



**T.C.
DÜZCE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MAKİNE ÖĞRENME TEKNİKLERİ KULLANILARAK BASINÇ
ÜLSERLERİNİN SINIFLANDIRILMASI**

BİLGE YILMAZ

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMAN
PROF. DR. İBRAHİM YÜCEDAĞ**

DÜZCE, 2021

T.C.
DÜZCE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**MAKİNE ÖĞRENME TEKNİKLERİ KULLANILARAK BASINÇ
ÜLSERLERİNİN SINIFLANDIRILMASI**

Bilge YILMAZ tarafından hazırlanan tez çalışması aşağıdaki jüri tarafından Düzce Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Prof. Dr. İbrahim YÜCEDAĞ

Düzce Üniversitesi

Eş Danışman

Öğr. Gör. Dr. Fadime ÖĞÜLMÜŞ DEMİRCAN

Düzce Üniversitesi

Jüri Üyeleri

Prof. Dr. İbrahim YÜCEDAĞ

Düzce Üniversitesi

Doç. Dr. Ali ÇALHAN

Düzce Üniversitesi

Dr. Öğr. Üyesi Ümit ŞENTÜRK

Abant İzzet Baysal Üniversitesi

Tez Savunma Tarihi: 18/08/2021

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

18 Ağustos 2021

Bilge YILMAZ



TEŞEKKÜR

Yüksek lisans öğrenimimde ve bu tezin hazırlanmasında gösterdiği her türlü destek ve yardımdan dolayı çok değerli hocam Prof. Dr. İbrahim YÜCEDAĞ'a en içten dileklerimle teşekkür ederim.

Tez çalışmam boyunca değerli katkılarını esirgemeyen eş danışmanım Öğr. Gör. Dr. Fadime ÖĞÜLMÜŞ DEMİRCAN'a da şükranlarımı sunarım.

Tez çalışmamdaki basınç ülseri görüntülerine erişmem konusunda bana yardımcı olarak bu verileri bana sağlayan ve bu alanda değerli bilgilerini bana aktaran sayın Dr. Öğr. Üyesi Burçin ACUNER'e çok teşekkür ederim.

Bu çalışma boyunca yardımlarını ve desteklerini esirgemeyen başta Arş. Gör. Ercan ATAGÜN olmak üzere, sevgili aileme ve çalışma arkadaşlarıma sonsuz teşekkürlerimi sunarım.

18 Ağustos 2021

Bilge YILMAZ

İÇİNDEKİLER

Sayfa No

ŞEKİL LİSTESİ	i
ÇİZELGE LİSTESİ	ii
KISALTMALAR.....	iii
ÖZET	iv
ABSTRACT	v
1. GİRİŞ.....	1
1.1. BASINÇ YARASI AŞAMALARI.....	3
1.1.1. Aşama 1	3
1.1.2. Aşama 2	3
1.1.3. Aşama 3	4
1.1.4. Aşama 4	4
1.2. GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE SAĞLIK ALANINDA YAPILAN ÇALIŞMALAR.....	9
2. MATERYAL VE YÖNTEM	14
2.1. KULLANILAN PROGRAM	14
2.1.1. Orange Yazılımının Özellikleri.....	14
2.1.1.1. Veri Kaynakları.....	14
2.1.1.2. Veri Ön işleme.....	14
2.1.1.3. Veri Madenciliği Algoritmaları.....	15
2.1.1.4. Veri Akış Tasarımı	15
2.2. YAPAY ZEKA, MAKİNE ÖĞRENİMİ, DERİN ÖĞRENME.....	16
2.2.1. Makine Öğrenmesi Algoritmaları	16
2.2.1.1. Denetimli Öğrenme.....	16
2.2.1.2. Denetimsiz Öğrenme	17
2.2.1.3. Takviyeli Öğrenme	18
2.3. GÖRÜNTÜ İŞLEME.....	18
2.3.1. Görüntü İşleme Teknikleri.....	19
2.3.1.1. Görüntü Ön işleme.....	19
2.3.1.2. Görüntü Geliştirme	19
2.3.1.3. Görüntü Ayırma	19
2.3.1.4. Özellik Çıkartma	20
2.3.1.5. Görüntünün Sınıflandırılması	20
2.4. BASINÇ ÜLSERİ SINIFLANDIRMASI İÇİN ÇALIŞILAN MAKİNE ÖĞRENMESİ TEKNİKLERİ	20
2.4.1. Destek Vektör Makinesi (SVM).....	20
2.4.1.1. Doğrusal Destek Vektör Makineleri.....	20
2.4.1.2. Doğrusal Olmayan Destek Vektör Makineleri	21
2.4.2. Yapay Sinir Ağları	22
2.4.2.1. Yapay Sinir Ağlarının Biyolojik Sinir Hücresi Yapısı	23
2.4.2.2. Tek Katmanlı Yapay Sinir Ağı.....	27
2.4.2.3. Çok Katmanlı Yapay Sinir Ağı	28
2.4.2.4. İleri Beslemeli Yapay Sinir Ağları	28
2.4.2.5. Geri Beslemeli Yapay Sinir Ağları	28
2.4.3. Derin Öğrenme Mimarileri	28

2.4.3.1. Geri Otomatik Kodlayıcılar (AEs)	29
2.4.3.2. Kısıtlı Boltzmann Makinesi (RBM) ve Derin İnanç Ağları (DBN's)	29
2.4.3.3. Evrişimli Sinir Ağı (CNN)	30
2.4.3.4. Tekrarlayan sinir ağı (RNN)	31
2.4.4. Logistic Regresyon	32
2.4.5. Yapay Sinir Ağları, Destek Vektör Makineleri(SVM) ve Lojistik Regresyon Yöntemlerinin Sınıflandırmada Karşılaştırması	33
3. DENEYSEL SONUÇLAR	36
3.1. PUBLIC VERİLERLE YAPILAN ÇALIŞMA	36
3.2. ÖZNİTELİK ÇIKARIMI	38
3.2.1. Kullanılan Derin Öğrenme Sinir Ağları	39
3.2.1.1. VggNet	39
3.2.1.2. GoogleNet	40
3.2.1.3. ResNet	40
3.3. GÖRÜNTÜ TANIMA MODELİNİN BASINÇ ÜLSERİ SINIFLANDIRMASINA ETKİSİ.....	43
3.4. GÖRÜNTÜ TANIMA MODELİNDE YAPAY SİNİR AĞLARI PARAMETRESİ NÖRON BASINÇ ÜLSERİ SINIFLANDIRMASINA ETKİSİ	46
3.5. VERİ AYIRMA ORANININ BASINÇ ÜLSERİ SINIFLANDIRMA BAŞARIMINA ETKİSİ	48
4. SONUÇLAR VE ÖNERİLER.....	51
5. KAYNAKLAR	53
5.1. EK 1: ETİK KURUL KARAR ONAYI.....	57
ÖZGEÇMİŞ	59

ŞEKİL LİSTESİ

Sayfa No

Şekil 1.1.	Basınç yaralanması oluşumunun risk faktörleri.	2
Şekil 1.2.	Basınç yarası evre 1.....	3
Şekil 1.3.	Basınç yarası evre 2	4
Şekil 1.4.	Basınç yarası evre 3	4
Şekil 1.5.	Basınç yarası evre 4	5
Şekil 1.6.	Npuap Epuap basınç yarası aşamaları.	5
Şekil 1.7.	Evrelendirilemeyen basınç yarası	6
Şekil 1.8.	Derin doku basınç yarası (DTPI).....	6
Şekil 1.9.	Basınca bağlı yaralanma ile ilişkili yerler	7
Şekil 2.1.	Orange yazılımı araç çubuğu.	15
Şekil 2.2.	Orange yazılımı veri akış diyagramı temsili.....	15
Şekil 2.3.	Doğrusal destek vektör makineleri.	21
Şekil 2.4.	Doğrusal olmayan destek vektör makineleri.	22
Şekil 2.5.	Bir sinir hücresinin biyolojik gösterimi	24
Şekil 2.6.	Bir sinir hücresinin matematiksel modeli.....	25
Şekil 2.7.	Yapay sinir ağı mimarisi.....	27
Şekil 2.8.	Basit bir otomatik kodlayıcı mimarisinin temsili.	29
Şekil 2.9.	Kısıtlı bir Boltzmann makine mimarisinin temsili.	30
Şekil 2.10.	Tekrarlayan bir sinir ağı mimarisinin temsili.	32
Şekil 2.11.	Logistic regresyon modeli.	32
Şekil 2.12.	Makine öğrenimi algoritmaları ile sınıflandırma gösterimi.	34
Şekil 3.1.	Veri ön işleme adımları.	39
Şekil 3.2.	Image Embedding işlemi sonra özellik çıkarımı.	41
Şekil 3.3.	Kullanılan yöntemler.	42
Şekil 3.4.	Inception V3 modeline göre başarımlar parametreleri.	43
Şekil 3.5.	Inception VGG 16 modeline göre başarımlar parametreleri.	43
Şekil 3.6.	VGG 19 modeline göre başarımlar parametreleri.....	44
Şekil 3.7.	Painters modeline göre başarımlar parametreleri.	44
Şekil 3.8.	DeepLoc modeline göre başarımlar parametreleri.....	45
Şekil 3.9.	SqueezeNet modeline göre başarımlar parametreleri.	45
Şekil 3.10.	Painters modelinin performansa etkisi.	46
Şekil 3.11.	Nöron sayıları değişimin performansa etkisi.....	46
Şekil 3.12.	Aktivasyon fonksiyonu sınıflandırma başarımları.....	47
Şekil 3.13.	Görüntü temel bilgileri.	49
Şekil 3.14.	Basınç ülseri hastalığının analizi.	49

ÇİZELGE LİSTESİ

	<u>Sayfa No</u>
Çizelge 1.1. Yara oluşum risk ölçekleri parametreleri	8
Çizelge 2.1. Görüntü analizine genel bakış	19
Çizelge 2.2. Yapay sinir ağlarının geleneksel algoritmalarla karşılaştırılması.....	23
Çizelge 2.3. Biyolojik sinir bölümlerinin yapay sinir ağı karşılıkları	27
Çizelge 3.1. Performans parametreleri	37
Çizelge 3.2. Eğitim oranı değerleri.....	48



KISALTMALAR

ADLs	Günlük yaşam aktiviteleri
AEs	Otomatik kodlayıcılar
ANNs	Yapay sinir ağları
CAD	Koroner arter hastalığı
CNN	Evrişimli sinir ağı
CPAP	Uyku apnesi hastalığı
DBNs	Derin inanç ağları
DIA	Dijital görüntü analizi
DL	Derin öğrenme
DTPI	Derin doku basınç yarası
EPUAP	Avrupa basınç ülseri paneli
IE	Görüntü gömme
IP	Görüntü işleme
İYE	İdrar yolu enfeksiyonu
LR	Lojistik regresyon
LSTM	Uzun kısa süreli bellek
MANNs	Çok katmanlı sinir ağı
NPUAP	Ulusal basınç ülseri paneli
PPPIA	Pan pasifik basınçlı yaralanma ittifakı
RBF	Radyal tabanlı fonksiyon
RBM	Kısıtlı boltzmann makinesi
RELU	Doğrultulmuş lineer birim
RNN	Tekrarlayan sinir ağı
SAE	Yığınlanmış otomatik kodlayıcı
SANNs	Tek katmanlı sinir ağı
SVM	Destek vektör makinesi

ÖZET

MAKİNE ÖĞRENME TEKNİKLERİ KULLANILARAK BASINÇ ÜLSERLERİNİN SINIFLANDIRILMASI

Bilge YILMAZ

Düzce Üniversitesi

Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Prof. Dr. İbrahim YÜCEDAĞ

Eş Danışman: Öğr. Gör. Dr. Fadime ÖĞÜLMÜŞ DEMİRCAN

Ağustos 2021, 58 sayfa

Basınç ülserleri yatağa bağlı hastalarda uzun süre hareketsizliğe bağlı oluşan yaralardır. Bu durum dünyada önemli bir sağlık sorunu haline gelmiştir. Tedavinin etkili olabilmesi için basınç ülserlerinin teşhisinin doğru yapılması çok önemlidir. Yara özellikleri, iyileşme üzerinde önemli bir etkiye sahiptir. Girişimsel bilgi alma yöntemleri, basınç ülserlerinin teşhisinde hastalar için acı vericidir. Ayrıca bu yöntemler, hastanın enfeksiyon kapmasına sebebiyet verebilir. Bu yüzden, cerrahi işlem gerektirmeyen yara izleme teknikleri tercih edilmelidir. Görüntüleme sistemleri sayesinde yara ile temas edilmeden yaranın özelliklerinin doğru bir şekilde analiz edilmesi sağlanır. Bu tez çalışmasının amacı, görüntü analizinde makine öğrenmesi tekniklerinden yararlanılarak basınç ülserlerinin sınıflandırılması ile tedavi süreçlerine olumlu bir katkıda bulunmak ya da yara oluşumunun önlenmesini sağlamaktır. Bu tezde literatürde basınç yarası problemine evrelendirme sayısı bakımından yenilik getirilmiştir. Basınç yarası evrelendirilmesi doğru bir görüntü sınıflandırma problemi şeklinde ele alınmıştır. 697 tane yara görüntüsünden oluşan gerçek hastane verileri, Lojistik Regresyon, Yapay Sinir Ağları ve Destek Vektör Makineleri yöntemleri ile analiz edilmiştir. Bu görüntülerindeki yara rengi, ölçüsü gibi özellikler görüntü işleme sayesinde ayrıştırılmış ve görüntülerden yaranın hangi evrede olduğu belirlenmiştir. Sınıflandırma için basınç ülserlerinin 6 evresi referans alınmıştır. Bu çalışmada az sayıda veri setindeki farklı açılardan elde edilen görüntülerin bulunması sınıflandırma için uzmanların sınıf değerlerini tayin etmelerinde zor olmasa da arka planda bulunan görüntüler sınıflandırmayı zorlaştırmaktadır. Eğitim için daha çok veri kullanılması ve Derin Öğrenme mimarileri kullanılması performans değerlerini artıracaktır.

Anahtar sözcükler: Basınç ülseri, Görüntü sınıflandırma, Yapay sinir ağları, Lojistik regresyon, Destek vektör makinesi

ABSTRACT

CLASSIFICATION OF PRESSURE ULCERS USING MACHINE LEARNING TECHNIQUES

Bilge YILMAZ

Düzce University

Institute of Graduate Studies, Department of Computer Engineering

Master's Thesis

Supervisor: Assoc. Prof. Dr. İbrahim YÜCEDAĞ

Co-advisor: Instructor Fadime ÖĞÜLMÜŞ DEMİRCAN

August 2021, 58 pages

Pressure ulcers are wounds caused by prolonged inactivity in bedridden patients. This situation has become an important health problem in the world. Correct diagnosis of pressure ulcers is essential for treatment to be effective. Wound characteristics have an important effect on healing. Interventional methods of obtaining information are painful for patients in diagnosing pressure ulcers. In addition, these methods may cause the patient to become infected. Therefore, non-surgical wound tracing techniques should be preferred. With imaging systems, it is ensured that the characteristics of the wound are analyzed accurately without contacting the wound. The aim of this thesis study is to make a positive contribution to the treatment processes or to prevent the formation of wounds with the classification of pressure ulcers by using machine learning techniques in image analysis. In this thesis, an innovation has been brought to the pressure sore problem in the literature in terms of the number of staging. Pressure ulcer staging is handled as an accurate image classification problem. Real hospital data consisting of 697 images wound Logistic Regression, Neural Networks and Support Vector Machines were analyzed by the method. Features such as wound color and size in these images were separated by image processing and the stage of the wound was determined from the images. The 6 stages of pressure ulcers are referenced for classification. Although it is not difficult for experts to determine the class values for classification, the images obtained from different angles in a small number of data sets in this study make it difficult to classify the images in the background. Using more data for training and using Deep Learning architectures will increase performance values.


Keywords: Pressure ulcer, Image classification, Artificial neural networks, Logistic regression, Support vector machine

1. GİRİŞ

Tıp alanındaki önemli gelişmeler sayesinde günümüze kadar olan süreçte dünya nüfusunun ortalama yaşam süresinin arttığı görülmekte ve bundan sonraki süreçte de artmaya devam etmesi beklenmektedir. Bununla birlikte uzmanlar, hareketsiz yaşam tarzı ve sağlıksız beslenme alışkanlıklarıyla birçok hastalığın arttığını gözlemlemişlerdir [1]. İnsanların bu iki eğilimi uzun süreli hareketsizliğe veya kronik yaralanmalara bağlı olarak basınç yaralarının oluşumuna neden olmaktadır. EPUAP (Avrupa Basınç Ülseri Paneli) / NPUAP (Ulusal Basınç Ülseri Danışma Paneli) / PPPIA (Pan Pasifik Basınçlı Yaralanma İttifakı)' na göre basınç ülseri “tek başına, basınç ya da yırtılma ile basıncın bir arada sebep olduğu, genellikle kemik çıkıntılar üzerinde ortaya çıkan lokalize deri ve / veya deri altı doku hasarıdır” şeklinde tanımlanmaktadır [2]. Diğer bir tanıma göre; basınç ülseri, vücut ağırlığını değiştirmeden çok uzun süre bir pozisyonda kaldığında alttaki cilt dokusunun zarar görmesiyle sonuçlanan, dinmeyen basıncın neden olduğu bir lezyondur [3]. Hasta güvenliğinin ve bakım kalitesinin değerlendirilmesinde de önemli bir ölçüt olarak kabul edilen basınç yaraları özellikle yaşlı ve yoğun bakım ünitesinde yatan hastalarda çok fazla görülmektedir. Basınç yarası geliştiğinde, bakım ve tedavisi uzun sürmekte, hastaların yaşam kalitesini düşürmekte ve yüksek maliyet gerektirmektedir. Yine birden fazla kronik hastalığı olan ve uzun süreli hareketsiz olarak yatan yoğun bakım hastaları için ölüm nedeni olabilmektedir. Bununla birlikte, uygun bir zamanda uygun tedavi yapıldığında, ölüm vakalarının yaklaşık %95'i önlenabilir [4]. Bu yaralar en sık topuk gibi kemik çıkıntılarında ve sakral bölgede görülmektedir [5]. Hastalığın tedavi sürecinde kullanılan girişimsel bilgi alma yöntemleri sadece hastalar için acı verici olmakla kalmayıp enfeksiyon riskini de artırabilirken, görüntüleme sistemleri kullanılarak yapılan incelemeler sayesinde hastalara herhangi bir zarar vermeden yara iyileşme süreçlerinin daha iyi izlenmesi sağlanmaktadır.

Basınç yarasının oluşumuna neden olan bazı faktörler yatar ya da oturur pozisyonda uzun süre hareketsiz kalmak, idrar veya dışkı kaçırmak, diyabet gibi kan akışını etkileyen hastalıklar, vücut hareketine engel olan yaralanmalar ve beslenme alışkanlıkları sayılabilir. Şekil 1.1’de gösterildiği gibi, basınç yarası oluşumuna neden olan dışsal ya da içsel birçok risk faktörü görülmektedir. Bunlar; İç Faktörler (Hastanın kendinden

kaynaklı faktörler); Yerleşik özellikleri (yaş, cinsiyet, ırk, etnik köken ve Vücut Kitle indeksi), Beslenme dahil cilt bütünlüğünü etkileyen faktörler(anemi, yetersiz beslenme, dehidratasyon, idrar kaçırma,ve bağırsak inkontinansı), Sistem yetmezliği (koma, kalp yetmezliği, solunum yetmezliği, son dönem böbrek yetmezliği, siroz), Hastalık (diyabet, multipl skleroz, koroner arter hastalığı [CAD], kronik obstrüktif akciğer hastalığı, periferik vasküler hastalık [venöz ve arteriyel]), Enfeksiyon (septisemi, pnömoni, idrar yolu enfeksiyonu [İYE], çok ilaca dirençli organizma), Hareketlilik (hemipleji, parapleji, kuadripleji, kalça kırık, günlük yaşam aktiviteleri [ADLs] bozukluğu), Duyusal değişiklikler ve biliş. Dış Faktörler (Hastanın kendinden kaynaklı olmayan dış nedenli faktörler); Nemlilik, Sürtünme, Yırtılma, Basınç, Sıcaklık, Kumaş(giysi veya yatak).



Şekil 1.1. Basınç yaralanması oluşumunun risk faktörleri.

Basınç yaralarına karşı alınacak tüm tedbirlere rağmen basınç yaraları yine de devam edebilir. Sağlıklı cilt, kas ve yağ dokusu; kan akışı yavaşladığı zaman veya basınç ile kesintiye uğradığında ölmeye başlar. Bu basınca, kemiklerin sert bir yüzeye (yatak, sandalye vb.) doğru itilmesi neden olabilir.

Basınç yarası aşamaları, yaranın en derin kısımlarına ve etkilenen doku tipine göre tanımlanır. Basınç yaralarının dört ana aşaması vardır [6].

1.1. BASINÇ YARASI AŞAMALARI

1.1.1. Aşama 1

Basınç yaralanması çoğu zaman kızarıklıkla beraber sağlam bir cilt olarak görünür. Bu alan genellikle kemik çıkıntı üzerindedir. Basınç geçtikten sonra da cilt kırmızı kalmaktadır. Bunun nedeni, basınçtan ilk olarak kas dokusunun etkilenmesidir. Bu aşamada doku; ağrılı, sıcak veya yumuşak olabilir.



Şekil 1.2. Basınç yarası evre 1 [7].

1.1.2. Aşama 2

Basınç yaralanması, cildin dermis (vücudu darbelere karşı koruyan katmanı) kısmında oluşan kalınlık kaybı ve pembe veya kırmızı bir alan olarak görülmektedir.



Şekil 1.3. Basınç yarası evre 2 [7].

1.1.3. Aşama 3

Basınç yaralanması, aşama 1 ve aşama 2'ye göre daha derin ve ciddi bir yaralanmadır. Yağ dokusu, granülasyon dokusu ve epibol (yuvarlanmış yara kenarları) görülmektedir. Ölü doku bulunabilir.



Şekil 1.4. Basınç yarası evre 3 [7].


1.1.4. Aşama 4

Basınç yaralanmasının, en şiddetli aşamasıdır. Basınç ülserinin en derin halidir. Kas dokusuna ve kemiklere ulaşabilir. Bu aşamada da ölü doku bulunabilir.



Şekil 1.5. Basınç yarası evre 4 [7].

Şekil 1.6'da, Avrupa Ulusal Basınç Ülseri Danışma Paneli (EPUAP) tarafından tanımlanmış basınç kaynaklı yaralanmaların aşamaları görülmektedir [6].



Şekil 1.6. Npuap Epuap basınç yarası aşamaları [6].

Ayrıca, Şekil 1.6’da görüldüğü üzere iki ek basınç aşaması vardır. Birine evrelendirilemeyen basınç yarası denir. Çünkü yarada çok fazla ölü dokular bulunur bu da doktorların yara derinliğini incelemesine izin vermez. Diğer tip basınç yaralanmalarına derin doku basınç yarası (DTPI) denir. Çoğu zaman parçalanmamış deri şeklindedir ve mor veya koyu mor renktedir. Bu yara, hızla açılabilir ve derin bir basınç yaralanmasına dönüşebilir.



Şekil 1.7. Evrelendirilemeyen basınç yarası [7].




Şekil 1.8. Derin doku basınç yarası (DTPI) [7].

Bu aşamaları dışında zaman içerisinde iki çeşit daha aşama görüldüğü düşünülmektedir. Bunlardan biri mukozal membran basınç yarasıdır. Bu aşamada yara sümüksü doku şeklinde görülür. Diğeri ise tıbbi cihazla ilgili basınç yarasıdır. Bu yaralar ise hastaların

oksijen tüpü, CPAP maskesi(uyku apnesi hastalığında kullanılan maske) gibi tıbbi cihazları uzun süre kullanımı ile oluşan basıncın etkisi ile görülür.

Basınc yaraları farklı alanlarda meydana gelebilir. Bu bölgeler; başın arka kısmı veya yanları, kulak kenarları, omuzlar, sırtın alt bölümü, dizlerin arka veya yan tarafları, topuklar, ayak bilekleri ve ayak parmakları gibi genelde kemik çıkıntısı olan bölgelerdir. Aşağıda Şekil 1.9’da bu bölgeler görülmektedir [8].



Şekil 1.9. Basınca bağlı yaralanma ile ilişkili yerler [8].

Basınc yaralanmalarının, hasta bakım hizmetleri için önemli bir ekonomik maliyet oluşturması ve ülkedeki yatak kapasitesini etkilemesi (özellikle içerisinde bulunduğumuz Covid-19 süreci düşünüldüğünde yatak kapasitesi daha da önem kazanmıştır.) gibi olumsuz etkilerinden dolayı önlenmesi fazlasıyla önemlidir. Ayrıca dış faktörlü kaynakların; zaten hasta olan kişilere bir hastalık daha eklememesi, bu hastalığa sebebiyet vermemesi amacıyla düzenlenmesi önleme aşaması için gereklidir. Basınc Yarasını önlemeye yönelik yöntemler, Basınc Yarası Önleme Paketi SKINCARE olarak kodlanmıştır [9]. Bunlar: Support surface, Keep repositioning, Incontinence care, Nutrition and hydration, Check medical devices, Assess risk and skin daily, Reduce head of bed $< 30^\circ$ (unless contraindicated), Elevate heels. Burada aynı pozisyonda uzun süre kalarak o noktaya uzun süre basınc uygulandığından dolayı oluşabilecek basınc yaralarının önlenmesi amacıyla; destek yüzeylerinin kullanılması, hastanın sık sık pozisyonunun değiştirilmesi, idrar kaçırma olmaması için bakımının yapılması, beslenmesine dikkat edilmesi, tıbbi cihazların kontrolü, riskli cildin günlük olarak değerlendirilmesi, yatak eğiminin 30° altında olması, topukların kaldırılması gibi önlemler baş harfleri birleştirilecek SKINCARE olarak kodlanmıştır. Basınc yaralarını önlemek için hastaların belirli sıklıkta pozisyon değiştirmesine ve uzun süre aynı

pozisyonda kalmamasına özen gösterilmelidir [10]. Yatalak hastaların cilt bakımlarına dikkat edilmelidir. Yara oluşumuna yatkın hastalarda yara oluşum riski her gün ölçülmelidir. Bu amaçla Norton, Waterlow, Braden gibi çeşitli risk değerlendirme ölçekleri kullanılmaktadır [11]. Bu ölçeklerin parametreleri aşağıda Çizelge 1.1’de görülmektedir [11].

Çizelge 1.1. Yara oluşum risk ölçekleri parametreleri [11].

Braden Ölçeği Parametreleri	Norton Ölçeği Parametreleri	Waterlow Ölçeği Parametreleri
Duyusal algılama, Nem, Aktivite, Mobilite(hareketlilik), Beslenme durumu, Sürtünme ve yırtılma	Fiziksel durum, Mental durum, Aktivite, Mobilite(hareketlilik), İnkontinans(idrar kaçırma)	Yaş, Kilo, Deri durumu, Mental durum, Mobilite(hareketlilik), Beslenme, Solunum, İnkontinans(idrar kaçırma), Hijyen,

Basınç yaralarında bu ölçekler hemşireler tarafından kullanılarak günlük olarak hastanın durumlarını belirten ölçekler doldurulmaktadır. Bu sayede basınç ölçeği değerlendirmesi yapılmakta ve hastalığın önlenmesi veya tedavisi aşamasına olumlu dönütler sağlanmaktadır. Basınç yaralanmasının durumuna ve aşamasına bağlı olarak tedavi her hastaya göre farklılık göstermektedir. Yara ilk aşamasındayken, enfeksiyon kapmasını önlemek için nazik bir temizlik ve uygun bir pansuman gerekmektedir. Basınç yaralanması 3. veya 4. aşamadayken, iyileşmesi birkaç ay sürebilir veya özellikle diğer risk faktörleri (zayıf kan dolaşımı ve damar hastalıkları, diyabet, yetersiz beslenme, hareketsizlik vb.) kalıcı olarak mevcutsa iyileşmeyebilir. Doğru tedavinin uygulanabilmesi için yaranın tespitinin doğru yapılması ve aşamasının tespit edilerek ona en uygun tedavi yöntemi tercih edilmelidir. Aksi takdirde tedavi süreci olumsuz sonuçlanıp bu durumdan hasta olumsuz etkilenebilir. Bütün bunlar göz önüne alındığı zaman hastanın deneyimli kişi tarafından bakılması ve gözlem altında tutulması gerektiğini göstermektedir. Hastanın sadece deneyimli kişiye bağlı olması zor ve pahalı bir iştir. Bu nedenle, basınç yaralanmalarının müdahale gerektirmeyen bir değerlendirme için kullanıcı dostu bir sistem, bu yaraların sık sık değerlendirilmesi ve izlenmesi için önemli bir araç olacaktır. Süreçte hastaların rahatsızlığını önlemek için cerrahi işlem

gerektirmeyen yara izleme teknikleri tercih edilir. Bu anlamda görüntü işleme teknikleri, yaranın kendisiyle temas etmesine gerek kalmadan özelliklerinin doğru bir şekilde analiz edilmesine olanak sağladığı için bu süreçte önemli bir rol oynayacaktır.

Görüntü işleme teknikleri, derin öğrenme mimarileri ve yapay sinir ağları gibi tekniklerle birlikte kullanılarak yapılan bazı çalışmalar aşağıda verilmiştir.

1.2. GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE SAĞLIK ALANINDA YAPILAN ÇALIŞMALAR

J. Delode ve arkadaşları çalışmasında dijital bir video tekniği kullanarak yara iyileşmesini izlemek için invazif olmayan bir yöntem izlemiştir. Yara bölgesini hesaplamak ve planimetrik bir ölçüm yapmak için bir görüntü işleme yazılımı kullanılmıştır. Kolorimetrik analiz yazılımı adı verilen başka bir yazılım, yara renginin siyah, sarı ve kırmızı yüzdesini belirler. Tüm bu veriler bir veri tabanında saklanmaktadır [12]. Dhane ve arkadaşları çalışmalarında elde tutulan bir optik kamera ile dijital olarak yakalanan görüntüleri kullanarak yara alanı tespiti için yeni bir yöntem önermişlerdir. Önerilen strateji, afinite matrisine dayalı olarak kümeleme için spektral yaklaşımı içermektedir. Spektral kümeleme (SC), Ng-Jorden-Weiss algoritmasına dayalı Laplacian'ın benzerlik matrisinin oluşturulmasını içermektedir. Bu yöntem bacak, basınç ve diyabet ayak olmak üzere 3 tip ülserle uygulanmıştır. Önerilen yöntem, FCM ve k-ortalamlarına dayalı sınıflandırma ile karşılaştırılmış, 3 yaklaşımdan elde edilen değerlendirme 3 bölge için analiz edilmiştir. Hedeflenen sonuç olan ülserin etkin bir şekilde tanımlandığı görülmüştür [13]. Mukherjee ve arkadaşları tarafından yapılan çalışmadaki amaç ise tıbbi görüntü işleme ve istatistiksel makine öğrenimi tekniklerini kullanarak kronik yara (CW) değerlendirmesi için bilgisayar destekli bir doku sınıflandırma (granülasyon, nekrotik ve slough) şeması geliştirmektir. Bu çalışmada istatistiksel öğrenme algoritmaları, yani Bayesian sınıflandırma ve destek vektör makinesi (SVM), farklı CW görüntülerinde yara dokusu sınıflandırması için eğitilmiş ve test edilmiş ve çalışma sonucunda kronik yara sınıflandırmasında bu yöntemlerin etkili olduğu görülmüştür [14]. Ortiz ve arkadaşları tarafından yapılan çalışmada, görüntünün her pikselinde bulunan gri tonlama değerinden elde edilen sentetik frekansları kullanarak kontrast değişikliklerine dayalı yeni bir görüntü bölümlenme tekniği kullanımı amaçlanmıştır. Sentetik frekansları değiştirerek görüntüyü farklı kontrast seviyelerine ayırmak için toroidal bir geometri kullanılmıştır [15]. Veredas ve arkadaşlarının çalışması, yara teşhisinde önemli bir rol oynayan yara dokusu türlerini

tespit etmeye ve sınıflandırmaya yardımcı olmak için görüntü işleme algoritmalarına ve denetimli öğrenme tekniklerine dayalı bir bilgisayarla görme yaklaşımı sunulmaktadır. Önerilen sistem, görüntü bölütleme için k-ortalama kümeleme algoritmasının kullanılmasını içerir ve her bölümlü bölgeyi uygun doku türü olarak etkili bir şekilde sınıflandırmak için üç farklı makine öğrenimi yaklaşımını - sinir ağları, destek vektör makineleri ve rastgele orman karar ağaçları – karşılaştırır [16]. Dalya ve Shedge tarafından yapılan çalışmada android tabanlı bir yazılım geliştirilerek görüntü analiz edilip yaraların değerlendirilmesi amaçlanmıştır. Sistemde yara görüntüsünü hasta çekip sisteme kaydetmekte ve K-shift algoritması ile görüntü analiz edilerek yara durum tespiti kullanıcıya gönderilmektedir. Aynı zamanda sistemde görüntüler uzman incelemesine de gönderilmekte ve uzmanlar yarayı inceleyerek tedavi için hastaya öneride bulunmaktadırlar [17]. J.E. Sanders ve arkadaşlarının çalışmasında görüntü işleme tekniklerinin cilt tanısında nasıl kullanılacağına detaylı bir şekilde açıklanması ve geleneksel yöntemlerle karşılaştırılması amaçlanmıştır. Cilt hastalıklarının teşhisinde görüntü işleme yöntemleri ile geleneksel kullanılan yöntemler karşılaştırıldığında toplam sürede bilgisayar yöntemi, geleneksel yöntemin yaklaşık iki katı zaman gerektirmiştir. Epidermal özellikleri belirlemek için özel olarak yazılmış yazılım yaklaşık 90 s/görüntü alırken, hücresel ve kolajen analizlerinin her biri 20 s/görüntüden daha az zaman almıştır. Geleneksel yöntem yaklaşık 20 s/görüntü gerektirmiştir. Ancak bilgisayar yöntemi, geleneksel yöntemle kıyasla veri derleme ve istatistiksel hesaplama aşamalarında daha hızlı olduğu görülmektedir. Bilgisayar sistemlerinin gelişmesiyle birlikte hem zamansal hem de kullanılabilirlik olarak görüntü işleme yöntemlerinin öne geçeceğini öngörmektedirler [18]. Mekkes ve Westerhof tarafından yapılan çalışmada görüntü işleme yönteminin yara iyileşmesine katkısını belirlemek amaçlanmıştır. Cilt yaralarının iyileşmesi için çeşitli yöntemler ve ilaçlar kullanıldığından bahsedilmiştir, fakat görüntü işleme yöntemlerinin yaraların iyileşme sürecini hızlandıracağına üzerinde durulmuştur. Bu çalışmada tasarlanmış bir dijital görüntü analizi (DIA) sistemi kullanılarak yara görüntülerinden yaranın geçiş aşamaları ölçümü (sarıdan kırmızıya) görüntü işleme ile açıklanmıştır [19]. Rajendran ve arkadaşlarının çalışmalarında düşük maliyetli, temassız görüntüleme tabanlı bir aşama I basıncı yarası tespit sistemi geliştirmek amaçlanmıştır. Çeşitli cilt tipleri incelenmiş, koyu tenli ve beyaz tenli cilt tiplerinde basıncı uygulandığında yara oluşma ihtimali üzerinde deneyler yapılmıştır. Geliştirilmiş sistemin görüntülerde daha yüksek kontrast sergilediği ve basıncı ülseri bölgesini muayene eden kişi için daha belirgin hale getirdiği görülmüştür [20]. Kosmopoulos ve Tzevelekou

tarafından yapılan çalışmada basınç ülseri görüntülerinden yararlanılarak hastalığın aşamalarını belirlemek, teşhis etmek ve sınıflandırmak amaçlanmıştır. Web altyapısı ile istenilen zamanda sisteme giriş yapılarak hastaların dijital görüntülerinin alınması ve yorumunun yapılabilmesi, sistemin tanı sağlayarak tedavi önermesi ve verilerin saklanması sağlayan bir sistem geliştirilmesi üzerinde durulmuştur. Görüntü analizinde 85 görüntüden yararlanılmıştır. Her sınıfın eğitimi için yaklaşık 100 örnek kullanılmıştır. Her hasta için, cilde oldukça benzeyen 1. aşamadaki basınç ülseri bölgeleriyle karşılaştırmak için sağlıklı cilt dokularını temsil eden bölgeler de dâhil edilmiştir. Segmentasyon sonucunun çoğu durumda tatmin edici olduğu sonucuna ulaşmışlardır [21]. Seidenari tarafından yapılan çalışmada, cilt hastalıklarının değerlendirilmesinde görüntü analizi tekniklerinin kullanılabileceğini kanıtlamak amaçlanmıştır. Bu çalışmada, görüntü işleme yöntemlerinin cilt hastalıklarında çok faydalı bir şekilde kullanılabileceğinden bahsedilmiştir. 20 MHz B-tarama görüntülerini işlemek için görüntü bölütleme ve üç boyutlu yeniden yapılandırma yazılımı geliştirilmiştir. Görüntü analizinde yüksek frekanslı ultrasonografik cihazdan faydalanılmıştır. Bu yüksek frekanslı ultrason dönüştürücü, cilde ses darbeleri yönlendirir. Yapısal arayüzlerde farklı akustik özelliklere sahip dokular arasında ultrason sinyalinin bir kısmı yansıtılır ve bir kısmı emilim gibi farklı fiziksel olaylara maruz kaldığı için ciltte dolaşmaya ve dağılmaya devam eder. Ekranda görüntülenen görüntüde, bir dizi yansımanın sonucuna bağlı olarak karşılaştığı dokuların akustik özellikleri ve ultrason ışını farklı ifade edilebilmektedir. Bu görüntülerin değerlendirilmesinde 3 mod kullanılmıştır. Bunlar:

A (genlik) modu: Dokudaki derinlik, tek bir yön boyunca yansıyan sinyal ve ekranda bir eğri olarak görünür. Her yansımanın genliği, bir fonksiyon olarak çizilir.

B (parlaklık) modu: Derinin bir kesitini sunan sayısallaştırılmış iki boyutlu bir resim, bileşeni A çizgilerinin toplanmasıyla elde edilir. Yansımaların yoğunluğu gri ile ifade edilir. Ölçek veya sözde renk ölçeği, burada görüntüyü oluşturan her pikselin parlaklığı veya rengin genliğine göre değişir.

C (sabit derinlik) modu: Belirli bir düzlemde uzanan yapıların iki boyutlu ultrasonik görüntüsü, yalnızca belirli bir cilt derinliğinden gelen yankılar seçilerek elde edilir.

Böylelikle, görüntü işleme tekniklerinin objektif bir teşhis aracına dönüştürülebilir olduğu, bir görüntünün bölümlerinin hızlı bir şekilde kontrol edilmesi ve elde edilen verilerin nicelleştirilmesine olanak sağladığı sonucuna ulaşılmıştır. Tıbbi uygulanan

görüntü işleme yöntemlerinin önemli bir dezavantajı ise, tüm bu bilgi sağlamak için kullanılan işlemlerin araca bağımlı olması ve farklı ekipman kullanan gruplardan toplanan verilerin bu nedenle karşılaştırılabilir olmadığıdır. Bu nedenle, görüntü ile gerçekleştirilen çalışmaların sonuçlarını tanımlarken görüntü işleme yazılımının bir açıklaması gereklidir [22]. Bulstrode, Goode, Scott tarafından yapılan çalışmada bacak ülserleri görüntü işleme teknikleri ile ölçülerek, bu yöntem geleneksel yöntemlerle karşılaştırılmıştır. Bu çalışmada, klinik durumda fotoğraf çekebilen bir bilgisayara bağlı taşınabilir bir stereo kamera geliştirilmiştir. Bu sistemin doğruluğu ve kesinliği, şu anda bu tür işler için kullanılan iki sistem olan doğrudan izleme ve basit fotoğrafçılıkla ölçülmüş ve karşılaştırılmıştır. Boyutları tam olarak bilinen kronik bacak ülseri modellerinde kenar uzunluğu ve alanı için %2'den daha iyi bir kesinliğe sahip olduğu ve %1 içinde doğru olduğu bulunmuştur. Hastaların ülserlerinde kullanıldığında, stereofotogrametrinin diğer iki sistemden beş ila on kat daha doğru olduğu bulunmuştur. Kronik bacak ülserlerinin iyileşme hızı, hastalar üzerinde yapılan bir klinik deneyde ölçülmüştür. Yalnızca stereofotogrametri, klinik deneyde ölçülen değişikliklerden tutarlı bir şekilde daha küçük hatalara sahiptir, bu da onu bu modelde iyileşme oranlarını incelemek için geçerli olarak kullanılabilecek tek sistem haline getirmiştir [23]. Jones ve Plassmann'ın çalışmalarında, bacak ülserlerinin görüntü işleme ile aktif kontur yöntemi kullanılarak bacak ülseri alanını ölçmek amaçlanmıştır. Görüntü ilk önce belirlenmiş ölçekte Gauss yumuşatma filtresinin uygulanmasıyla bulanıklaştırılır. Aktif kontur ilk olarak en yüksek ölçekte başlatılır ve değiştirilmiş greedy algoritma ile yakınsama için yinelenir. Yakınsanmış kontur daha sonra algoritmayı başlatmak için kullanılır. Bu çalışmada Gauss ölçeğini temsil etmek için B-spline'ları kullanılmıştır. Çalışmanın sonucunda aktif kontur modeli kullanılarak yapılan görüntü işlemede bazı sınırlılıklar görülmüştür. Yine de manuel yöntemlerle karşılaştırıldığında görüntü işleme tekniklerinin daha başarılı olduğu sonucuna ulaşılmıştır [24]. Wannous ve arkadaşları tarafından yapılan çalışmada, yara ölçümleri için görüntü işleme teknikleri kullanılmış ve 3 boyutlu bir model hesaplanarak doku sınıflandırılması yapılmıştır. Bu model oluşturulurken, destek vektör makinesi(SVM) sınıflandırıcısından yararlanılmıştır. Fakat görüntülerdeki aydınlatma koşullarındaki farklılıklar ve perspektif bozulmalar nedeniyle tekrarlanabilirlik özelliğinin kullanılamaması hasta muayenelerinde önemli farklılıklar göstermektedir. Bu çalışmanın amacı, doku sınıflandırması için çoklu görüş stratejisiyle bu dezavantajın üstesinden gelmektir. 3 boyutlu yara yüzeyi ölçümleri ile doku sınıflandırması tek bir araçta birleştirilerek, gelişmiş yara değerlendirmesi elde edilmiştir.

Bu çalışmada yalnızca basit bir el tipi dijital kamera gerekli olduğu için klinik personel tarafından yaygın kullanımı çok kolay olacaktır. Bu geliştirilen model, hastanelerde tedavinin takibinde ve web altyapısı kullanılarak yara değerlendirmesinin tekrarlanabilir ve doğruluğunun kritik olduğu klinik araştırmalarda kullanılmak üzere tasarlanmıştır [25].

Bu tez çalışmasında görüntü analizinde makine öğrenme tekniklerinden yararlanılarak basınç yaralanmalarının sınıflandırılması, bu sayede yaranın önleme veya tedavi süreçlerine olumlu bir katkı sağlamak amaçlanmaktadır. Görüntü işleme teknikleri kullanılarak veri setindeki basınç yarası görüntülerinin hangi aşamada oldukları tespit edilmektedir. Kullanılan veri seti Zonguldak Bülent Ecevit Üniversitesi, Plastik Cerrahi bölümü Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığı onayı ile alınan veri setidir [7]. Daha doğru aşama tespiti için aşama fotoğraflarının sayısı birbirine yakın olmasına dikkat edilmiştir.



2. MATERYAL VE YÖNTEM

2.1. KULLANILAN PROGRAM

Orange, Ljubljana Üniversitesi ekibi tarafından geliştirilmiş bir paket yazılımdır. Orange, veri görselleştirme, makine öğrenimi, veri madenciliği ve veri analizi için bileşen tabanlı bir görsel programlama yazılım paketidir. Orange bileşenlerine widget denir. Bunlar veri, görselleştirme, sınıflandırma, regresyon, değerlendirme ve denetimsiz öğrenme gibi bir dizi makine öğrenimi, ön işleme ve veri görselleştirme algoritması içerir. Biyoinformatik, veri birleştirme ve metin madenciliği eklentileri de mevcuttur. Orange yazılımı C++ dili ile geliştirilmiştir. Yazılımın ara yüzleri ve grafik ortamı ise Qt kütüphanesi ve Python kullanılarak geliştirilmiştir. Program, deney seçimi, öneri sistemleri ve tahmine dayalı modelleme için bir platform sağlar. Biyotıp, biyoinformatik, genomik araştırma ve öğretimde kullanılmaktadır. Bilimde, yeni makine öğrenimi algoritmalarını test etmek, genetik ve biyoinformatikte yeni teknikleri uygulamak için kullanılmaktadır. Eğitimde biyoloji, biyotıp ve bilişim öğrencilerine makine öğrenmesi ve veri madenciliği yöntemlerini öğretmek için kullanılmaktadır. Bu yazılım görsel programlamada ve Python komut dizisinde oldukça başarılıdır [26].

2.1.1. Orange Yazılımının Özellikleri

Python diliyle geliştirildiği için yazılım içerisinde script kod kullanılabilir.

Kısa zamanda kurulumu tamamlanmaktadır (yaklaşık 6 dakika).

Fazla denilebilecek depolama alanı gerektirir. (yaklaşık 1.20 GB yer kaplar).

2.1.1.1. Veri Kaynakları


Program sadece metin dosyasından (TXT, TAB) veri içer aktarma işlemine olanak tanımaktadır.

2.1.1.2. Veri Ön işleme

Kullanılan algoritmaların bazıları veri ön işleme amaçlı da olabilir. Ön işleme için bir bölüm bulunmaz.

2.1.1.3. Veri Madenciliği Algoritmaları

SVM, K-NN, Hiyerarşik algoritmalar, MDS, Partitioning tabanlı algoritmalar, Prediction tabanlı algoritmalar, C4.5 gibi algoritmalar bulunur.



Şekil 2.1. Orange yazılımı araç çubuğu.

2.1.1.4. Veri Akış Tasarımı

Programın araç kutusunda olan bütün nesneler tıklandığında tuval üzerine gelir. Düğümler arasında veri alışverişi bir düğümden diğer düğüme fare sürükleme yöntemi ile oluşur.



Şekil 2.2. Orange yazılımı veri akış diyagramı temsili.

2.2. YAPAY ZEKA, MAKİNE ÖĞRENİMİ, DERİN ÖĞRENME

Yapay zeka, bir makinenin özellikle bilişsel yeteneklerde, insan zekasını taklit etme veya ötesine geçme tekniklerini kapsayan bir yöntemdir. Yapay zeka, makine öğrenimi ve derin öğrenme arasındaki fark, uzman olmayanlar tarafından anlaşılması zor ayrımlar içerir. Yapay zeka, kural tabanlı sistemler gibi çeşitli alt alanları içerir. Yapay zeka klasik olarak programcının sağlanan bilgileri açıkça kodladığı bir yaklaşımdır. Buna karşılık, makine öğrenimi, açıkça insan yönergeleri olmadan bir dizi sağlanan veriden kalıpları tanımayı öğrenmek için istatistiksel yöntemler uygulayan bir yapay zeka alt alanıdır. Derin öğrenme, önceki örnekleme daha yüksek ve biraz daha soyut bir örnekleme dönüştüren, çok sayıda basit ama doğrusal olmayan modül aracılığıyla verileri temsil etmek için biyolojik yapıyı örnek alan yapay sinir ağlarını kullanan yeni bir makine öğrenimi yaklaşımıdır. Mimarının bileşimsel doğası, derin sinir ağlarının, benzeri görülmemiş bir ayırım gücü sağlayan oldukça karmaşık ve doğrusal olmayan temsiller oluşturmaya izin verir. Derin ağlar, görüntü sınıflandırma ve konuşma tanımda dâhil olmak üzere birçok önemli problemde yeni yöntemlere yol açan sonuçlar üretmiştir [27].

Tıp alanında bilgisayar ve teknolojinin kullanımı güçlü makine öğrenimi tekniklerinin ortaya çıkışı, grafik hesaplama kaynaklarının ilerlemesi ve tıbbi verilerin sürekli artan sayısallaştırılması ile daha da artmıştır [27]. Bu sistemler, aşamalı olarak tıbbi teşhis için klasik görüntü analizi tekniklerinin yerini aldı. Bu gelişmeler makine öğrenimine olan ilginin yoğunlukla artmasını sağladı.

Bir makine öğrenimi algoritmasının amacı, genellikle sağlanan görevle ilgili eğitim verilerini kullanarak bir görevi öğrenmek ve doğru bir çıktı üretmek için bir girdi verisinin alınmasını, işlenmesini içerir. Eğitim verileri, görev girişinin farklı örneklerini içerir. Ayrıca, genellikle etiketler olarak adlandırılan doğru çıktının örneklerini de içerebilir.

2.2.1. Makine Öğrenmesi Algoritmaları

Makine öğrenmesi algoritma türleri şöyledir; denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme diye nitelendirilebilir.

2.2.1.1. Denetimli Öğrenme

Girdi verileri tüm örnekler için karşılık gelen etiketi içerdiğinde, buna denetimli öğrenme denir [26]. Denetimli öğrenme, tıp alanında dijital hastalık teşhisinde kullanılan yaygın yaklaşımlardan biridir.

Denetimli Öğrenme problemleri;

Sınıflandırma: Çıktı değişkenlerinin kategoriler halinde olduğu belirli bir örneğin sonucunu tahmin etmektir. Basınç ülserlerinin aşama1, aşama2, aşama3 ve bunun gibi aşama ayrımının yapılması sınıflandırmaya örnektir.

Regresyon: Verilen değişkenin gerçek değerler biçiminde olduğu belirli bir örneğin sonucunu tahmin etmektir. Basınç yarasının yoğunluk tahmini buna örnektir.

Sınıflandırma ve regresyon görevlerinde denetimli öğrenme için bir karar ağacı kullanılır [27]. Karar verme süreci, bir dizi verinin ardışık teste bölünmesiyle çalışır. Bu testler, her kararın bir düğüme karşılık geldiği ağaç benzeri bir yapı oluşturur. Tek bir kök düğümünden başlayarak, her düğüm girdi örneğine bir test uygular ve test sonucuna göre örneği ağacın yukarısındaki çocuklarından birine iletir. Bir örnek bir yaprağa (çocuksuz bir düğüm) ulaştığında, o yaprakla ilgili karar örneğe atanır. Karar ağaçları eğitim ve çıkarımda çok verimlidir, ancak aşırı uyum sağlamaya eğilimlidirler. Öğrenilen model aşırı karmaşık hale geldiğinde eğitim verilerine iyi uyum sağlar, ancak görünmeyen verilere genelleme yapamaz [27].

En önemli denetimli öğrenme algoritmalarından bazıları şunlardır: k-Nearest Neighbors, Linear Regression, Logistic Regression, Support Vector Machines (SVMs), Decision Trees and Random Forests, Neural networks [27].

2.2.1.2. Denetimsiz Öğrenme

Giriş verileri bulunan, çıkış verileri olmayan algoritmadır. Modelleme için etiketsiz eğitim verileri kullanılır [27]. Denetimsiz öğrenme, verilerden önemli ölçümleri veya özellikleri çıkarmak için yaygın olarak kullanılır.

Denetimsiz öğrenme problemleri;

Birleştirme: Farklı bileşenlerin bir arada olma ihtimali üzerine çalışmalar yapılır.

Kümeleme: Farklı bir kümedeki örnekleri ayırarak birbirine benzeyen örnekleri bir arada tutma işlemidir.

Boyut Azaltma: Önemli bilgilerin saklanarak bir veri kümesinin değişkenlerinin sayısını azaltmak anlamına gelir. Boyut azaltma; özellik seçimi ve öznetelik çıkarımı yöntemleri ile işlenebilir.

2.2.1.3. Takviyeli Öğrenme

Ödülü en üst seviyeye çıkaracak davranışları öğrenerek, sıradaki en etkili işlemi mevcut duruma dayalı olarak belirlemesini sağlayan bir makine öğrenmesi algoritması çeşididir [27]. Bu öğrenme türündeki yazılımlar, genellikle deneme yanılma yoluyla en iyi eylemleri öğrenirler. Genellikle psikomotor davranış gözlemleri nedeniyle robotik kodlamada kullanılan öğrenme algoritmasıdır. Burada bir robot, engele çarptıktan sonra negatif geri bildirim alarak çarpışmalardan kaçmayı öğrenebilir.

Bir makine öğrenimi algoritması, bir modeli öğrenmek için eğitim verilerini kullanmadan önce, verileri kodlanabilir hale getirmek gerekir. Bir örnek veri, model olarak verilerden alakasız bilgileri atar ve işe yarayacak bilgileri daha erişilebilir hale getirir. Tıp alanında bir veri seti renkli görüntülerden oluşacaktır. Bu her renkli görüntü, bir bilgisayar programının gördüğü şekliyle yaklaşık 30 milyar sayıdır. Girdi verilerinin bu büyüklüğü, öğrenme yöntemlerinin çoğunu kullanılamaz kılabilir ve bu boyutu küçültten bir yöntem kullanmak kaçınılmazdır [27].

2.3. GÖRÜNTÜ İŞLEME

Görüntü işleme sistemleri ile milyonlarca görsel kimlik arasındaki benzerlikleri veya farklılıkları bularak yeni bilgiler elde edilmektedir [28]. Görsel işleme ile elde edilmesi beklenen bilgiler fotoğraf üzerindeki bir nesnenin etiketlenmesinden çok hem işlenebilecek veri sayısındaki artış hem de kullanılan algoritmaların gelişmesi ile daha öteye gitmiştir [28]. Artık görsel işleme teknikleri ile kanserli hücre tanısı yapmak veya askeri sahalarda kullanılacak sensörler geliştirmek gibi hayati önem taşıyan sahalarda çalışılmaktadır. Görüntü işlemedeki bu ileri teknoloji, başta makine öğrenmesi olmak üzere, derin öğrenme ve yapay sinir ağları gibi tekniklerin kullanımıyla mümkün olmaktadır.

Görüntü analizinin genel işleyişi aşağıdaki Çizelge 2.1’de verilmiştir [29].

Çizelge 2.1. Görüntü analizine genel bakış [29].

İşleme ve Ayırıştırma	Özellik çıkarma ve Seçme	Hastalık tespiti, Sınıflandırma ve Son işleme
Renk aydınlatma ayırıştırması	Yapısallığın ölçümü	Denetimli
Yumuşatma	Renk	Denetimsiz
Gürültü arındırma	Dokusal	Sinir ağları
İyileştirme	Yoğunluğa dayalı	Denetimli Öğrenme algoritması (lojistik regresyon)
Eşikleme	Yapısal	Karmaşık sistem
Köşe merkezli	Doğrusal, doğrusal olmayan özellik azaltma	Yapısal fonksiyonlar
Bölge merkezli		
Aktif renk		
Kümeleme		

2.3.1. Görüntü İşleme Teknikleri

Başlıca görüntü işleme teknikleri; görüntü önileme, görüntü geliştirme, görüntü ayırma, özellik çıkartma ve görüntü sınıflandırılmasıdır [29].

2.3.1.1. Görüntü Önileme

Görüntü önileme, piksellerin geometrisi ve parlaklık değerleri ile ilgili hataların engellenmesini sağlar. Bu hatalar ampirik ya da matematik modeller kullanılarak düzeltilir.

2.3.1.2. Görüntü Geliştirme

Görüntü geliştirme, görselin görünümünü iyileştirerek görüntünün insan ya da makine yorumu için daha uygun biçime dönüştürülmesini sağlar. Görsel geliştirme temel olarak piksel parlaklık değerleri üzerindeki oynamalarla sağlanır.

2.3.1.3. Görüntü Ayırma

Görüntü ayırma, görüntüyü kendini oluşturan bileşenlere ve nesnelere ayırma işlemidir. Aranılan nesne veya bileşen görüntüden elde edildiği anda ayırma işlemi durdurulur.

2.3.1.4. Özellik Çıkartma

Özellik çıkartma, nesnenin boyutu, şekli, kompozisyonu, konumu gibi özelliklere göre nesneyi tanımlama işlemidir. Tanıma sisteminin verimliliği üzerinde gözlemlenebilir bir etkiye sahip olduğu için önemli bir basamaktır.

2.3.1.5. Görüntünün Sınıflandırılması

Görüntünün sınıflandırılması bir piksel ya da piksel grubunun gri değerine bağlı olarak etiketlenmesidir. En sık kullanılan bilgi toplama yöntemlerinden biridir. Etiketleme sırasında bir nesnenin çoklu özellikleri kullanır ve bunun için veri tabanında aynı nesneye ait birçok görüntünün olması sınıflandırma işlemini kolaylaştırır [29].

2.4. BASINÇ ÜLSERİ SINIFLANDIRMASI İÇİN ÇALIŞILAN MAKİNE ÖĞRENMESİ TEKNİKLERİ

Bu çalışmada görüntü ayrımı için çeşitli makine öğrenme algoritmaları denenmiştir. Bunlar;

2.4.1. Destek Vektör Makinesi (SVM)


Destek Vektör Makinesi (SVM), regresyon problemleri ya da sınıflandırma için kullanılabilen denetimli bir makine öğrenmesi algoritmasıdır. Aynı zamanda, genellikle sınıflandırma problemlerinde kullanılır. Küçük ve orta büyüklükteki veri setleri için uygundur. Destek Vektör Makinesi, temelinde iki sınıfa ait verileri birbirinden en uygun şekilde ayırmak için kullanılır. Bu sebeple karar sınırları veya başka bir isimle hiper düzlemler belirlenir. Destek Vektör Makinelerinin avantajları şöyledir; Yüksek boyutlu uzaylarda etkilidirler, Örneklem sayısının, Boyut sayısından az olduğu durumlarda etkilidirler, Karar fonksiyonunda bir takım eğitim noktaları kullanılır (“support vectors”). Böylelikle bellek verimli bir şekilde kullanılmış olur, Çok yönlüdürler. Karar fonksiyonu için birçok farklı çekirdek fonksiyonları (“kernel functions”) kullanılabilmektedir [30]. Destek Vektör Makineleri, veri setinin doğrusal olup olmasına göre ikiye ayrılmaktadır:

2.4.1.1. Doğrusal Destek Vektör Makineleri

Destek vektör makineleriyle sınıflandırmada, veri setindeki iki sınıfta verileri doğrusal olduğunda bu iki sınıfın, eğitim verisi kullanılarak elde edilen bir karar fonksiyonu yardımıyla birbirinden ayrılması amaçlanır. Veri setini ikiye ayıran doğru karar doğrusu

olarak adlandırılmaktadır. Sonsuz tane karar doğrusu çizebilme imkanı mümkün olsa da önemli kısım en uygun (optimal) karar doğrusunu belirlemektir. Karar doğrusu, yeni verisine karşı dayanıklı olabilmesi amacıyla sınır çizgisinin, iki sınıfın sınır çizgilerine en yakın uzaklıkta olması gerekmektedir. Bu sınır çizgisine en yakın noktalar, destek noktaları olarak isimlendirilmektedir. Destek vektör makineleri, sınır düzlemleri üzerinde yer alır. Bu sınıf düzlemlerinin tam ortasında bulunan, böylelikle ikisine de eşit uzaklıkta olan düzlem ise hiper düzlem olarak isimlendirilmektedir [30].

Destek vektör makineleri ile sınıflandırmada çoğunlukla $(+1, -1)$ şeklinde sınıf etiketleri kullanılmaktadır.



Şekil 2.3. Doğrusal destek vektör makineleri.

2.4.1.2. Doğrusal Olmayan Destek Vektör Makineleri


Destek vektör makineleriyle sınıflandırmada, veri setindeki veriler doğrusal olmadığında SVM'ler doğrusal bir hiper-düzlem çizemez. Bu sebeple çekirdek hilesi olarak isimlendirilen kernel trick'ler kullanılır. Bu yöntemde kernel fonksiyon uygulanarak aslında doğrusal olarak ayrılamayan sınıflar doğrusal olarak ayrılabilir hale getirilir. Çekirdek hilesi yöntemi, doğrusal olmayan verilerde makine öğrenimini büyük oranda yükseltmektedir [30].

En çok kullanılan çekirdek yöntemleri: Polynomial Kernel ve Gaussian RBF (Radial Basis Function) Kernel.

Polinomial Çekirdek (Polynomial Kernel): Veri setine polinomial öznelilikler eklemek hem istenileni verir hem de kullanışlı ve basittir. Ancak, karmaşık veri setlerinde düşük dereceden polinomlar istenileni gerçekleştirmezken, yüksek dereceden polinomlar ise

modele yüksek sayıda öznitelik eklediğinden modeli çok fazla yavaşlatabilirler. Bu tip durumlar Polinomial Çekirdek yönteminin dezavantajlarıdır [31].

Gauss Dairesel Tabanlı İşlev Çekirdeği (Gauss RBF Kernel): Bu yöntemde doğrusallaştırma terimi gibi davranan bir parametre vardır. Bu parametre arttıkça, “çan eğrisi” (bell curve) daralır. Eğer modeliniz aşırı öğreniyor ise bu parametre azaltılmalı, model eksik öğreniyor ise de bu parametre artırılmalıdır [31].



Şekil 2.4. Doğrusal olmayan destek vektör makineleri.

2.4.2. Yapay Sinir Ağları

Yapay Sinir Ağları insan beynini taklit eden yapay zeka yöntemlerindendir. Yapay sinir ağları, ağırlıklı bağlantıları kullanarak birbirine bağlanan ve her biri kendi belleğine ait işlem elemanlarından oluşan dağıtılmış ve paralel bilgi işleme yapıları; bir diğer anlamıyla, biyolojik sinir ağlarını model alıp taklit eden bilgisayar programlarıdır. İnsan sinir sistemindeki nöronların etkileşimi temel alınmıştır. Yapay sinir ağları, karşılaştığı örnekler ile ilgili bilgiler toplar, genellemeler yapar ve sonrasında daha önce karşılaşmadığı örneklerle karşı karşıya gelince öğrendiklerini kullanarak o örneklerle ilgili karar verebilmektedir [32]. Yapay sinir ağları bu genelleme yapabilme ve öğrenebilme özellikleri sebebiyle günümüzde bilim alanlarında büyük çapta uygulama olanağı bulmakta ve karmaşık problemleri çözebilmede başarılı olmaktadır. Sağlık alanında kullanıldıktan sonra mühendislik alanında oldukça yaygın bir yöntem haline gelmiştir.

Yapay sinir ağıları; görüntü-ses tanıma, tahmin, kontrol-sistem tanımlama, hata analizi, tıp, yorumlama, haberleşme, trafik, veri ilişkilendirme, veri filtreleme gibi alanlarda kullanılabilir. Yapay sinir ağıları, Geleneksel algoritmalarla karşılaştırıldığında aşağıdaki Çizelge 2.2 ortaya çıkacaktır [33].

Çizelge 2.2. Yapay sinir ağlarının geleneksel algoritmalarla karşılaştırılması [33].

Geleneksel Algoritmalar	Yapay Sinir Ağları
Hızlı sayılabilir.	Yavaştır. Hızı donanıma bağlıdır.
Hatadan düzeltilemez.	Hata düzeltilebilir.
Algoritmalar ve bilgiler kesindir.	Deneyimle çalışır.
Hazır bilgi yüklenmiş, bellek paketlenmiştir.	Bellek ayrılmış ve ağa paylaşılmıştır.
Belirlenen kurallara göre girişlerin uygulanmasıyla çıkışlar oluşur.	Giriş, çıkış bilgilerine göre kuralların koyulması öğrenme aşamasında gerçekleşir.
Tek merkezden ardışık ve eş zamanlı hesaplama yapılır.	Öğrenme sonrasında paralel, eş zamansız toplu hesaplama yapılır.


Yapay sinir ağlarının avantajları şunlardır; Hata ile karşılaştıklarında çalışmalarına devam edebilirler, böylelikle belirsiz veya eksik bilgiyle çalışabilmiş olurlar. Hatalı durumlarda kademeli bozulma (graceful degradation) gösterirler. Öğrenme becerileri vardır ve farklı öğrenme algoritmalarıyla öğrenebilirler. Sınıflandırma ve Örüntü tanıma yapabilirler. Bütün olmayan örüntüleri tamamlayabilirler. Birçok hücreden oluşurlar ve bu hücreler aynı anda çalışarak karmaşık işleri gerçekleştirir. Karşılaşılmamış çıktılar için bilgi üretebilirler. Denetimsiz öğrenim gerçekleştirilir. Gerçek zamanlı bilgiyi işleyebilmekte aynı zamanda da paralel çalışabilmektedirler [32].

2.4.2.1. Yapay Sinir Ağlarının Biyolojik Sinir Hücresi Yapısı

Biyolojik sinir hücreleri yapay sinir ağlarını oluşturur. Bu hücreler bilgiyi işlerler. İnsan beyinde yer alan sinir hücrelerinin (nöronların) sayısının yaklaşık yüz milyar olduğu düşünülmektedir [32]. Her hücre değişken başka birçok hücre ile bağlantı sağlayabilir ve insan beyinde çok yüksek sayıda bağlantı bulunduğu tahmin edilmektedir [32]. İnsan davranışlarının incelenerek, matematiksel olarak modellenmesiyle yapay modeller


oluşur. Bu işleme sibernetik adı verilir [32]. Alınması istenen sonuç eğitilebilir. Yapay Sinir ağları, kendi kendine değerlendirme yapıp öğrenebilmesiyle insan beyninin öğrenme yapısının modelini oluşturmaya çalışmaktadır. Yapay sinir ağı modellemesi için algoritmasını bilmek gerekmektedir. Algoritma, yapay sinir ağlarını verilen örneklerle eğiterek istenen çıktıya erişmeyi amaçlayan komutlardır. Yapay sinir ağlarının modellenmesinde algoritma sonuçları değişkenlik gösterir. Girilen bilgilere göre model sonuçta az veya çok öğrenebilir [32]. Girilen bilgi olarak sadece olumlu veriler değil olumsuz veriler de kullanılabilir.

Sinir hücresi, temel olarak hücre gövdesi Şekil 2.5’de görüldüğü gibi dentrit ve aksondan oluşur [33]. Hücre gövdesine dentritler ile diğer sinir hücrelerinden gelen uyarılar akson boyunca iletilir. Giriş sonucu elde edilen veriler çekirdekte kaldıktan sonra, çıkışa yine dentritler aracılığıyla akson boyunca taşınarak başka sinir hücresine bağlanır. Böylelikle hücreler arasındaki bu ilişkilerin kurulması ve ilişkilerin değişimi ile öğrenme gerçekleşmiş olur [32].



Şekil 2.5. Bir sinir hücresinin biyolojik gösterimi [32].

İnsan sinir hücresinin matematiksel olarak modellenmesiyle oluşan yapay sinir hücresi modeli aşağıdaki Şekil 2.6’de gösterilmektedir [31], [32].



Şekil 2.6. Bir sinir hücresinin matematiksel modeli [31], [32].

Bu yapay hücre beş bölümden oluşmaktadır; Girdiler, Ağırlıklar, Toplama fonksiyonu (Birleştirme fonksiyonu), Aktivasyon fonksiyonu ve Hücre çıktısı [32], [33].

Girdiler, sinir ağlarına dışarıdan gelen verilerdir. Öğrenilmesi istenen veriler girdileri belirler. Biyolojik sinir hücrelerindeki gibi çekirdekte toplanırlar.

Ağırlıklar, yapay sinir hücresine gelen verinin hücre üzerindeki etkisini ve önemini gösterir. Hücreye gelen veriler bağlantılarının ağırlıklarıyla çarpılarak çekirdeğe ulaşır. Böylelikle girdilerle çıktıların üzerindeki etki değiştirilebilir. Ağırlıkların sayısal değerlerinin önemiyle ilişkisi yoktur. Düşük sayısal değere sahip ağırlık önemli bir veriyi içerebilir.

Toplama Fonksiyonu (Birleştirme Fonksiyonu), hücreye gelen net girdiği hesaplar. Bu hesap, her gelen verinin kendi ağırlığı ile çarpılarak toplanması sonucundan oluşur.

Aktivasyon Fonksiyonu, hücrenin girdiye karşılık üreteceği çıktıyı, hücreye gelen girdilerin ağırlıklı toplamını alarak belirler. Bu çıktı sonraki katmana iletilir. Seçim yapılırken aktivasyon fonksiyonu, çoğunlukla doğrusal değildir ve türev hesaplaması kolay olmalıdır. Bazı aktivasyon fonksiyonları; Relu, sigmoid, Lineer, step, tanjant hiperbolik, eşik değer, sinüs'tür.

Rectified Linear Units (ReLU), yapay sinir ağlarında en çok kullanılan aktivasyon fonksiyonlarından biridir.

$$B(x) = \max(0, x) \quad (2.1)$$

Bu denkleme göre x değeri 0 dan büyük ise B fonksiyonu x değerini çıktı olarak verir. Eğer x değeri 0'dan küçük veya 0'a eşitse B fonksiyonu çıktı olarak 0 değerini verir. Bu problemde Yapay Sinir Ağı'nın mimarisindeki aktivasyon fonksiyonu için ReLU fonksiyonu kullanılmıştır. ReLU fonksiyonu özellikle görüntü işleme problemlerinde tercih edilmektedir. Tanh, Identity, Logistic fonksiyonları uygulanmıştır.

Sigmoid, türevi alınabilir ve sürekli fonksiyondur. Doğrusal olmadığı için en çok kullanılan diğer fonksiyondur. Girdi değerlerinin her biri için sıfır ve bir arasında değer üretir.

$$B(x) = \frac{1}{1+e^{-x}} \quad (2.2)$$

Lineer, doğrusal problemlerde kullanılır. Birleştirme fonksiyonu sonucu belirli bir katsayı ile çarpılıp çıktı hesaplanır.

$$B(x) = Z * x \quad (Z \text{ sabit sayıdır.}) \quad (2.3)$$

Step, adım aktivasyon fonksiyonudur. Net giriş değerinin belli olan eşik değerinin alt veya üst bölümünde yer almasına göre çıktı 1 veya 0 olur.

$$B(x) = \begin{cases} 1 & \text{eğer } x > \text{eşik değeri} \\ 0 & \text{eğer } x < \text{eşik değeri} \end{cases} \quad (2.4)$$

Tanjant hiperbolik, sigmoid fonksiyonuna benzerdir. Sigmoid fonksiyonunda çıkış 1 veya 0 arasındayken tanjant hiperbolik fonksiyonunda çıkış -1 veya 1 arasındadır.

$$B(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.5)$$

Eşik Değer, gelen verilerin 0 ile karşılaştırmasını yaparak çıktı üretir.

$$B(x) = \begin{cases} 0 & \text{eğer } x \leq 0 \\ x & \text{eğer } 0 < x < 1 \\ 1 & \text{eğer } x \geq 1 \end{cases} \quad (2.6)$$

Sinüs, öğrenilmesi istenen verilerin sinüs fonksiyonuyla uyumlu dağılım gösterdiğinde tercih edilir.

$$B(x) = \sin(x) \quad (2.7)$$


Hücre çıktısı, aktivasyon fonksiyonunun belirlediği çıktıdır. Girdi birden fazla olsa da tek bir çıktı olabilir. Bu çıktı, dışarıya veya başka hücreye iletilir veya hücrenin kendisine girdi olabilir.

Biyolojik sinir hücresindeki bölümlerin yapay sinir hücresindeki karşılıkları aşağıdaki Çizelge 2.3’de belirtilmiştir [33].

Çizelge 2.3. Biyolojik sinir bölümlerinin yapay sinir ağı karşılıkları [33].

Biyolojik Sinir Hücresi	Yapay Sinir Hücresi
Nöron	İşlemci kısım
Sinapslar	Ağırlıklar
Dentrit	Toplama fonksiyonu
Aksonlar	Hücre çıktısı
Hücre gövdesi	Transfer fonksiyonu

Yapay sinir ağları üç katmanda incelenir. Bunlar; giriş(input) katmanı, gizli(hidden) katmanlar ve çıkış(output) katmanıdır.



Şekil 2.7. Yapay sinir ağı mimarisi.

Bilgiler giriş katmanından gelir, Gizli katmanlarda işlenir ve çıkış katmanına iletilirler. İşleme olayı, gelen bilgilerin ağırlık değerlerinin kullanılıp çıkış üretilmesidir [32]. Girdilere göre doğru çıktılar alabilmek için ağırlıkların doğru olması önemlidir. Yapay sinir ağları, tek bir katmandan oluşuyorsa tek katmanlı sinir ağı(single layer artificial neural network) denir. Eğer birden fazla sinir ağından ve gizli katmandan oluşuyorsa buna çok katmanlı sinir ağı(multilayer artificial neural network) denir [32].

2.4.2.2. Tek Katmanlı Yapay Sinir Ağı

Sadece giriş ve çıkış katmanlarından oluşur. En basit yapay sinir ağları olarak görülür. Giriş ya direkt çıkışa ya da sonraki katmana gönderilebilir. Her bağlantının bir ağırlığı bulunur. Mantık devrelerindeki kapılara benzetilir [32]. Çoğunlukla iki girdi tek çıktısı olur. Çıkışın sıfır olmasını önleyen eşik değeri kullanılır. Eşik değeri her zaman bir alınır. Girişler ağırlıklarıyla çarpılarak eşik değeri ile toplanması sonucu çıkış elde edilir. Bu işlem girdi değerlerinin aktivasyon fonksiyonundan geçirilmesi işlemidir. Çıkış

fonksiyonu doğrusaldır ve 1 veya -1 değerleri arasında değişir. 1 değeri birinci sınıfa, -1 değeri ise ikinci sınıfa aktarılır [33].

2.4.2.3. Çok Katmanlı Yapay Sinir Ağı

Tek katmanlı yapay sinir ağlarının yetersiz olduğu durumlarda tercih edilmektedir. Şekil olarak bakıldığında doğrusal olmayan aktivasyon fonksiyonlarına sahip yapay sinir ağlarının birbirine sıralı şekilde bağlanmasıyla oluşur. Yapay sinir ağları genellikle geri beslemeli ağlar ve ileri beslemeli ağlar olarak ikiye ayrılmaktadır.

2.4.2.4. İleri Beslemeli Yapay Sinir Ağları

Sinyal çıkışı tek yönlüdür. Çoklu katmanlar halinde çalışır. Bu yüzden hücreler katmanlar halinde oluşturulur. Bir katmandaki hücrenin çıkışları bir sonraki katmana ağırlıklar vasıtasıyla giriş olarak iletilir. Bu sinir ağında giriş katmanı dışarıdan değişiklik yapmadan bilgileri alarak gizli katmana gönderir. Gelen bilgi işlenerek çıkış hesaplanır. Böylelikle doğrusal olmayan değişmez bir işlem gerçekleştirilmiş olur [33]. Ağa örnekler ve bu örneklerden istenen sonuçlar verilmektedir. Ağ, bu örneklerden genellemeler yaparak bir problem uzayı olan bir çözüm uzayı oluşturur. Sonrasında gösterilen benzer örnekler için bu çözüm uzayı sonuçlar ve çözümler üretebilir.

2.4.2.5. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağlarında, en az bir hücrenin çıktısı kendisine veya diğer hücrelere girdi olarak sağlanır ve genellikle geri besleme bir gecikme elemanı aracılığıyla sağlanır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arası hücreler arasında da gerçekleşebilir. Böylelikle geri beslemeli döngü doğrusal olmayan dinamik davranış sergiler. Bu nedenle, geri beslemenin nasıl yapıldığına göre değişik yapı ve davranışlara sahip geri besleme yapıları türetilir.

2.4.3. Derin Öğrenme Mimarileri


Yara görüntüsü analizi için kullanılan Derin Öğrenme teknikleri; derin öğrenme (DL) olarak bilinen makine öğreniminde yapay sinir ağlarının (ANNs) bir alt alanı, nesne algılama ve tanıma, akustik modelleme, ilaç keşfi ve toksikoloji gibi birçok uygulama alanında çokça kullanılmaya başlanmıştır. Bu alanda; konuşma tanıma, dil modelleme, biyoinformatik ve diğer birçok araştırma konusu bulunmaktadır [34]. İnsan beyninin biyolojik sinir ağından esinlenen derin sinir ağları, klasik makine öğrenimi modellerinden çok daha verimli bir öğrenme sürecine yol açmaktadır. Biyomedikal görüntü işlemede,

derin öğrenme yaklaşımlarının veri analizinde etkili olduğu kanıtlanmıştır [34]. Bu alanda kullanılan derin öğrenme mimarileri:

- Otomatik kodlayıcılar (AEs)
- Kısıtlı Boltzmann makinesi (RBM) ve derin inanç ağları (DBNs)
- Evrişimli sinir ağı (CNN)
- Tekrarlayan sinir ağı (RNN)

2.4.3.1. Geri Otomatik Kodlayıcılar (AEs)

Bir otomatik kodlayıcı, Şekil 2.8’de gösterildiği gibi, gizli katmanda daha az nöron kullanırken, girdide verilen çıktı ile aynı çıktıyı üretmeyi öğrenen denetimsiz bir öğrenme algoritmasıdır. Otomatik kodlayıcı, veriyi eğitirken kendi etiketlerini kendi ürettiği için öz-denetimli (self-supervised) bir öğrenme modeli olarak da geçer. Encoder(kodlayıcı) ve decoder(kod Çözücü) olmak üzere iki fazdan oluşur. Kodlayıcı kısmı, girdinin özelliklerini daha az parametre ile öğrenir ve bu nedenle boyutsallığını azaltır. Kod çözücü kısmı ise, çıktı vektörünü gizli katmandaki sıkıştırılmış vektörün bir temsili olarak üretir [35]. Otomatik kodlayıcının birden fazla gizli birimi olduğunda, yığılanmış otomatik kodlayıcı (SAE) olarak adlandırılır. Bu türden bir mimari de biyomedikal görüntü analizi kullanılmıştır ve Alzheimer sınıflandırılması ve hafif kognitif bozukluk hastalıklar gibi çeşitli görüntü işleme görevleri de etkili olduğu kanıtlanmıştır [36], [37].




Şekil 2.8. Basit bir otomatik kodlayıcı mimarisinin temsili.

2.4.3.2. Kısıtlı Boltzmann Makinesi (RBM) ve Derin İnanç Ağları (DBN's)

Girdi verileri girildiğinde, RBM parametrelerini, gizli katmanda sunulan olasılık

dağılımının girdiye mümkün olduğunca uyacak şekilde ayarlayan yapay sinir ağıdır [38]. RBM'nin ilk katmanı görünür ya da giriş katmanı ve ikinci katmanı gizli katman olarak adlandırılır. Kısıtlı BM, Şekil 2.9'da gösterildiği gibi yalnızca girdi ve gizli değişkenler arasında bağlantılara sahiptir, ama aynı katmanın iki değişkeni birbirine bağlı değildir. Katmanlar arası iletişim bulunmaz, bundan dolayı Kısıtlı Boltzmann Makinesidir. Her düğümde girdiler hesaplanır ve bir sonraki düğüme o girdiyi iletip iletmeyeceğine ilişkin rastgele kararlar verir. Derin İnanç Ağları (DBN'ler), birden çok kısıtlı Boltzmann makinesinin bir bileşimidir.



Şekil 2.9. Kısıtlı bir Boltzmann makine mimarisinin temsili.

2.4.3.3. Evrişimli Sinir Ağı (CNN)

Evrişimli sinir ağları (CNNs), biyomedikal görüntü analizi için kullanılan en yaygın derin öğrenme mimarisini temsil etmektedir, görüntü segmentasyonu ve örüntü tanımda çok verimli olduğu kanıtlanmıştır [39], [40]. Diğer ismi ConvNets'dir. Evrişim, havuzlama ve tam bağlantılı katmanlarından oluşan ileri beslemeli sinir ağlarıdır.

Evrişim Katmanı

Bu katman, evrişimli sinir ağlarının arkasındaki ana kısmı temsil eder. Özellik haritaları elde etmek amacıyla bir girdi görüntüsünün çekirdeklerle birleştirilmesine dayanır. Filtre, giriş görüntüsü boyunca hareketinde, evrişim için aynı parametreleri kullanır. Bu yüzden, oluşturulan harita, görüntüdeki belirli bir deseni karakterize eder. Böylelikle CNN, belirli kalıpları tanıyabilir ayrıca, bozulmalara ve geometrik dönüşümlere karşı dayanıklıdır. Evrişim katmanının birçok özelliği vardır. Filtre büyüklüğü, kıvrımlı alt bölgelerin büyüklüğünü tanımlar. Filtrelerin sayısı, evrişim kısmında kanal sayısını ifade eder.

Adım, görüntü boyunca filtre hareketinin adım boyutunu tanımlar.

Havuzlama Katmanı


Bu katman, önceki katmanı tekrar boyutlandırarak ağda kullanılan parametre sayısını en aza indirir. Önceki katmanın bir alt bölgesinin en yüksek veya ortalama değerini döndürür.

Tam Bağlantılı Katman

Bu katman, tüm düğümlerini önceki tüm düğümlere bağlar. Sınıflandırma amacıyla, çalışılan türün sayısına eşdeğer olan nihai çıktıyı üretir.

2.4.3.4. Tekrarlayan sinir ağı (RNN)


Tekrarlayan sinir ağlarının önemli kullanım alanları, dil modelleme, konuşma işleme ve tahmin, görüntü etiketleme alanlarındadır. Bu tip alanlarda çıktı, önceki verilerle yüksek oranda ilişkilidir. Sistemler verileri bağımsız olarak değil, bir bütün olarak işlemelidir. Bu sebeple, Tekrarlayan Sinir Ağları, karakter ve kelime dizileri ya da zaman serisi verileri gibi sıralı verileri içeren sorunlara çözüm için en uygun olanıdır. Tekrarlayan sinir ağları, Şekil 2.10'daki gibi, bir katmanın çıktısının aynı katmanın ya da önceki katmanın girdisi olduğu döngü ya da döngüler sunar. Fakat basit RNN mimarileri bazı dezavantajları vardır. Girdi veri boyutu çoğunlukla büyüktür, bu yüzden öğrenilen bağlam aralığı oldukça sınırlıdır ve bu yüzden gradyanlar, neredeyse kaybolacakları noktaya kadar çok küçük hale gelir. Bu problem, kaybolan gradyan problemi olarak adlandırılır [41]. Uzun kısa süreli bellek (LSTM) ağları, geçmiş bilgilere ulaşmak için kapılar olarak da isimlendirilen hücreler ekleyerek bu eksikliği giderir. Silinecek ve öğrenilecek bilgileri seçerek uzun dizilerin verimli bir şekilde öğrenilmesini sağlar.



Şekil 2.10. Tekrarlayan bir sinir ağı mimarisinin temsili.

2.4.4. Logistic Regresyon

Logistic Regresyon, bağımlı değişkenin kategorik olduğu durumlarda tercih edilen ve gözetimli öğrenme kategorisinde yer alan makine öğrenmesi algoritmasıdır. Logistic Regresyon, bir probleme uygulanabilmesi için verilerin kategorilere ayrılmış olması beklenir. Lojistik regresyonda tahmin edilen değerler kesikli değerlerdir. Lojistik regresyon olayların birbirinden bağımsız olmasını varsaymaktadır. Olayın olasılığı, olayın olma olasılığının, olmama olasılığına oranıdır. Lojistik regresyon modeli, bir regresyon fonksiyonu olarak olasılıkların doğal logaritmasını alır. Bir öngörücü X ile, bu $\ln[\text{odds}(Y=1)] = \beta_0 + \beta_1 X$ biçimini alır, burada $\ln$ doğal logaritmayı temsil eder, Y sonuçtur ve olay gerçekleştiğinde $Y=1$ (Y 'ye karşı) $=0$ olmadığında), β_0 kesişim terimidir ve β_1 regresyon katsayısını, X tahmininde 1 birimlik bir değişiklikte olayın olasılıklarının logaritmasındaki değişikliği temsil eder [42]. Logaritmalardaki fark değeri, iki değer oranının logaritmasına eşittir, dolayısıyla β_1 'in üst değerini alarak, X 'teki 1 birimlik bir değişime karşılık gelen oranların oranını (ods oranı) elde ederiz [42]. Lineer regresyondan farklı olarak, lojistik regresyonda β tahminleri için bir formül yoktur. En iyi tahminleri bulmak, istikrara ulaşılan kadar yaklaşık tahminlerin tekrar tekrar iyileştirilmesini gerektirir [42]. Bu, bir bilgisayarda kolayca yapılır. Logistic Regresyon ile ilgili sağlık alanında endometriyal kanser varlığı belirlenmesi [43], duygusal ve sosyal yalnızlıkla ilişkili sosyal ve demografik ilişkiler incelenmesi [44] ve COVID-19 pandemisi esnasında endoskopi yapılan hastalardaki hemostatik müdahale için kullanıldığı [45] çalışmalar olduğu görülmektedir. Logistic Regresyon modeli klasik olarak 2 sınıfı bulunan bir çıktıyı tahmin etmek için kullanılır. 2 sınıftan fazla olan problemler Multinomial Lojistik Regresyon kullanılır.



Şekil 2.11. Logistic regresyon modeli.

2.4.5. Yapay Sinir Ağları, Destek Vektör Makineleri(SVM) ve Lojistik Regresyon Yöntemlerinin Sınıflandırmada Karşılaştırması

Yapay sinir ağları, destek vektör makineleri ve lojistik regresyon, sınıflandırmada bu üç yöntem de oldukça başarılıdır. Sınıflandırmada kullanılacak yöntem belirlenirken çalışılan veri setinin iyi tanınması ve uygulanacak yöntemin veri için uygun olmasına dikkat etmek gerekir.

Küçük boyuta sahip ve düşük standart sapma değerine sahip, veri ile çalışılacaksa, lojistik regresyon yöntemi en iyi sınıflayıcı olabilir. Örnek büyüdükçe, bağımsız değişken sayısı arttıkça, değişkenler arasında çoklu ilişki söz konusuysa ve kayıp veriler varsa bu yöntem tercih edilmez. Bu durumda alternatif Kernel lojistik regresyon yöntemi, özellikle giriş değişkenlerinin sayısal özellikte olduğu durumlarda tercih edilir.


Yapay sinir ağları yarı parametrik varsayıldığından, parametrik test koşullarını sağlamayan veri setlerinde iyi bir sınıflayıcı olarak kullanılabilir. Büyük veri sektöründe, normal dağılıma sahip olmayan verilerde, bağımlı ve bağımsız değişken arasında, karmaşık ve doğrusal olmayan ilişki varlığında da çalışabilir. Kayıp verinin etkisini azaltmak, yöntemin eksik veri setlerinde de çalışmasını sağlar. Veri sayısının büyük olduğu veri setlerinde sınıflama başarısı oldukça yüksektir.

Yapay sinir ağlarının dezavantajları; eğitim adı verilen ve dışarıdan müdahale edilebilecek basit bir matematik model ile çalışıyor olması, katsayıların ve olasılık oranlarının tespit edilememesidir. Yapay sinir ağlarının sınıflamayı en uygun hale getirmek için büyük eğitim setini ihtiyacı vardır. Başlatma ve ayarlama gibi bireysel parametre değerlerini gerektirir. Güven aralığı ve katsayılarına kolaylıkla hesaplayamaz ve ağırlıkları programın kendisi ürettiği için açıklanamaz. Bunlar yapay sinir ağlarında karşılaşılabilecek sorunlardır.

Destek vektör makineleri ise küçük boyutlu veri setlerinde üretilmemiş ve gerçek veri seti ile çalışılacaksa tercih edilir. Bu yöntem standart sapmanın büyük ve sınıf sayılarının eşit olmadığı modellerde tercih edilir.

Bu çalışma ile tıbbi görüntü verilerinde aşama ayrımı probleminin çözümünde en uygun algoritmanın denetimli öğrenmede sınıflandırma olduğu görülmüştür. Bu problemin çözümü için öncelikle yapılan, hasta görüntülerinden oluşan veri setine görüntü işleme sistemlerinin uygulanmasıdır. Gerçek verilerin elde edilebilmesi için Zonguldak Bülent Ecevit Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığına başvuru yapılmıştır. Başvuru onayına kadar olan süreçte public veri seti ile Lojistik

Regresyon ve Yapay Sinir Ağları yöntemleri ile çalışılmıştır [46]. Etik kurul karar onayı ile alınan veri seti Zonguldak Bülent Ecevit Üniversitesi Plastik Cerrahi bölümünden alınan basınç ülseri hasta görüntülerinden oluşmaktadır [7]. Elde edilen görüntüler bir plastik cerrahi uzmanı tarafından kategorize edilmiştir. Sonrasında makine öğrenmesi algoritmaları ile sınıflandırma yapılmıştır. Bu işlemlerin genel özeti Şekil 2.12 ile gösterilmektedir:



Şekil 2.12. Makine öğrenimi algoritmaları ile sınıflandırma gösterimi.

Veri Ön işleme adımları 3 aşamadan oluşmaktadır.

Adım1: Resimleri toplama adıımıdır. Basınç ülseri hastalığına sahip hastaların erişilen veri setinden alınan [7] fotoğraflarının aynı tür dosya biçimi olması sağlanmıştır. Algoritmaların uygulanabilmesi için bütün fotoğraflar jpeg dosya formatında hazırlanmıştır.

Adım 2: Elde edilen fotoğraf verisindeki her bir fotoğraf bir uzman aracılığıyla basınç ülseri seviyesine göre sınıflara ayrılmıştır.

Adım3: Fotoğrafların sayısal verilere dönüştürülmesi sağlanmıştır. Sayısal veri formuna dönüşen veriler sınıflandırma algoritmalarının uygulanabilmesi için hazırlanmıştır.

Veri ön işleme adımlarından sonra basınç ülseri görüntüleri aşağıdaki gibi matris formuna dönüştürülmektedir.

Görüntü gömme işlemi ile bir veri setinde 2048 adet öznitelik bulunur. Kullanılan veri setinde 697 tane; aşama 1, aşama2, aşama3, aşama4, evrelendirelemeyen basınç ülseri ve derin doku basınç ülseri olarak sınıflandırılmış yara görüntüleri bulunmaktadır. Görüntülerin sınıflandırılması plastik cerrahi uzmanı tarafından yapılmıştır. Alınan veriler, tıp fakültesi hastahanesi verileri olduğundan dolayı genellikle yoğun bakım hastalarının görüntülerinden oluşmaktadır. Yoğun bakım hastalarında çoğunlukla aşama3, aşama4 ve evrelendirilemez basınç yarası aşamaları görülmektedir. Bundan dolayı evreler arasında görüntü sayısı farklılıkları vardır. Modellemenin daha kararlı bir sonuç vermesi amacıyla görüntüler birbirine yakın sayıda girdi olarak sağlanmış, bazı görüntüler çıkarılmıştır.



3. DENEYSEL SONUÇLAR

3.1. PUBLIC VERİLERLE YAPILAN ÇALIŞMA

Bu çalışmada basınç ülseri görüntüleri public bir veri setinden temin edilmiş ve elde edilen görüntüler bir plastik cerrahi uzmanı tarafından kategorize edilmiştir [46]. Sonrasında Lojistik Regresyon ve Yapay Sinir Ağları kullanılarak sınıflandırma yapılmıştır. Sınıflandırma algoritmalarının uygulanabilmesi için görüntüler sayısal veri formuna dönüştürülmüştür [47].

Logistic Regresyon algoritmasında L1(Lasso) veya L2(Ridge) düzenlemesi ORANGE 3.26 kullanılarak yapılmıştır. Logistic Regresyon algoritması uygulanırken boş sütun ve sınıf etiketi bulunmayan veri kaldırılır [47].

Basınç ülseri probleminde en uygun değer Ridge(L2) olduğu belirlenmiştir. Cost strength değeri en uygun 5 olarak ölçülmüştür [47]. Ridge(L2) değeri tüm parametrelerin eşit olarak düzenlendiği özel bir durumdur. Resimlerden üretilen özniteliklerin Lojistik regresyon ile formülize edilmiş hali şu şekildedir:

$$Log = \binom{q}{1-q} 0.081 x n1 + 0.001 x n2 + 0.09 x n3 + 0.78 x n4 \quad (3.1)$$

Basınç ülseri bulunan bir görüntünün hangi evrede olduğunun sınıflandırılması yapılabilmektedir [47].

Yapay sinir ağlarının basınç ülseri problemine uygulanmasında gizli katmanda 200 nöron, aktivasyon fonksiyonu olarak ReLu kullanılmıştır. Solver parametresi Adam olarak seçilmiş ve alfa Regularization değeri 0,0001 olarak belirlenmiştir. Problemin iterasyon sayısı 10000 olarak seçilmiştir. Bu parametreler yapılan deneylerden sonra elde edilen en uygun parametre değerleridir [47].

Değerlendirme ölçütü olarak kullanılan birimler; Precision (Kesinlik), Recall (Duyarlılık), Accuracy (Doğruluk).

Precision değeri:

$$Precision = TP / (TP + FP) \quad (3.2)$$

Recall değeri:

$$Recall = TP / (TP + FN) \quad (3.3)$$

Accuracy değeri:

$$Accuracy = (TP + TN) / (TP + FP + TN + FN) \quad (3.4)$$

F1 değeri:

$$F1 = (2 \times Precision \times Recall) / (Precision + Recall) \quad (3.5)$$

Çizelge 3.1. Performans parametreleri [47].

Split Ratio	Algorithm	Accuracy	F1	Precision	Recall
Train: 80 % Test : 20 %	Artificial Neural Network	0.741	0.739	0.742	0.741
	Logistic Regression	0.759	0.742	0.732	0.759
Train: 70 % Test : 30 %	Artificial Neural Network	0.547	0.533	0.533	0.547
	Logistic Regression	0.616	0.568	0.545	0.616
Train: 66 % Test : 33 %	Artificial Neural Network	0.571	0.561	0.569	0.571
	Logistic Regression	0.582	0.537	0.509	0.582
Train: 60 % Test : 40 %	Artificial Neural Network	0.570	0.553	0.539	0.570
	Logistic Regression	0.561	0.522	0.497	0.561

Eğitim ve test verileri farklı oranlarda seçilerek basınç ülseri sınıflandırma işlemi gerçekleştirilmiş ve elde edilen sonuçlar Çizelge 3.1 ile gösterilmiştir [47].

Çizelge 3.1’de Artificial Neural Network ile Logistic Regression sonuçları gösterilmiştir. Elde edilen sonuçlarda eğitim verisi arttıkça sınıflandırma başarı oranının arttığı gözlenmiştir. Verilerin %60 eğitim ve %40 test olduğu Yapay Sinir Ağları daha yüksek sonuç verirken; verilerin %66 eğitim %33 test olduğu, %70 eğitim %30 test ve %80 eğitim %20 test olduğu durumlarda Lojistik Regresyonun daha yüksek başarı accuracy değeri verdiği görülmektedir. Sonuçları incelediğimizde basınç ülseri sınıflandırma problemi için Lojistik regresyon algoritmasının daha uygun olduğu gözlenmiştir [47].

Public veriler kullanılarak yapılan çalışma, gerçek veriler öncesi Lojistik Regresyon ve Yapay Sinir Ağları yöntemlerinin görüntü sınıflandırmasında karşılaştırılması ve başarılı olup olmadıklarını gözlemleme adına çok fayda sağlamıştır. Bu tez çalışmasında gerçek veriler ile bu yöntemlerin yanı sıra yine makine öğrenmesi denetimli algoritmalarından olan, Sanal vektör makineleri (SVM) de problem çözümünde kullanılmıştır.

3.2. ÖZNETELİK ÇIKARIMI

Makine öğrenmesi, örüntü tanıma ve görüntü işleme(image processing) gibi alanlarda öznitelik çıkarımı oluşturulmaktadır. Bir model veya algoritmaya girdi olarak ölçülmüş değerler öznitelikleri oluşturmaktadır. Üretilen değerlerin açıklayıcı, bilgi verici, eksiksiz olması öğrenme sürecini olumlu etkilemektedir [48]. Bazı durumlarda özniteliklerin bireyler tarafından anlaşılması beklenirken genellikle makine öğrenmesi algoritmaları tarafından anlaşılır olması gerekmektedir.

Görüntü verilerinden sınıflandırma işlemi yapılırken görüntünün sayısal hale getirilmesi gerekir. Görüntü Gömme(Image Embedding) Derin sinir ağları ile görüntüleri yerleştirme işlemi yapar. Veri girişi için görüntülerin listesi kullanılır. Gömme(Embedding) işlemi ise görüntünün sayısal veri haline temsil edilmesini sağlar. Gömme işleminde hesaplanamayan görüntüler sayısal hale dönüştürülmezler. Dolayısıyla bu veriler görüntü sınıflandırma işleminde kullanılamazlar. Görüntü Gömme işleminde görüntüler okunarak uzak bir sunucu üzerine yüklenmektedir. Ayrıca yerel sunucuya yüklenebilmektedir. Her bir görüntü sayısal bir vektör formunda ifade edilmektedir. Bu bakımdan uygun bir görüntü resim yolu, resim tipi gibi bilgiye ihtiyaç duymaktadır Bu işlemler, ORANGE 3.26 kullanılarak yapılmıştır. Bu işlemlerin genel özeti Şekil 3.1 ile görselleştirilmiştir.



Şekil 3.1. Veri ön işleme adımları.

3.2.1. Kullanılan Derin Öğrenme Sinir Ağları

3.2.1.1. VggNet

Yeni sayılabilecek, 2014 yılında geliştirilen derin öğrenme modelidir. ImageNet 2014 yarışmasında oldukça başarılı bir performans sergilemiştir. Bu yarışmada hata oranı %7.3'tür. Oxford üniversitesinde, Simonyan ve Zisserman tarafından tasarlanan bu mimari ile 6 farklı mimari daha elde edilmiştir. Bu modellerde 11, 13, 16, 19 evrişim katmanları bulunur. Diğer derin öğrenme mimarilerinde yer alan evrişimlerden farkı, 2x2'lik ve 3x3'lük filtrelerin uygulanmış olmasıdır. VggNet mimarisinde, FC-FullConnected adında art arda 3 tam bağlı katman bulunur. Son katmanda nöron sayısı

1000'dir. Çıkışı elde etmek amacıyla yararlanılan sınıflandırma katmanında, SoftMax adında yumuşak bağlı katman yer alır.

3.2.1.2. *GoogleNet*

ILSVRC yarışmasını 2014 yılında kazanmıştır. Inception adı da verilen bu mimarinin karmaşık bir yapısı vardır. Yüksek başarımlı, %5.7 gibi düşük hata oranı ile elde edilmiştir. 144 katmandan oluşan GoogleNet mimarisinde 22 katman derinliği bulunur. GoogleNet naive ve inception modüllerini barındırır. Inception modülü boyut azaltma modülüdür. Bu modülde farklı boyutlarda filtreleme yaparak önceki derin öğrenme mimarilerinden farklı bir yapı elde edilmiştir. Kullanılan katman sayısı bağımsız yapı taşlarına göre değişebilmektedir. Inception modülünde yer alan filtreler 1x1, 3x3, 5x5 biçimindedir. Diğer mimarilerdeki art arda katman yapısından farklılaşarak derinlikli bir yapı oluşturulmuştur.

3.2.1.3. *ResNet*

ILSVRC ImageNet yarışmasında 2015 yılında %3.6 gibi çok düşük bir hata oranı ile galip olmuştur. Microsoft firmasına aittir. Normal hata oranlarının altında oluşu çok daha iyi görsel tanıma yaptığını göstermektedir. Katman sayısının diğer mimarilerden fazla olması, bu mimarilerden daha fazla derinliği içermesi farklarıdır. Bu mimaride, iki RELU fonksiyonu ile doğrusal katman arasında Residual Value denilen kalıntı değeri ve Residual Block denilen beslenen bir blok bulunur. Öğrenmenin bu mimari ile daha hızlı gerçekleşeceği düşünülmüştür. Resnet mimarisi, 152 katmandan oluşmaktadır.

Görüntü Gömme önceden belli görevler için tanımlanmış bazı Embedder(gömücüler) kullanır. Resim verileri bir sunucuya yüklenir veya yerel bir sunucu aracılığıyla vektörlerin oluşması sağlanır. SqueezeNet embedder, internet bağlantısı gerektirmeyen model kullanır. Diğer Embedder'lar internet bağlantısı gerektirmektedir. İnternet bağlantısı gerektiren Embedder görüntü verilerini saklamadan öznitelik oluşturmaktadır.

SqueezeNet: ImageNet üzerinde görüntü tanıma için eğitilmiş küçük hızlı ve internet bağlantısı gerektirmeyen modeldir.

Inception v3: Google tarafından geliştirilen ve ImageNet üzerinde eğitilmiş modeldir.

VGG-16: 16 katman bulunan ve ImageNet üzerinde eğitilmiş olan görüntü tanıma modelidir.

VGG-19: 19 katman bulunan ve ImageNet üzerinde eğitilmiş olan görüntü tanıma

modelidir.

Painters: Resimleri işleyerek ressamını tahmin etmeye çalışan bir modeldir.

DeepLoc: Maya hücresi(yeast cell) görüntülerini tanımak için eğitilmiş modeldir.

Embedder, InceptionV3, Google tarafından görüntü tanıma için geliştirilen derin sinir ağıdır. ImageNet veri kümesi ile eğitime işlemi yapılmıştır. Embedding işlemi için vektörler ile görüntüleri temsil eden önceki katmanlardaki aktivasyonlar kullanılmaktadır.

SqueezeNet, çok daha az parametre kullanarak ImageNet'te AlexNet seviyesinde doğruluk sağlayan görüntü tanıma ağıdır. SqueezeNet de InceptionV3 gibi ImageNet veri kümesinde eğitilmiştir. Önceden eğitilmiş modelin ağırlık bilgilerini kullanarak SqueezeNet yeniden uygulanmıştır. SqueezeNet, Embedding işlemi için pre-softmax(flatten10) katmanının aktivasyonlarını kullanmaktadır.

VGG16 ve VGG19, Oxford Üniversitesi bünyesinde bulunan bir grup tarafından görüntü tanım için geliştirilmiş sinir ağıdır. Hem VGG16 hem de VGG19 ImageNet veri kümesinde eğitilmiştir. Embedding işlemi için sondan önceki katman olan fc7 katmanının aktivasyonlarını kullanmaktadır.

Painters isimli Embedder ise 79433 resim üzerinde eğitilmiş ve Kaggle fotoğraf yarışmasını kazanmış bir sinir ağıdır. Ağıın önceki katmanının aktivasyonlarını Embedding olarak kullanmaktadır.

DeepLoc, 15 adet yerel bölmeden manuel olarak atanan 21.882 tek hücre görüntüsü ile oluşturulan bir evrimsel ağıdır. DeepLoc, önceden eğitilmiş ağıları kullanmaktadır. Embedding işlemi önceki katman fc_2'nin aktivasyonlarını tarafından gerçekleştirilir.

hidden origin type	category	image name	image n/Desktop/basınç image	size	width	height	n0 True	n1 True	n2 True
7	Evre 1	IMG_1189	Evre ...	3636069	4032	3024	0.1745	0.464041	0.00579197
8	Evre 1	IMG_1190	Evre ...	3740958	4032	3024	0.184769	0.480483	0.00558499
9	Evre 1	IMG_1192	Evre ...	4802707	4032	3024	0.212551	0.146594	0.0394259


n2037 True	n2038 True	n2039 True	n2040 True	n2041 True	n2042 True	n2043 True	n2044 True	n2045 True	n2046 True	n2047 True
0.248531	0.562812	0.136802	0.213454	0.00567439	0.204743	0.0321678	0.0893021	0.102522	-0.161058	0.016542
0.275439	0.317191	0.132582	0.251046	-0.00195106	0.277401	0.0609501	0.126599	0.0842732	-0.14968	0.0189613
0.234596	0.164417	0.182177	0.367472	-0.147712	0.191822	0.137733	0.0470059	0.162592	-0.29851	0.0296401

Şekil 3.2. Image Embedding işlemi sonra özellik çıkarımı.

Şekil 3.2 ile Painters modeli ile elde edilen özneteliklerin elde edilmesi gösterilmiştir.

Sınıflandırma problemi için kullanılan öznitelikler gösterilmiştir. Özniteliklerin tamamı sayısal verilerden oluşmuştur. Sayısal veriler kullanılarak sınıflandırma işlemi yapılmaktadır. Bu bakımdan Embedding işlemi ile elde edilen özniteliklerin optimum şekilde elde edilmesi son derece önemlidir. Bu bakımdan tez çalışması için farklı Embedder aracılığıyla kontrol edilmiştir.

Öznitelik çıkarımı işlemi tamamlandıktan sonra makine öğrenmesi algoritmalarının uygulanması için hazır hale getirilmiştir.



Şekil 3.3. Kullanılan yöntemler.


Şekil 3.3 ile Basınç ülseri problemini sınıflandıran algoritmalar gösterilmiştir.

Bu tez çalışmasında üniversite hastanesi ile iletişime geçilerek Basınç ülseri hastalığı hakkında veri temini için başvurulmuştur. Hastane ortamında uzmanlar tarafından fotoğraf makinesi yardımıyla elde edilen farklı hastalara ait veriler uzman tarafından derlenmiştir. Elde edilen fotoğraflar bilgisayar ortamına aktarılmıştır. Bilgisayar ortamındaki veriler plastik cerrahı uzmanı tarafından basınç ülseri hastalık evrelerine göre sınıflandırılmıştır. Etiketli basınç yarası görüntüleri makine öğrenmesi yöntemlerinden


gözetimli öğrenme kategorisindeki sınıflandırma problemine uygun hale getirilmiştir.

3.3. GÖRÜNTÜ TANIMA MODELİNİN BASINÇ ÜLSERİ SINIFLANDIRMASINA ETKİSİ


Basınç ülseri sınıflandırılması için farklı modeller kullanılmıştır.




Şekil 3.4. Inception V3 modeline göre başarımlar parametreleri.




Şekil 3.5. Inception VGG 16 modeline göre başarımlar parametreleri.




Şekil 3.6. VGG 19 modeline göre başarımlar parametreleri.



Şekil 3.7. Painters modeline göre başarımlar parametreleri.




Şekil 3.8. DeepLoc modeline göre başarımlar parametreleri.



Şekil 3.9. SqueezeNet modeline göre başarımlar parametreleri.


Tablo sonuçları göz önüne alındığında Painters modeli ile en yüksek sınıflandırma başarısı elde edilmiştir.



Şekil 3.10. Painters modelinin performansa etkisi.


3.4. GÖRÜNTÜ TANIMA MODELİNDE YAPAY SİNİR AĞLARI PARAMETRESİ NÖRON BASINÇ ÜLSERİ SINIFLANDIRMASINA ETKİSİ

Yapay sinir ağı algoritması basınç ülseri sınıflandırma problemine uygulanmış ve en uygun nöron sayısı tespit edilmeye çalışılmıştır. En uygun doğruluk (accuracy) değerinin 400 olduğu belirlenmiştir.



Şekil 3.11. Nöron sayıları değişimin performansa etkisi.

Şekil 3.11 ile gizli aktivasyonda kullanılan nöron sayılarının değişimi incelenmiştir. Nöron sayılarının değişimi YSA'nın sınıflandırma başarımını etkilemiştir. Yapılan deneylerde nöron sayılarının az olması ve çok olması değil optimum olması gerekir. Basınç ülseri sınıflandırma probleminde en uygun nöron sayısının 400 olduğu gözlenmiştir.



Şekil 3.12. Aktivasyon fonksiyonu sınıflandırma başarımı.

Şekil 3.12 ile aktivasyon fonksiyonu değişiminin Yapay sinir ağlarına etkisi gözlenmiştir. Rectified Linear Unit(ReLU) fonksiyonu diğer aktivasyon fonksiyonlarından daha yüksek başarımlar göstermiştir.

Yapay sinir ağları çıkış fonksiyonuna bağlı olarak lineer veya lineer olmayan fonksiyon olarak tanımlanabilmektedir. Sinir ağlarının kontrol edilmesi için aktivasyon fonksiyonları kullanılmaktadır. Yapay sinir ağı giriş katmanını eğitilmesi için görüntü verisinin sayısallaştırılmış hali olarak gelmiştir. Ardından doğrusal işlev yapabilmesi için aktivasyon fonksiyonları tercih edilmiştir. Bir sonraki aşamada sonuçlar girdi olarak kullanılmaktadır. Basınç ülseri sınıflandırma probleminde farklı aktivasyon fonksiyonları denenmiş ve en uygun aktivasyon fonksiyonunun ReLU fonksiyonu olduğu gözlenmiştir.

ReLU fonksiyonu yaygın olarak kullanılan aktivasyon fonksiyonlarından biridir. Basınç ülseri probleminde olduğu gibi diğer birçok problemde de ReLU fonksiyonu daha yüksek performans göstermiştir.


3.5. VERİ AYIRMA ORANININ BASINÇ ÜLSERİ SINIFLANDIRMA BAŞARIMINA ETKİSİ

Basınç ülseri görüntüleri farklı eğitim seti oranları denenmiştir. En uygun veri ayırma yöntemi hangi oranda olacağı belirlenmiştir.

Çizelge 3.2. Eğitim oranı değerleri.


Veri Ayırma Oranı	Algoritma	Doğruluk (Accuracy)	F1	Kesinlik (Precision)	Duyarlılık (Recall)
%80 Eğitim %20 Test	SVM	0.728	0.723	0.725	0.728
	YSA	0.778	0.773	0.773	0.778
	LR	0.750	0.745	0.749	0.750
Veri Ayırma Oranı	Algoritma	Doğruluk (Accuracy)	F1	Kesinlik (Precision)	Duyarlılık (Recall)
%75 Eğitim %25 Test	SVM	0.743	0.740	0.740	0.743
	YSA	0.730	0.726	0.723	0.730
	LR	0.725	0.722	0.728	0.725
Veri Ayırma Oranı	Algoritma	Doğruluk (Accuracy)	F1	Kesinlik (Precision)	Duyarlılık (Recall)
%90 Eğitim %10 Test	SVM	0.698	0.691	0.694	0.698
	YSA	0.729	0.722	0.728	0.729
	LR	0.711	0.702	0.706	0.711

Çizelge 3.2 ile eğitim oranının %80 test oranının %20 oranında olduğu belirlenmiştir. Eğitim kümesinin oranının artması her zaman başarı oranını artırmamaktadır. Eğitim setinin veri içindeki az olması da öğrenme işleminin az olmasına neden olmaktadır. Bu bakımdan en uygun veri ayırma yöntemi yapılan deney sonuçlarına göre belirlenmiştir. Uygun veri ayırma işlemi yapılmadığı küçük eğitim kümesinde underfitting(düşük öğrenme) yüksek eğitim kümesinde overfitting(yüksek öğrenme, ezberleme) yapabilmektedir.



Şekil 3.13. Görüntü temel bilgileri.

Şekil 3.13 ile Basınç yarası görüntüleri farklı evrelerine göre yükseklik, genişlik ve boyut bilgileri gösterilmiştir. Evre 3 daha yüksek genişlik özelliğine sahiptir. Derin Doku Bası Hastalığı 1000 ve 5000 genişliğe sahip olurken Evrelendirilemeyen sınıfındaki veriler genellikle 1000, 2000 ve 5000 genişliğe sahip bölgede yoğunlaşmaktadır. Evre 3 ise genellikle 5000 seviyelerinde yoğun olmuştur. Evre 2 ise 1000 ve 2000 genişlik arasında bulunurken, Evre 4 1000 ve 2000 arasında yoğunluk göstermektedir. Evre 1 ise 4000 ile 5000 arasında yoğun olmaktadır.



Şekil 3.14. Basınç ülseri hastalığının analizi.

Basınç ülseri görüntülerinin analizi gösterilmiştir. 6 farklı sınıfa ait olan Basınç ülseri görüntüleri belirtilmiştir. Orange 3.26 makine öğrenmesi programı ile elde edilen görüntüde Painters isimli özellik çıkarma modeli kullanılmıştır. Görüntülerin arasındaki mesafeler hesaplanarak Hiyerarşik kümeleme ile ifade edilmiştir. Şekil 3.14 üzerinden de görülebileceği üzere birbirine benzer özellikteki Basınç ülseri görüntüleri uzaklık bilgileri hesaplanmaktadır. Basınç yarası sınıflandırma probleminde görüntüler sayısal veriler haline dönüştürüldükten sonra algoritmaların uygulanacağı hale dönüştürülmüştür. Yapay sinir ağları, destek vektör makineleri ve lojistik regresyon algoritmaları kullanılmıştır. Basınç yarası görüntüleri özellik çıkarımı yapılması esnasında gerçek hasta verileri kullanılmıştır. Basınç yarası görüntüleri basınç yarasının farklı açılardan çekilmiş fotoğraflarda ameliyat ortamındaki görüntüler de yer almaktadır. Bu durum öznitelik çıkarımını etkilemektedir. Öznitelik çıkarımı algoritmaların uygulanıp sınıflandırma modelinin ortaya çıkmasında etkili olmaktadır. Bu bakımdan veri ön işleme aşamasında görüntülerinin temizlenmesi gibi ekstra algoritmaların da uygulanması ihtiyacı farklı çalışma alanları bakımından ortaya çıkmaktadır. Küçük boyuta sahip ve düşük standart sapma değerine sahip, veri ile çalışılacaksa, lojistik regresyon yöntemi en iyi sınıflayıcı olabilir. Örnek büyüdükçe, bağımsız değişken sayısı arttıkça, değişkenler arasında çoklu ilişki söz konusuysa ve kayıp veriler varsa bu yöntem tercih edilmez. Bu durumda alternatif Kernel lojistik regresyon yöntemi, özellikle giriş değişkenlerinin sayısal özellikte olduğu durumlarda tercih edilir. Yapay sinir ağları yarı parametrik varsayıldığından, parametrik test koşullarını sağlamayan veri setlerinde iyi bir sınıflayıcı olarak kullanılabilir. Büyük veri sektöründe, normal dağılıma sahip olmayan verilerde, bağımlı ve bağımsız değişken arasında, karmaşık ve doğrusal olmayan ilişki varlığında da çalışabilir. Kayıp verinin etkisini azaltmak, yöntemin eksik veri setlerinde de çalışmasını sağlar. Veri sayısının büyük olduğu veri setlerinde sınıflama başarısı oldukça yüksektir. Yapay sinir ağlarının dezavantajları; eğitim adı verilen ve dışarıdan müdahale edilebilecek basit bir matematik model ile çalışıyor olması, katsayıların ve olasılık oranlarının tespit edilememesidir. Yapay sinir ağlarının sınıflamayı en uygun hale getirmek için büyük eğitim setine ihtiyacı vardır. Başlatma ve ayarlama gibi bireysel parametre değerlerini gerektirir. Güven aralığı ve katsayılarına kolaylıkla hesaplayamaz ve ağırlıkları programın kendisi ürettiği için açıklanamaz. Bunlar yapay sinir ağlarında karşılaşılabilecek sorunlardır. Destek vektör makineleri ise küçük boyutlu veri setlerinde üretilmemiş ve gerçek veri seti ile çalışılacaksa tercih edilir. Bu yöntem standart sapmanın büyük ve sınıf sayılarının eşit olmadığı modellerde tercih edilir.

4. SONUÇLAR VE ÖNERİLER

Son yıllarda artan Basınç yaraları pek çok insanın yaşamını etkilemiştir. Basınç yaralarındaki zaman ve tedavi maliyetlerinin artması Basınç yarası tespitlerini önemli bir hale getirmiştir. Bu çalışma ile basınç yarası takibi için yaraların izlenmesi ve yaraların evrelerine göre sınıflandırılması önemli hale gelmiştir. Basınç yaralarının evrelendirilmesi ile tedavi süreçlerinin daha etkin yapılmasına olanak kazandırması sağlanacaktır. Bir basınç yarasının hangi evrede olduğu tespit edilerek daha hızlı tedavi yönteminin uygulanması gerçekleşecektir. Bu tezde literatürde basınç yarası problemine evrelendirme sayısı bakımından yenilik getirilmiştir. Basınç yarası evrelendirilmesi doğru bir görüntü sınıflandırma problemi şeklinde ele alınmıştır. Destek Vektör Makineleri, Logistic Regresyon ve Yapay Sinir Ağları tıbbi veri seti bulunan problemlerde oldukça sık kullanılır. Logistic Regresyon ve Yapay Sinir Ağları modellerinin matematiksel altyapıları da benzerlik gösterdiği için tercih edilmiştir. Yapay Sinir Ağlarının en yüksek sonuç verdiği gözlenmiştir. Destek Vektör Makineleri, Logistic Regresyon ve Yapay Sinir Ağları ile basınç yarası sınıflandırması yapılmış ve Doğruluk (Accuracy), Duyarlılık (Recall), Kesinlik (Precision) değerleri elde edilmiştir. Gerçek hastane verileri elde edilerek Destek Vektör Makineleri, Logistic Regresyon ve Yapay Sinir Ağları kullanılmıştır. Yapay sinir ağları, destek vektör makineleri ve lojistik regresyon, sınıflandırmada bu üç yöntem de oldukça başarılıdır. Sınıflandırmada kullanılacak yöntem belirlenirken çalışılan veri setinin iyi tanınması ve uygulanacak yöntemin veri için uygun olmasına dikkat etmek gerekir.

Küçük boyuta sahip ve düşük standart sapma değerine sahip, veri ile çalışılacaksa, lojistik regresyon yöntemi en iyi sınıflayıcı olabilir. Örnek büyüdükçe, bağımsız değişken sayısı arttıkça, değişkenler arasında çoklu ilişki söz konusuysa ve kayıp veriler varsa bu yöntem tercih edilmez. Bu durumda alternatif Kernel lojistik regresyon yöntemi, özellikle giriş değişkenlerinin sayısal özellikte olduğu durumlarda tercih edilir.

Yapay sinir ağları yarı parametrik varsayıldığından, parametrik test koşullarını sağlamayan veri setlerinde iyi bir sınıflayıcı olarak kullanılabilir. Büyük veri sektöründe, normal dağılıma sahip olmayan verilerde, bağımlı ve bağımsız değişken arasında, karmaşık ve doğrusal olmayan ilişki varlığında da çalışabilir. Kayıp verinin etkisini

azaltmak, yöntemin eksik veri setlerinde de çalışmasını sağlar. Veri sayısının büyük olduğu veri setlerinde sınıflama başarısı oldukça yüksektir.

Yapay sinir ağlarının dezavantajları; eğitim adı verilen ve dışarıdan müdahale edilebilecek basit bir matematik model ile çalışıyor olması, katsayıların ve olasılık oranlarının tespit edilememesidir. Yapay sinir ağlarının sınıflamayı en uygun hale getirmek için büyük eğitim setini ihtiyacı vardır. Başlatma ve ayarlama gibi bireysel parametre değerlerini gerektirir. Güven aralığı ve katsayılarına kolaylıkla hesaplayamaz ve ağırlıkları programın kendisi ürettiği için açıklanamaz. Bunlar yapay sinir ağlarında karşılaşılabilecek sorunlardır.

Destek vektör makineleri ise küçük boyutlu veri setlerinde üretilmemiş ve gerçek veri seti ile çalışılacaksa tercih edilir. Bu yöntem standart sapmanın büyük ve sınıf sayılarının eşit olmadığı modellerde tercih edilir.

Bu çalışmada az sayıda veri setindeki farklı açılardan elde edilen görüntülerin bulunması sınıflandırma için uzmanların sınıf değerlerini tayin etmelerinde zor olmasa da arka planda bulunan görüntüler sınıflandırmayı zorlaştırmaktadır. Hastane ve ameliyat ortamındaki çekilen fotoğraflar arka plandaki bazı fotoğraflarda yer alması bakımından öznitelik oluşturulmasına neden olmuş ve algoritmaların performansına etki etmiştir. Eğitim için daha çok veri kullanılması ve Derin Öğrenme mimarileri kullanılması performans değerlerini artıracaktır.

5. KAYNAKLAR

- [1] D. C. Klonoff, "The increasing incidence of diabetes in the 21st century," *Diabetes Science and Technology*, c. 3, sayı 1, ss. 1-2, 2009.
- [2] P. A. N. Pacific, "Prevention and treatment of pressure ulcers: quick reference guide," National Pressure Ulcer Advisory Panel, Avusturalya, Rapor, 11, 2014.
- [3] D. I. Kosmopoulos ve F. L. Tzeveleku, "Automated pressure ulcer lesion diagnosis for telemedicine systems," *IEEE Engineering in Medicine and Biology Magazine*, c. 26, sayı 5, ss. 18-22, 2007.
- [4] J. Leachtenauer, S. Kell, B. Turner, C. Newcomer, C. Lyder, ve M. Alwan, "A non-contact imaging-based approach to detecting stage i pressure ulcers," *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, New York, ABD, 2006, ss. 6380-6383.
- [5] S. D. Horn, S. A. Bender, M. L. Ferguson, R. J. Smout, N. Bergstrom, G. Taler, A. S. Cook, S. S. Sharkey ve Anne Coble Voss, "The national pressure ulcer long-term care study: pressure ulcer development in long-term care resident," *Journal of the American Geriatrics Society*, c. 52, sayı 3, ss. 359-367, 2004.
- [6] Pressure Injury Stages. (2019, 10 Şubat). [Online]. Erişim: <https://npiap.com/page/PressureInjuryStages>.
- [7] Burçin ACUNER, kişisel görüşme, Mart 2021.
- [8] D. Berlowitz ve K. E. Schmader, "Clinical staging and management of pressure-induced skin and soft tissue injury," *UpToDate. Waltham, MA. Accessed*, c. 1, sayı 2887, ss. 1-24, 2018.
- [9] A. Preston, A. Rao, R. Strauss, R. Stamm, ve D. Zalman, "Deep tissue pressure injury: a clinical review," *AJN The American Journal of Nursing*, c. 117, sayı 5, ss. 50-57, 2017.
- [10] M. Farshbaf, S. Ostadabbas, R. Yousefi, M. Nourani, ve M. Pompeo, "Pressure ulcer monitoring and intervention: a software platform," *In 2011 IEEE International Conference on Bioinformatics and Biomedicine Workshops (BIBMW)*, Atlanta, ABD, 2011, ss. 897-898.
- [11] R. Chou, T. Dana, C. Bougatsos, I. Blazina, A. J. Starmer, K. Reitel, ve D. I. Buckley, "Pressure ulcer risk assessment and prevention: a systematic comparative effectiveness review," *Annals of Internal Medicine*, c. 159, sayı 1, ss. 28-38, 2013.
- [12] J. Delode, E. Rosow, C. Roth, J. Adams, ve F. Langevin, "A wound-healing monitoring system," *ITBM-RBM*, c. 22, sayı 1, ss. 49-52, 2001.
- [13] D. M. Dhane, V. Krishna, A. Achar, C. Bar, K. Sanyal, ve C. Chakraborty, "Spectral clustering for unsupervised segmentation of lower extremity wound beds using optical images," *Journal of Medical Systems*, c. 40, sayı 9, ss. 1-10, 2016.
- [14] R. Mukherjee, D. D. Manohar, D. K. Das, A. Achar, A. Mitra, ve C. Chakraborty, "Automated tissue classification framework for reproducible chronic wound

- assessment," *Biomed Research International*, c. 2014, sayı 851582, ss. 1-9, 2014.
- [15] D. P. Ortiz, D. Sierra-Sosa, ve B. G. Zapirain, "Pressure ulcer image segmentation technique through synthetic frequencies generation and contrast variation using toroidal geometry," *Biomedical engineering online*, c. 16, sayı 1, ss. 1-19, 2017.
 - [16] F. J. Veredas, R. M. Luque-Baena, F. J. Martín-Santos, J. C. Morilla-Herrera, ve L. Morente, "Wound image evaluation with machine learning," *Neurocomputing*, c. 164, sayı 1, ss. 112-122, 2015.
 - [17] V. Dalya ve D. K. Shedge, "Design of smartphone-based wound assessment system," *2016 International Conference on Automatic Control and Dynamic Optimization Techniques (ICACDOT)*, 2016, ss. 709-712.
 - [18] J. E. Sanders, B. S. Goldstein, D. F. Leotta, ve K. A. Richards, "Image processing techniques for quantitative analysis of skin structures," *Computer Methods and Programs in Biomedicine*, c. 59, sayı 3, ss. 167-180, 1999.
 - [19] J. R. Mekkes ve W. Westerhof, "Image processing in the study of wound healing," *Clinics in Dermatology*, c. 13, sayı 4, ss. 401-407, 1995.
 - [20] P. J. Rajendran, J. Leachtenauer, S. Kell, B. Turner, C. Newcomer, C. Lyder, ve M. Alwan, "Improving the detection of stage I pressure ulcers by enhancing digital color images," *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, New York, ABD, 2006, ss. 5206-5209.
 - [21] D. I. Kosmopoulos ve F. L. Tzevelekou, "Automated pressure ulcer lesion diagnosis for telemedicine systems," *IEEE Engineering in Medicine and Biology Magazine*, c. 26, sayı 5, ss. 18-22, 2007.
 - [22] S. Seidenari, "High-frequency sonography combined with image analysis: a noninvasive objective method for skin evaluation and description," *Clinics in Dermatology*, c. 13, sayı 4, ss. 349-359, 1995.
 - [23] C. J. K. Bulstrode, A. W. Goode, ve P. J. Scott, "Stereophotogrammetry for measuring rates of cutaneous healing: a comparison with conventional techniques," *Clinical Science*, c. 71, sayı 4, ss. 437-443, 1986.
 - [24] T. D. Jones ve P. Plassmann, "An active contour model for measuring the area of leg ulcers," *IEEE Transactions on Medical Imaging*, c. 19, sayı 12, ss. 1202-1210, 2000.
 - [25] H. Wannous, Y. Lucas, ve S. Treuillet, "Enhanced assessment of the wound-healing process by accurate multiview tissue classification," *IEEE Transactions on Medical Imaging*, c. 30, sayı 2, ss. 315-326, 2010.
 - [26] Orange. (2021, 4 Mayıs). *Orange Data Mining Library*. [Online] Erişim: <https://orangedatamining.com/>
 - [27] S. Robertson, H. Azizpour, K. Smith, ve J. Hartman, "Digital image analysis in breast pathology—from image processing techniques to artificial intelligence," *Translational Research*, c. 194, sayı 1, ss. 19-35, 2018.
 - [28] S. Van der Walt, J. L. Schönberger, J. Nunez-Iglesias, F. Boulogne, J. D. Warner, N. Yager, E. Gouillart ve T. Yu "scikit-image: image processing in Python," *PeerJ*, c. 2, sayı 453, ss. 1-19, 2014.
 - [29] A. D. Belsare ve M. M. Mushrif, "Histopathological image analysis using image processing techniques: an overview," *Signal & Image Processing*, c. 3, sayı 4, ss.

23, 2012.

- [30] E. K. Ulgen (2021, 24 Temmuz). *Makine Öğrenimi Bölüm-4 (Destek Vektör Makineleri)*. [Online]. Erişim: <https://medium.com/@k.ulgen90/makine-%C3%B6%C4%9Frenimi-b%C3%B6l%C3%BCm-4-destek-vekt%C3%B6r-makineleri-2f8010824054>.
- [31] M. F. Akca. (2021, 24 Temmuz). *Nedir Bu Destek Vektör Makineleri?*. [Online]. Erişim: <https://medium.com/deep-learning-turkiye/nedir-bu-destek-vekt%C3%B6r-makineleri-makine-%C3%B6%C4%9Frenmesi-serisi-2-94e576e4223e>.
- [32] E. Yıldırım. (2021, 25 Temmuz). *Yapay Sinir Ağı(Artificial Neural Network) Nedir*. [Online]. Erişim: <https://www.veribilimiokulu.com/yapay-sinir-agiartificial-neural-network-nedir>.
- [33] N. Şengöz. (2021, 25 Temmuz). *Yapay Sinir Ağları*. [Online]. Erişim: <https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari>.
- [34] S. Zahia, M. B. G. Zapirain, X. Sevilano, A. González, P. J. Kim, ve A. Elmaghraby, "Pressure injury image analysis with machine learning techniques: a systematic review on previous and possible future methods," *Artificial Intelligence in Medicine*, c. 102, sayı 101742, 2020.
- [35] Q. V. Le, "A tutorial on deep learning part 2: autoencoders, convolutional neural networks and recurrent neural networks," *Google Brain*, c. 20, ss. 1-20, 2015.
- [36] H. I. Suk ve D. Shen, "Deep learning-based feature representation for AD/MCI classification," *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, Berlin, Heidelberg, 2013, ss. 583-590.
- [37] H. I. Suk, S. W. Lee ve D. Shen, "Latent feature representation with stacked auto-encoder for AD/MCI diagnosis," *Brain Structure and Function*, c. 220, sayı 2, ss. 841-859, 2015.
- [38] A. Fischer ve C. Igel, "An introduction to restricted Boltzmann machines," *Iberoamerican Congress On Pattern Recognition*, Springer, Berlin, Heidelberg, 2012, ss. 14-36.
- [39] S. Zahia, D. Sierra-Sosa, B. Garcia-Zapirain, ve A. Elmaghraby, "Tissue classification and segmentation of pressure injuries using convolutional neural networks," *Computer Methods and Programs in Biomedicine*, c. 159, ss. 51-58, 2018.
- [40] O. Ronneberger, P. Fischer, ve T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, Cham, 2015, ss. 234-241.
- [41] J. F. Kolen ve S. C. Kremer, "Gradient flow in recurrent nets: the difficulty of learning longterm dependencies," *A Field Guide to Dynamical Recurrent Networks*, 3. baskı, New York, ABD: Wiley-IEEE Press Yayınevi, 2003, böl. 20, ss. 237-243.
- [42] M. P. LaValley, "Logistic regression," *Circulation*, c. 117, sayı 18, ss. 2395-2399, 2008.
- [43] M. Dueholm, I. M. D. Hjorth, P. Secher, A. Jørgensen, ve G. Ørtoft, "Structured

- hysteroscopic evaluation of endometrium in women with postmenopausal bleeding," *Journal of Minimally Invasive Gynecology*, c. 22, sayı 7, ss. 1215-1224, 2015.
- [44] I. N. Fierloos, S. S. Tan, G. Williams, T. Alhambra-Borrás, E. Koppelaar, L. Bilajac, A. Verma, A. Markaki, F. Mattace-Raso, V. Vasiljev, C. B. Franse ve Hein Raat "Socio-demographic characteristics associated with emotional and social loneliness among older adults," *BMC Geriatrics*, c. 21, sayı 1, ss. 1-10, 2021.
- [45] J. W. Blackett, N. A. Kumta, R. E. Dixon, Y. David, S. Nagula, C. J. DiMaio, D. Greenwald, R. Z. Sharaiha, K. Sampath, D. Carr-Locke, A. Guerson-Gil, S. Ho, B. Lebowhl, R. Garcia-Carrasquillo, A. Rajan, V. Annadurai, T. A. Gonda, D. E. Freedberg, ve S. Mahadev, "Characteristics and Outcomes of Patients Undergoing Endoscopy During the COVID-19 Pandemic: A Multicenter Study from New York City," *Digestive Diseases and Sciences*, 2020, ss. 1-10.
- [46] Medetec. (2020, 25 Temmuz). [Online]. Erişim: <http://www.medetec.co.uk/files/publications.html>.
- [47] B. Yılmaz, E. Atagün, F. Öğülmüş Demircan ve İ. Yücedağ, " Classification of Pressure Ulcer Images with Logistic Regression," *International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*, Kocaeli, Türkiye, 2021, ss. 1-6. IEEE.
- [48] Vikipedi. (2021, 20 Temmuz). *Öznitelik Çıkarımı*. [Online]. Erişim: https://tr.wikipedia.org/wiki/%C3%96znitelik_%C3%A7%C4%B1kar%C4%B1m%C4%B1.

5.1. EK 1: ETİK KURUL KARAR ONAYI

Zonguldak Bülent Ecevit Üniversitesi, Plastik Cerrahi bölümünden alınan basınç yarası hastalarının yara görüntülerinden oluşan veri setinin etik kurul karar onayı aşağıdadır.

	T.C. ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığı	
SAYI : 2021/07 KONU : Toplantı Kararı		11/03/2021
 Sayın, Prof. Dr. İbrahim YÜCEDAĞ Düzce Üniversitesi Fen Bilimleri Enstitüsü Elektrik ve Bilgisayar Mühendisliği Anabilim Dalı Öğretim Üyesi		
Üniversitemiz Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığı'nın 10/03/2021 tarihinde yapmış olduğu toplantıda çalışmanızla ilgili almış olduğu karar ekte sunulmuştur. Bilgilerinizi ve gereğini rica ederim.		
 Prof. Dr. Günnur ÖZBAKİŞ DENGİZ Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanı		
Ek: Karar <u>1</u> adet		
Zonguldak B.E.Ü. Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu 67600 KOZLU/ ZONGULDAK, Tel:0 372 261 32 60 Fax: 0 372 261 02 65		

EK 1: (DEVAM) ETİK KURUL KARAR ONAYI



T.C.
ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar
Etik Kurul Başkanlığı

TOPLANTI TARİHİ : 10/03/2021
TOPLANTI NO : 2021/05

KARARLAR :

- 10- Düzce Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik ve Bilgisayar Mühendisliği Anabilim Dalı Başkanlığı'nın "Derin Öğrenme Teknikleri Kullanılarak Basınç Ülserlerinin Sınıflandırılması" konulu çalışmasının Etik Kurul İlkelerine uygun olduğuna,

Oy birliği ile karar verilmiştir.

A S L I G İ B İ D İ R

Prof. Dr. Günnur ÖZBAKİŞ DENGİZ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanı

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Bilge YILMAZ

Yabancı Dili : İngilizce

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Y. Lisans	Bilgisayar Mühendisliği	Düzce Üniversitesi	2021
Lisans	Bilgisayar Mühendisliği	Bülent Ecevit Üniversitesi	2021
Lisans	Bilgisayar Sistemleri Öğretmenliği	Süleyman Demirel Üniversitesi	2013
Lise	Bilgisayar Programcılığı	Düzce Ticaret Meslek Lisesi	2007

YAYINLAR

Yılmaz B., Atagün E., Öğülmüş D.F. ve Yücedağ İ. (2021)" Classification of Pressure Ulcer Images with Logistic Regression", *2021 International Conference on Innovations in Intelligent SysTems and Applications*, Kocaeli, Türkiye, 2021, ss. 1-6.