali, S., Islam, K., Haque, J., Miah, S., and Rahman, M. (2021). An enhanced technique of skin cancer classification using deep convolutional neural network with transfer learning models. *Machine Learning with Applications*, 5, 1-8.
40. Kausar, N., Hameed, A., Sattar, M., Ashraf, R., Imran, A. S., Abidin, M. Z., and Ali, A. (2021). Multiclass Skin Cancer Classification Using Ensemble of Fine-Tuned Deep Learning Models. *Applied Sciences*, 11, 1-20.
41. Ucuza, H. (2020). *Yapay Zekâyâ Dayalı Anlamsal Video İşleme Yöntemlerinin Tıpta Kullanılabilirliğinin Araştırılması*. Yayınlanmamış Yüksek Lisans Tezi, İnönü Üniversitesi Sağlık Bilimleri Enstitüsü, Malatya.
42. Todd, J., Gepp, A., Stern S., and Vanstone, B. J. (2022). Improving decision making in the management of hospital readmissions using modern survival analysis techniques. *Decision Support Systems*, 156(2), 1-35.
43. Çakmak, I. (2017). *Makine Öğrenmesi Yöntemleriyle Tümör Kontrol Olasılığının Hesaplanması*. Yayınlanmamış Yüksek Lisans Tezi, KTÜ, Sağlık Bilimleri Enstitüsü, Trabzon.
44. Çorapçıoğlu, M. E. (2006). *TIPÇIT: Tıbbi Karar Destek Sistemi Çekirdeği*. Yayınlanmamış Yüksek Lisans Tezi, Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
45. Tsoukalas, A., Albertson, T., and Tagkopoulos, I. (2015). From Data to Optimal Decision Making: A Data-Driven, Probabilistic Machine Learning Approach to Decision Support for Patients With Sepsis. *Jmir Medical Informatics Journal*, 3(1), 1-15.
46. Podzraj, P. (2019, Aug). *A brief demonstration of some Python GUI libraries*. Paper presented at the 8th International Conference on Informatics and Applications ICIA2019, Takamatsu, Japan.
47. Atay, C. ve Demir, E. (2017). Akciğer Kanseri Verilerinin Karar Destek Sistemleri için Veri Ambarında Saklanması. *Dokuz Eylül Üniversitesi-Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 19(57), 987-997.
48. Kuru, K. ve Tunca, Y. (2011, Kasım). *Genetik Faktörlerden Kaynaklanan Dismorfik Hastalıkların Ön Tanısının Etkin Olarak Konulabilmesi İçin Tanısal Karar Destek Sistemlerinin Geliştirilmesi*. VIII. Ulusal Tıp Bilişimi Kongresinde sunuldu, Belek, Antalya.
49. Özel, D. (2010). *Yoğun Bakımda Hastaların Kabulü, Tanı ve Tedavi Süreçleri için Karar Desteği Sağlayan Web-Tabanlı Klinik Rehber Geliştirilmesi*. Yayınlanmamış Yüksek Lisans Tezi, Akdeniz Üniversitesi Sağlık Bilimleri Enstitüsü, Antalya.
50. Khan, M. A., Akram, T., Sharif, M., Kadry, S., and Nam, Y. (2021) Computer Decision Support System for Skin Cancer Localization and Classification. *Computers, Materials & Continua*, 68(1), 1043-1064.

51. Urban, K., Mehrmal, S., Uppal, P., Giese, R. L., and Delost, G. R. (2021). The global burden of skin cancer: A longitudinal analysis from the Global Burden of Disease Study, 1990-2017. *Jaad International Journal*, 2, 98-108.
52. L'opez, A. (2017). *Skin Lesion Detection From Dermoscopic Images Using Convolutional Neural Networks*. Unpublished Degree Thesis, Barcelona Technical University Telecommunication Faculty, Barcelona.
53. Zhang, C., Zhu, X., Hou, S., Pan, W., and Liao, W. (2022). Functionalization of Nanomaterials for Skin Cancer Theranostics. *Frontiers in bioengineering and biotechnology*, 10, 1-12.
54. Sümen, A. (2014). *Denizcilik Lisesi Öğrencilerine Cilt Kanseri Konusunda Verilen Eğitimin Bilgi ve Davranışlarına Etkisi*. Yayımlanmamış Yüksek Lisans Tezi, Akdeniz Üniversitesi Sağlık Bilimleri Enstitüsü, Antalya.
55. Kızılbey, K. and Akdeste, Z. M. (2013). Melanom Cancer. *Journal of Engineering and Natural Sciences*, 31(4), 555-569.
56. Kassem, A. (2016). *Segmentation of Skin Cancer By Using Image Processing Techniques*. Unpublished Master's Thesis, Yıldız Technical University Department Of Computer Engineering, İstanbul.
57. Reinehr C. P. H. and Bakos R. M. (2019). Actinic keratoses: review of clinical, dermoscopic, and therapeutic aspects. *An Bras Dermatol*, 94(6), 637-657.
58. Yavuz, G. Ö. ve Yavuz, İ. H.. (2014). Melanotisitk Nevüsler. *Van Tıp Dergisi*, 21(4), 259-268.
59. Argenziano G, Zalaudek I, Sera, F., Cicale, G., Ruocco, E., Hofmann-Wellenhof, R., Soyer, P., and Corona R. (2004). Vascular Structures in Skin Tumors: A Dermoscopy Study. *Arch Dermatol*. 140(12), 1485–1489.
60. An, İ., Uçmak, D., İbiloğlu, İ., ve Öztürk, M. (2018). Plaque with asymptomatic verrucous surface on the right leg: Dermatofibroma. *Archives of Clinical and Experimental Medicine*, 3(2), 111-113.
61. Salehi, H. and Burgueno, R. (2018). Emerging artificial intelligence methods in structural engineering. *Engineering Structures*, 171, 170-189.
62. Sarker, I. H. (2022). AI-Based Modeling: Techniques, Applications and Research Issues Towards Automation. *Intelligent and Smart Systems*, 3(158), 1-6.
63. Sarker I. H. (2021). Machine learning: algorithms, real-world applications and research directions. *SN Comput Sci.*, 2(3), 159.
64. Alafi, B. (2019). Artificial Intelligence And Deep Learning Methodologies. *The Journal Of Cognitive Systems*, 4(2), 57-61.
65. Çelik, Ö. and Altunaydın, S. S. (2018). A Research on Machine Learning Methods and Its Applications. *Journal of Educational Technology & Online Learning (JETOL)*, 1(3), 25-40.

66. Gazel, S. ve Bati, C. T. (2019). Derin Sinir Ağları ile En iyi Modelin Belirlenmesi: Mantar Verileri üzerine Keras Uygulamaları. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 29(3), 406-417.
67. Jadon, S. (2020, October). *A survey of loss functions for semantic segmentation*. Paper presented at IEEE 2020 Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB), Virtual Conference.
68. Khan, A., Sohail, A., Zahoor, U., and Qureshi, S. A. (2020). A Survey of the Recent Architectures of Deep Convolutional Neural Networks. *Artif Intell Rev*, 53, 5455–5516.
69. Bezdan, T. and Džakula, N. B. (2019, April). *Convolutional Neural Network Layers And Architectures*. Paper presented at International Scientific Conference On Information Technology And Data Related Research, Beograd, Serbia.
70. Doğan, F. and Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*, 10(2), 414-416.
71. Varatharasan, V., Shin, H., Tsourdos, A., and Colosimo, N. (2019, November). *Improving Learning Effectiveness For Object Detection and Classification in Cluttered Backgrounds*. Paper presented at Workshop on Research, Education and Development of Unmanned Aerial Systems (RED-UAS), Cranfield, UK.
72. Ronneberger, O., Fischer, P., and Brox, T. (2015, October). *U-Net: Convolutional Networks for Biomedical Image Segmentation Olaf Ronneberger*. Paper presented at MICCAI 2015, Munich, Germany.
73. Zhou, Z., Siddiquee, M. R., Tajbakhsh, N., and Liang, J. (2018, September). *UNet++: A Nested U-Net Architecture for Medical Image Segmentation*. Paper presented at Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, Granada, Spain.
74. Darrell T., Shelhamer, E., and Long, J. (2015, June). *Fully Convolutional Networks for Semantic Segmentation*. Paper presented at 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, USA.
75. Ning, H., Wang, C., Li, Z., and Yang, L. (2020). Choosing an appropriate training set size when using existing data to train neural networks for land cover segmentation. *Annals of GIS*, 26(4), 329-335.
76. Ali, L., Alnajjar, F., Jassmi, H. A., Gocho, M., Khan, W., Serhani, A. (2021). Performance Evaluation of Deep CNN-Based Crack Detection and Localization Techniques for Concrete Structures. *Sensors Journal*, 21(5), 8-9.
77. Akyel C and Arıcı N. (2022). LinkNet-B7: Noise Removal and Lesion Segmentation in Images of Skin Cancer. *Mathematics*. 10(5),736- 751.
78. Setiawan, W. and Damayanti, F. (2020). Layers Modification of Convolutional Neural Network for Pneumonia Detection and Fitri Damayanti. *Journal of Physics: Conference Series*, 1477, 1-4.

79. Tschandl, P., Rosendahl, C., and Kittler, H. (2018). The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Sci. Data*, 14(5), 1-9.
80. Boyraz, Ö. F. (2015). *Mobil Damar Görüntüleme Cihazı Tasarımı*. Yayımlanmamış Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
81. Codella, N., Rotemberg, V., Tschandl, P., Celebi, M. E., Dusza, S., Gutman, D., Helba, B., Kalloo, A., Liopyris, K., Marchetti, M., Kittler, H., and Halpern, A. (2018, April). *Skin Lesion Analysis Toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration (ISIC)*. Paper presented at 15 th IEEE International Symposium on Biomedical Imaging, Washington, USA.
82. Mendonça, T., Marçal, A. R. S., Marques, J. S., and Rozeira, J. (2013, July). *PH2 - A dermoscopic image database for research and benchmarking*. Paper presented at Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2013 IEEE Engineering in Medicine and Biology Society, Osaka, Japan.
83. Rotemberg, V., Kurtansky, N., Betz-Stablein, B., Caffery, L., Chousakos, E., Codella, N., Combalia, M., Dusza, S., Guitera, P., Gutman, D., Halpern, A., Helba, B., Kittler, H., Kose, K., Langer, S., Lioprys, K., Malvey, J., Musthaq, S., Nanda, J., Reiter, O., Shih, G., Stratigos, A., Tschandl, P., Weber, J., and Soyer, P. (2021). A patient-centric dataset of images and metadata for identifying melanomas using clinical context. *Sci Data*, 34(8), 1-8.
84. Nieradzick, L., Scheuermann, G., Saur, D., and Gillmann, C. (2021). Effect of the output activation function on the probabilities and errors in medical image segmentation. *ArXiv Journal*, abs/2109.00903, 1-27.
85. Fang, T., Wang, B., Zhang, J., and Chen, P. (2020). Crop leaf disease grade identification based on an improved convolutional neural network. *Journal of Electronic Imaging*, 29(1), 11-12.
86. Chen, F. H., Guokui N., and Tiantian Y. (2020). Deep Residual Learning for Nonlinear Regression Dongwei. *Entropy journal*, 22(2), 1-22.
87. Fan, Z., Lin, H., Li, C., Su, J., Bruno, S., and Loprencipe, L. (2022). Use of Parallel ResNet for High-Performance Pavement Crack Detection and Measurement. *Sustainability Journal*, 14(3), 1-21.
88. Shamim, S., Awan, M. J., Zain, A. M., Naseem, U., Mohammed, M. A., and Garcia-Zapirain, B. (2022). Automatic COVID-19 Lung Infection Segmentation through Modified U-Net Model. *Journal of Healthcare Engineering*, 2022, 1-13.
89. Hansen, B. E. (2015). The Integrated Mean Squared Error Of Series Regression and A Rosenthal Hilbert-Space Inequality. *Econometric Theory*, 31(2), 337-361.
90. Savioli, N., Montana, G., and Lamata, P. (2019, February). *V-FCNN: Volumetric Fully Convolution Neural Network For Automatic Atrial Segmentation*. Paper presented at International Workshop on Statistical Atlases and Computational Models of the Heart, Granada, Spain.

91. Loshchilov, I., and Hutter, F. (2019, May). *Decoupled Weight Decay Regularization*. Paper presented at ICLR 2019 Conference, New Orleans, USA.
92. Padilla, R., Netto, S. L., and Da Silva, E. A. B. (2020, July). *A Survey on Performance Metrics for Object-Detection Algorithms*. Paper presented 2020 International Conference on Systems, Niteroi, Brazil.
93. Mascarenhas, S. and Agarwa, M. (2021, November). *A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification*. Paper presented at 2021 CENTCON, Bengaluru, India.



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : AKYEL, Cihan

Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Lisans	Ankara Üniversitesi / Bilgisayar	2015
Yüksek lisans	Gazi Üniversitesi / Bilgisayar Mühendisliği	2013
Lisans	Gazi Üniversitesi / Bilg. Sis. Öğrt.	2008

İş Deneyimi

Yıl	Yer	Görev
2022-Halen	MEB	Mühendis
2008-2021	MEB	Öğretmen

Yabancı Dil

İngilizce, Yökdil: 88.750

Yayınlar

1. Akyel C. and Arıcı N. (2022). LinkNet-B7: Noise Removal and Lesion Segmentation in Images of Skin Cancer. *Mathematics*. 10(5):736-751.
2. Akyel C. ve Arıcı N. (2020). Cilt Kanserinde Kıl Temizliği ve Lezyon Bölütlemesinde Yeni Bir Yaklaşım. *Politeknik Dergisi*. 23(3): 821-828.
3. Akyel C. and Arıcı N. (2022). Hair Removal and Lesion Segmentation with FCN8-ResNetC and Image Processing in Images of Skin Cancer. *Bilişim Teknolojileri Dergisi*.15(2): 231-238.
4. Akyel C. and Arıcı N. Hair Removal and Lesion Segmentation with Fully Convolutional Neural Network and Image Processing in Images of Skin Cancer. *ICI-CS2021*, Ankara, TÜRKİYE, 9-11 December 2021.
5. Akyel C. ve Arıcı N. Yürüme Engelliler İçin Etkileşimli Bir Web Portalı Hazırlanması Ve Kullanılabilirlik Analizi, *International Symposium on Multidisciplinary Studies and Innovative Technologies-ISMSIT 2018*, Ankara, Turkey, 19 - 21 October 2018.



GAZİLİ OLMAK AYRICALIKTIR.