



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DERİN ÖĞRENME YAKLAŞIMLARIYLA
TIBBİ YARA GÖRÜNTÜLERİNİN
SEGMENTASYONU VE SINIFLANDIRILMASI

Hüseyin ELDEM

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Haziran-2023
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Hüseyin ELDEM tarafından hazırlanan “DERİN ÖĞRENME YAKLAŞIMLARIYLA TIBBİ YARA GÖRÜNTÜLERİNİN SEGMENTASYONU VE SINIFLANDIRILMASI” adlı tez çalışması 08/06/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü BİLGİSAYAR MÜHENDİSLİĞİ Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Harun UĞUZ

.....

Danışman

Prof. Dr. Erkan ÜLKER

.....

Üye

Doç. Dr. Şaban GÜLCÜ

.....

Üye

Doç. Dr. Hüseyin HAKLI

.....

Üye

Dr. Öğr. Üyesi Vahit TONGUR

.....

Yukarıdaki sonucu onaylıyorum.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

Bu tez çalışması Konya Teknik Üniversitesi Bilimsel Araştırma Projeleri tarafından 231113005 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Hüseyin ELDEM

Tarih:

ÖZET

DOKTORA TEZİ

DERİN ÖĞRENME YAKLAŞIMLARIYLA TIBBİ YARA GÖRÜNTÜLERİNİN SEGMENTASYONU VE SINIFLANDIRILMASI

Hüseyin ELDEM

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Erkan ÜLKER

2023, 113 Sayfa

Jüri

Prof. Dr. Erkan ÜLKER
Prof. Dr. Harun UĞUZ
Doç. Dr. Şaban GÜLCÜ
Doç. Dr. Hüseyin HAKLI
Dr. Öğr. Üyesi Vahit TONGUR

Tıp alanında doktorların her ne kadar çalıştığı uzmanlık alanında becerileri yüksek olsa da, aynı hasta için farklı zamanlarda farklı karar verme durumları ve tedavi önermeleri söz konusu olabilmektedir. Bu durum, karar verme süreçlerinde danışılanlar arasında farklılıklara yol açabilmektedir. Bu tür özelliklerin azaltılması ve giderek ortadan kalkabilmesi için tüm dünyada doktorlara yardımcı olabilecek nicel ölçütlere dayalı tanı sistemlerinin geliştirilmesi çalışmaları gün geçtikçe artmaktadır.

Bu tez çalışmasında derin öğrenme tabanlı evrimsel sinir ağı (ESA) yöntemleriyle tıbbi yara görüntülerinin segmentasyonu ve sınıflandırılmasının sağlanması amacıyla farklı yöntemler önerilmiştir. Tez çalışmasının kapsamı şu şekildedir: (i) Anlamsal bölütleme (semantik segmentasyon) yöntemleriyle yara görüntülerinin mevcut görüntüden ayrıştırılması, (ii) Ayrıştırılan görüntülerin literatürde güncel derin öğrenme mimarileri ile sınıflandırılması, (iii) Sınıflandırma aşamasında en iyi sonuçlar veren mimari için parametre optimizasyonunun yapılması, (iv) En başarılı yöntemden yola çıkılarak evrimsel sinir ağları modellerinin tasarlanmasıdır.

İlk olarak tıbbi yara görüntülerinin segmente edilmesi için kodlayıcı-kod çözücü (encoder-decoder) temelli 20 farklı yaklaşım ele alınmıştır. Kodlayıcı-kod çözücü tabanlı derin öğrenme mimarilerinin segmentasyon başarıları ile yara görüntülerinin segmentasyonunda farklı özellik çıkarıcı ESA mimarilerinin temel model olarak kullanıldığı durumlardaki segmentasyon başarıları incelenmiştir. Segmentasyon işleminde ön eğitilmiş derin öğrenme mimarilerinin yanı sıra 5 katmanlı bir Vanilla ESA ağı tasarlanmış ve segmentasyonda temel model olarak kullanılmıştır. Literatürde kodlayıcı-kod çözücü segmentasyon yöntemleriyle tıbbi yara görüntülerinin segmente edilmesi ilk defa bu tez kapsamında gerçekleştirilmiştir.

İkinci olarak, yara görüntülerinin granül, nekrotik ve slough sınıflarından hangisine ait olacağına karar verecek şekilde sınıflandırma probleminde, yöntemlerin sınıflandırma başarıları araştırılmıştır. Bunun için 19 adet ESA mimarisinin veri seti üzerinde sabit tanımlı parametrelerle başarılarının ölçülmesi hedeflenmiştir. Sonraki aşamada ise ESA mimarilerinde kullanılan parametre değerlerinin sonuçlar üzerindeki etkisi ele alınmıştır. Çalışmada yara görüntülerinin sınıflandırılmasında başarıyı en iyi bulan epok sayısı, yığın boyutu ve öğrenme hızı parametrelerinin bulunması da ele alınmıştır.

Üçüncü olarak, 19 adet ESA mimarisinden, en başarılı yöntem olan AlexNet mimarisine odaklanılmıştır. Özgün olarak üretilen bir yara veri seti üzerinde, basınç ve diyabetik ayak yarası görüntülerinin sınıflandırılmasında kullanılan eğitim parametrelerinin başarıyı ne kadar etkilediği incelenerek, optimum sonuçların bulunmasında hangi parametre(ler)in etkili olduğu araştırılmıştır. Yapılan

parametre optimizasyon deneylerinde, değerlendirme metrikleri üzerinde yapılan değişimler incelendiğinde öğrenme hızı parametresinin $1e-4$ değerinde optimum değerleri ürettiği gözlenmiştir.

Son olarak optimum sonuçların elde edildiği parametreler ile en iyi sonuçların elde edildiği AlexNet mimarisi modifiye edilmiş, farklı versiyonları önerilmiş ve sınıflandırma başarıları incelenmiştir. Farklı sayıda evrişim katmanına sahip yeni modeller üretilerek performansları ölçülmüş ve yara görüntülerinin tanımlanmasındaki başarımları karşılaştırılmıştır. Ayrıca AlexNet mimarisinin sınıflandırma katmanında bulunan Softmax Sınıflandırıcı yerine Destek Vektör Makinesi (SVM) sınıflandırıcısı da kullanılarak, karşılaştırmalı deneyler yapılmıştır. Bu modellerin eğitim ve test aşamalarında kullanılmak üzere yara görüntülerine ait 2100 adet görüntüden oluşan özgün yeni bir veri seti de oluşturulmuştur.

Segmentasyon için tasarlanan kodlayıcı-kod çözücü tabanlı modeller arasında en yüksek doğruluğu elde eden MobileNet-UNet modelinin başarısı %99.67 olarak bulunmuştur. Sınıflandırma işlemi için en yüksek doğruluğa sahip ESA modeli AlexNet mimarisinin başarısı ise %95.83 olarak elde edilmiştir. Son olarak AlexNet mimarisinin geliştirilmesiyle önerilen modeller arasında altı evrişim katmanına sahip 6Conv_SVM modeliyle sınıflandırma doğruluğu %98.85 başarıya yükseltilmiştir.

Özetle bu tez çalışmasında, tıbbi yara görüntüleri üzerinde otomatik karar vermeye yardımcı yeni yöntemlerin tasarlanması hedefiyle, derin öğrenme evrişimsel sinir ağı yöntemleri kullanılarak tıbbi yara görüntülerinin segmentasyonu ve sınıflandırılması için yeni yöntemler önerilmiştir.

Anahtar Kelimeler: Basınç Yaraları, Derin Öğrenme, Diyabetik Ayak Yaraları, Evrişimsel Sinir Ağları, Transfer Öğrenme, Yara Segmentasyonu, Yara Sınıflandırması, Yapay Zekâ.

ABSTRACT

Ph.D THESIS

SEGMENTATION AND CLASSIFICATION OF MEDICAL WOUND IMAGES WITH DEEP LEARNING APPROACHES

Hüseyin ELDEM

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Prof. Dr. Erkan ÜLKER

2023, 113 Pages

Jury

Prof. Dr. Erkan ÜLKER

Prof. Dr. Harun UĞUZ

Assoc. Prof. Dr. Şaban GÜLCÜ

Assoc. Prof. Dr. Hüseyin HAKLI

Assist. Prof. Dr. Vahit TONGUR

In the field of medicine, although doctors have high skills in the specialty they work in, different decisions and treatment recommendations can be made for the same disease at different times. This may lead to differences among observers in decision-making processes. In order to reduce and gradually eliminate such subjectivity, efforts to develop diagnostic systems based on quantitative criteria that can help doctors all over the world are increasing day by day.

In this thesis, different methods have been proposed to provide segmentation and classification of medical wound images with deep learning convolutional neural network methods. The scope of the thesis work is as follows: (i) Segmentation of wound images from the existing image by semantic segmentation methods, (ii) Classification of the segmented images with popular deep learning architectures in the literature, (iii) Parameter optimization for the architecture that gives the best results in the classification phase, (iv) Designing new convolutional neural network models based on the most successful method.

First, 20 different encoder-decoder-based methods are discussed for segmenting medical wound images. The study discusses how deep learning performs in this field by examining the effects of these approaches on pixel-level (pixel-based) classification when used together with different featureextracting CNN architectures in the segmentation of wound images. Thus, the study also examines the segmentation success of the base (backbone) model. In the segmentation process, in addition to the pre-trained deep learning architectures, a 5-layer vanilla CNN network was designed and used as the base model in the segmentation. To our knowledge of the literature, this is the first attempt to segment medical wound images with encoder-decoder semantic segmentation methods undertaken within the scope of this thesis.

Secondly, classification performances were investigated to decide whether the wound images belonged to granule, necrotic, and slough classes. For this, it is aimed to measure the success of 19 CNN architectures with constantly initialized parameters on the data set. The next stage discusses the effect of parameter values used in CNN architectures on the results. At this stage, finding the epoch number, batch size, and learning rate parameters that find the best success in the classification of wound images are also discussed.

Thirdly, AlexNet architecture, which is the most successful method among 19 CNN architectures, is discussed. The effect of training parameters used in the classification of pressure and diabetic foot wound images on success was examined and investigated which parameter/s were effective in finding the optimum results.

In the parameter optimization experiments, when the changes made to the evaluation metrics were examined, it was observed that the learning rate parameter produced the optimum values at the value of $1e-4$.

Finally, by using the parameters with which optimum results are obtained, the AlexNet architecture, in which the best results are obtained, has been modified, different versions have been proposed and the classification successes have been examined. The performances of the models with different number of convolution layers were measured and their performances in defining the wound images were compared. In addition, comparative experiments were carried out by using the SVM classifier instead of the Softmax Classifier in the classification layer of the AlexNet architecture. A unique data set consisting of 2100 images of wound images was created to be used in the training and testing stages of these models.

The success of the MobileNet-UNet model, which achieved the highest accuracy among the encoder-decoder-based models designed for segmentation, was achieved at 99.67%. The success of the AlexNet architecture, which is the CNN model with the highest accuracy for the classification process, has been achieved at 95.83%. In addition, with the development of the AlexNet architecture, the classification accuracy was increased to 98.85% with the 6Conv_SVM model, which has six convolution layers, among the proposed models.

In summary, in this thesis, new methods have been proposed for the segmentation and classification of medical wound images with deep learning CNN methods with the aim of designing new methods for automatic decision-making on medical wound images.

Keywords: Artificial Intelligence, Convolutional Neural Networks, Deep Learning, Diabetic Foot Ulcers, Pressure Wounds, Transfer Learning, Wound Classification, Wound Segmentation.

ÖNSÖZ

Doktora tez çalışmam boyunca teşvik edici fikirleriyle bana rehberlik eden, fikirleriyle çalışmaya yön veren, önerilerini ve katkılarını esirgemeyen, akademik hayattaki kariyerim sürecinde bana engin bir bakış açısı kazandıran, çok değerli hocam, danışmanım, Sayın Prof. Dr. Erkan ÜLKER hocama en içten teşekkürlerimi sunuyorum.

Tez izleme komitesinde bulunarak fikir ve önerileriyle çalışmalarına yön veren çok değerli hocalarım Sayın Prof. Dr. Harun UĞUZ ve Sayın Doç. Dr. Şaban GÜLCÜ'ye teşekkür ediyorum.

Tez çalışmalarımnda veri setinin elde edilmesi, yorumlanması ve tıp dünyasının bu konudaki taleplerini benimle paylaşan, Dr. Öğr. Üyesi Osman Yaşar IŞIKLI hocama yapmış olduğu katkıdan dolayı teşekkür ederim.

Beni her konuda yüreklendiren, dualarını eksik etmeyen biricik annem Müşerref ELDEM'e, çalışmalar boyunca her türlü hoşgörüyü ve fedakârlığı gösteren her zaman yanımda olan, sevgili hayat arkadaşım, kıymetli eşim Dr. Öğr. Üyesi Ayşe ELDEM'e, moral ve motivasyon kaynağım oğullarım Mehmet Ali ELDEM ve Furkan Eymen ELDEM'e, ailemin son gül goncası kızım Gülce Vera ELDEM'e ithaf ederim.

Hüseyin ELDEM
KONYA-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1. Tezin Amacı ve Önemi	3
1.1.1 Tezin Amacı.....	3
1.1.1 Tezin Önemi	5
1.2. Tezin Organizasyonu	6
2. KAYNAK ARAŞTIRMASI	8
2.1. Medikal Görüntü Analizinde Kullanılan Derin Öğrenme Mimarilerine ait Genel Çalışmalar	8
2.2. Yara Bakımı için Segmentasyon ve Sınıflandırmaya ait Çalışmalar.....	11
2.3. Kronik Yara Görüntülerinin DÖ Teknikleriyle Segmentasyonu	15
2.4. Kronik Yara Görüntülerinin DÖ Teknikleriyle Sınıflandırılması	17
2.5. AlexNet Mimarisi Eğitim Parametrelerinin Etkisi ve AlexNet Mimarisinin Modifikasyonları.....	19
3. MATERYAL VE YÖNTEM.....	21
3.1. Medikal Görüntü İşleme, Tıbbi Yara Görüntü Yorumlama ve Derin Öğrenme .	21
3.2. Evrimsel Sinir Ağları (ESA)	22
3.2.1 ESA Katmanları	23
3.2.2. ESA Eğitim Parametreleri	30
3.2.3. Yara Segmentasyonunda ESA Modelleri	32
3.2.3.1 Segmentasyon ESA Modelleri (Kod Çözücü Modeller)	32
3.2.3.2 Kodlayıcı (Backbone) ESA Modelleri.....	35
3.2.4. Yara Sınıflandırmasında ESA Modelleri	37
3.3. Transfer Öğrenme (TÖ)	39
3.4. Kullanılan Veri Setleri	41
3.4.1 Veri Arttırma (Data Augmentation) Teknikleri.....	44
3.4.1.1 Yara Segmentasyonunda Veri Arttırma Teknikleri	44
3.4.1.2 Yara Sınıflandırmasında Veri Arttırma Teknikleri.....	45
4. ÖNERİLEN YÖNTEMLER.....	46
4.1. Önerilen Segmentasyon Modellerinin Tasarımı	46
4.2 Önerilen Sınıflandırma Modellerinin Tasarımı	48
4.2.1. Başarılı Model Tespiti	48

4.2.2. En Başarılı Model AlexNet için parametre etkilerinin incelenmesi	49
4.2.3. AlexNet Modelinin Performansının Geliştirilmesi.....	50
5. DENEYSEL ÇALIŞMALAR VE TARTIŞMA	58
5.1. Performans Değerlendirme Ölçütleri.....	58
5.2. Segmentasyon Deneysel Analiz Sonuçları	60
5.2.1. Tartışma	66
5.3. Sınıflandırma Deneysel Analiz Sonuçları.....	67
5.3.1. Optimum Parametreler Kullanılarak Mimarilerin Performans Testleri.....	73
5.3.2. Tartışma	76
5.4. AlexNet Mimarisinde Parametre Optimizasyonu.....	77
5.4.1. Tartışma	85
5.5. Yara Görüntüsü Sınıflandırmada AlexNet Mimarisinin Modifiye Edilmesi.....	85
5.5.1. Tartışma	92
6. SONUÇLAR VE ÖNERİLER	93
6.1 Sonuçlar	93
6.2 Öneriler	95
KAYNAKLAR	97
EKLER	111

SİMGELER VE KISALTMALAR

AUC	: Eğri Altında Kalan Alan (Area Under the Curve)
ROC	: Alıcı İşlem Karakteristiği (Receiver Operating Characteristics)
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
GPU	: Grafik İşlem Birimi (Graphic Processing Unit)
DÖ	: Derin Öğrenme (Deep Learning)
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
ESA	: Evrimsel Sinir Ağları (Convolutional Neural Networks-CNN)
ILSVRC	: Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge)
MÖ	: Makine Öğrenmesi (Machine Learning-ML)
ReLU	: Düzleştirilmiş Doğrusal Birim (Rectified Linear Unit)
YSA	: Yapay Sinir Ağları (Artificial Neural Networks-ANN)
SGDM	: Momentumlu Stokastik Gradyan İniş (Stochastic Gradient Descent with Momentum)
Adam	: Uyarlanabilir An Tahmini (Adaptive Moment Estimation)
RMSProp	: Kök Ortalama Kare Yayılımı (Root Mean Squared Propagation)
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
EK	: Evrişim Katmanı
OK	: Ortaklama Katmanı
TBK	: Tam Bağlantılı Katman
FCNs	: Tam Evrimsel Ağlar (Fully Convolutional Networks)
PSPNet	: Piramit Sahne Ayrıştırma Modeli
RGB	: Kırmızı, Yeşil, Mavi Renk Uzayı (Red, Green, Blue)
YZ	: Yapay Zekâ (Artificial Intelligence-AI)
Encoder-Decoder	: Kodlayıcı-kod çözücü
PU	: Basınç Yarası (Pressure Ulcer)
DFU	: Diyabetik Ayak Yarası (Diabetic Foot Ulcer)
CU	: Kronik Yaralar (Chronic Ulcers)
TÖ	: Transfer Öğrenmesi (Transfer Learning)
EPUAP	: Avrupa Basınç Ülseri Danışma Paneli
NPUAP	: Ulusal Basınç Ülseri Danışma Paneli
SVM	: Destek Vektör Makinesi (Support Vector Machine)

1. GİRİŞ

Tezin odağındaki problem olan kronik yaralar, ciltte ve/veya altta yatan yumuşak dokuda, genellikle kemikli bir belirginlikte veya tıbbi bir cihaz veya başka bir cihazla ilişkili olarak oluşan bölgesel (lokal) hasardır. Basınç yaralanmaları sağlam cilt veya açık yaralanma şeklinde ortaya çıkabilir ve ağrılı olabilir. Bu tür yaralanmalar, yoğun ve uzun süreli temas veya basınç sonucu oluşur (Ulusal Basınç Ülseri Danışma Paneli [NPUAP-National Pressure Ulcer Advisory Panel], 2014) (Haesler, 2014), (Panel, 2009), (Pieper, 2012) Basınç yaralanmaları, yatak yarası (bedsore), bası yarası (pressure sore- pressure wound), dekübit (decubit), dekübit ülseri (decubit ulcer) gibi terimlerle de ifade edilmektedir.

Kronik basınç yaralarının iyileşme sürecinde ağrı ve enfeksiyon nedeniyle hastanede kalış süresinin uzaması ve bakım maliyetlerinin artması gibi olumsuz etkiler ortaya çıkmaktadır. Genellikle, tedavi sürecinin uzun olmasından dolayı uzun süreli tıbbi bakım gerektirmektedir (Sen ve ark., 2009). Dünya çapında milyonlarca hastayı etkilediğinden sağlık sistemlerine ciddi bir ekonomik yük getirmektedir. Sadece Amerika Birleşik Devletleri'nde tahmini 6,5 milyon hasta kronik yaralardan etkilenmektedir. Kronik yara bakımının tüm yönleri için yıllık 25 milyar dolardan daha fazla bir maliyet ve çok fazla zaman harcanmaktadır (Fauzi ve ark., 2015; Mervis ve Phillips, 2019; Alipoor ve ark., 2021; Yilmazer ve Tuzer, 2022).

Artan sağlık bakım maliyetleri, yaşlanan nüfus, diyabet ve obezite sağlık sorunlarının dünya çapında giderek artması nedeniyle problemin önemi gün geçtikçe daha çok dikkat çekmektedir (Bauer ve ark., 2016). Kronik yaralar ayrıca, hasta ve yakınlarının maddi ve manevi kayıplarına da sebep olmaktadır (Frykberg ve Banks, 2015; Tubaishat ve ark., 2018; Sen, 2019). Kapsamlı deri değerlendirmesi ile birlikte doğru risk değerlendirmesi, yüksek riskli hastalar arasında ortaya çıkan basınç yaralanmalarının hızla tanımlanmasını ve tedavi edilmesini sağlar (Alderden ve ark., 2017).

Hastaların kendisi ve ülkelerin sağlık sistemi için yüksek maliyetli olan basınç ve diyabetik ayak yaraları gün geçtikçe yeni çalışmalara konu olan, üzerinde araştırmalar yapılması gereken bir konudur. Hastaların acı çekmesi ve yaşam standartlarının düşmesi yanında, hastanelerdeki bakım sürelerinin uzaması ve maliyetlerin çok olması gibi sorunların azaltılabilmesi için katkı sunabilecek çalışmalara ihtiyaç duyulmaktadır (Gefen, 2022; Hultin ve ark., 2022; Jodheea-Jutton ve ark., 2022; Parisod ve ark., 2022; Sun ve ark., 2022a; Sun ve ark., 2022b).

Yara görüntülerini analiz etmek, yara dokusu bileşimini karakterize etmek, hastanın ziyaretleri arasında yaranın değişimlerini izlemek için hızlı ve güvenilir yöntemlere gün geçtikçe daha çok ihtiyaç duyulmaktadır. Bunun için hem maliyetleri düşürücü tedavi yöntemlerinin doktorlar tarafından daha hızlı ve daha doğru alınabilmesi hem de iyileşme süreçlerinin daha kısa sürede tamamlanabilmesi için yeni yaklaşımlar geliştirilmektedir.

Kronik yaraların klinikler tarafından manuel olarak görsel bir şekilde değerlendirilmesi, zaman ve işgücü olarak maliyetli olmaktadır. Ayrıca yara alanının değerlendirilmesinde görecelilik (subjective) olduğundan değerlendirmede yüksek hata payı söz konusu olabilmektedir (Kim ve ark., 2022b; Morrison ve ark., 2022). Sonuçların objektif olması, geleneksel yöntemlerle değerlendirmede oluşabilecek sorunların ortadan kaldırılabilmesi için bilgisayar destekli zeki sistemlerin tasarlanması, tıbbi sorunların en aza indirilmesine yardımcı olacaktır.

Risk altındaki hastaların tanımlanması ve yaranın iyileşme sürecinde takibinin yapılabilmesi için de yara dokularının yüksek doğrulukla sınıflandırılarak takip edilebilmesi büyük önem taşımaktadır. Hastanelerdeki hastalardan elde edilen görüntülerin analizine ve takibine yardımcı olmak amacıyla yapılan çalışmalar, yeni yaklaşımların geliştirilmesi ve mevcut yaklaşımların iyileştirilmesi şeklinde ele alınmaktadır.

Bu tez çalışması kapsamında, kronik yara görüntülerini içeren medikal görüntülerin segmentasyonu ve sınıflandırılması ele alınmıştır. İlk olarak hastalardan toplanan görüntülerden yara bölgesinin kodlayıcı-kod çözücü tabanlı segmentasyon yöntemleriyle segmente edilmesi sağlanmıştır. Ardından bu görüntülerin granül nekrotik ve slough sınıflarına ayrıştırılmasında derin öğrenme mimarileri incelenmiştir. Yara görüntülerini en iyi tanıyan ESA mimarisinin tespit edilmesi, bu mimarinin hangi parametre eşlerinde daha iyi sonuçlar elde edildiğinin etkisi araştırıldıktan sonra bu mimariden esinlenilerek, farklı geliştirilmiş özgün ESA mimarileri önerilmiştir. Önerilen yöntemlerin sınıflandırma başarıları, değerlendirme metrikleri ile tez kapsamında üretilen özgün veri seti üzerinde test edilerek sonuçları hesaplanmıştır. Tez çalışmasındaki segmentasyon ve sınıflandırma için ele alınan mimarilerin detayları Bölüm 4'te sunulmuştur.

1.1. Tezin Amacı ve Önemi

1.1.1 Tezin Amacı

Basıncılı yaralanmalar, ağrı ve enfeksiyon nedeniyle yaşam kalitesini düşürür, hastanede kalış süresini uzatır ve bakım maliyetini arttırır. Basıncı yaralanmalarını önlemek için ayrılan süre, bakım ve tedavileri için ayrılanlardan daha kısa ve daha az maliyetlidir. Genellikle iyileşmeye dirençli ve uzun süreli tıbbi bakım gerektirmektedir (Sen ve ark., 2009).


Basıncı yaraları, hastanın uzun süre aktif olmaması nedeniyle ortaya çıkan cilt hasarlarıdır. Dış yüzey ile kemik belirginliği arasındaki yumuşak dokuyu azaltarak kılcal kan damarlarının tıkanmasına neden olurlar. Bu nedenle, kan akımı azalır ve nekroz ve hücre ölümüne yol açan kas ve cilt iskemisine yol açarlar (Ortiz ve ark., 2017). Basıncı yaralanmalarının önlenmesinde temel prensip risk altındaki hastaların önceden belirlenerek basıncın giderilmesi için uygun tedbirlerin alınmasıdır (Sullivan ve Schoelles, 2013).

Kapsamlı deri değerlendirmesi ile birlikte doğru risk değerlendirmesi, yüksek riskli hastalar arasında ortaya çıkan kronik yaralanmalarının hızla tanımlanmasını ve tedavi edilmesini sağlar (Alderden ve ark., 2017).

Basıncı yaralarının değerlendirmesinde EPUAP (Avrupa Basıncı Ülseri Danışma Paneli) ve NPUAP tarafından geliştirilen sınıflandırma sistemi kullanılmaktadır. Basıncı yaralanmalarında, deri ve doku hasarı dört düzeyde ortaya çıkmaktadır. Evrelendirilemeyen derin doku hasarları da ayrı olarak evrelendirilmektedir (Garcia-Zapirain ve ark., 2017), (Guadagnin ve ark., 2014), (Pieper, 2012), (Bulut, 2019).

Aynı şekilde diyabetik ayak yaralarının değerlendirilmesi, sağlık ekonomisi ve tedaviyi hızlandırma eğilimleri açısından, araştırmalarda güncel bir konu olarak ele alınmaktadır (Jodheea-Jutton ve ark., 2022). 2021'de dünya genelinde 536.6 milyon kişinin diyabet hastası olduğu, 2045 yılında ise hızla artarak 783.2 milyon kişiye ulaşacağı tahmin edilmektedir. Klinik olarak, asemptomatik aşama (asymptomatic stage) esnasında daha erken tanı koyma ve tedavinin daha erken başlatılmasını sağlamak için önemlidir (Ogurtsova ve ark., 2022; Sun ve ark., 2022a). Yara dokularının yüksek doğrulukla otomatik olarak sınıflandırılması ve takip edilebilmesi, uygulanacak yara bakımı (woundcare) nın tanımının doğru yapılabilmesi için büyük önem arz etmektedir (Powers ve ark., 2016). Kronik yara dokusu, sırasıyla kırmızı renkli granül dokulu, sarı

renkli slough dokulu ve siyah renkli nekrotik dokulu olarak Şekil 1.1'deki gibi sınıflandırılabilir.



Şekil 1.1. Yara Dokusu Çeşitleri

Yukarıda bahsedilen nedenler dikkate alındığında kronik yaraların görüntülerinin analiz edilmesi, yara dokusu bileşiminin karakterize edilebilmesi ve uygun tedavi yaklaşımlarının ortaya konmasının bilgisayar ortamında geliştirilen akıllı bir modelle ortaya konması uygun tedbir ve tedavilerin uygulanmasına büyük katkı sağlayacaktır.

Sınıflandırma, bir veri kümesinde bulunan değerlerin, önceden belirli kategorilerden hangisine ait olacağını ön görülmesi işlemidir. Herhangi bir hastalık ile ilgili geliştirilen bir sınıflandırmanın hem akılda tutulmasının kolay olması hem de o hastalığı ayrıntılarıyla tarif edebilmesi beklenir. İdeal bir sınıflandırılmada benzer özellikler taşıyan hasta grupları için belirli bir tedavi yaklaşımı ortaya konabilir ve hastalar arasındaki tedavi sonuçları karşılaştırılabilir. Ayrıca iyi bir sınıflandırma ile elde edilen sonuçlar hakkında çıkarımlar, tahminler yapılabilmesine olanak tanınmaktadır.

Makine öğrenmesi (MÖ), bilgisayar sistemlerinin, dışarıdan herhangi bir talimat almadan, kalıplara (pattern) ve çıkarımlara (inference) dayanan, belirli bir görevi yerine getirmek için kullandığı algoritmaların ve istatistiksel modellerin bilimsel bir çalışmasıdır. Yapay zekanın bir alt kümesi olarak görülür. Makine öğrenme algoritmaları, belirtilen görevi gerçekleştirmek üzere öngörülerde veya kararlarda bulunmak için "eğitim verileri" olarak bilinen örnek verilerden matematiksel bir veri modeli oluşturur. Makine öğrenmesi, matematiksel ve istatistiksel yöntemler kullanarak mevcut verilerden çıkarımlar yapan, bu çıkarımlarla bilinmeyene dair tahminlerde bulunan yöntem paradigması olarak da ifade edilebilir (Wikipedia, 2019).

Son dönemlerde Grafiksel İşlem Birimi (GPU) nun hesaplama kabiliyetlerinin de artmasıyla geleneksel makine öğrenmesi yöntemlerinin alt kümesi olan derin öğrenme

(DÖ) yöntemleriyle görüntüler üzerinde başarısı yüksek modeller üretilmesi amacıyla çalışmalar yapılmaktadır.

Medikal görüntüler üzerinde otomatik karar vermeye yönelik yeni yöntemlerin tasarlanması ve geliştirilmesi, insanların görsel yorumlama ve karar verme süreci ile benzer biçimde işleyen otomatik karar verme sistemlerini tasarlayabilmek hususları doğrultusunda, bu tez çalışmasında, derin öğrenme evrimsel sinir ağı yöntemleriyle tıbbi yara görüntülerinin segmentasyonu ve sınıflandırılmasının sağlanması amaçlanmaktadır.

1.1.1 Tezin Önemi

Artan sağlık bakım maliyetleri, yaşlanan nüfus, diyabet ve obezite sağlık sorunlarının dünya çapında giderek artması nedeniyle problemin önemi gün geçtikçe daha çok dikkat çekmektedir (Bauer ve ark., 2016). Örneğin, Amerika Birleşik Devletleri'nde tahmini 6,5 milyon hastanın, kronik yaralardan etkilendiği rapor edilmiştir. Kronik yara bakımının tüm yönleri için para yönünden yıllık 25 milyar dolardan daha fazla bir maliyet ve sayısız saat harcanmaktadır (Fauzi ve ark., 2015). Yatılı hastalar ve ayakta tedavi merkezlerinde zamanında ve doğru bir şekilde kronik yara tedavi süreçlerinin kayda alınıp dokümantasyonun yapılabilmesi gerekmektedir. Bu sayede, klinisyenlerin iş yükü önemli ölçüde azaltılabilir; tedavi ve bakımı daha tutarlı ve kesin hale getirilebilir; tıbbi kayıtlardaki dokümantasyon kalitesini artırılabilir ve klinisyenlerin yara bakımı için kalite kriterleri elde etmelerini sağlanabilir (Fauzi ve ark., 2015)

Basınç (dekübit) ve diyabetik ayak yaraları olarak adlandırılan kronik yaralar tüm dünyada olduğu gibi ülkemizde de sağlık sektöründe çok ciddi ekonomik ve iş gücü kaybına ve hastane yatak işgaline sebep olmaktadır. Bunun ana nedenlerinin başında yaraların iyileşme sürecinin uzun ve multi-disipliner yaklaşım gerektirmesi, hastaların tüm poliklinikleri dolaşarak muhatap bir klinik bulamamaları, yara bakımı konusunda ihtisaslaşmış uzmana ulaşımın zor olması gibi nedenler sayılabilir.

Tedavi, takip ve ölçeklendirmede invazif görüntüleme sistemleri kullanılmadığı (MR, Tomografi, USG) sadece görsel takip yapıldığı için kullanılan yara bakım ürünlerinin bilimsel etkinliklerinin değerlendirilmesinde güvenilirlik açısından ciddi sorunlar yaşanmaktadır. Kronik Yaralar bütçeye ciddi bir ekonomik yük olması bir yana hasta ve yakınlarının maddi ve manevi kayıplarına da sebep olmaktadır.

Medikal yara görüntülerinin uzman doktorlar tarafından değerlendirilmesi ve sürecin takip edilmesi uzun zaman almaktadır. Görüntülerin objektif bir şekilde daha kısa sürede yüksek doğrulukla değerlendirilmesi ve uzmanlara göre değişiklik gösterecek özelliğın azaltılması gibi problemlerin çözümünde akıllı sistemlere ihtiyaç duyulmaktadır. Özellikle son zamanlarda grafiksel işlem birimlerinin (GPU) hesaplama güçlerinin artmasıyla görüntüler üzerinde başarılı sınıflandırmalar mümkün olabilmektedir.

Yara bakımında, görüntülerin değerlendirilerek önleyici bir ön tedavi işlemi uygulanması için gerekli tüm çalışmalar, katkılar ve uygun tedavi yöntemlerinin hızlı bir şekilde önerilebilmesi için yara görüntülerinin segmentasyonu ve sınıflandırılması yara tedavisinin verimli olması için büyük önem taşımaktadır. Bu tez çalışmasındaki amaç, derin öğrenme yöntemleriyle kronik yaraları tanımlayıp uluslararası prensiplere uygun derecelendirme ve uygun tedavi metodunu önerebilecek şekilde, görüntüler üzerindeki segmentasyon ve sınıflandırma başarısının ve verimliliğinin artırılması için ESA temelli yeni bir yöntemin geliştirilmesidir. Bunun için ESA tabanlı modeller ile yara görüntülerinin segmentasyon başarımları ölçülmüş ardından segmente edilen görüntülerin sınıflandırılmasında etkili olan ön-eğitilmiş ESA model tespiti yapılmıştır. En etkili mimari için eğitim parametrelerinin etkisi incelenerek en başarılı parametre eşleri bulunmuştur. Son olarak en iyi parametre değerleri ile en iyi mimarinin sonuçlarının iyileştirilmesi için mimaride geliştirmeler önerilmiştir. Ayrıca tez kapsamında Karaman Eğitim ve Araştırma Hastanesi bünyesinde, basınç ve diyabetik ayak yarasına ait 2100 adet görüntüden oluşan özgün bir veri seti oluşturulmuştur.

1.2. Tezin Organizasyonu

Sunulan bu tez çalışmasında Bölüm 1’de tezin amacı ve önemi açıklanmıştır. Bölüm 2’deki kaynak araştırması kısmında yara bakımı, yara görüntülerinin segmentasyonu, yara görüntülerinin sınıflandırılması, sınıflandırmada kullanılan ESA eğitim parametrelerinin analizi ve optimizasyonu hakkında literatürde yapılan çalışmalar belirtilmiştir. Tez çalışmasında kullanılan materyaller ve yöntemler hakkında bilgilendirmeler Bölüm 3’te yapılmıştır. Bölüm 4’ te önerilen modellerin tasarımı, yara segmentasyonu, yara sınıflandırması, parametre optimizasyonu ve yara sınıflandırmada kullanılan AlexNet mimarilerinin geliştirilmesi konularında temel bilgiler verilmiştir. Bölüm 5’ te deneysel çalışmalar, segmentasyonda ve sınıflandırmada kullanılan

performans ölçütlerine yer verilmiştir. Son olarak önerilen yöntemin diğer yöntemlerle test sonuçları karşılaştırılıp gerekli tartışmalar yapılmıştır. Bölüm 6’da ise tez kapsamında elde edilen araştırma sonuçları aktarılmış ve öneriler sunulmuştur.



2. KAYNAK ARAŞTIRMASI

Tıp alanında görüntü analizi ile ilgili çözülecek problemler, görüntü sınıflandırma (Image Classification), nesne tanımlama (Object Detection) ve anlamsal bölütleme (Semantic Segmentation) olarak gruplandırılmaktadır. Resimdeki her bir pikselin tanımlanması ve sınıflandırılması olarak tanımlanabilen anlamsal bölütleme farklı birçok alanda resim segmentasyonunda kullanılmaktadır. Anlamsal bölütlemenin görevi, görüntünün piksel bazlı bir maskesini çıkarmak için bir yapay zekâ yöntemi kullanılarak, görüntünün çok daha düşük bir seviyede, yani piksel seviyesinde anlaşılmasına yardımcı olmaktır. MÖ yöntemleriyle görüntü analizi üzerinde resim segmentasyonu yapan çalışmalar da mevcuttur (Seo ve ark., 2020; Singh ve ark., 2021). Gelişen donanım ve hesaplama kapasiteleri (özellikle GPU) sayesinde MÖ yöntemlerinin bir alt kolu olan DÖ teknikleri, yüksek görüntü işleme başarısından dolayı, görüntü işleme (image processing) ve bilgisayarlı görü (computer vision) konularında araştırma konusu olarak öne çıkmaktadır (Voulodimos ve ark., 2018; O'Mahony ve ark., 2019).

Bu tez çalışması kapsamında yara görüntülerinin segmentasyonu, sınıflandırılması, sınıflandırmada başarılı DÖ mimarisinin parametre etkileri ve son olarak en başarılı mimari de geliştirmeler yapılarak yeni yaklaşımlar önerilmiştir.

Bu ana başlık altındaki alt bölümlerde kaynak araştırması kategorik bir şekilde sunulmuştur. Birinci bölümde, medikal görüntü analizinde kullanılan DÖ mimarileri hakkında yapılan genel literatür taraması verilmiştir. İkinci bölümde, yara bakımında kullanılan yara dokusu üzerinde YZ teknikleriyle yapılan segmentasyon ve sınıflandırma çalışmalarına dair genel literatür taramasına yer verilmiştir. Üçüncü bölümde, bu tez çalışmasında sonuçların karşılaştırılmasında da kullanılan DÖ teknikleriyle, yara görüntüsü segmentasyonu yapan literatürdeki çalışmalar detaylandırılmıştır. Dördüncü bölümde ise yine bu tez çalışmasında karşılaştırmalarda da kullanılan DÖ teknikleriyle, yara görüntüsü sınıflandırması yapan literatürdeki çalışmalara yer verilmiştir.

2.1. Medikal Görüntü Analizinde Kullanılan Derin Öğrenme Mimarilerine ait Genel Çalışmalar

Medikal alandaki birçok problemde elde edilen görüntülerin analiz edilmesinde de resim segmentasyonu ve sınıflandırılması ele alınmıştır (Sundelius, 2018; Cheng ve ark., 2019; Dong ve ark., 2020) (Shen ve ark., 2017; Hesamian ve ark., 2019; Tajbakhsh

ve ark., 2020; Qureshi ve ark., 2022). Derin öğrenmenin medikal resim işleme başarısı, beyin, retina, göğüs x-ray, göğüs CT, dijital patoloji, meme görüntüsü, kardiyak görüntü, karın (abdominal) görüntü, kas -iskelet sistemi (musculoskeletal), baş ve boyun tümör (head&neck tumor) segmentasyonu, vessel tanımı ve segmentasyonu gibi tıbbi bir çok alanda görüntü işleme çalışmalarına konu olmasından da görülebilir (Litjens ve ark., 2017b) . Ayrıca karaciğer-tümör (liver-tumor) segmentasyonu, beyin tümörü segmentasyonu, optik disk (optic disc), hücre (cell) segmentasyonu, akciğer nodülü (lung nodüle) segmentasyonu gibi çalışmalarda da derin öğrenmenin kullanıldığı görülmektedir (Hao ve ark., 2020; Lei ve ark., 2020; Alzubaidi ve ark., 2021b; Suganyadevi ve ark., 2022; Wang ve ark., 2022; Zhang ve ark., 2022).

Derin öğrenme yöntemleri son zamanlarda araştırmacıların oldukça ilgi odağı olmuş ve görüntü segmentasyonunda da popülerlik kazanmıştır (Garcia-Garcia ve ark., 2017; Ghosh ve ark., 2019; Hao ve ark., 2020; Minaee ve ark., 2020; Alzubaidi ve ark., 2021b; Suganyadevi ve ark., 2022; Wang ve ark., 2022). Son zamanlarda derin öğrenme tabanlı algoritmalar, biyomedikal resim segmentasyonu (Lei ve ark., 2020), beyin tümörü (Havaei ve ark., 2017; Wang ve ark., 2017) gibi medikal alanda yapılan çeşitli çalışmalarda başarılı sonuçlar elde etmiştir.

Tıbbi öğrenme süreci için vücudun diğer bölgelerinden alınan görüntüler üzerinde derin öğrenme modelleri yaygın olarak kullanılmaktadır. Birçok araştırma çalışmasında, beyin, retinal, göğüs X-ray, meme, kalp, karın ve kas-iskelet sistemi gibi farklı tıbbi görüntü türlerinde de görüntü sınıflandırma, nesne algılama, bölümlendirme ve sınıflandırma için derin öğrenme kullanmıştır (Jimenez-del-Toro ve ark., 2017; Litjens ve ark., 2017a; Cao ve ark., 2018; Pandya ve ark., 2019).

Kawahara ve Hamarneh (2016), çoklu görüntü çözünürlüklerinden gelen bilgi tabanlı öğrenmek amacıyla, deri lezyonu sınıflandırması için bir evrimsel sinir ağı (ESA) önermişlerdir. Çok ölçekli yaklaşımlara göre sınıflandırma doğruluğu yüksek sınıflandırma gerçekleştirmişlerdir. 10 sınıftan 1300 cilt lezyonu görüntüsü üzerinde deneyler yapılmıştır (Kawahara ve Hamarneh, 2016).

Esteva ve ark (2017), 1000 nesne sınıfı için, önceden eğitilmiş Google'ın Inception v3 ESA mimarisini kullanarak cilt kanseri sınıflandırması yapmışlardır (Esteva ve ark., 2017).

Andrearczyk ve Whelan (2017) biyomedikal görüntüleme uygulamalarında yaygın bir sorun olan doku analizine özgü ESA hakkında bilgi vermiştir. Ayrıca diğer

yöntemlere kıyasla biyomedikal doku sınıflandırmasına özgün yeni bir ESA mimarisi önermişlerdir (Andrearczyk ve Whelan, 2017).

Vasconcelos ve Vasconcelos (2017) dermoskopi görüntü analizi için derin öğrenme kullanarak deneysel sonuçlar sunmuşlardır. Ölümcül bir cilt kanseri çeşidi olan melanomun teşhisi için, (Gutman ve ark., 2016) tarafından oluşturulan 900 adet dermoskopik görüntü üzerinde GoogleNet (Szegedy ve ark., 2015) ESA topolojisi kullanılarak deneysel sonuçlar elde edilmiştir (Vasconcelos ve Vasconcelos, 2017a; Vasconcelos ve Vasconcelos, 2017b).

Kamnitsas ve ark. (2017) beyin lezyonu segmentasyonu için 11 katman derinlikli, hem yerel hem de daha geniş bağlamsal bilgiler barındıran, normal görüntüler ve aşağı örneklenmiş görüntülerden oluşan ikili bir yol içeren üç boyutlu bir ESA önermişlerdir (Kamnitsas ve ark., 2017).

Diğer bir çalışmada, (çok modlu yığın derin polinom ağları (DPN)) MM-SDPN algoritmasının iki aşamalı SDPN' den oluşan Alzheimer hastalığı teşhisi için çok modlu nörogörüntüleme verilerinden kaynaştırıcı ve özellik gösterimini öğrenmesi önerilmiştir (Shi ve ark., 2018).

Zilly ve ark. (2017), retina görüntülerini segmentlere ayırmak için grup öğrenme tabanlı (ensemble learning based) evrimsel sinir ağı (ESA) mimarileri kullanarak yeni bir yöntem önermişlerdir (Zilly ve ark., 2017).

Cicero ve ark. (2017), frontal göğüs radyografik görüntülerini sınıflandırmak için GoogLeNet ESA mimarisini kullanmışlardır (Cicero ve ark., 2017).

Rajkomar ve ark. (2017), önceden eğitilmiş GoogLeNet ESA mimarisi ile 909 hastadan toplanılan 1885 göğüs radyografik görüntüsünün sınıflandırmasını yapmışlardır (Rajkomar ve ark., 2017).

Derin öğrenme tüm dünyada olduğu gibi ülkemizde de oldukça ilgi çeken ve üzerinde çalışılan bir sahadır. X-ray görüntülerindeki tehditlerin tespitinde, meme kanseri, patolojik görüntüleme, histopatolojik görüntüleme, zatürre hastalığının tespiti, gibi birbirinden farklı ve güncel konularda ele alınmaktadır (Toraman, 2018; Resul ve ark., 2019; Toğaçar ve ark., 2019; Menteşe ve Hançer, 2020; Şişmanoğlu ve ark., 2020; Aslan, 2021; Bozkurt, 2021; Bozkurt ve Yağanoğlu, 2021; Canbay ve ark., 2021; Eker ve Nevcihan, 2021; Altındağ, 2022; Canatalay, 2022; Çalışkan ve Demir, 2022; Demir ve Yılmaz, 2022; Karakurt ve İşeri, 2022).

2.2. Yara Bakımı için Segmentasyon ve Sınıflandırmaya ait Çalışmalar

Kronik basınç ve ayak yaralarının bakımı ve değerlendirilmesi amacıyla da resim üzerinden yara bölgesinin segmentasyonu için makine öğrenmesi ve derin öğrenmesi yöntemleriyle çalışmalar yapılmıştır (Anisuzzaman ve ark., 2020; Zahia ve ark., 2020b). Makine öğrenmesi yöntemlerinden Destek vektör makinesi (SVM) (Kolesnik ve Fexa, 2004a; Kolesnik ve Fexa, 2005; Wang ve ark., 2016) , SVM ve Snake algoritması (Kolesnik ve Fexa, 2006), Cr-Dönüşümü, Luv-Dönüşümü, and FCM (Wantanajittikul ve ark., 2012), MLP and RBF (Song ve Sacan, 2012), K-means kümeleme (Hani ve ark., 2012), K-means ve Bulanık C-means kümeleme (Yadav ve ark., 2013a) yöntemleri kullanılarak yara görüntüleri üzerine özellik çıkarımı ve segmentasyon yapılmıştır.

Zahia ve ark (2018) evrişimsel sinir ağları (ESA) ile bası yaralarının doku sınıflandırmasını ve segmentasyonunu gerçekleştirmişlerdir. Önerilen sistemde, basınç yaralanmalarında (granül, slough ve nekrotik dokularda) mevcut olan farklı doku tiplerinin optimize edilmiş segmentasyonunu gerçekleştirmeye yönelik bir ESA (CNN) kullanılmaktadır (Zahia ve ark., 2018a).

Elmogly ve ark (2018) bası yaraları için bir 3D evrişimli sinir ağını temel alan doku sınıflandırması sistemi önermişlerdir. Önerilen sistemin temel fikri, renkli RGB bası yarası görüntülerinin beş farklı modeliyle slough, granül ve nekrotik dokularını doğru bir şekilde segmentlere ayırmaktır. Birinci ve ikinci modeller orijinal RGB bası yarası görüntüleri ve eşdeğer HSV görüntüleridir. Üçüncü model, orijinal görüntüyü önceden seçilmiş bir Gauss çekirdeği (Gaussian kernel) ile birleştirerek düzgünleştirilmiş görüntüdür. Son iki model ise mevcut ve önceki görsel görünümün birinci dereceden modelleridir (Elmogly ve ark., 2018).

García-Zapirain ve ark. (2018) bası yaraları görüntülerinden granül, nekrotik ve slough bölümlerini otomatik olarak bölümlene yapabilen bir segmentasyon sistemi önermişlerdir. HSI ve 3D Gauss çekirdeği (kernel) ile evrilmiş HSI görüntüleri 3D CNN ağına verilmiştir (García-Zapirain ve ark., 2018).

Mukherjee ve ark (2014) kronik yara değerlendirmesi için tıbbi görüntü işleme ve istatistiksel makine öğrenme tekniklerini kullanarak bilgisayar destekli doku sınıflandırması (granülasyon, nekrotik ve slough) şeması geliştirmişlerdir. Bayes sınıflandırması ve destek vektörü makinesi gibi istatistiksel öğrenme algoritmalarıyla farklı kronik yara görüntülerinde yara dokusu sınıflandırması için eğitilmiş ve test edilmiştir (Mukherjee ve ark., 2014).

Wang ve ark (2015) önceki farklı segmentasyon yöntemlerinden farklı olarak önerdikleri derin öğrenme metoduyla ilişkili ortak görevli görsel özellikleri öğrenip yara segmentasyonu gerçekleştirerek, öğrenilen özelliklerin enfeksiyon algılamada ve iyileşme süreci takibi hakkında tahminde de bulunmaktadır (Wang ve ark., 2015a).

Sheet ve ark (2015) klinik raporlama değişkenliğini azaltmak amacıyla sağlıklı cildi histolojik olarak karakterize etmek ve yaraları iyileştirmek için, benek temsillerini danışmansız öğrenmek amacıyla gürültü temizleyici otomatik kodlayıcıları (denoising auto-encoders) (DAE) kullanarak derin bir sinir ağı (ESA) tabanlı mimari önermişlerdir (Sheet ve ark., 2015) .

Chakraborty (2019), sürekli kronik yara durumu takibi için otomatik bir teşhis sistemi önermiştir. Yara görüntüsü segmentasyonu için standart hesaplamalı öğrenme yöntemlerinden doğrusal ayırmacı analiz (Linear Discriminant Analysis (LDA)), Karar Ağaçları, Naive Bayes ve Rastgele Orman (Random Forest) yöntemlerinin yanı sıra Bulanık C-Means yöntemini önermiştir (Chakraborty, 2019) .

Veredas ve ark (2010), yara görüntülerinde otomatik doku tanımlaması için sinir ağları ve bayes sınıflandırıcılarına dayanan hibrit bir yaklaşım kullanılmıştır. Ülser bölgesinde etkili yara bölgesi segmentasyonu için ortalama bir değişim prosedürü (mean shift) ve bir bölge büyüme (region-growing techniques) stratejisi uygulamışlardır. Renk ve doku özellikleri, k çok katmanlı perceptrona ve bayes sınıflandırıcıya verilerek ülser resminin farklı türlerinin sınıflandırılması amaçlanmıştır. 113 basınç yarası resmin üzerinde yapılan deneylerde %78.7 duyarlılık (duyarlılık), %94.7 özgüllük (specificity), ve %91.5 doğruluk (accuracy) oranlarını elde etmişlerdir (Veredas ve ark., 2010).

Chakraborty ve ark (2016), doğrusal ayırmacı analiz (Linear Discriminant Analysis (LDA)) yöntemini kullanarak Telemedicine iş modülü (framework) ile bağlantılı kronik yara dokusu tahmin ve teşhis modeli önermişlerdir. Önerilen Telemedicine tabanlı yara dokusu tahmini (TWTP) modeli yara dokusunu tanımlayabilmekte ve iyi bir doğruluk oranında yara durumunu tahmin etmektedir (Chakraborty ve ark., 2016).

Dorileo ve ark (2010), ayakta ve bacakta oluşan ülser lezyonlarının doku bileşimi analizini kolaylaştırmak için renkli görüntüleme ve görüntü işleme metotları önermişlerdir. Verilen bir resmin kırmızı granülasyon, sarı fibrin, siyah eskar ve beyaz hiperkeratozik dokulara karşılık gelecek şekilde segmentasyonu için önerdikleri bu metotla lezyon bölgesinin keşfinde 172 resim üzerinde test yaparak bir dermatoloğun manuel olarak sağladığı katkının daha üzerinde bir performans sağlamışlardır (Dorileo ve ark., 2010) .

Azevedo-Marques ve ark (2013), farklı ülser dokularını bölümlere ayırmak için kümeleme segmentasyon yöntemi önermişlerdir. Renk bileşenlerinin renk doygunluğu histogramları ve matematiksel morfoloji temelli yöntemleriyle 172 ülser görüntüsü üzerinde testler yapmışlardır. Bir dermatolog tarafından ortaya konulan sonuçlarla segmentasyon arasında ortalama $56 \pm 22\%$ lik Jaccard katsayısı ortalaması elde etmişlerdir. Lezyonların doku bileşimi kullanılarak tahmin edilen önerilen segmentasyon yöntemi ile manuel analiz arasında %5'lik bir standart sapma ve %4'lük bir kök-ortalama-kare hatası elde edilmiştir (Azevedo-Marques ve ark., 2013).

Fauzi ve ark (2015), kronik yara resimlerinin granül (kırmızı), slough (sarı) ve eskar (siyah) dokusu içeren alanlarını otomatik olarak yara dokümantasyonu için gerekli ölçümleri yapan bir segmentasyon yöntemi geliştirmişlerdir. Segmentasyon tekniklerine rehberlik edecek kırmızı-sarı-siyah-beyaz (RYKW) olasılık haritası oluşturarak görüntülerde bu bölgeleri yakalamak için kullanmışlardır (Fauzi ve ark., 2015).

Veredas ve ark (2015), k-means kümeleme tekniği temelli bir basınç yarası doku segmentasyon sistemi önermişlerdir. Farklı ülser dokularını ayırt etmek için yapay sinir ağları, rastgele orman ve destek vektör makinesi yöntemlerini kullanmışlardır. Önerilen sistem, görüntü ayırma için k-ortalama kümeleme algoritmasının kullanılmasını içermektedir. Her bir bölünmüş bölgeyi etkili bir şekilde uygun doku tipi olarak sınıflandırmak için üç farklı makine öğrenme yaklaşımını karşılaştırmışlardır (Veredas ve ark., 2015).

Ortiz ve ark (2017), bası yarası doku segmentasyonu için resmin her pikselinde olan gri tonlama değerinden elde edilen sentetik frekansları kullanarak belirlenen kontrast değişiklikleri temelli yeni bir teknik önermektedirler. Önerdikleri yöntem, görüntüden farklı zıtlık (kontrast) seviyelerinin toroidal geometri ile çıkarılması ardından otsu eşik tekniği ile resimleri bölümlenmektedir (Ortiz ve ark., 2017).

Guadagnin ve ark (2014), basınç yarasına sahip hastaların tedavisini desteklemek için görüntü madenciliği tabanlı, doku ve rengin yorumunu yapan bir sistem önermektedir. Weka ortamında sınıflandırma için karar ağaçlarını kullanmışlardır. (Guadagnin ve ark., 2014)

Mankar ve Nagdeve (2013), kronik yaralara uygulanan görüntüleme teknolojileri üzerine yapılan çalışmalar hakkında bilgi vermişlerdir. Kronik yaralara uygulanan görüntüleme teknolojileri üzerine güvenilirlikleri, hassasiyetleri ve kullanımlarının karşılaştırıldığı bir çalışma sunmuşlardır. Planimetrik teknikler, hacimsel teknik ve doku sınıflandırması hakkında bilgi vermişlerdir (Mankar ve Nagdeve, 2013).

Yadav ve ark (2013), çalışmalarında uygun renklerle alan seçimi sayesinde yaraların kronik yara değerlendirmesi için yara alanı segmentasyonu yapmışlardır. Kümeleme yaklaşımına dayalı bir segmentasyon yöntemi kronik yara görüntülerinde yara bölgesi segmentasyonu için kullanılmıştır. k-means ve bulanık C-Means kümeleme (FCM) algoritmaları ile bölge segmentasyonu dermatologlar tarafından onaylanmış 77 dijital fotoğraf üzerinde yapılarak 5 farklı kronik yara (diyabetik ülser, pyoderma gangrenosum, habis ülser, bası ülseri ve venöz ülseri) türü üzerinde test edilmiştir (Yadav ve ark., 2013b).

Mesa ve ark (2008), yara görüntülerinde otomatik doku tanımlaması için sinir ağları ve Bayes sınıflandırıcılara dayalı bir melez yaklaşım kullanmıştır. Renk ve doku desenleri girdileriyle bir dizi k çok katmanlı algılayıcıların eğitilmesi ile klinik uzmanlarca tanımlanan kategorik doku sınıfları çıkışları mevcuttur. Çapraz doğrulama kullanılarak eğitim süreci tanımlanmıştır. Son olarak k adet sinir ağlarının sınıflandırılmasının birleştirilmesi için bir bayes sınıflandırıcısını eğiterek bayes komite makinesi tasarlanmıştır. (Mesa ve ark., 2008).

Wannous ve ark (2007), destek vektör makinesi (SVM) sınıflandırıcı kullanarak dokuları granül, slough ve nekrozda sınıflandırmak için renk ve dokusal özellikleri çıkarmadan önce ortalama kaydırma (mean shift), JSEG ve CSC tekniklerini 25 yara görüntüsünü ayırmada karşılaştırmışlardır. Hem segmentasyonun hem de sınıflandırmanın granülasyon dokularda slough ve nekroz dokulara göre daha iyi çalıştığını bildirmişlerdir (Wannous ve ark., 2007).

Hettiarachchi ve ark (2013), bir mobil cihazda yara segmentasyonu ve ölçümü girişiminde bulunmuşlardır. Android 2.2 versiyonu için yazılan uygulama, kamera mesafesi, açı ve ışık koşullarına karşı oldukça hassas olmasına rağmen %90 oranında doğruluk oranına sahip olduğunu belirtmişlerdir (Hettiarachchi ve ark., 2013).

Hani ve ark (2012), kronik ülserlerde iyileştirici değerlendirme için, granül dokusu büyümesini saptamak amacıyla hemoglobin dağılımını araştırmışlardır. Bağımsız bileşen analizi (Independent Component Analysis-ICA) ile kronik ülserlerin Kırmızı-Yeşil- Mavi (RGB) renkli görüntülerinden gri seviye hemoglobin görüntülerini elde etmeye çalışılmıştır. Sonrasında veri kümeleme teknikleri, tespit edilen granülasyon dokusu bölgelerini sınıflandırmak ve bölümlere ayırmak için uygulanmıştır. %88.2 özgüllük ve %98.8 duyarlılık değerleri, 30 görüntülük veri tabanı için rapor edilmiştir (Hani ve ark., 2012).

Perez ve ark (2001) renkli görüntülerdeki bacak ülseri dokularının segmentasyonu ve analizi için bir yöntem önermişlerdir. Segmentasyon, görüntünün kırmızı, yeşil, mavi, doygunluk ve yoğunluk kanallarının analizi ile elde edilmiştir (Perez ve ark., 2001).

Wantanajittikul ve ark (2012), segmentasyon hatalarını azaltmak için matematiksel morfoloji uygulamadan önce yanık yara bölgesini sağlıklı deriden ayırmak için Cr-dönüşüm, Luv-dönüşüm ve bulanık c-means kümeleme tekniğini kullanmışlardır. Yanık derecesini belirlemek için, SVM sınıflaması için özellik vektörlerini çıkarmak amacıyla h-transformasyon ve doku analizi kullanılır. 5 resimdeki yanık alanlarının %75.0 sınıflandırma doğruluğu ile pozitif tahmin ve duyarlılıkların %72.0 ile %98.0 arasında olarak segmentasyon yapıldığını rapor etmişlerdir (Wantanajittikul ve ark., 2012).

Song ve Sacan (2012) otomatik görüntü segmentasyonu ve yara bölgesi tanımlaması yapabilen bir sistem önermiştir. Aday yara bölgelerinin bir koleksiyonunu elde etmek için yaygın olarak kullanılan birkaç bölümlenme yöntemi (k-means kümeleme, kenar algılama (edge detection), eşikleme (thresholding) ve bölge büyütme) kullanılmıştır. Yara tanımlama tahmin sürecinde, çok katmanlı perceptron (MLP) ve radyal temelli fonksiyon (RBF) metotlarını, denetimli öğrenme ile uygulamışlardır. 14 hastadan alınan 92 resim üzerinde (78 eğitim, 14 test) yapılan deney sonuçları, hem MLP hem de RBF'nin kendi avantajları ve dezavantajları ile iyi bir verimliliğe sahip olduğunu göstermiştir (Song ve Sacan, 2012).

Kolesnik ve Fexa (2004, 2005, 2006), 3 boyutlu renk histogramından, yerel ikili desenden ve lokal kontrast varyasyonundan, destek vektör makinesi (SVM) sınıflandırıcı ile 23 doku görüntüsünün 50'li parçalara ayrılmış eğitim görüntülerini segmente etmek için renk ve dokusal özellikleri kullanmışlardır. SVM tarafından oluşturulan yara sınırı, deforme olabilen yılan ayarı (deformable snake adjustment) kullanılarak daha da belirginleştirilmektedir. Renk, doku ve hibrit özellikler için sırasıyla %6.6, %22.2 ve %5.8 ortalama hata bulunmuştur (Kolesnik ve Fexa, 2004b; Kolesnik ve Fexa, 2005; 2006).

2.3. Kronik Yara Görüntülerinin DÖ Teknikleriyle Segmentasyonu

Basınç yara segmentasyonu amacıyla derin öğrenme yöntemlerinin kullanıldığı sınırlı sayıda çalışma vardır (Wang ve ark., 2015b; Goyal ve ark., 2017; Liu ve ark., 2017; Li ve ark., 2018; Zahia ve ark., 2018b; Ramachandram ve ark., 2022).

VGG-16 tabanlı, tam evrişimsel ağ (FCN) çeşitlerinden FCN-32s, FCN-16s, ve FCN-8s ile segmentasyon için Alex-Net mimarisinden oluşan FCN-AlexNet gibi farklı mimariler, Lancashire Teaching Hospitals den toplanılan 705 adet diyabetik ayak yarası (DFU) görüntülerinin segmentasyonunda kullanılmıştır (Goyal ve ark., 2017).

(Wang ve ark., 2015b), 5 adet kodlayıcı 4 adet kod çözücü katmanı bulunan yeni bir evrişimsel kodlayıcı-kod çözücü ağ önermişlerdir. Önerilen yöntem ile tahmin edilen maske ve gerçek zemin maskesi arasındaki uyumluluğu gösteren ortalama IoU metriği %47.30 olarak ölçülmüştür.

(Liu ve ark., 2017), yara alanını bularak segmente eden FCN mimarisi tabanlı WoundSeg isimli bir derin evrişimsel ağ (deep Convolutional networks) önermişlerdir. Farklı katmanlardan tahminleri bir arada değerlendirmek için atlama linki (skip-link) kullanarak FCN mimarisinde kod çözücü yapısında değişiklik yapmışlardır. 950 resimden oluşan verisetlerinde %91.66 F1-skor başarısına ulaşmışlardır.

(Li ve ark., 2018), geleneksel metotlarla derin öğrenmeyi birleştirerek bir yara segmentasyon modeli önermişlerdir. Kendi görüntü verisetlerini (Wang ve ark., 2015b) in yöntemiyle, farklı senaryolarda gruplandırmalarla deneyler yapmışlardır.

(Zahia ve ark., 2020a) basınç yaralanmasına ilişkin nicel bilgileri otomatik olarak alan bir sistem önermişlerdir. Yaranın dış sınırlarının segmentasyon çıktısını, 2D resimden elde etmek için Mask RCNN ESA mimarisini kullanmışlardır. Sonrasında bu segmentasyon çıktısını 3D ağda (mesh) segmentlerine ayırarak ölçümler üretmişlerdir.

(Ohura ve ark., 2019) ImageNet yarışmasındaki orijinal yapılarında değişiklik yapılmamış SegNet, LinkNet, U-Net ön eğitilmiş ESA mimarileri ile, Kyorin University Hastanesindeki hastalardan topladıkları 440 çeşitli yara görüntüsü üzerinde çalışmışlardır. Farklı test senaryoları ile örneğin basınç yarası (pressure ulcer (PU)) ile eğitilen mimariyi DFU tespitinde kullanmışlardır.

(Chang ve ark., 2022) U-Net, DeepLabV3, PspNet, FPN ve Mask-RCNN mimarilerini kullanarak doku sınıflandırmasında görüntülerin etiketlenmesi için bir süper piksel destekli, bölge tabanlı bir yöntem önermişlerdir.

Diğer bir çalışmada, (Niri ve ark., 2021) CHRO (Fransa'da Orleans Bölge Hastanesi) hastanesinden, 7 hastadan toplanılan 270 DFU resmi, 3D yüzel modelleme üzerinde DÖ ile yara segmentasyonu konusunda çalışmışlardır.

(Scebba ve ark., 2022) basınç, ameliyat, diyabet ve menenjit yara görüntülerinden rastgele seçtikleri 53 resim üzerinde UNet, ConvNet, DeepLab ve FCN modellerinin performanslarını karşılaştırmışlardır.

(Ong ve ark., 2020) U-Net mimarisine benzer bir mimari önermişlerdir. Önerilen mimari ile yerel hastaneler ve kurumsal inceleme kurumundan (Institutional Review Board) toplanılan kronik yara görüntülerini %80 eğitim ve %20 test ayırarak, önerdikleri metot üzerinde test etmişlerdir.

2.4. Kronik Yara Görüntülerinin DÖ Teknikleriyle Sınıflandırılması

Son yıllarda, DÖ yöntemlerini kullanarak görüntü sınıflandırması üzerine yapılan çalışmalar gün geçtikçe artmaktadır (Tripathy ve Singh, 2022). Çalışmalar, genellikle ESA modellerinin üzerinde yapılan modifikasyonlar, model parametrelerindeki etkinin araştırılması ve modellerin bir arada kullanılarak (ensemble) etkisi yüksek olanın belirlenmesi şeklinde gruplanabilir. Ayrıca literatürdeki çoğu çalışmada belirli bir görüntü veri setinin yerine çalışmaya özel toplanılan veri seti üzerinde çalışmalar da mevcuttur.

(Shenoy ve ark., 2018) , Palo Alto VA Hastanesi ve Washington Üniversitesi St. Louis sağlık merkezindeki hastalardan topladıkları 1335 yara görüntüsü üzerinde pozitif/negatif şeklinde ikili (binary) sınıflandırma yapmışlardır. DeepWound adını verdikleri yöntemle bir yara görüntüsünün, belirledikleri 9 sınıfın her biri için pozitif ya da negatif şeklinde o kategoriye ait olup olmadığını belirlemişlerdir.

(Rostami ve ark., 2021) ise Azh yara ve vasküler merkezinde (AZH Wound and Vascular Center, Milwaukee) topladıkları, venöz, diyabetik, basınç, and cerrahi yara türlerinin her birinden 100 resim olmak üzere 4 sınıfa ait 400 resim üzerinde çalışmışlardır. Topluluk derin ESA (Ensemble Deep CNN) tabanlı bir sınıflandırıcı ile cerrahi ve venöz sınıflarıyla ikili sınıflandırma, cerrahi venöz ve diyabetik sınıflarıyla 3-sınıflı sınıflandırma yapmışlardır. 4 sınıfa ait resimlerin olduğu testlerinde başarı oranları %68.69 ile oldukça düşüktür.

(Alzubaidi ve ark., 2020b), Irak Nasiriyah Hospital Diabetic Center deki hastalardan topladıkları 754 ayak resimleri üzerinde DFU_QUTNet ismini verdikleri bir ESA mimarisi önermişlerdir. Çalışmada yaralar ikili sınıflandırma yapılarak görüntülerin normal yada anormal sınıfları üzerindeki başarıları ölçülmüştür.

(Goyal ve ark., 2018), Lancashire Eğitim Hastaneleri (Lancashire Teaching Hospitals) den 292 si diyabetik ayak yarası (abnormal), 105 tanesi sağlıklı hastadan olmak üzere toplamda 397 resim üzerinde çalışmışlardır. Yaraların ikili sınıflandırması yapılarak normal ve anormal sınıfları için %92.5 doğruluk elde etmişlerdir.

(Goyal ve ark., 2020), Lancashire Eğitim Hastanelerinden topladıkları 1459 yeni veriseti üzerinde diyabetik ayak yaralarının enfeksiyonlu (infection) ve iskemik (ischemia) olup olmadığını tespit etmişlerdir. InceptionV3, ResNet50 ve InceptionResNetV2 mimarilerini kullanmışlardır. Görüntülerin iskemik olup olmadığına dair ikili sınıflandırmada %90.3, enfeksiyonlu olup olmadığına dair ikili sınıflandırmada ise %72.7 başarı elde etmişlerdir.

(Das ve ark., 2021), Lancashire Eğitim Hastanelerinden 292 si diyabetik ayak yarası (abnormal), 105 tanesi sağlıklı hastadan olmak üzere toplamda 397 resim üzerinde çalışmışlardır. DFU_SPNet isimli önerdikleri ESA mimarisi ile elde edilen sonuçları (Alzubaidi ve ark., 2020b) ve (Goyal ve ark., 2018) çalışmalarıyla karşılaştırmışlardır.

Literatür incelendiğinde var ya da yok şeklinde daha çok ikili (binary) sınıflandırma üzerine çalışmalar yapıldığı görülmektedir. Yine doku türünün sınıflandırılmasından ziyade, yara görüntülerinin hangi yara tipine ait olduğunu belirten çalışmalar bulunmaktadır. Bazı çalışmalarda ESA mimarilerinin kullanılmaya başlandığı da gözlemlenmektedir. Çalışmaların çoğu veri setlerini kendileri üretmektedir. Literatürdeki sınıflandırmada kullanılan verisetleri Çizelge 2.1’de özetlenmiştir.

Çizelge 2.1. ESA mimarisi kullanılarak yapılan yara sınıflandırmasına ait literatür çalışmaları

Referans	Veri Seti Toplama Yeri	Veriseti Boyutu	Sınıflandırma / Hedef Sınıf Sayısı
(Shenoy ve ark., 2018)	Palo Alto VA Hastanesi ve Washington Üniversitesi Medikal Merkezi	1335	Pozitif / Negatif
(Rostami ve ark., 2021)	AZH Yara ve Vasküler Merkezi Milwaukee, Wisconsin	400	Diyabetik / Venöz/ Cerrahi
(Alzubaidi ve ark., 2020b)	Irak Nasiriyah Hastanesi Diyabet Merkezi	754	Normal / Anormal
(Goyal ve ark., 2018)	Lancashire Eğitim Hastanesi	397	DFU / Normal
(Goyal ve ark., 2020)	Lancashire Eğitim Hastanesi	1459	Enfeksiyonlu / Enfeksiyonsuz
(Das ve ark., 2021)	Lancashire Eğitim Hastanesi	397	Normal / Anormal

2.5. AlexNet Mimarisi Eğitim Parametrelerinin Etkisi ve AlexNet Mimarisinin Modifikasyonları

AlexNet mimarisi medikal resim sınıflandırmasında yaygın bir şekilde kullanılmaktadır (Kumar ve ark., 2016; Ahn ve ark., 2019; Alebiosu ve Muhammad, 2019; Lu ve ark., 2019; Titoriya ve Sachdeva, 2019; Wang ve ark., 2020; Chen ve ark., 2022b; Kim ve ark., 2022a).

AlexNet mimarisinin başarısı, eğitim aşamasında kullanılan parametrelere bağlı olarak değişebilmektedir (Alom ve ark., 2018). (Zhao ve ark., 2018) akciğer nodül sınıflandırması için ESA mimarisinin performansını geliştirmek amacıyla çekirdek boyutu (kernel size), öğrenme hızı (learning rate (LR)), yığın boyutu (batch size (MBS)) ve ağırlık parametrelerini optimize etmek amacıyla AlexNet ve LeNet mimarileri üzerinde çalışmışlardır.

Literatürde Farklı ESA mimarilerinin optimizasyon yöntemleriyle bir arada kullanılarak parametre optimizasyonu üzerinde yaptıkları çalışmalar da bulunmaktadır. Alamri ve ark (2022), Arı algoritması (Bees Algorithm (BA)) ve Bayes optimizasyonu (BO) yöntemleriyle ESA mimarisinin parametre ve ağırlıklarının optimize edilmesi için cifar10DataDir, el yazısı rakamlar ve beton çatlak görüntüleri (handwritten digits concrete crack images) benchmark veri setleri üzerinde test edilen hibrit bir yöntem geliştirmişlerdir (Alamri ve ark., 2022).

Xu ve ark (2022), AlexNet mimarisinin optimal tasarımı ve özelliklerin optimal seçimi için Bowerbird optimizasyon algoritmasının modifiye edilmiş bir versiyonunu kullanarak Akciğer kanseri tanısı (Lung cancer diagnosis) yapmışlardır (Xu ve ark., 2022).

Diğer taraftan modifiye edilen AlexNet mimarileri farklı çalışmalarda ele alınmaktadır. Modifiye AlexNet mimarileri, diyabetik retinopati görüntüleri (diabetic retinopathy) (Shanthi ve Sabeenian, 2019), x-ray (Salih ve ark., 2020), mamogram görüntülerinde tümör tespiti (Omonigho ve ark., 2020; Boudouh ve Bouakkaz, 2022), bitki yaprağı sınıflandırması (Wagle, 2021), patates sınıflandırması (Muthiah ve ark., 2020a), mahsul hastalığı tespiti (Yeh ve ark., 2021), göğüs röntgen görüntüleri (Kaur ve ark., 2021), kefalometrik radyografiler (Lee ve ark., 2020), patolojik beyin araştırması (Lu ve ark., 2019), manyetik rezonans görüntüleri (Lu ve ark., 2019), göğüs röntgeni ve akciğer BT tarama görüntüleri (Bhandary ve ark., 2020), M-FISH kromozom görüntüleri (Kanimozhi ve ark., 2021a), dijital meme tomosentezi 3D görüntüleme (El-Shazli ve ark.,

2022), domates yaprağı sınıflandırması (Chen ve ark., 2022a), gibi çalışmalarda önerilmiştir.

Bazı çalışmalarda ek olarak evrişim katmanı (EK), Max Pooling (MK) gibi AlexNet mimarisinde kullanılan katmanlar eklenmiş, bazı çalışmalarda detaylı özelliklerin çıkarımı için evrişim katmanları azaltılmıştır. Bazı çalışmalarda sadece tam bağlantılı katmanında (TBK) mevcut AlexNetteki 1000 farklı sınıf yerine ilgili çalışmadaki sınıf sayısı (2, 3, 4 gibi) değiştirilerek sadece transfer öğrenme (TÖ) yapılmıştır. Ayrıca normalizasyon işlemi için yerel yanıt normalizasyonu (local response normalization) yerine çapraz kanal normalizasyonu (cross channel normalizasyonu), yığın normalizasyonu (batch normalization) gibi farklı normalizasyon işlemleri uygulanarak, çalışmalardaki başarıların artırılması hedeflenmiştir (Zhu ve ark., 2016; Jing ve ark., 2017; Lu ve ark., 2019; Shanthi ve Sabeenian, 2019; Bhandary ve ark., 2020; Ghulanavar ve ark., 2020; Lee ve ark., 2020; Muthiah ve ark., 2020b; Omonigho ve ark., 2020; Salih ve ark., 2020; Xie ve ark., 2020; Gundewar ve Kane, 2021; Kanimozhi ve ark., 2021b; Kaur ve ark., 2021; Sameer ve ark., 2021; Wagle, 2021; Yeh ve ark., 2021; Boudiaf ve ark., 2022; Boudouh ve Bouakkaz, 2022; Chen ve ark., 2022a; El-Shazli ve ark., 2022).

Literatürdeki çalışmalar incelendiğinde, özel olarak, yara görüntülerinin sınıflandırılmasında standart AlexNet mimarisi sadece (Rostami ve ark., 2021) tarafından venöz, diyanetik, basınç, ve cerrahi yara türlerinin sınıflandırılmasında kullanılmıştır.

3. MATERYAL VE YÖNTEM

Bu bölümde ilk olarak DÖ yöntemlerinden ESA ve ESA katmanları hakkında kısaca bilgi verilmiştir. Ardından segmentasyon işleminde kullanılan segmentasyon yöntemleri (kod çözücü), kodlayıcı olarak kullanılan ESA mimarileri ele alınmıştır. Sonrasında sınıflandırmada kullanılan ESA mimarileri hakkında bilgi verilerek eğitim parametreleri ve öneminden bahsedilmiştir. Büyük verilerin kullanılmasıyla eğitilmiş ön-eğitilmiş modellerin, belirli bir veri setinin eğitim setinin eğitilmesinde, deneyimin transfer edilmesi (Transfer Öğrenme TÖ) hakkında da bilgi verilmiştir. Segmentasyon ve sınıflandırma sonuçlarının değerlendirilmesinde kullanılan performans ölçütlerine de yer verilmiştir. Son olarak bu tez çalışması kapsamında özgün olarak toplanan yara görüntülerini içeren veri seti ile literatürde kullanılan Medetec veri setinden bahsedilmiştir.

3.1. Medikal Görüntü İşleme, Tıbbi Yara Görüntü Yorumlama ve Derin Öğrenme

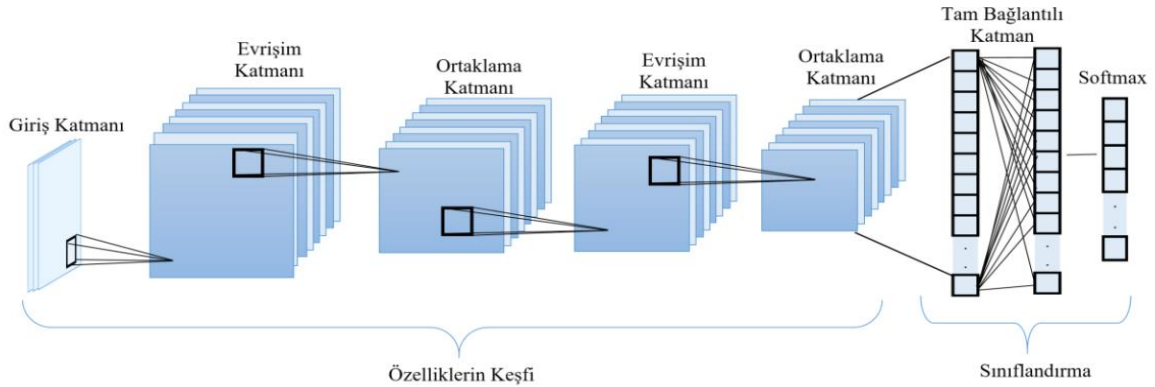
Yara görüntüsü analizi oldukça önemli bir konudur. Bilgisayarlı görüntüleme ve görüntü işleme konularında son zamanlarda hızla gelişen yapay zeka makine öğrenmesinin alt kolu olan DÖ konusu yara resimlerinin analizinde de sıklıkla çalışılan güncel bir çalışma konusudur (Zhang ve ark., 2022). Yara görüntüsünün sınıflandırılması, yerinin tespit edilmesi, görüntüden sadece yaraya ait kısmın çıkarılması (segmente edilmesi) konularında da derin öğrenme yaklaşımlarının ele alınması son zamanlarda dikkat çekmektedir. Özellikle benchmark veri setinin olmayışı bu alanda yapılacak yeni çalışmaların karşılaştırılmalarında zorluklar barındırır da yara görüntüleri üzerine yapılacak her çalışma ve katkı büyük önem taşımaktadır. Bu çalışma sahasının gelişmesi için yanık, diyabetik ayak yarası, diyabetik yaralar, cilt yaraları, kronik yaralar gibi farklı tür yara görüntüleri üzerinde ortak karar veren zeki sistemlerin tasarlanması için derin öğrenme yöntemleri kullanılmaktadır. Bu sayede yara resminin sınıflandırılması, tanımlanması ve ayrıştırma işlemleri gerçekleştirilmektedir. Ayrıca, bu alanda, yara şiddetinin sınıflandırılması, doku sınıflandırması, bölge segmentasyonu, derinlik segmentasyonu, doku segmentasyonu şeklinde çalışmalar çeşitlenmektedir (Zhang ve ark., 2022).

3.2. Evrişimsel Sinir Ağları (ESA)

ESA, DÖ' nün en temel mimari yapısıdır. ESA' lar görüntü sınıflandırma, görüntü segmentasyonu, nesne tespiti, nesne tanımlama vb. problemlerde başarılı sonuçlar elde edebilmektedir. Mimaride bulunan katmanlar sayesinde, klasik MÖ öğrenme yöntemlerinin aksine özelliklerin otomatik olarak çıkarılması ve sınıflandırılmasını sağlamaktadır. DÖ ile ilgili çalışmaların temeli geçmişe dayanmasına rağmen günümüzde yorumlanacak verilerin artması ve verilerin işlenebilme gücünün (GPU) artarak yaygınlaşması sayesinde popüler bir konuma gelmiştir. Özellikle, büyük ölçekli görüntü tanıma (ImageNet Large Scale Visual Recognition Challenge (ILSVRC)) yarışması ile birlikte, her çeşit görüntü işleme konusunda önemli bir kullanım alanı bulmuştur. 2012 yılında AlexNet ESA mimarisi, en yüksek doğruluk oranıyla bu yarışmayı kazanarak ses getiren bir ESA mimarisi olmuştur (Krizhevsky ve ark., 2012).

Klasik MÖ ve görüntü işleme tekniklerinde bulunan ön işlem adımları, özellik çıkarımı (feature extraction) ve özellik seçimi (feature selection) işlemleri için ihtiyaç duyulan uzman kişi yardımı yerine ESA mimarilerindeki katmanlar sayesinde otomatik olarak gerçekleştirilmektedir. Çünkü ESA ağları yapısındaki çok fazla katman sayesinde ham veri üzerinden gerekli görüntü çıkarımlarını yüksek doğrulukla yapabilmektedir.

ESA mimarileri temelde 2 ana bölümden oluşmaktadır. İlki giriş görüntüsünün çeşitli özelliklerini ayıran ve tanımlayan özellik çıkarma kısmıdır. Özellik çıkarma kısmı, bir çok evrişim (Convolution), ReLU ve havuzlama (pooling) katmanından oluşmaktadır. Diğeri ise sınıflandırma işleminin gerçekleştirildiği tam bağlantılı katman, ReLU ve düğüm seyreltme katmanlarının bulunduğu kısımdır. ESA nın genel yapısı Şekil 3.1'de verilmiştir.



Şekil 3.1. Derin Öğrenmede Temel bir ESA Mimarisinin Yapısı

İlk olarak giriş katmanında, mimarinin yapısına uygun bir boyutta giriş görüntüsü verilir. Bu katmanda 3 kanallı RGB görüntüsü ya da tek kanallı bir görüntü giriş verisi olarak verilebilir. İkinci sırada, özelliklerin keşfedilmesindeki en önemli katman olan evrişim katmanı gelir. 2×2 , 3×3 , 5×5 , 7×7 gibi farklı boyutlardaki filtrelerle (ağırlık matrisi, aktivasyon haritası, özellik haritası) özellikler çıkarılır. Bu filtreler giriş görüntüsü üzerinde belirli bir kayma (Stride) ve dolgu (padding) değerleri ile filtre sayısı kadar özellik haritası görüntüsü çıkarılır. Sonrasında ReLU katman ile giriş görüntüsündeki negatif değerlerin sifira çekilmesi, diğer değerlerin çıkışa aynen aktarılması sağlanır. ReLU katmanından sonra havuzlama (ortaklama) katmanı (OK) gelir. Aşağı örnekleme (downsampling) olarak da bilinen bu katmanda görüntünün boyutu küçültülerek, mimarinin eğitim süresi ve hesaplama maliyetinin azaltılması, ağın ezberlememesi sağlanır. Özelliklerin çıkarımı/keşfi yapılan ilk bölümden sonra sınıflandırmanın yapıldığı ikinci bölümde tam bağlantılı katman (TBK) bulunmaktadır. Bu katman, kendinden önceki katmanın tüm alanlarına bağlıdır. Sınıflandırma için, son evrişim katmanı sonucunda oluşan iki boyutlu özellik haritasının (feature map) tek boyutlu bir vektöre dönüştüğü katmandır. Sınıflandırma aşamasında ağın ezberlemesini önleyen düğüm seyreltme (dropout) katmanı yer alır. Mimarinin her bir iterasyonunda rastgele düğümlerin pasifleştirilmesi ile ağıdaki etkinliği devre dışı bırakılır. Bu katmandan sonra ise Softmax katmanında nesnenin 0-1 arasında olasılıksal değeri hesaplanır ve mimarinin çıkış sınıflarından uygun olana dâhil edilir. Katmanın çıkış değeri sınıf sayısına eşittir. Bu katmanda Softmax sınıflandırıcı yerine farklı sınıflandırma algoritmaları da tercih edilebilmektedir.

3.2.1 ESA Katmanları

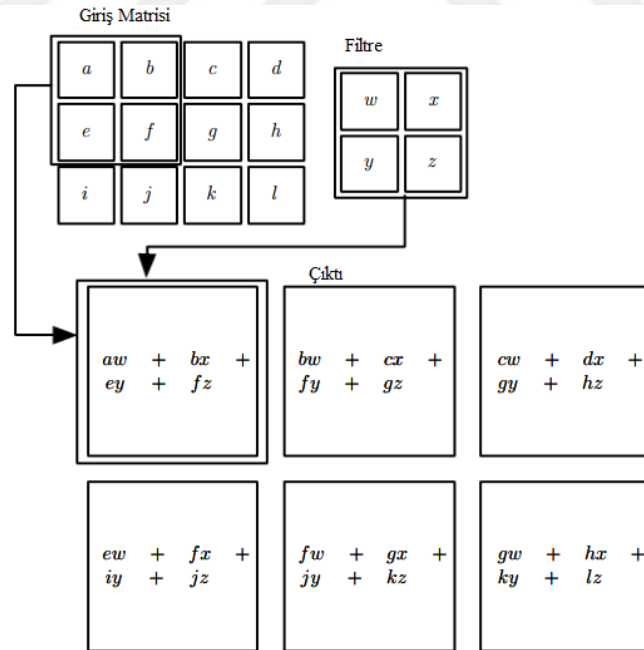
3.2.1.1. Giriş Katmanı

ESA modellerine giriş verilerinin verildiği ilk katmandır. Tasarlanacak modelin ilgili veriler üzerinde yüksek doğruluğa sahip sonuçların elde edilmesinde görüntü veri boyutlarının önemi büyüktür. Görüntü boyutları büyük olduğunda, ESA modeli tarafından verinin eğitilmesi için gereken süre artmaktadır. Ayrıca giriş katmanında her bir iterasyonda modelin eğiteceği örnek sayısı (batch size), renk kanalı (RGB, tek kanallı), görüntünün boyutu (hwx) arttıkça yüksek belleğe ve grafiksel işlem birimine (GPU) olan ihtiyaç artmaktadır. Giriş görüntü boyutunun düşük seçilmesi ise bellek

ihtiyacını azaltır ve eğitim süresini kısaltır. Fakat kurulacak ağın performansı düşük olabilir. Bu yüzden hesaplama maliyetlerini ve ağ başarısını dengede tutacak görüntü boyutunun seçilmesi gerekir (Özkan ve Ülker, 2017).

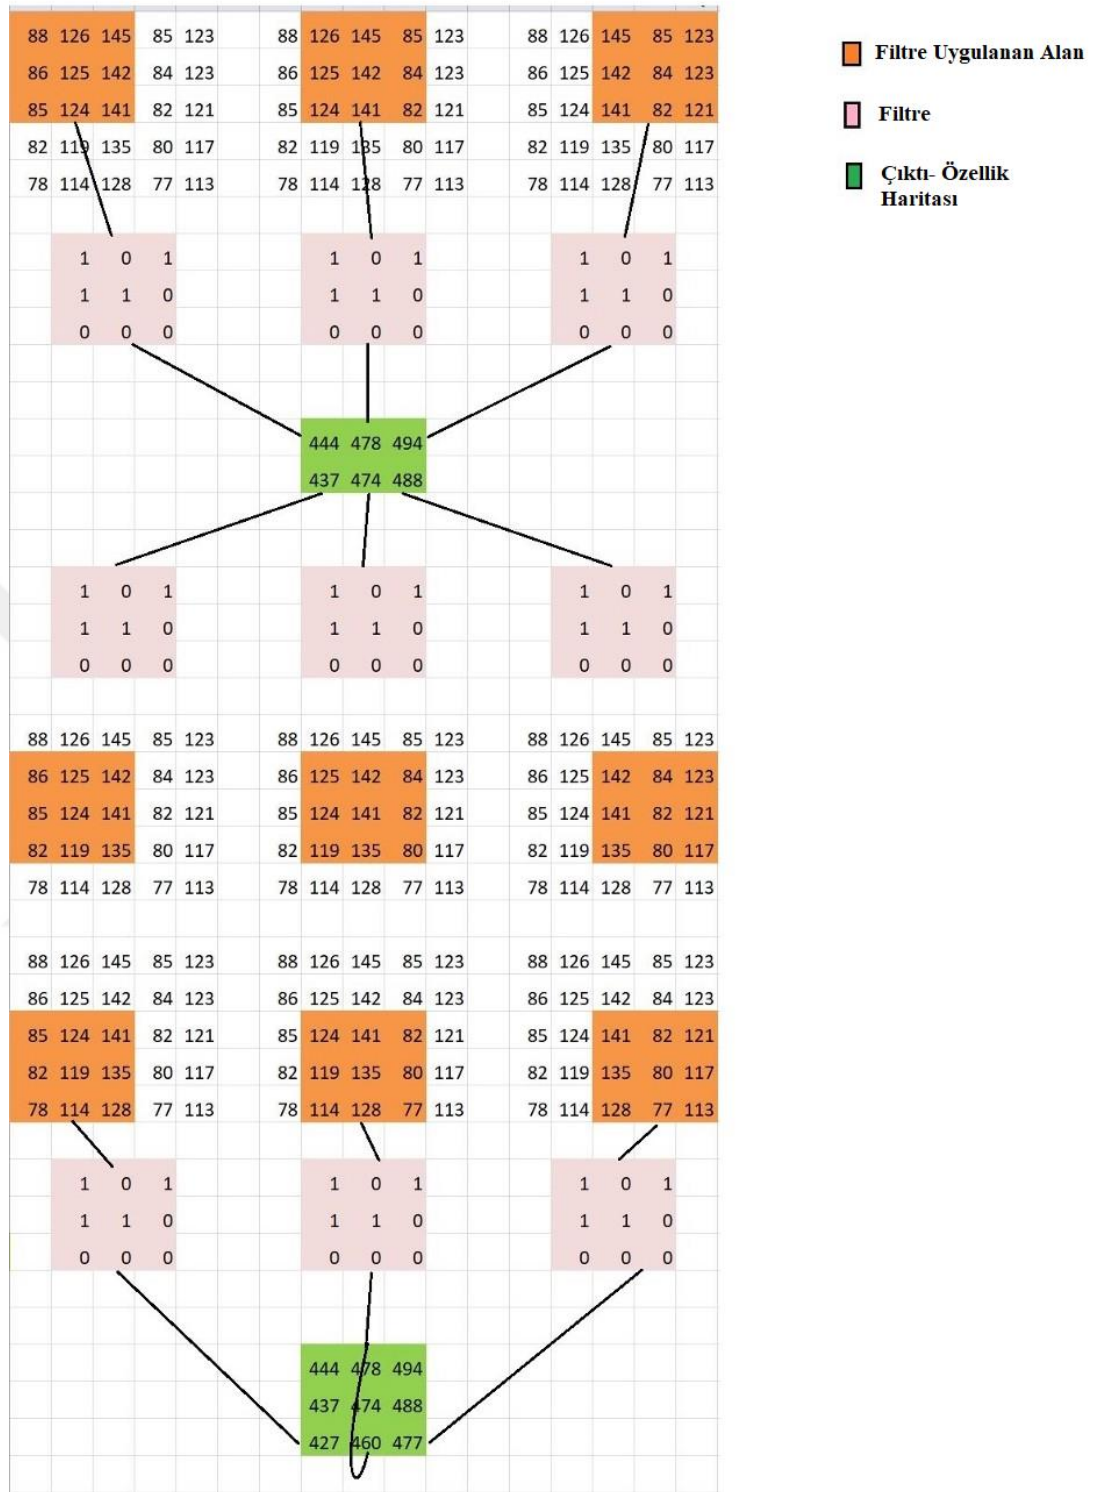
3.2.1.2. Evrişim (Konvolüsyon- Convolution) katmanı

ESA modellerine adını da veren bu katmanda tüm görüntü üzerinde belirli filtrelerin dolaştırılmasıyla özellik haritası (activation map) oluşturulmaktadır. Özellik haritası her bir filtreye özgün görüntüye ait özelliklerin keşfedilmesi işlemidir. Tasarlanan ESA modelinin evrişim katman sayısına bağlı olarak, temel ve gelişmiş görüntüler elde edilerek sonraki katmanlara iletilir. Evrişim, renkli görüntülerde kırmızı, yeşil ve mavi kanalların her birine ayrı ayrı uygulanmaktadır. Evrişim katmanlarında kullanılan filtreler sayesinde, görüntüde aranan önemli verinin hangi bölgelerde olduğu belirlenir. Bu sayede görüntüdeki anlamlı kısımların büyüklüğünden bağımsız bir şekilde belirlenebilir. Şekil 3.2’de iki boyutlu bir tensör matrisine uygulanan evrişim gösterilmiştir (Goodfellow ve ark., 2016).



Şekil 3.2. İki boyutlu evrişim örneği (Goodfellow ve ark., 2016)

Şekil 3.3’te 5x5 lik bir görüntü matrisi üzerinde 3x3 lük bir filtrenin dolaştırılarak evrişim işlemi adımları gösterilmiştir.



Şekil 3.3. Evrişim işlem süreci örneği

Yapılan bu işlemde, filtre matrisi görüntünün ilgili piksel değerleriyle çarpılıp toplamları elde edilir. Bu işlem her bir görüntü için yapıldıktan sonra elde edilen değerlerin ortalaması alınır. Elde edilen ortalama değer, evrişim katmanından sonra elde edilen görüntünün ilgili pikseline yazılır. Evrişim katmanında filtrelerin görüntüye uygulanması sonucu oluşan çıktı boyutu Denklem 3.1’ de verilmiştir. Burada I giriş boyutunu, F filtre (kernel) boyutunu, P dolguyu (padding), S ise görüntüde filtrenin gezinmesi esnasındaki kayma (stride) değerini ifade etmektedir.


$$\text{Çıktı boyutu} = \frac{I-F+2P}{s} + 1 \quad (3.1)$$

Şekil 3.3’teki örnekte verilen değerler Denklem 3.1 ile hesaplandığında 5*5 lik giriş görüntüsünden, 3x3 lük bir özellik haritası elde edilmiştir.

3.2.1.3. Aktivasyon (Düzleştirilmiş doğrusal birim- ReLU) katmanı

Bu katman, her evrişim katmanından ve tam bağlantılı katmandan sonra gelir. Aktivasyon fonksiyonu, evrişim katmanı sonucu oluşan lineer yapının, lineer olmayan bir ağ yapısına dönüştürülmesini sağlar. Evrişim sonrası oluşan özellik matrisi bu katmanın giriş verisi olup, negatif değerlerin sıfıra eşitlenmesini sağlar. ReLU dışında sigmoid, logistic, hyperbolic tangent, rectified hyperbolic tangent ve Softmax aktivasyon fonksiyonları da bulunmaktadır. Aktivasyon katmanında ReLU nun tercih edilmesinin nedeni, diğer fonksiyonların, modelin geri yayılımındaki türev alımında ağırlıkların güncellenmesinin neredeyse sıfıra yakınsaması (yok olma gradyanı problemi, vanishing gradient problem) sorununa sebep olmalarıdır (Chen ve Ho, 2019; Tan ve Lim, 2019; Hu ve ark., 2021). Bu fonksiyonlarda ESA modelinin öğrenmesi çok uzun zaman aldığından daha hızlı öğrenme gerçekleştiren ReLU fonksiyonu kullanılır. Fonksiyon tanımı Denklem 3.2’ de, grafiksel gösterimi Şekil 3.4’te verilmiştir.


$$f(x) = \begin{cases} 0, & \text{eğer } x < 0 \\ x, & \text{eğer } x \geq 0 \end{cases} \quad (3.2)$$




Şekil 3.4. ReLU aktivasyon fonksiyonu

3.2.1.4. Ortaklama (Havuzlama) katmanı

Aşağı örnekleme (Downsampling, subsampling) olarak da bilinen bu katmanda, tanımlanan filtreler, hesaplama karmaşıklığını azaltmak ve ağın ezberlemesini engellemek için, ReLU katmanından gelen öznetelik matrisini alt bölgelere ayırır. Giriş matrisinde kanal sayısı sabit olup yükseklik ve genişlik bilgisi indirgenir. Bu durum görüntüdeki önemli bilgilerin kaybolmasına sebep olmaktadır ancak anlamlı verinin elde edilmesine katkı sağlamaktadır. Bir sonraki katmandaki hesaplama yükünü azaltmak için gereklidir. Max Pooling, Average Pooling, Sum Pooling, L2-norm Pooling şeklinde kullanımları mevcuttur. Şekil 3.5'te genel bir örnekte veri boyutundaki değişimle daha az piksel içermesine, Şekil 3.6'da ise maksimum ortaklamaya (max pooling) ait örnekler gösterilmiştir.



Şekil 3.5. Havuzlama Katmanı Örneği



Şekil 3.6. Maksimum ortaklama sonrası görüntü matrisindeki değişim.

3.2.1.5. Tam Bağlantılı Katman (Fully Connected- Dense)


ESA mimarilerinde ikinci kısım olan sınıflandırma bölümünde yer alan katmanda girdi nöronu bir ağırlık matrisi ile çarpılır ve bu sonuca bias değeri eklenir. Dense katmanı da olarak bilinir. Sınıflandırma için, özellik çıkarımı katmanları sonucunda oluşan iki boyutlu özellik haritasını (feature map) tek boyutlu bir vektöre dönüştüğü katmandır. Bu sayede sınıflandırma sürecindeki olasılık değerlerinin hesaplanmasına yardımcı olmaktadır. Bu katman kendinden önceki katmanın bütün alanlarına bağlıdır.

Tasarlanan ESA modellerinde kaç adet tam bağlantılı katman kullanılacağı, çalışmalarda değişiklik gösterebilmektedir. ESA modellerinde evrişim katmanının yanı

sıra en fazla parametrenin bu katmanda kullanıldığı dikkate alınarak uygun parametre seçimi önemlidir.

3.2.1.6. Düşüm seyreltme (DropOut) katmanı

Eğitilen modelin ESA mimarilerindeki en önemli problemlerinden birisi de, modelin ezberlemesidir (overfitting). Ezberleme, belirli bir modelin, eğitim verileri üzerinde çok iyi çalıştığına, ancak yeni bir veride kullanıldığında ise modelin performansında olumsuz bir etkiye neden olduğunda ortaya çıkar. Ağın ezberlemesini engellemek için bazı düğümlerin ve düğüm bağlantılarının rastgele kaldırılması işlemi bu katmanda gerçekleşir (Srivastava ve ark., 2014). Bu işlem her bir ağın eğitiminde her bir devirde (epok) bir öncekinden bağımsız olarak rastgele nöronların seçilmesiyle uygulanır. Şekil 3.7’de ağın orijinal yapısı ve düşüm seyreltme katmanının uygulanışı sonrası gösterilmiştir.



Şekil 3.7. ESA ağında düşüm seyreltme işlemi

3.2.1.7. Sınıflandırma Katmanı

Tam bağlantılı katmandan sonra gelen ve ağın öğrendiği bilgiyi dışarıya aktardığı katmandır. Sınıflandırma katmanında çıkış değeri ağa verilen örneklerin sınıflandırılması istenen nesne sayısına eşitlenmelidir. Ön eğitilmiş ağların performansının test edilmesi istenen bir veri kümesinde sınıf sayısına eşit olacak şekilde değiştirilmesi gerekmektedir. Başarısından dolayı bu katmanda genellikle Softmax sınıflandırıcısı tercih edilir. Her bir nesne kümesindeki örnek için üretilen $[0,1]$ aralığındaki olasılıktan hangisi en yüksek ise modelin tahmini olarak o sınıfa dahil olacak şekilde etiketlenir.

3.2.2. ESA Eğitim Parametreleri

ESA modellerinin eğitim aşamasında kullanılan parametreler veri setine göre en yüksek başarıyı sağlayacak şekilde belirlenmelidir. ESA mimarilerinin başarısının artırabilmek amacıyla en uygun eğitim parametre eşlerinin seçilmesi, belirli bir veri setinde parametre eşlerinin nasıl performans sergilediğinin incelenmesi önemlidir. Bu kısımda tez çalışması kapsamında, veri seti üzerindeki etkisinin araştırıldığı eğitim parametreleri hakkında kısaca bilgi verilmiştir.

- **Optimizasyon algoritması (Optimizer Algorithm):** ESA mimarisinde ağırlıkların ve öğrenme oranlarının değiştirilmesiyle kayıpların azaltılmasına katkı sağlar. Bu sayede mümkün olan en doğru sonuçların elde edilmesini ve model başarısının artırımını amaçlar (Im ve ark., 2016; Haji ve Abdulazeez, 2021). Optimum değerleri bulabilmek, başarılı ve hızlı sonuçların elde edebilmek için farklı yöntemler kullanılmaktadır. Bu tez çalışmasında optimizasyon algoritması olarak SGDM, RMSProp ve Adam optimizasyon yöntemleri kullanılmıştır.
- **Yığın boyutu (Mini batch size-MBS):** ESA mimarisine verilen alt örneklerin sayısıdır. Verilen örnekler, her bir epokta ESA'nın sonuna kadar giderek ağırlık hata oranı hesaplanıp, ağırlıkların güncellenen optimizasyon işlemi yapılır. MBS, ağırlık eğitiminde kullanılan donanımsal CPU ya da GPU belleği boyutuna sığmadığında yetersiz bellek kullanımından dolayı ağırlık eğitimi yapılamadığı durumlar söz konusu olabilmektedir. Bu nedenle ESA mimarisinin katman sayısına ve donanımsal yeterliliğe göre olabilecek en uygun MBS değerleri seçilmelidir (Masters ve Luschi, 2018). Çalışmalarda MBS olarak, eğitim verisetinden az olacak şekilde GPU belleğine sığabilecek bir değer olarak belirlenmelidir. Genellikle ikinin kuvvetleri şeklinde alınmaktadır (8, 16, 32 gibi).
- **Maksimum devir sayısı (epok):** Ağırlık eğitiminde kullanılan tüm veri setinin tüm ağırlık boyunca çalışması sayısıdır (forward-backpropagation). Belirlenen MBS daki örneklerin tamamının ağırlıkta tamamen işlenerek ağırlıkların güncellenmesidir. Epok sayısının çok fazla olması ağırlık ezberlemesine sebep olmaktadır. Genellikle epok sayısı minimum 10 maksimum 150

alınmaktadır. Tezde maksimum epok sayısı olarak 10,25, 50, 100 ve 150 değerleri kullanılmıştır.


- **Öğrenme Hızı (Learning Rate- LR):** Model ağırlıklarının, geriye yayılım (backpropagation) sırasında değiştirilerek güncellenme oranıdır. LR parametresinin büyük olması, algoritmanın hızlı bir şekilde öğrenmesine olanak sağlamaktadır. Ancak ağıın büyük adımlarla öğrenmeye çalışması durumunda genellikle en uygun sonucun bulunması gereken şartları yerine getirme ihtimali çok düşüktür. Mimarinin yüksek doğruluk üreteceği ağırlık değerlerinin ıskalanmasına sebep olmaktadır. LR parametresinin çok küçük olması halinde ise ağıın ağırlıklarının güncellenmesi küçük adımlarla olacağından optimum sonucun bulunabilmesi mümkündür. Bu durumda ise mimarinin eğitim süresinin çok uzun sürmesi ve yerel (lokal) bir çözüme takılarak optimum sonuca ulaşamaması gibi problemler oluşabilmektedir. Bu yüzden uygun LR nin bulunması ESA mimarisinin başarımı için önemlidir. Genellikle $1e-1$ başlayarak $1e-1$ katları ($1e-2$, $1e-3$, $1e-4$ gibi) şeklinde değerler alınmaktadır.
- **Öğrenme Hızı Programı (Learning Rate Schedule-LRS)** parametresi ise LR parametresinin ağıın eğitimi boyunca sabit kalıp kalmadığını belirlemektedir. “None” ise eğitim boyunca LR sabit kalmaktadır. “Piecewise” olduğunda ise belirlenen bir epok sayısında (Öğrenme Hızını Düşürme Periyodu - LearningRateDropPeriod) Öğrenme Hızı Düşürme Faktörü (LearnRateDropFactor) parametresinde belirtilen oranda azaltılır. Bu sayede ağıın başlangıçtaki ağırlık değişimlerini azaltarak öğrenme sürecinin sonuna doğru küçük değişimlerle azaltılarak küçük değişimler (ince ayar fine-tuning) yapılmasını sağlamaktadır.
- **Momentum katsayısı:** ESA modellerinde ağıın optimum değere daha hızlı ulaşması için kullanılan parametredir. Genellikle 0.9 olarak belirlenmektedir.

3.2.3. Yara Segmentasyonunda ESA Modelleri


Görüntü içinden anlamlı parçanın çıkarılarak sınıflandırmada kullanılması, modellerin başarımlarını artırmaktadır. Bu tez çalışması kapsamında, segmentasyon işlemi için önerilen yaklaşımlarda kullanılan segmentasyon yöntemleri kod çözücü (decoder) ve temel kodlayıcı (encoder) ESA modellerine ait bilgiler alt başlıklar halinde incelenmiştir.

3.2.3.1 Segmentasyon ESA Modelleri (Kod Çözücü Modeller)

Tam Evrişimsel Ağlar (FCN): Semantik resim segmentasyonu için mevcut AlexNet, VGGNet ve GoogleNet ESA mimarilerinde değişiklik yaparak pixel bazında (pixel-wise) tahminler yapmayı verimli bir şekilde öğrenebilen Şekil 3.8’de gösterilen FCN ağları kullanılmaktadır (Long ve ark., 2015). Evrişim modelinin son havuzlama katmanının (pooling layer) önceki havuzlama katmanlarıyla birlikte kaynaşmaları (fuse) ile yukarıya örnekleme yapılmaktadır (upsampling). Bu sayede farklı havuzlama katmanlarının tahminlerini kombine ederek FCN-8s, FCN-16s ve FCN-32s versiyonları ele alınmıştır. Şekil 3.9’da gösterildiği üzere ESA mimarileriyle evrişim ağı, aşağı örnekleme (downsampling), atlama bağlantısı (skip connection) kullanımıyla da farklı havuzlama katmanlarından (pool4, pool3) yukarı örnekleme (upsampling) yapılarak ters evrişim (deconvolution) ağı oluşturulmuştur. Semantik resim segmentasyonu için önerilen ilk derin öğrenme yaklaşımlarından biri olan FCN, PASCAL VOC 2011-2, NYUDv2, ve SIFT Flow veri setlerinde test edilmiştir (Long ve ark., 2015). FCN mimarisi Şekil 3.9’da gösterilmiştir.

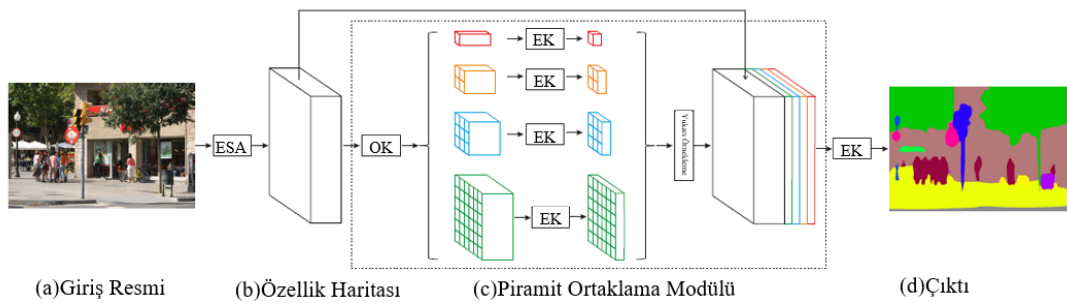


Şekil 3.8. FCN resim segmentasyon modeli (Long ve ark., 2015)



Şekil 3.9. FCN Ters Evrişim (Deconvolution) yapısı (Upsampling) (Long ve ark., 2015).

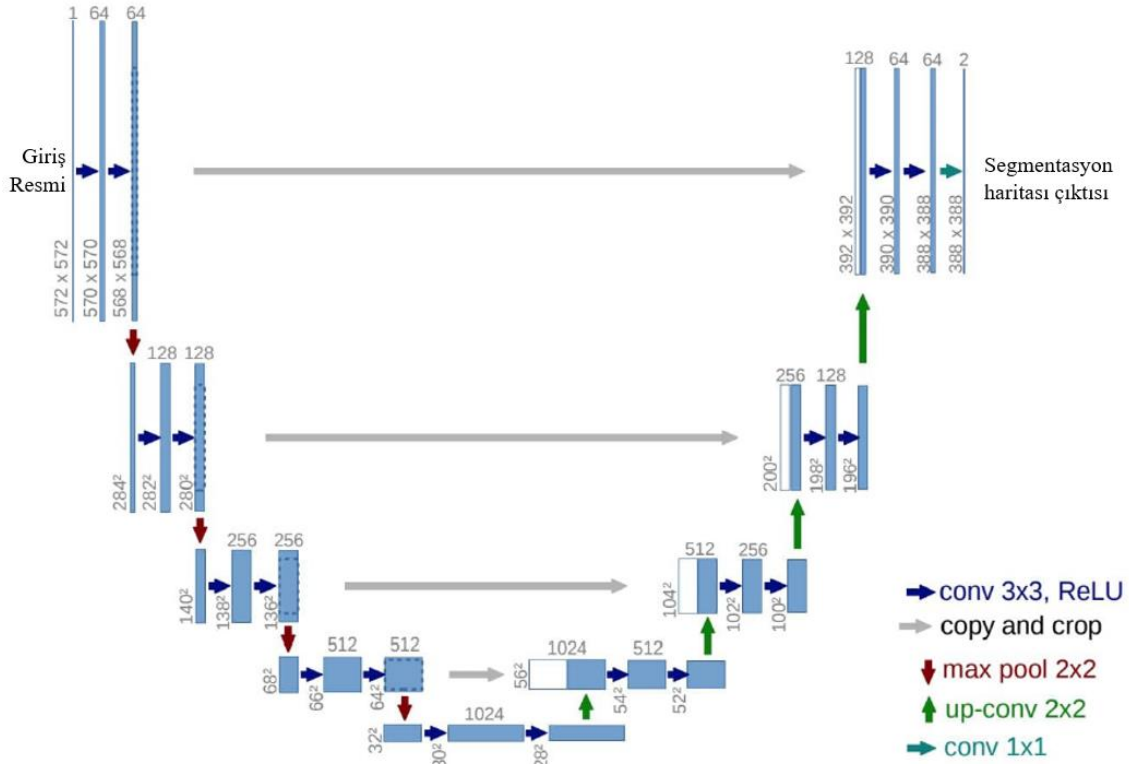
Piramit Sahne Ayrıştırma Modeli (PSPNet): (Zhao ve ark., 2017), özellik haritasının çıkarımı için, ön eğitilmiş (pre-trained) ResNet modelini, genişletilmiş network stratejisi ile (dilated network strategy) kullanarak, piksel seviyesinde tahmin yapabilen FCN tabanlı PSPNet modelini önermişlerdir. Özellik çıkarıcı olarak ResNet ağını kullanarak giriş görüntüsünden farklı özellik haritaları çıkarmışlardır. ResNet ağından gelen özellik haritaları kullanılarak, farklı çözünürlüklerde çok ölçekli havuzlama katmanlarıyla (multi-scale (1x1,2x2, 3x3 and 6x6) pooling layers) farklı alt bölgelerin tespit edilmesi sağlanır. Son olarak piramit ayrıştırma modülündeki parçalar, yukarı örneklenir ve birleştirilir (birleştirme katmanı-concatenation layer). Son olarak evrişim katmanı ile piksel seviyesinde segmente edilmiş tahmin elde edilir. Önerilen yöntem, ImageNet, Pascal Voc 2012 ve CitySpaces benchmark verisetlerinde test edilmiştir.



Şekil 3.10. Pixel tabanlı tahmin edici PSPNet modeli yapısı (Zhao ve ark., 2017).

U-NET: Medikal görüntü analizinde oldukça sık kullanılan U-NET mimarisi ilk olarak biyomedikal resim segmentasyonu için önerilmiştir (Ronneberger ve ark., 2015). Eşit miktarda aşağı örnekleme (downsampling) ve yukarı örnekleme (upsampling) katmanlarına sahiptir. Bu mimaride bu iki katman karşılıklı simetrik olarak atlama bağlantısı (skip connection) ile birleştirilir. Aşağı örnekleme (downsampling (kodlayıcı)) katmanlarında 3x3 evrişim, ReLU ve 2x2 maksimum havuzlama (max pooling) işlemleri


gerçekleştirilir. Bu aşamada her bir adımda özellik iki katına çıkarılmaktadır. Yukarı örnekleme (upsampling) katmanında ise özellik haritası simetrisindeki ile eşleştirilerek yarıya indirgenir. Mimariyi başarılı kılan, katmanların hem kendisiyle hem de karşı katmanla evrişim içinde olmasıdır. Bu sayede mimarideki yukarı örnekleme (upsampling) katmanlarına model bilgilerinin kaybolmasını önlemek için ağın aşağı örnekleme kısmından özellik haritaları yukarı örnekleme kısmına kopyalanır (copy and crop). U-Net mimarisi Şekil 3.11’de gösterilmiştir.



Şekil 3.11. U-net mimarisi (32x32 pixel için) (Ronneberger ve ark., 2015)

SEG-Net: Evrişimsel kodlayıcı- kod çözücü tabanlı bu mimaride 5 kodlayıcı, 5 kod çözücü blok mevcuttur. Kodlayıcı blokta, özellik çıkarıcı olarak VGG-16 mimarisini kullanmaktadır (Badrinarayanan ve ark., 2017). Kodlayıcı bloklarında geleneksel ESA tanımındaki gibi evrişim, (Batch normalizasyon ve ReLU ile) katmanları bulunmaktadır. Kod çözücü kısmında ise seyrek özellik haritası (sparse feature map) üretmek için kodlayıcı bloğundaki havuz indislerini (pool indices) kullanarak yukarı örnekleme yapar (upsampling). Bu sayede piksel tabanlı sınıflandırma için kodlayıcı katmanında üretilen düşük çözünürlüklü özellik haritalarının, girdi görüntü ile birlikte yüksek çözünürlüklü

özellik haritasının yeniden üretilmesi sağlanır. Yöntem, CamVid 11 Road ve SUN RGB-D veri setlerinde test edilmiştir. Seg-Net mimarisi Şekil 3.12’de gösterilmiştir.



Şekil 3.12. Seg-Net mimarisi (Badrinarayanan ve ark., 2017)

DeepLabV3: Google tarafından semantik resim segmentasyonu için geliştirilen bu mimari (Chen ve ark., 2017), her bir konvolüsyon bloğunun özelliğini kullanarak karşılık gelen ters evrişim (deconvolutional) bloğuyla birleştirir. Yukarı örnekleme için atröz genişlemiş evrişim (atrous dilated convolution) kullanmaktadır. Yöntem PASCAL VOC 2012, PASCAL-Context, PASCAL-Person-Part, and Cityscapes verisetlerinde test edilmiştir.

3.2.3.2 Kodlayıcı (Backbone) ESA Modelleri

Segmentasyon modellerinde modelin seçiminde resmi piksel bazında kodlamak için (downsampling) uygun bir temel ESA mimarisinin seçilmesi gerekmektedir. Kodlayıcı aşamasında, orijinal resmin özellikleri çıkarılır. Resmi aşağı örnekleme yaparak özellik çıkarımı (feature extractor) ile yüksek seviye detaylar yakalanır. Genellikle segmentasyon işlemlerinde ImageNet için önceden eğitilmiş modeller tercih edilmektedir.

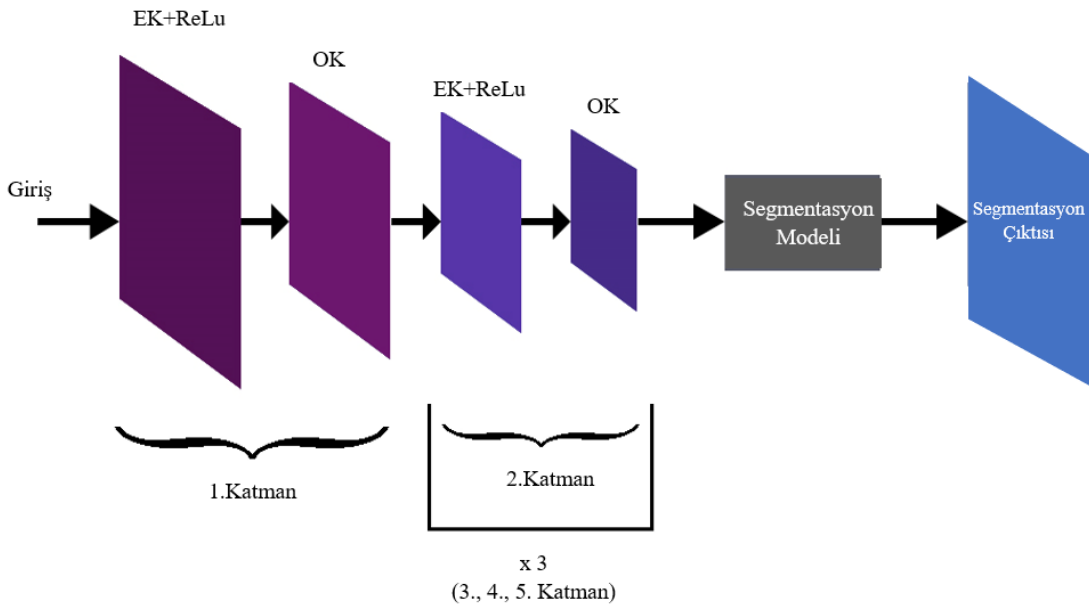
ResNet: Microsoft tarafından önerilen ve ImageNet 2016 yarışmasında %96.4 doğruluk elde eden modeldir (He ve ark., 2016). ResNet, çeşitli uygulamalar için önceden eğitilmiş bir model olarak kullanılır. ResNet, eğitimi mümkün kılan artık bağlantılarla birlikte çok sayıda katmana sahiptir. Modelin giriş katman boyutları 224x224 piksel çözünürlüğündedir. VGG modellerine göre daha derin modeller olmasına karşın parametre sayısı ve modelin boyutu azdır. Bu sayede daha hızlı öğrenme gerçekleştirilmektedir.

VGG16: Oxford'un önerdiği ve ImageNet 2013 yarışmasında %92.7 doğruluk elde eden modeldir (Simonyan ve Zisserman, 2014). Modelin giriş görüntü boyutu 224x224 piksel çözünürlüğündedir. VGG16, çok sayıda uygulama için standart önceden eğitilmiş model olarak kullanılmaktadır.

MobileNet: Bu model (Howard ve ark., 2017), Google tarafından önerilmiş olup, küçük bir model boyutuna ve daha hızlı çıkarım süresine sahip olacak şekilde optimize edilmiştir. Bu sayede, cep telefonları gibi mobil cihazlarda çalışması açısından ideal bir modeldir.

EfficientNet: 2019 yılında önerilen bu ESA mimarisi, derinlik, genişlik ve çözünürlüğün tüm boyutlarını ölçeklendirebilmek için bileşik katsayı (compound coefficient) adı verilen bir yöntem kullanmaktadır. Bu yöntem sayesinde geleneksel yöntemlerin aksine genişlik, derinlik ve çözünürlük, sabit bir ölçekleme katsayısıyla ölçeklendirilir. Temel Efficient-B0 ağı, sıkma ve eksitasyon bloklarına ek olarak MobileNetv2'nin ters darboğaz kalıntısı bloklarına dayanmaktadır (Tan ve Le, 2019).

Vanilla CNN: Önceden eğitilmiş bir ImageNet modeli kullanmanın yanı sıra, farklı sayıda evrişim+ReLU+havuzlama katmanlarının bulunduğu özel bir ağ kullanılabilir. Bu tez çalışması kapsamında geleneksel ESA mimarisi adımlarından faydalanılarak beş katmanlı bir ağ, kodlayıcı olarak tasarlanarak Şekil 3.13'te gösterilmiştir (Eldem ve ark., 2023c).



Şekil 3.13. Tasarlanan Vanilla ESA Mimarisi (Eldem ve ark., 2023c)

3.2.4. Yara Sınıflandırmasında ESA Modelleri

Son zamanlarda derin öğrenme mimarileri görüntü analizinde başarıları ile ön plana çıkmıştır. Literatürde çalışılan farklı görüntülerden oluşan veri setlerinde derin öğrenme mimarilerinin hangisinin başarılı sonuçlar gösterebileceği farklılık gösterebilmektedir. Ayrıca kullanılan derin öğrenme mimarilerinde parametre seçimi de önem arz etmektedir. Aşağıda, bu tezde kullanılan sınıflandırıcı derin öğrenme mimarileri tanıtılmıştır.

GoogleNet: Bu mimari 22 katman derinliğine sahip bir ESA mimarisidir. Google araştırmacıları tarafından ILSVRC 2014 yarışması için önerilmiştir. 224x224 görüntü giriş büyüklüğüne sahiptir. Sınıflandırma için kullanılan mimari mevcut verisetindeki sınıf sayısına göre çıkış değeri ayarlanır. %6.7 hata oranıyla ILSVRC2014 yarışmasında birinci olmuştur (Szegedy ve ark., 2015).

Densenet201: (Huang ve ark., 2017) tarafından önerilen bu ESA mimarisi 201 katman derinliğe sahiptir. 224x224 görüntü giriş büyüklüğüne sahip bu ağ Resnet mimarisinden esinlenerek geliştirilmiştir. Yoğun bağlantı (Dense connectivity) ile katmanlar arasındaki bilgi akışını daha da iyileştirmek için her bir katmanın bağlantılarının kendisini takip eden katmanlar arasında bağlantılar kurmaktadır (Huang ve ark., 2017).

Mobilenetv2: (Sandler ve ark., 2018) tarafından, mobil cihazlar için önerilen bir ESA mimarisidir. Google tarafından önerilen bu mimari, 224x224 görüntü giriş büyüklüğüne sahiptir. 53 katman derinliğine sahip olan bu mimari mobilenetv1 mimarisinin gelişmiş versiyonudur.

Resnet18: Microsoft tarafından önerilen ve ImageNet 2016 yarışmasında %96.4 doğruluk elde eden modeldir (He ve ark., 2016). 224x224 görüntü giriş büyüklüğüne sahip olan Resnet18 mimarisinin 18 katman derinliği bulunmaktadır.

Resnet50: (He ve ark., 2016) tarafından önerilen, ILSVRC 2015 yarışmasının kazananı olan bu mimari 224x224 görüntü giriş büyüklüğüne sahiptir. 50 kalıntı ağları(residual networks) derinliğe sahiptir. Birçok evrişim katmanının (EK) bir araya gelmesiyle oluşan kimlik bloğu (identity block) yapısından oluşmaktadır. Katmanlar arasında kimlik bağlantıları olan, derin kalıntılı ağ (deep residual network) dir. Bu sayede ufuk çizgisinin kaybolması probleminin (vanishing gradient problem) ortadan kaldırılması amaçlanmıştır.

Resnet101: (He ve ark., 2016) tarafından önerilen bu mimari 224x224 görüntü giriş büyüklüğüne sahiptir. 101 katman derinliğe sahiptir.

Shufflenet: Kısıtlı-limitli hesaplama gücüne sahip mobil cihazlar için (Zhang ve ark., 2018) tarafından önerilen bu mimari, 50 katman derinliğine 224x224 görüntü giriş büyüklüğüne sahiptir. Özellik kanalları (features channel) arasında bilgi akışına yardımcı olmak için kullanılan yeni bir kanal karıştırma işlemi (shuffle operation) içerir.

Nasnetmobile: Google takımı tarafından geliştirilen Neural Architecture Search Network (Nasnet) 224x224 görüntü giriş boyutuna sahiptir. Takviyeli öğrenme (Reinforcement learning) kullanarak optimize edilen temel yapı bloklarından (basic building block) oluşturulmuş bir mimaridir. Mimari 12 bloktan oluşmakta ve 5.3 milyon parametreye sahiptir (Zoph ve ark., 2018).

Efficientnetb0: Giriş çözünürlüğü 224x224 olup 82 katman derinliğe sahiptir. (Tan ve Le, 2019) tarafından önerilen, ImageNet ve yaygın resim sınıflandırma transfer öğrenme görevlerinde etkili bir mimaridir.

Vgg16: Oxford'un önerdiği ve ImageNet 2013 yarışmasında %92.7 doğruluk elde eden modeldir (Simonyan ve Zisserman, 2014). 16 katman derinliğe, 224x224 görüntü giriş boyutuna sahiptir. AlexNet' e kıyasla yüksek çekirdek boyutları azaltılmıştır. VGGNet mimarisi tüm katmanlarında 3x3 filtre kullanır ve Evrişim-ReLU katmanlarını havuzlama katmanından önce üst üste kullanır. Diğer derin mimarilerdeki gibi VGG mimarisinde de giriş katmanından çıkışa doğru matrislerin yükseklik ve genişlik boyutları azalırken derinlik değeri artar.

Vgg19: 19 katman derinliğine sahip ESA mimarisidir. Model 224x224 görüntü giriş boyutu kullanmaktadır. 16 katmanlı Vgg16 mimarisinden tek farkı katman (layer) sayılarıdır (Simonyan ve Zisserman, 2014).

Squeezenet: (Iandola ve ark., 2016) tarafından önerilen 50 katman derinliğe ve 224x224 giriş çözünürlüğüne sahip bir mimaridir. Geleneksel ESA mimarilerindeki performansın artırılması amacıyla network ağırlıklarını azaltan 1x1 filtreler kullanılmaktadır. Dağıtılmış katmanlar sayesinde, AlexNet mimarisine göre, hesaplama maliyetinin azaltılarak daha hızlı çalışmaktadır.

AlexNet: (Krizhevsky ve ark., 2012) tarafından geliştirilen bir evrişimsel sinir ağı mimarisi olup giriş görüntü boyutu 227x227'dir. 8 katman derinliğe sahip AlexNet ILSVRC 2012 yarışmasının kazananıdır. İlk 5 katmanı evrişim son 3 katmanı ise tam bağlı katmandan oluşmaktadır. Katmanlar arasında havuzlama ve aktivasyon katmanları

da bulunmaktadır. ESA modelleri arasında önemli bir yere sahiptir (Sunitha Nandhini ve ark., 2022).

Darknet19: Bu mimari 19 katman derinliğine sahip bir ESA mimarisidir. 256x256 görüntü giriş büyüklüğüne sahiptir. Nesne tanımlamada kullanılan YOLOv2 modelinin backbone modeli olarak kullanılmaktadır. 3x3 filtre ile başlayan mimaride her bir havuz katmanından sonra kanal sayısı 2 katına çıkarılır (Redmon ve Farhadi, 2017).

Darknet53: Bu mimari 53 katman derinliğine sahip bir ESA mimarisidir. 256x256 görüntü giriş büyüklüğüne sahiptir (Redmon ve Farhadi, 2018) . Bir önceki versiyonu Darknet19' un gelişmiş olan model YOLOv3 nesne tamlama modelinin backbone modeli olarak kullanılır.

Inceptionv3: (Szegedy ve ark., 2015) tarafından başlangıç modeli olarak oluşturulan GoogleNet (Inceptionv1) ESA mimarisi üzerine kurulmuştur. (Szegedy ve ark., 2016) başlangıç modelinin yeni versiyonu olarak Inceptionv3 geliştirmişlerdir. Inception_v3; inception_V1 ve inception_V2 ye göre daha fazla parametreye sahiptir. Aynı giriş tensörü, birden fazla filtreyle kullanılmakta olup çıktılar birleştirilerek bir sonraki başlangıç (inception) modülüne gönderilmektedir. 3 farklı boyutta filtre (1x1, 3x3, 5x5) ile paralel evrişimli katman bloğuna sahiptir. Bununla birlikte 3x3 maksimum havuzlama yapılmaktadır. 48 katmana sahip olan mimari 299x299 görüntü giriş büyüklüğüne sahiptir.

Xception : (Chollet, 2017) tarafından önerilen bu ESA mimarisi 71 katmandan oluşmakta olup 299x299 görüntü giriş büyüklüğüne sahiptir. Derinlemesine konvülasyonlar içeren bu mimari, Inception mimarisinin (Szegedy ve ark., 2015) geliştirilmiş bir versiyonudur.

Inceptionresnetv2: (Szegedy ve ark., 2017) tarafından önerilen bir ESA mimarisi olup ImageNet veri tabanındaki bir milyondan fazla görüntü ile eğitilmiştir. Model 299x299 görüntü giriş boyutu kullanmakla birlikte çıkış olarak sınıf olasılıklarının bir listesini verir. Inception ve Resnet in birleştirildiği hibrid bir tekniktir.

Nasnetlarge: ImageNet veritabanından bir milyondan fazla görüntüde eğitilmiş evrişimsel bir mimaridir. 331x331 görüntü giriş boyutuna sahiptir (Zoph ve ark., 2018).

3.3. Transfer Öğrenme (TÖ)

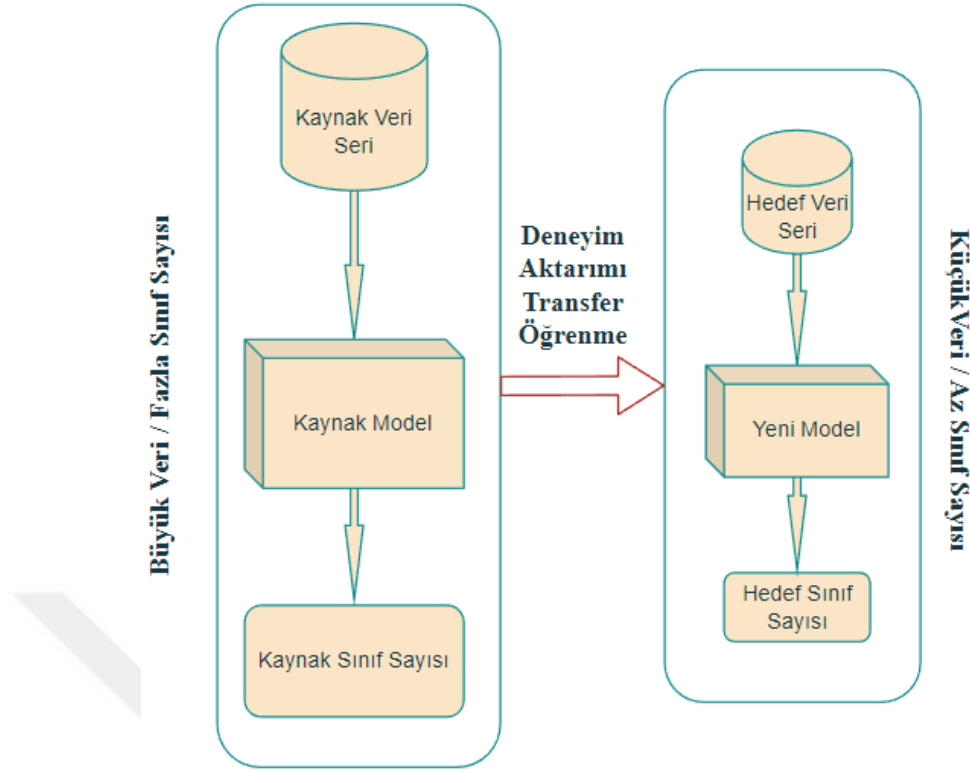
DÖ mimarileri son zamanlarda her ne kadar büyük bir çalışma alanı bulsa da tasarlanan ve önerilen yeni modellerin öğrenme süreçleri için çok sayıda veri ve büyük

hafıza gerektirmektedir. DÖ mimarilerinin eğitiminde yeterli sayıda kullanılacak veri olmaması durumunda transfer öğrenme yapısı tercih edilmektedir (Khan ve ark., 2019; Alzubaidi ve ark., 2020a; Kora ve ark., 2021; Yu ve ark., 2022). Transfer öğrenmedeki asıl önemli katkı, önceden büyük bir görüntü veri setinden öğrenilen deneyimin, farklı bir görev için zekice uygulanabilmesidir.

ImageNet veriseti üzerinde eğitilerek oluşturulan ağırlıkların kullanılması yakınsamayı hızlandırabilir ve az sayıda veri üzerinde daha iyi sonuçların elde edilmesini sağlar. Ağın tamamının eğitilmesi yerine ön eğitilmiş ağlardan ağırlıkları alınır ancak son katmanda ince ayar yapılarak sınıf sayısına göre yeniden eğitilir. Rastgele ağırlıkların atanarak başta eğitilen bir ağı eğitmekten çok daha ve hızlı bir şekilde, öğrenme gerçekleşir. ESA mimarilerinde ilk evrişim katmanlarında düşük seviyeli özellikler, ilerleyen katmanlarda ise yüksek seviyeli ve girdi görüntülerine özgün nitelikler yakalanır. Dolayısıyla transfer öğrenme sayesinde son evrişim katmanlarında probleme özgü bir şekilde değişiklik yapılabilir.

Özellikle medikal alanda veri elde etmenin zorluklarından dolayı Transfer Öğrenme kullanılarak mevcut mimariler medikal görüntü sınıflandırma problemlerinde kullanılmaktadır. TÖ sayesinde ImageNet gibi büyük bir veri seti üzerinde eğitilen bir DL mimarisi, medikal görüntü sınıflandırma için mimarinin önceki (knowledge/experience) deneyiminden faydalanmaktadır. Böylece farklı medikal problemler için daha hızlı veya daha iyi çözümler sağlanmaktadır.

Tez çalışması kapsamında, sınıflandırma işlemlerinde, oluşturulan orijinal yara görüntüsü veri seti üzerinde, literatürdeki yöntemler, transfer öğrenme kullanılarak eğitilmiştir. Segmentasyon işlemlerinde ise base (Backbone) modellerde kullanılan ön eğitilmiş modellerin katmanlarının son katmanı olan tam bağlantılı çıkarılmıştır. Bu sayede hem segmentasyon işleminde hem de sınıflandırma işleminde transfer öğrenimi, küçük bir eğitim veri setinden son derece doğru bir model elde edebilmektedir (Alzubaidi ve ark., 2020a; Alzubaidi ve ark., 2021a; Azizi ve ark., 2021; Alzubaidi ve ark., 2022). Transfer öğrenme ayrıca modelin sınıf sayısına göre tam bağlantılı katmanların ve sınıflandırma katmanının eğitilmesini de kapsamaktadır. Şekil 3.14'te transfer öğrenme işleyişinin blok diyagramı gösterilmiştir.



Şekil 3.14. Transfer Öğrenme Diyagramı

3.4. Kullanılan Veri Setleri

Tez çalışması kapsamında literatürden alınan Medetec veri seti ve Karaman Eğitim Araştırma Hastanesi Yara Bakımı Ünitesindeki hastalardan ve Türkiye’deki diğer uzman doktorlar tarafından toplanılan 2018-2022 yılları arasında yara görüntüleri kullanılmıştır. Çalışma kapsamında kullanılan özgün veri seti için gereken etik kurul kararı, çalışmada sorumlu araştırmacı olarak tez kapsamında verilerin toplanması ve etiketlenmesi konularında katkı sunan ve uzman doktor olarak görev yapan Opr. Dr. Osman Yaşar IŞIKLI tarafından alınmıştır (Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kararı 06.12.2019 tarih ve 2019/2212 sayılı karar yazısıyla). Etik kurul raporu Ek-1’ de sunulmuştur.

Medetec Veriseti: Medetec yara veritabanı, venöz bacak ülserleri (venous leg ulcers), arteriyel bacak ülserleri (arterial leg ulcers), basınç ülserleri (basınç yaraları), kötü huylu yaralar (malignant wounds), cerrahi yara enfeksiyonu, diyabetik ayak yarası gibi cilt veya diyabetle ilişkili mikrovasküler değişikliklerden kaynaklanan 14 kategoriye


ayrılmış tüm açık yara görüntülerini içermektedir. Veriseti toplamda farklı çözünürlüklerde 610 adet resim içermektedir. Ücretsiz olarak internet ortamında paylaşılmaktadır (Steve, 2021a). Bu çalışmada, Medetec veri setindeki 177 adet çözünürlükleri farklı (genellikle 560x410) olan basınç yarası resimlerinin tümü kullanılmıştır (Steve, 2021b). Bu veri kümesi için veri toplama hakkında daha fazla bilgi bulunmamaktadır. Medetec veri kümesindeki basınç yarasının bazı görüntüleri Şekil 3.15'te verilmiştir.



Şekil 3.15. Medetec Basınç Yarası Resim Örnekleri (Steve, 2021b)

Literatürdeki yara segmentasyonunu konu alan kimi çalışmalarda Medetec veri setindeki tüm resimler ya da ele alınan konu gereği, bir kısım yara sınıfındaki (basınç, diyabetik, venöz, akut, bacak, arteriyel ve kötü huylu, vb.) resimler seçilmiştir (Bose ve ark., 2022).

Özgün Veriseti: Bu çalışmada, Karaman Eğitim ve Araştırma Hastanesi bünyesinde, granül, nekrotik ve slough kategorilerinde toplanılan 2100 orijinal resim kullanılmıştır. Resimler Iphone 7 Plus ve 48mp Android işletim sistemli cep telefonu ve Ipad Pro tablet ile en fazla 30 cm uzaklıktan tüm yara bölgesini kapsayacak şekilde elde edilmiştir. Resimler genellikle 1200x1600 çözünürlükte olup 1050 tanesi basınç yarası, 1050 tanesi ise diyabetik ayak yarısından oluşmaktadır. Veri setindeki resimlerden Şekil 3.16'da örnek verilmiştir.



Şekil 3.16. Özgün kronik yara görüntüleri

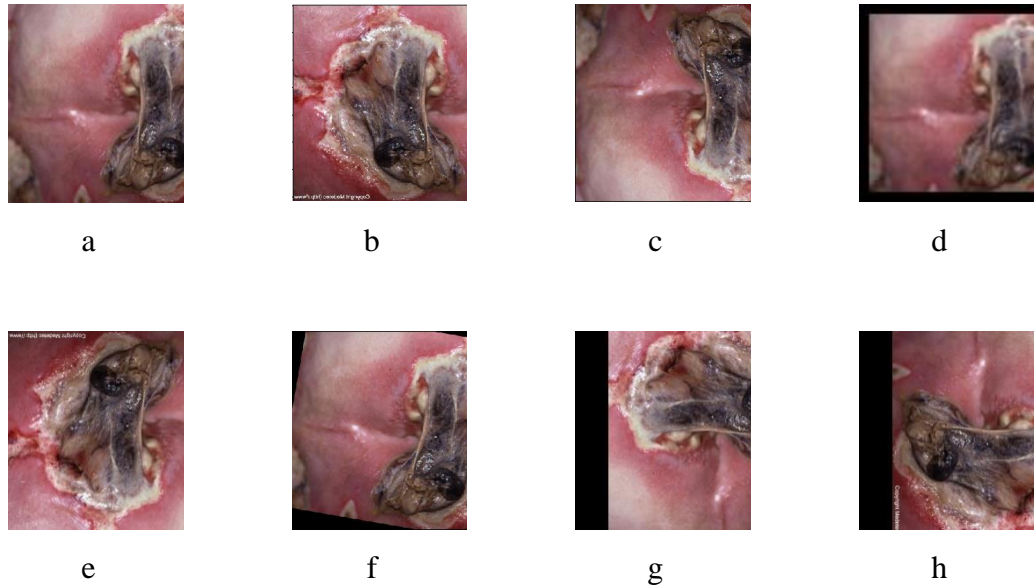
3.4.1 Veri Arttırma (Data Augmentation) Teknikleri

Veri artırma, yapay zekâ, makine öğrenmesi ve derin öğrenme mimari modellerinin eğitilmesinde fayda sağlamaktadır. Derin öğrenme modellerinin daha fazla veri ile eğitilebilmesi, modelin öğrenmeyi bırakarak ezberlemesinin engellenmesi (overfitting) gibi sebeplerle veri artırma derin öğrenme mimarilerinin önemli bir parçasıdır (Shorten ve Khoshgoftaar, 2019).

DÖ mimarilerinin eğitiminde başarılı olabilmesi için çok büyük miktarda modeli besleyecek veri gerekmektedir. Belirli bir konuda çalışma yapılması istendiğinde bu verinin toplanılması ve etiketlenmesi çok zaman alıcı ve zahmetlidir. Bu problemin çözümü için sentetik veri üretilmesi gerekmektedir. Literatürde DÖ mimarilerinin başarılı bir şekilde segmentasyon ve sınıflandırma yapılabilmesi için oldukça yaygın ve gerekli bir adımdır (Perez ve Wang, 2017; Mikołajczyk ve Grochowski, 2018; Shorten ve Khoshgoftaar, 2019; Yang ve ark., 2022).

3.4.1.1 Yara Segmentasyonunda Veri Arttırma Teknikleri

Veri setinde farklı çözünürlükteki tüm resimler ilk olarak 480x360 çözünürlüğe çevrilerek bir ön işlem uygulanmıştır. Segmentasyon işlemlerinde, yatay çevirme (horizontal flip), dikey çevirme (vertical flip), açısız döndürme (rotate) ve dolgu ekleme (padding) veri artırma yöntemleri kullanılmıştır. Böylece veri setinde bulunan 177 resim, çoğaltılarak 1416 resim ile modeller test edilmiştir (Eldem ve ark., 2023c). Kullanılan veri artırma teknikleri bir yara görüntüsü ile örneklenerek Şekil 3.17’de gösterilmiştir.



Şekil 3.17. Bir yara görüntüsü üzerinde kullanılan veri artırma yöntemlerinin uygulanması
(Eldem ve ark., 2023c)

a.Giriş Resmi, **b.** Yatay Çevirme, **c.** Dikey Çevirme, **d.** Dolgu Ekleme [5,5,5,5], **e.** Açısal Döndürme (180°), **f.** Açısal Döndürme (-25°,25°), **g.** Açısal Döndürme (90°), **h.** Açısal Döndürme (270°)

3.4.1.2 Yara Sınıflandırmasında Veri Arttırma Teknikleri

Eğitim aşamasında aşırı öğrenmeden (overfitting) kaçınmak için verisetindeki tüm resimler, döndürme (rotation), yansıtma (mirroring), döndürme (flipping) ve kırpma (cropping) yöntemleriyle veri artırma yapılmıştır. Sonuç olarak, 3500 granül, 3500 nekrotik ve 3500 slough olmak üzere toplamda 10500 resim içeren yeni bir veri seti üretilmiş ve bu tez çalışmasında kullanılmıştır (Eldem ve ark., 2022; 2023b; 2023a). Veri setine ait bilgiler Çizelge 3.1’de sunulmuştur.

Çizelge 3.1. Toplanan orjinal veri ve zenginleştirme sonrası dağılımı


Yara Türü	Orjinal	Veri Artırma Sonrası
Basınç yarası	1050	4200
	• 350 granül,	• 1400 granül,
	• 350 nekrotik	• 1400 nekrotik
	• 350 slough	• 1400 slough
Diyabetik ayak yarası	1050	4200
	• 350 granül,	• 1400 granül,
	• 350 nekrotik	• 1400 nekrotik
	• 350 slough	• 1400 slough

4. ÖNERİLEN YÖNTEMLER

Tez kapsamında yara görüntülerinin segmentasyonu ve sınıflandırması için önerilen yaklaşımlar bu bölümde sunulmuştur. Ayrıca parametre etkilerinin incelenmesi ve önerilen AlexNet mimarilerinin geliştirmeleri ile ilgili detaylar verilmiştir.

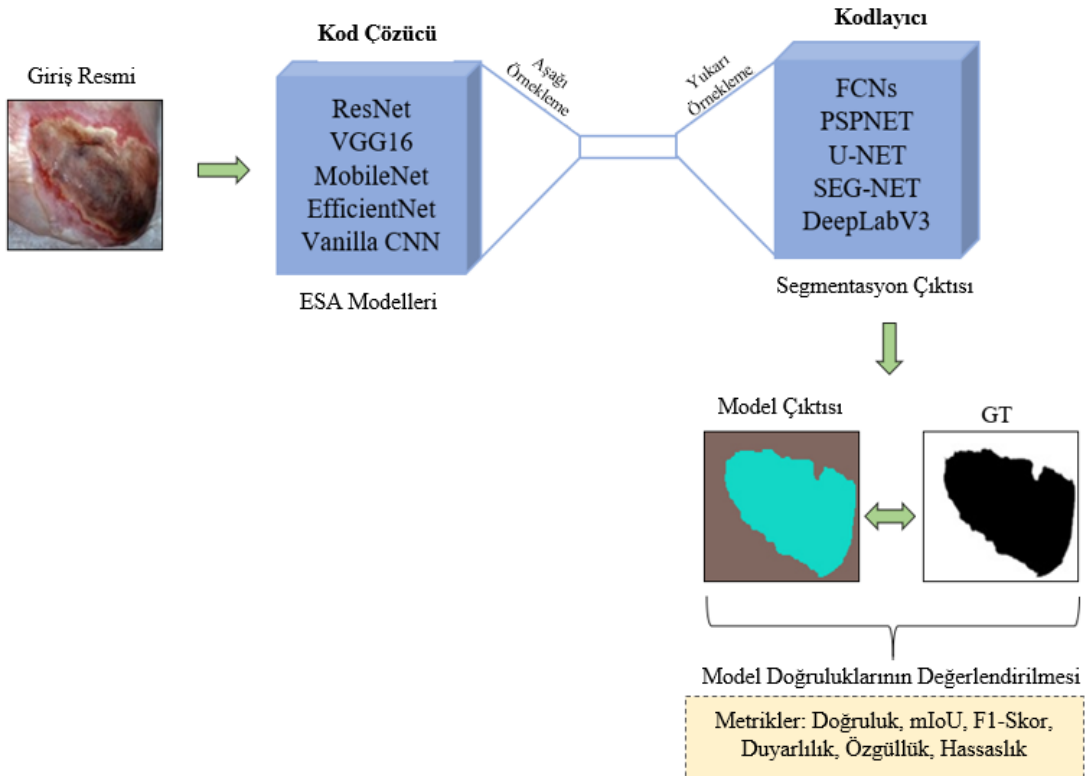
4.1. Önerilen Segmentasyon Modellerinin Tasarımı

Yara görüntülerinin başarılı bir şekilde segmente edilmesi, görüntülerin sınıflandırılması açısından önemlidir. Giriş görüntüsünden sadece yara bölgesinin çıkartılarak sınıflandırma işlemlerinde kullanılması için semantik (piksel tabanlı) segmentasyon yöntemi kullanılmıştır. Resimdeki her bir pikselin tanımlanması ve sınıflandırılması olarak tanımlanabilen semantik segmentasyon farklı birçok alanda resim segmentasyonunda kullanılmaktadır. Semantik segmentasyonun görevi, görüntünün piksel bazlı bir maskesini çıkarmak için, bir yapay zekâ yöntemi kullanarak, görüntünün çok daha düşük bir seviyede, yani piksel seviyesinde anlaşılmasına yardımcı olmaktır. Bu yöntemde modele verilen giriş resimlerinin çıkış değerlerinin yorumlanabilmesi için, DÖ ağına sınıf bilgisi olarak görüntünün tıp uzmanı tarafından yara bölgesinin işaretlenmiş gerçek zemininin verilmesi gerekmektedir. Bu sayede görüntülerin gerçek zeminini (ground truth – GT) ile giriş görüntüsü piksel bazlı karşılaştırma yapılır. Veri setindeki yara görüntülerinin gerçek zeminleri Karaman Eğitim ve Araştırma Hastanesinde görevli Op.Dr. Osman Yaşar IŞIKLI tarafından oluşturulmuştur (Eldem ve ark., 2023c). Bazı yara görüntüleri ve GT' ları Şekil 4.1'de gösterilmiştir.



Şekil 4.1. Yara Görüntüleri ve Gerçek Zeminleri (GT)

Bu tez çalışmasında yara görüntülerinin segmentasyonu için, tıbbi yara görüntü veri seti üzerinde DÖ tabanlı Tam Evrişimsel Ağlar (FCN8-16-32), PSP-Net, U-Net ve Seg-Net, DeepLabV3 segmentasyon modelleri ile basınç yara segmentasyonu başarımları ele alınmıştır. Backbone (Base) model olarak Resnet, VGG-16, MobileNet, EfficientNet ve Vanilla CNN kullanılmıştır. Çalışmada kullanılan mimarileri ve işlem adımlarını gösteren akış şeması Şekil 4.2’de gösterilmiştir.



Şekil 4.2. Kodlayıcı - Kod çözücü tabanlı yara segmentasyonu akış şeması (Eldem ve ark., 2023c)

Yara segmentasyonu çalışmasında, 20 farklı model, yara veri seti üzerinde test edilerek Temel (Base) Model ve Segmentation Model başarımları değerlendirilmiştir. Çalışmada kullanılan modellere ait bilgiler Çizelge 4.1’de verilmiştir.

Çizelge 4.1. Segmentasyon işlemlerinde kullanılan mimariler (Eldem ve ark., 2023c)

Model No	Model Adı	Temel Model (Base -Backbone)	Segmentasyon Modeli (Kod çözücü Model)
1	CNN-FCN8	Vanilla CNN	FCN8
2	CNN-FCN16	Vanilla CNN	FCN16
3	CNN-FCN32	Vanilla CNN	FCN32
4	VGG16-FCN8	VGG16	FCN8
5	VGG16-FCN16	VGG16	FCN16
6	VGG16-FCN32	VGG16	FCN32
7	CNN-PSPNet	Vanilla CNN	PSPNet
8	VGG16-PSPNet	VGG 16	PSPNet
9	ResNet-PSPNet	Resnet	PSPNet
10	CNN-UNet	Vanilla CNN	U-Net
11	VGG16-UNet	VGG 16	U-Net
12	ResNet-UNet	Resnet	U-Net
13	MobileNet-UNet	MobileNet	U-Net
14	EfficientNet-UNet	EfficientNet	U-Net
15	CNN-SegNet	Vanilla CNN	Segnet
16	VGG16-SegNet	VGG 16	Segnet
17	ResNet-SegNet	Resnet	Segnet
18	MobileNet-SegNet	MobileNet	Segnet
19	VGG16-DeepLabV3	VGG 16	DeepLabV3
20	ResNet- DeepLabV3	Resnet	DeepLabV3

4.2 Önerilen Sınıflandırma Modellerinin Tasarımı

Sınıflandırma işlemi 3 aşamadan oluşmaktadır. İlk olarak literatürde sıklıkla kullanılan ESA modellerinden hangisinin, veri seti üzerinde daha başarılı olduğu tespit edilmiştir. Ardından ESA modelinde kullanılan parametrelerden optimum sonucu üretenler bulunmuştur. İkinci olarak 19 mimariden en iyi sonuçları üreten AlexNet mimarisi üzerinde yapılan parametre optimizasyonu ile sonuçlar iyileştirilmiştir. Son olarak optimum parametrelerin ve modelin tespit edilmesiyle AlexNet mimarisinde geliştirmeler önerilmiştir.

4.2.1. Başarılı Model Tespiti

Bu çalışmada, kullanılan derin öğrenme yaklaşımlarının bu çalışma için yeni üretilmiş bir veri seti üzerinden farklı yara çeşitlerinde doku analizini yüksek başarımla yapabilmesini sağlamak amacıyla deneysel analizler yapılmıştır.

Tez çalışma kapsamında GoogleNet (Szegedy ve ark., 2015), DenseNet201 (Huang ve ark., 2017), MobileNetv2 (Sandler ve ark., 2018), ResNet18 (He ve ark., 2016), ResNet50 (He ve ark., 2016), ResNet101 (He ve ark., 2016) ShuffleNet (Zhang ve ark., 2018), NasnetMobile (Zoph ve ark., 2018), EfficientNet (Tan ve Le, 2019), Vgg16

(Simonyan ve Zisserman, 2014), Vgg19 (Simonyan ve Zisserman, 2014), SqueezeNet (Iandola ve ark., 2016), AlexNet (Krizhevsky ve ark., 2012), DarkNet19 (Redmon ve Farhadi, 2017), DarkNet53 (Redmon ve Farhadi, 2018), Inceptionv3 (Szegedy ve ark., 2016), Xception (Chollet, 2017), InceptionResNetv2 (Szegedy ve ark., 2017) ve Nasnetlarge (Zoph ve ark., 2018) ESA modellerinin performans karşılaştırması ele alınmıştır. Literatürde kullanılan ön eğitilmiş ESA modellerinin bazı özellikleri Çizelge 4.2’de verilmiştir.

Çizelge 4.2. Sınıflandırma işlemlerinde kullanılan mimariler (Eldem ve ark., 2022)


Model No	ESA Modeli	Derinlik	Parametre Sayısı (Milyon)	Görüntü Giriş Boyutu
1	GoogleNet	22	7.00	224x224
2	Densenet201	201	20.00	224x224
3	Mobilenetv2	53	3.50	224x224
4	Resnet18	18	11.70	224x224
5	Resnet50	50	25.60	224x224
6	Resnet101	101	44.60	224x224
7	Shufflenet	50	1.40	224x224
8	Nasnetmobile	12	5.30	224x224
9	Efficientnetb0	82	5.30	224x224
10	Vgg16	16	138.00	224x224
11	Vgg19	19	144.00	224x224
12	Squeezenet	18	1.24	227x227
13	AlexNet	8	61.00	227x227
14	Darknet19	19	20.80	256x256
15	Darknet53	53	41.60	256x256
16	Inceptionv3	48	23.90	299x299
17	Xception	71	22.90	299x299
18	Inceptionresnetv2	164	55.90	299x299
19	Nasnetlarge	*	88.90	331x331

İlk olarak, Çizelge 4.2’de detayları verilen 19 adet ESA mimarilerinin (Stojnic ve ark.) mevcut veri seti üzerinde sürekli başlatılmış (constant initialized) parametrelerle başarıları ölçülmesi hedeflenmiştir. Sonraki aşamada ise ESA mimarilerinde kullanılan parametre değerlerinin sonuçlar üzerindeki etkisi ele alınmıştır. Çalışmada yara görüntülerinin sınıflandırılmasında başarıyı en iyi bulan epok sayısı, MBS ve LR parametrelerinin bulunması hedeflenmiştir.

4.2.2. En Başarılı Model AlexNet için parametre etkilerinin incelenmesi

DeneySEL çalışmalarda açıklanacağı üzere, veri seti üzerinde en başarılı sonuçlar, Çizelge 4.2’de bazı özellikleri verilen AlexNet modeli, 2012 yılında Büyük Ölçekli

Görsel Tanıma Yarışmasını (ILSVRC) kazanmıştır (Krizhevsky ve ark., 2012). Mimari 8 katman derinliğe sahiptir. İlk 5 katmanı evrişim son 3 katmanı ise tam bağlı katmandan oluşmaktadır. Katmanlar arasında Max havuzlama ve aktivasyon katmanları bulunmaktadır. ReLU aktivasyon fonksiyonunu kullanmaktadır. 2 adet dropout katmanı bulunmaktadır. Çıkış katmanında Softmax aktivasyon fonksiyonu kullanılır. Görüntü giriş boyutu 227x227'dir. AlexNet mimarisi Şekil 4.3'te gösterilmiştir.



Şekil 4.3. AlexNet architecture (Krizhevsky ve ark., 2012)

AlexNet mimarisinde yara görüntülerinin sınıflandırılmasında kullanılan eğitim parametreleri, ağırlık eğitimi esnasında, her bir epoktaki ağırlıkların değiştirilerek kayıp fonksiyonunun en aza indirilmesi için önemlidir. Bu sayede kayıpların azaltılarak model doğruluğunun artırılması hedeflenir. Çalışmanın bu aşamasında eğitim esnasında kullanılan parametrelerin önemi ele alınarak parametre optimizasyonu yapılmıştır.

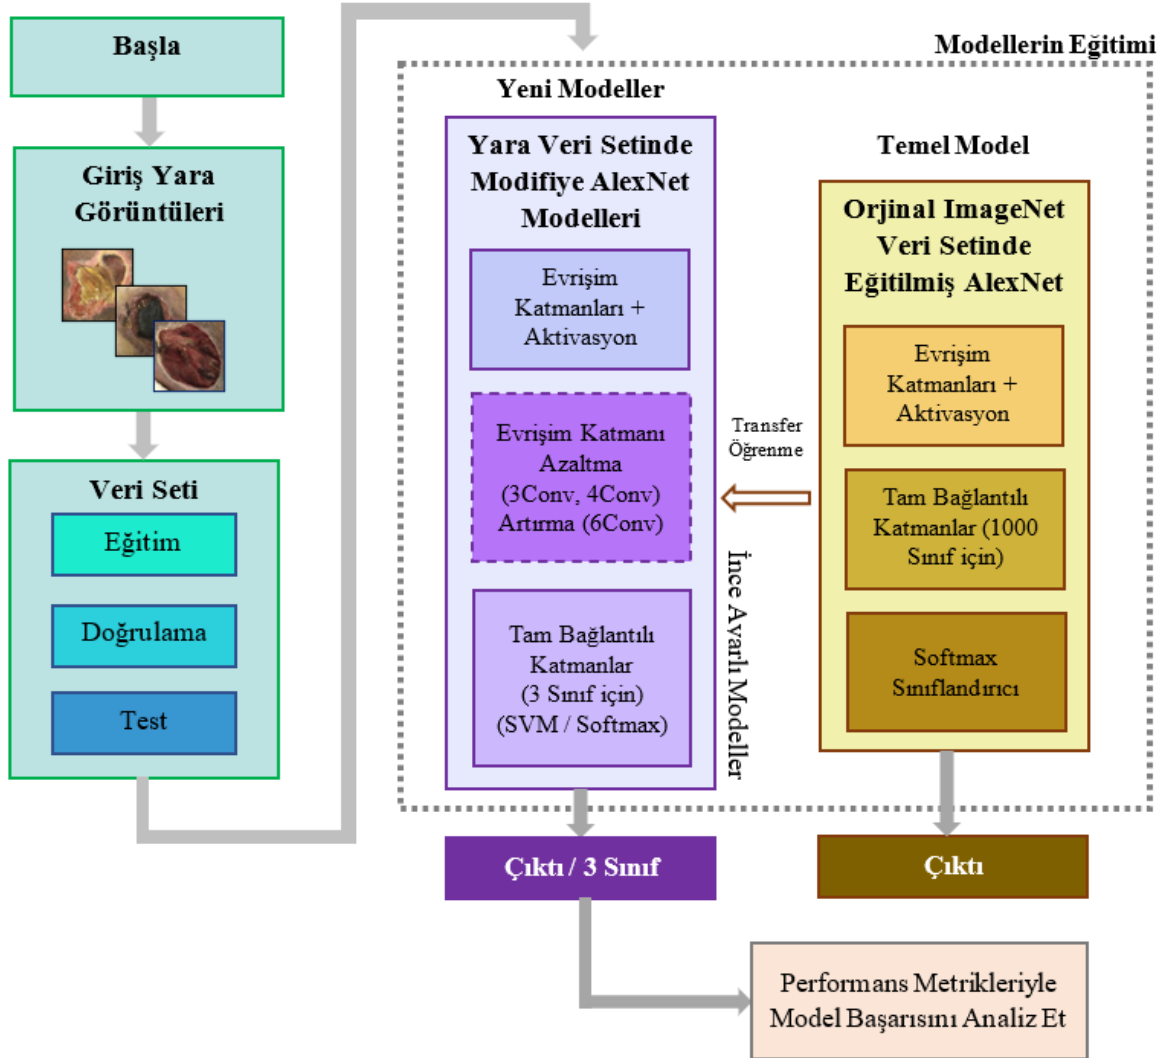
Çalışmanın bu aşamasında, AlexNet mimarisinde kullanılan optimizasyon algoritması, yığın boyutu, maksimum epok sayısı, öğrenme hızı ve öğrenme hızı zamanlaması parametrelerinin eğitim başarısını nasıl etkilediği incelenmiştir.

4.2.3. AlexNet Modelinin Performansının Geliştirilmesi

Tez çalışmasının bu aşamasında, deneyler sonucu veri seti üzerinde en iyi öğrenmeyi başaran AlexNet mimarisi üzerinde geliştirmeler yapılarak yara görüntüsü sınıflandırmadaki performansının artırılması hedeflenmiştir. Bu sayede literatüre yeni bir bakış açısı ve katkı sağlanması amaçlanmıştır.

ESA tabanlı AlexNet mimarisi modifiye edilerek 3,4 ve 6 adet evrişim katmanlı 3 mimari geliştirilmiştir. Ayrıca bu üç mimari için, SVM sınıflandırıcısı da kullanılarak mevcut AlexNet modelindeki Softmax sınıflandırıcısına göre nasıl bir performans

sergilediği de incelenmiştir. Bu çalışmada ele alınan TÖ stratejisi ve önerilen sisteme ait iş akışı (work flow) Şekil 4.4'te gösterilmiştir.



Şekil 4.4. Önerilen Modifiye AlexNet Model Yapısının İş Akışı ve Transfer Öğrenme Stratejisi (Eldem ve ark., 2023a)

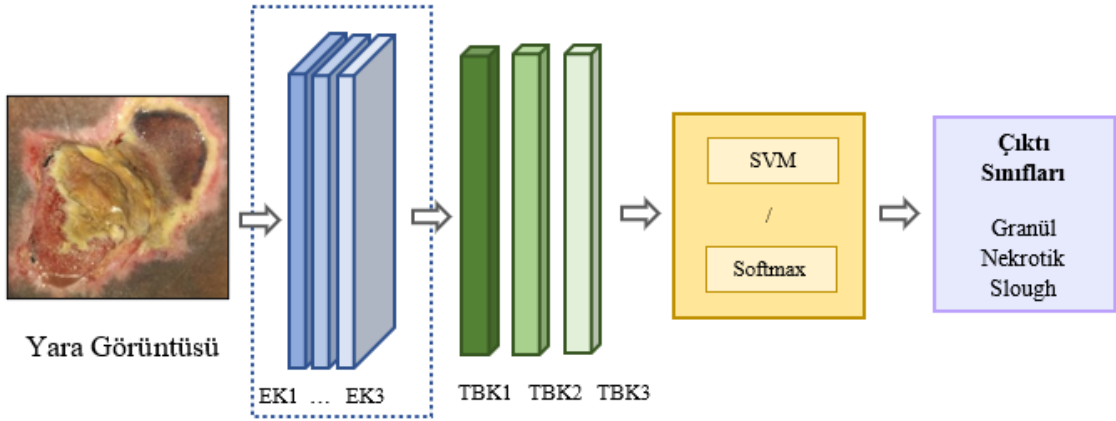
Çalışmanın bu aşamasında, evrişim katman sayısının artırılması ve azaltılması ile elde edilen 3 model önerilmiştir. Ayrıca her 3 model hem mevcut AlexNet mimarisindeki gibi Softmax sınıflandırıcısıyla hem de SVM sınıflandırıcısıyla ele alınmıştır. Bu sayede ESA mimarisindeki evrişim katmanının, sınıflandırma sonucunu nasıl etkileyeceği ve iyileştirileceği incelenmiştir. Son olarak Softmax ve SVM Sınıflandırıcıları önerilen bu

üç mimarideki etkisi de araştırılmıştır. Önerilen her 3 yöntemin yapısı Şekil 4.5, 4.6 ve 4.7’de gösterilmiştir. Hiperparametreler deneysel sonuçlarla sağlanmıştır.

Yara görüntülerinin sınıflandırılmasında kullanılan ve 3Conv_SVM ile 3Conv_Softmax olarak adlandırılan ESA modelinin tasarım özellikleri Çizelge 4.3’de verilmiş olup tasarlanan model Şekil 4.5’te görsel olarak sunulmuştur.

Çizelge 4.3. 3Conv_Softmax/SVM modelinin tasarım özellikleri (s= Adım Kayma p = Dolgu)
(Eldem ve ark., 2023a)

3Conv_Softmax/SVM		
Katman No	Katman Adı	Katman Parametreleri
1	Giriş Resmi	227x227x3
2	Evrişim Katmanı (EK1)	96 11x11 s=[4 4] p=[0 0 0 0]
3	Aktivasyon Fonksiyonu	ReLU
4	Normalizasyon	Çapraz kanal normalizasyonu
5	Ortaklama Katmanı (OK1)	3x3 s= [2 2] p= dolgu yok
6	Evrişim Katmanı (EK2)	256 11x11x3 s=[4 4] p=[2 2 2 2]
7	Aktivasyon Fonksiyonu	ReLU
8	Normalizasyon	Çapraz kanal normalizasyonu
9	Ortaklama Katmanı (OK2)	3x3 s= [2 2] p= dolgu yok
10	Evrişim Katmanı (EK3)	384 5x5x3 s=[4 4] p=[1 1 1 1]
11	Aktivasyon Fonksiyonu	ReLU
12	Ortaklama Katmanı (OK3)	3x3 s= [2 2] p= dolgu yok
13	Tam Bağlantılı Katman (TBK1)	4096 tam bağlantılı katman
14	Aktivasyon Fonksiyonu	ReLU
15	Düğüm Seyreltme Katmanı	50% Seyreltme
16	Tam Bağlantılı Katman (TBK2)	4096 tam bağlantılı katman
17	Aktivasyon Fonksiyonu	ReLU
18	Düğüm Seyreltme Katmanı	50% Seyreltme
19	Tam Bağlantılı Katman (TBK3)	3 tam bağlantılı katman
20	Sınıflandırıcı	Softmax / SVM
21	Sınıflandırma Katmanı	Sınıf Sayısı: 3 (Granül, Nekrotik, Slough)



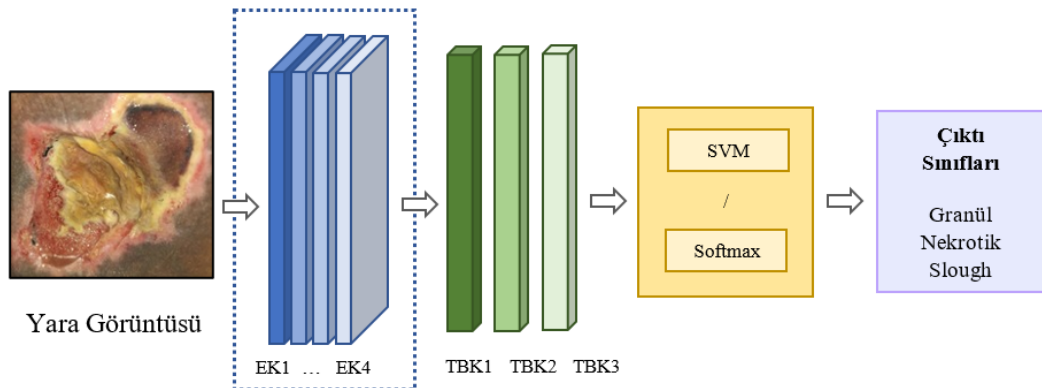
Şekil 4.5. 3Conv_Softmax ve 3Conv_SVM Modelleri Yapısı (Eldem ve ark., 2023a)

Şekil 4.5'teki 3 evrişim katmanlı mimaride sırasıyla 11x11, 5x5 ve 3x3 filtrelere sahip 3 adet evrişim katmanı vardır. Her bir evrişim katmanının sırasıyla 96, 256, 384 filtre; 0, 2 ve 1 padding ve ReLu aktivasyon fonksiyonu bulunmaktadır.

Yara görüntülerinin sınıflandırılmasında kullanılan ve 4Conv_SVM ile 4Conv_Softmax olarak adlandırılan ESA modelinin tasarım özellikleri Çizelge 4.4'te verilmiş olup tasarlanan model Şekil 4.6'da görsel olarak sunulmuştur.

Çizelge 4.4. 4Conv_Softmax/SVM modelinin tasarım özellikleri (s= Adım Kayma p = Dolgu)
(Eldem ve ark., 2023a)

4Conv_Softmax/SVM		
Katman No	Katman Adı	Katman Parametreleri
1	Giriş Resmi	227x227x3
2	Evrişim Katmanı (EK1)	96 11x11 s=[4 4] p=[0 0 0 0]
3	Aktivasyon Fonksiyonu	ReLu
4	Normalizasyon	Çapraz kanal normalizasyonu
5	Ortaklama Katmanı (OK1)	3x3 s= [2 2] p= dolgu yok
6	Evrişim Katmanı (EK2)	256 11x11x3 s=[4 4] p=[2 2 2 2]
7	Aktivasyon Fonksiyonu	ReLu
8	Normalizasyon	Çapraz kanal normalizasyonu
9	Ortaklama Katmanı (OK2)	3x3 s= [2 2] p= dolgu yok
10	Evrişim Katmanı (EK3)	384 5x5x3 s=[4 4] p=[1 1 1 1]
11	Aktivasyon Fonksiyonu	ReLu
12	Evrişim Katmanı (EK4)	256 5x5x3 s=[4 4] p=[1 1 1 1]
13	Aktivasyon Fonksiyonu	ReLu
14	Ortaklama Katmanı (OK3)	3x3 s= [2 2] p= dolgu yok
15	Tam Bağlantılı Katman (TBK1)	4096 tam bağlantılı katman
16	Aktivasyon Fonksiyonu	ReLu
17	Düğüm Seyreltme Katmanı	50% Seyreltme
18	Tam Bağlantılı Katman (TBK2)	4096 tam bağlantılı katman
19	Aktivasyon Fonksiyonu	ReLu
20	Düğüm Seyreltme Katmanı	50% Seyreltme
21	Tam Bağlantılı Katman (TBK3)	3 tam bağlantılı katman
22	Sınıflandırıcı	Softmax / SVM
23	Sınıflandırma Katmanı	Sınıf Sayısı: 3 (Granül, Nekrotik, Slough)



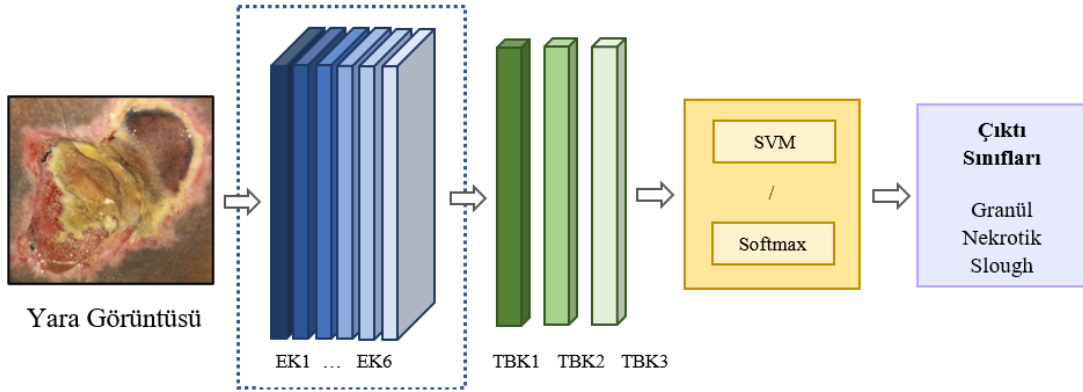
Şekil 4.6. 4Conv_Softmax ve 4Conv_SVM Modelleri Yapısı (Eldem ve ark., 2023a)

Şekil 4.6'daki 4 evrişim katmanlı mimaride sırasıyla 11x11, 5x5, 3x3 ve 3x3 filtrelerle sahip 4 adet evrişim katmanı vardır. Her bir evrişim katmanının sırasıyla 96, 256, 384, 256 filtre; 0, 2, 1 ve 1 padding ve ReLu aktivasyon fonksiyonu bulunmaktadır.

Yara görüntülerinin sınıflandırılmasında kullanılan ve 6Conv_SVM ile 6Conv_Softmax olarak adlandırılan ESA modelinin tasarım özellikleri Çizelge 4.5'te verilmiş olup tasarlanan model Şekil 4.7'de görsel olarak sunulmuştur.

Çizelge 4.5. 6Conv_Softmax/SVM modelinin tasarım özellikleri (s= Adım Kayma p = Dolgu)
(Eldem ve ark., 2023a)

6Conv_Softmax/SVM		
Katman No	Katman Adı	Katman Parametreleri
1	Giriş Resmi	227x227x3
2	Evrişim Katmanı (EK1)	96 11x11 s=[4 4] p=[0 0 0 0]
3	Aktivasyon Fonksiyonu	ReLu
4	Normalizasyon	Çapraz kanal normalizasyonu
5	Ortaklama Katmanı (OK1)	3x3 s= [2 2] p= dolgu yok
6	Evrişim Katmanı (EK2)	256 11x11x3 s=[4 4] p=[2 2 2 2]
7	Aktivasyon Fonksiyonu	ReLu
8	Normalizasyon	Çapraz kanal normalizasyonu
9	Ortaklama Katmanı (OK2)	3x3 s= [2 2] p= dolgu yok
10	Evrişim Katmanı (EK3)	384 5x5x3 s=[4 4] p=[1 1 1 1]
11	Aktivasyon Fonksiyonu	ReLu
12	Evrişim Katmanı (EK4)	384 5x5x3 s=[4 4] p=[1 1 1 1]
13	Aktivasyon Fonksiyonu	ReLu
14	Evrişim Katmanı (EK5)	384 5x5x3 s=[4 4] p=[1 1 1 1]
15	Aktivasyon Fonksiyonu	ReLu
16	Evrişim Katmanı (EK6)	256 11x11x3 s=[4 4] p=[1 1 1 1]
17	Aktivasyon Fonksiyonu	ReLu
18	Ortaklama Katmanı (OK3)	3x3 s= [2 2] p= dolgu yok
19	Tam Bağlantılı Katman (TBK1)	4096 tam bağlantılı katman
20	Aktivasyon Fonksiyonu	ReLu
21	Düğüm Seyreltme Katmanı	50% Seyreltme
22	Tam Bağlantılı Katman (TBK2)	4096 tam bağlantılı katman
23	Aktivasyon Fonksiyonu	ReLu
24	Düğüm Seyreltme Katmanı	50% Seyreltme
25	Tam Bağlantılı Katman (TBK3)	3 tam bağlantılı katman
26	Sınıflandırıcı	Softmax / SVM
27	Sınıflandırma Katmanı	Sınıf Sayısı: 3 (Granül, Nekrotik, Slough)

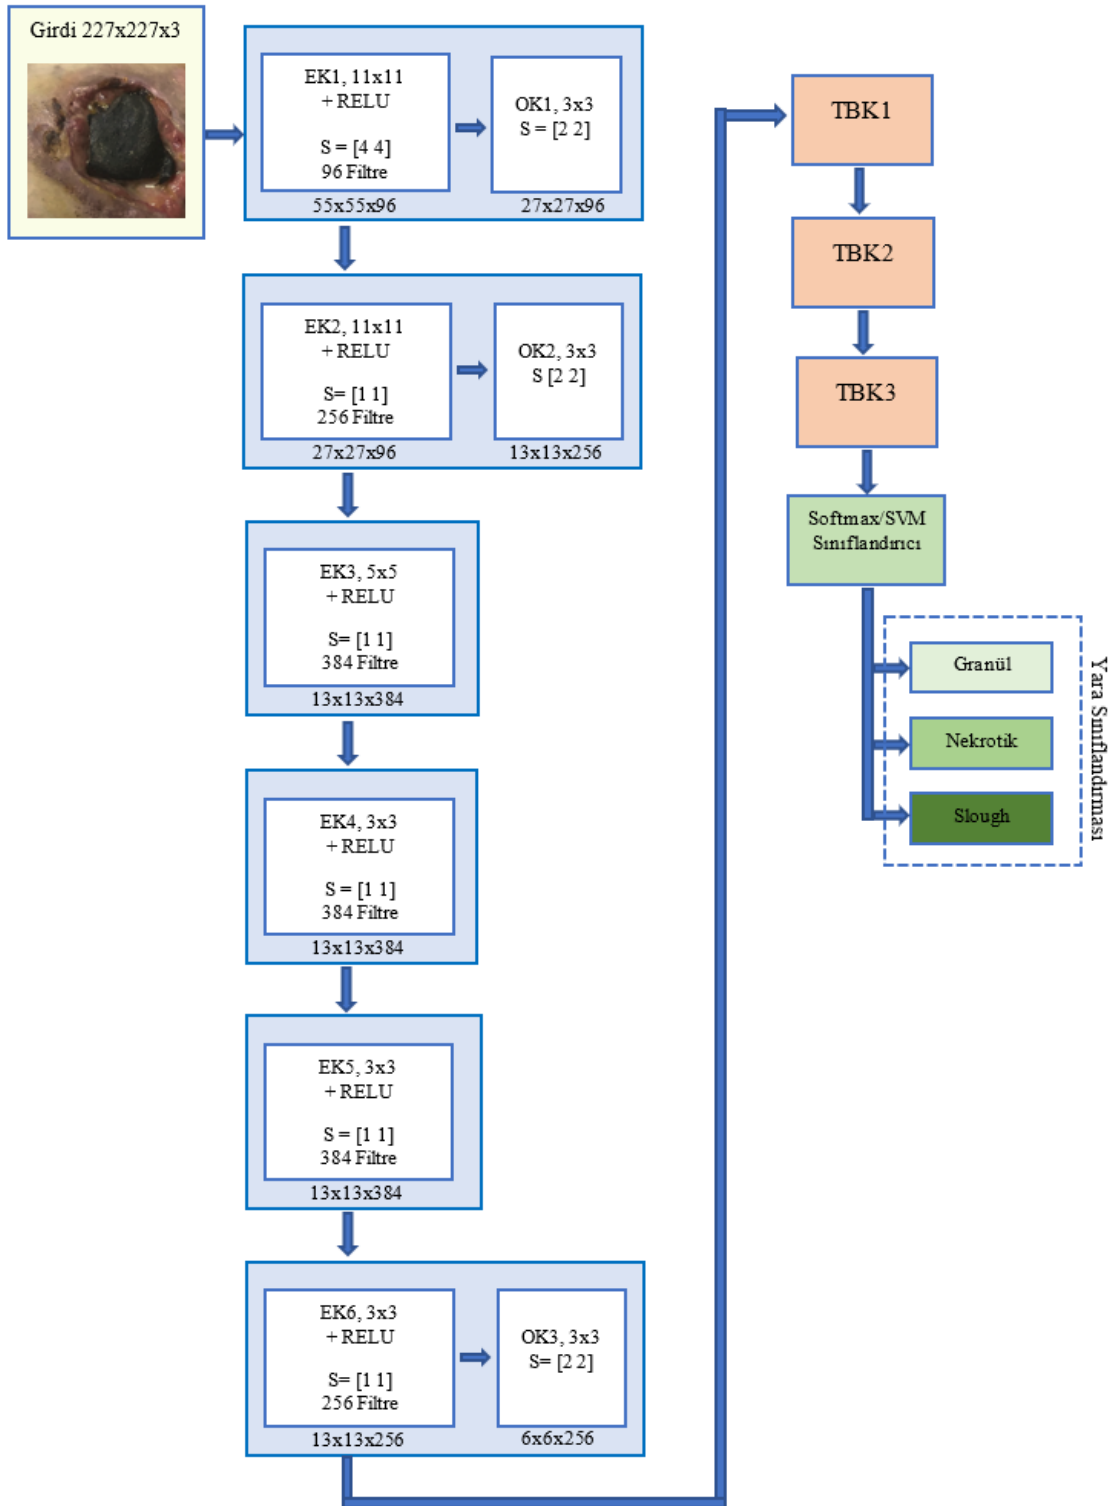


Şekil 4.7. 6Conv_Softmax ve 6Conv_SVM Modelleri Yapısı (Eldem ve ark., 2023a)

Şekil 4.7’deki 6 evrişim katmanlı mimaride sırasıyla 11x11, 5x5, 3x3, 3x3, 3x3 ve 3x3 filtrelere sahip 6 adet evrişim katmanı vardır. Her bir evrişim katmanının sırasıyla 96, 256, 384, 384, 384, 256 filtre; 0, 2, 1, 1, 1 ve 1 padding ve ReLu aktivasyon fonksiyonu bulunmaktadır.

ReLU aktivasyon katmanı gradyan problemini ortadan kaldırarak öğrenme hızını ve sınıflandırma doğruluğunu artırmaktadır (Li ve ark., 2014). Her 3 modelde de Evrişim ve ReLu katmanlarından sonra 3x3 filtre boyutunda Maximum Havuzlama katmanları kullanılmıştır. Bu sayede özellik haritasının hesaplama maliyeti azaltılarak değerli özellikler tutulur ve sınıflandırma başarısı artar (Pang ve ark., 2017).

Önerilen bu modeller tarafından elde edilen sonuçların karşılaştırılması tez çalışmasının 5. Bölümü olan Deneysel Çalışmalar ve Tartışma’da sunulmuştur. Ayrıca deneysel sonuçlar kısmında detayları açıklanan en başarılı olan 6 katmanlı 6Conv_SVM modelinin katmanları ve parametre değerlerine ait akış diyagramı Şekil 4.8’de verilmiştir.



Şekil 4.8. Önerilen geliştirilmiş yöntemlerden en başarılı model 6Conv_SVM katman yapısı (Eldem ve ark., 2023a)

5. DENEYSEL ÇALIŞMALAR VE TARTIŞMA

Bu bölümde, tez kapsamında önerilen segmentasyon ve sınıflandırma yöntemlerinin parametre etkileri de ele alınarak, deneysel sonuçları sunulmuştur.

Deneysel sonuçlarda eğitim ve test işlemlerinde, Intel® Xeon Silver 4114 2.2 GHz işlemci, 32 GB RAM ve NVIDIA Quadro P5000x2 grafik kartı (GPU) olan bir bilgisayar kullanılmıştır. Yazılım olarak Python, Keras, Tensorflow kütüphaneleri ile Matlab 2020b 64-bit (win64) Deep Learning Toolbox platformları kullanılmıştır.

5.1. Performans Değerlendirme Ölçütleri

DÖ yöntemlerinde segmentasyon ve sınıflandırma başarılarının ölçülmesi için karmaşıklık matrisi (confusion matrix) kullanılmaktadır. Karmaşıklık matrisleri, yöntemlerin sınıflandırma performansının test edilmesinde kullanılan görüntülerin, gerçek sınıfa ait olup olmadığına dair bilgi vermektedir. Her bir sütunda gerçek sınıf değerleri, her bir satırda ise model tarafından tahmin sonuçları görülmektedir.

Bu matris gerçek değerlerin bilinmekte olduğu bir dizi test verisi üzerinde bir segmentasyon/sınıflandırma modelinin performansını tanımlamak için sıklıkla kullanılan bir tablodur. İkili sınıflandırma için kullanılan karmaşıklık matrisi Çizelge 5.1'de verilmiştir.

Çizelge 5.1. İkili sınıflandırma için karmaşıklık matrisinin temsili

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

TP ve TN modelin doğru olarak tahminlediği, FN ve FP ise modelin yanlış olarak tahminlediği alanlardır. Değerlendirme metrik formüllerinde kullanılan, TP, TN, FP ve FN sırasıyla doğru pozitif (doğru onaylanmış örnek), doğru negatif (doğru reddedilen örnek), yanlış pozitif (yanlış onaylanmış örnek) ve yanlış negatif (yanlış şekilde

reddedilen örnek) anlamına gelir . Belirtilen değerlendirme metrikleri ile ilgili detaylı bilgi (Fawcett, 2006) çalışmasından edinilebilir.

Karmaşıklık matrisi kullanılarak hesaplanan doğruluk (accuracy), duyarlılık (sensitivity/recall), özgüllük (specificity), hassaslık (precision), ve F1-skor (F1-measure/F1-Score/Dice Similarity), sınıflandırma uygulamalarında kullanılan performans metrikleridir. Bunlara ek olarak segmentasyon uygulamalarında birleşimdeki kesişim (Mean IoU/Jaccard Index) ve Matthews correlation coefficient (MCC) sıklıkla kullanılan performans metrikleridir (Fawcett, 2006; Dalianis ve Dalianis, 2018; Handelman ve ark., 2019). Yöntemlerin performans değerlendirmelerinde alıcı işlem karakteristiği (Receiver Operating Characteristics (ROC)) eğrisi ve eğri altında kalan alan (Area Under the Curve (AUC)) metrikleri de kullanılmıştır. Hata değerlerinin hesaplanması amacıyla standart sapma (standart deviation (stdDev)) kullanılmıştır.

Doğruluk (Accuracy-ACC): Sınıflandırmada yapılan doğru tahminlerin bütün tahminlere olan oranını ifade etmektedir. Modelin genel performansıdır. Eşitlik 5.1' deki gibi hesaplanmaktadır.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad (5.1)$$

Duyarlılık (Sensitivity-SEN): Gerçek pozitif oranı ifade eder ve pozitif sınıfın ne kadar iyi tahmin edildiğini özetlemektedir (TPR=True Positive Rate). Sınıflandırmada pozitif veya negatif olan sınıflardan ne kadarının doğru olarak tahmin edildiğini ifade etmektedir. Duyarlılık değeri Eşitlik 5.2'ye göre hesaplanmaktadır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (5.2)$$

Özgüllük (Specificity-SPE): Gerçek negatif oranı ifade eder ve negatif sınıfın ne kadar iyi tahmin edildiğini gösteren orandır (TNR= True Negative Rate). Özgüllük değeri Eşitlik 5.3'e göre hesaplanmaktadır.

$$Özgüllük = \frac{TN}{FP + TN} \quad (5.3)$$

Hassaslık (Precision-PRE): Sınıflandırma sonucu doğru sınıflandırılan örneklerin gerçekte ne kadarının doğru (pozitif) olduğunu gösteren metriktir. (PPV= Positive Predictive Value). Pozitiflik durumun doğruluk hassaslığı olarak da ifade edilen bu metrik ne kadar yüksekse ESA modelinin başarısı o derecede yüksektir denilebilir. Hassaslık değeri Eşitlik 5.4'e göre hesaplanmaktadır.

$$Hassaslik = \frac{TP}{TP + FP} \quad (5.4)$$

F1-Skor (F1SCO): Duyarlılık ile Hassaslık metriklerinin harmonik ortalamasıdır. Bu iki metrikten herhangi biri düşük değere sahipse bu değere öncelik tanıyarak daha iyi bir model değerlendirmesini sağlar. Eşitlik 5.5'teki gibi hesaplanır.

$$F1 - Skor = \frac{2 * TP}{2 * TP + FP + FN} \quad (5.5)$$

Mean IoU (mIoU): Segmentasyonda modelin tahmin ettiği alan ile gerçek zemin arasındaki ilişkiyi ifade eder. Tahmin edilen bölge ile gerçek zemin arasındaki kesişimin, bu iki alanın birleşimine oranıdır. Eşitlik 5.6' daki gibi hesaplanır.

$$mIoU = \frac{TP}{TP + FP + FN} \quad (5.6)$$

Matthews Korelasyon Katsayısı (MCC) : Segmentasyon işleminde gerçek sınıf ve modelin tahmininin piksel bazlı karşılaştırmasında ikisi arasındaki korelasyon katsayısını hesaplar. Gerçek zemin (GT) ile tahmin arasındaki korelasyonun yüksek olması, segmentasyon alanının doğru belirlendiğini gösterir. Eşitlik 5.7' deki gibi hesaplanır.

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (5.7)$$

5.2. Segmentasyon Deneysel Analiz Sonuçları

Tez çalışması kapsamında , literatürden alınan Medetec basınç yara görüntü veri seti üzerinde derin öğrenme tabanlı Tam Evrişimsel Ağlar (FCN8-16-32), PSP-Net, U-

Net ve Seg-Net, DeepLabV3 segmentasyon modelleri ile basınç yara segmentasyonu başarımları ele alınmıştır. Backbone (Base) model olarak Resnet, VGG-16 ve MobileNet kullanılmıştır.

Bu çalışmada, ResNet, VGG-16, MobileNet, EfficientNet ön eğitilmiş mimarileri özgün (parametre ve ağırlıklarıyla) olarak kullanılmıştır. Bu çalışmada ayrıca geleneksel ESA adımlarından faydalanarak 5 katmanlı bir ağ kodlayıcı olarak tasarlanmıştır. Mimarinin detaylarına ait bilgiler Bölüm 3.2.3.2 de verilmiştir.

Her bir model 50 epok ve adam optimizasyon yöntemi (Kingma ve Ba, 2014) kullanarak çalıştırılmıştır. Başlangıç öğrenme hızı (LR) $1e-6$ olarak belirlenmiştir. Tüm sonuçlar, 5-fold çapraz doğrulama ile elde edilmiştir. Bu sayede modellerin, görünmeyen verilerde ne kadar iyi performans göstereceği belirlenir (Zhang ve Liu, 2022). Her bir fold da elde edilen model tahmin başarımının ortalaması alınarak yöntemin başarısı bulunur. Bu yöntemle 1416 kronik yara resminden oluşan veri setine uygun olarak 5-folda bölünmüştür. Verilen bölümlenme şeması Şekil 5.1’de gösterilmiştir.

	K=1	K=2	K=3	K=4	K=5	
Doğrulama 1	284	283	283	283	283	Performans 1
Doğrulama 2	284	283	283	283	283	Performans 2
Doğrulama 3	284	283	283	283	283	Performans 3
Doğrulama 4	284	283	283	283	283	Performans 4
Doğrulama 5	284	283	283	283	283	Performans 5
Tahmin Başarısı:						Ortalama (Tüm Performans)

Şekil 5.1. Segmentasyon işleminde veri bölümlenme şeması (5 katlı çapraz doğrulama) (Eldem ve ark., 2023c)

Deneysel çalışmalarda, modellerin başarımlarının ölçülebilmesi ve karşılaştırılması için, Doğruluk, Mean IoU, F1-skor, Duyarlılık (recall), Özgüllük, Hassaslık ve MCC olmak üzere 7 adet ölçüm metriği kullanılmıştır. Modellerin performans sonuçları Çizelge 5.2’de verilmiştir.

Çizelge 5.2. Segmentasyon işlemi deneysel sonuçlar * (Eldem ve ark., 2023c)

Model No	Model Adı	Doğruluk	Mean IoU (mIoU)	dice=F1-skor	Duyarlılık	Özgüllük	Hassaslık	Matthews Korelasyon Katsayısı (MCC)
1	CNN-FCN8	91.13	80.17	90.94	91.43	90.85	90.90	77.21
2	CNN-FCN16	91.51	80.77	91.33	91.85	91.18	91.03	77.96
3	CNN-FCN32	91.89	81.37	91.71	92.27	91.51	91.15	78.71
4	VGG16-FCN8	84.84	70.87	84.64	85.47	84.23	83.82	64.64
5	VGG16-FCN16	84.84	70.87	84.64	85.05	84.23	84.02	64.64
6	VGG16-FCN32	84.84	70.88	84.64	84.64	84.23	84.23	64.64
7	CNN-PSPNet	90.67	79.55	90.54	91.37	90.01	88.29	76.31
8	VGG16-PSPNet	85.16	71.33	84.96	85.67	84.69	83.98	65.29
9	ResNet-PSPNet	85.94	72.44	85.75	86.46	85.45	85.11	66.85
10	CNN-UNet	93.91	81.11	93.35	94.17	92.86	86.66	76.72
11	VGG16-UNet	86.69	71.46	86.48	87.23	86.17	85.73	84.10
12	ResNet-UNet	96.02	84.93	95.88	96.70	95.34	94.63	81.73
13	MobileNet-UNet	99.67	98.49	99.09	99.38	99.12	99.52	97.27
14	EfficientNet-UNet	93.95	84.00	93.68	93.95	93.30	91.38	84.46
15	CNN-SegNet	91.12	80.25	90.99	91.83	90.43	89.79	77.20
16	VGG16-SegNet	90.82	79.75	90.67	91.44	90.21	89.72	76.58
17	ResNet-SegNet	91.40	80.70	91.28	92.13	90.71	90.45	77.78
18	MobileNet-SegNet	93.18	83.54	93.06	93.94	92.45	92.21	81.32
19	VGG16-DeepLabV3	86.20	72.53	86.00	86.58	85.63	85.25	69.98
20	ResNet-DeepLabV3	91.12	79.36	90.97	91.76	90.50	90.06	75.45

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir.

Çizelge 5.2'deki sonuçlar değerlendirildiğinde ilk olarak tüm metriklerde MobileNet-UNet (Model No:13, TemelModel: MobileNet and Segmentation Model: UNet) modelinin en başarılı sonuçlara ulaştığı görülmektedir. Ayrıca segmentation model ortalamalarına göre en iyi sonuçların kod çözücü olarak U-Net kullanılan modellerde elde edildiği görülmektedir. Kodlayıcı olarak ise, MobileNet modeli ile elde edilen sonuçların diğer kodlayıcı modellerin sonuçlarına göre daha iyi olduğu görülmektedir.

Çizelge 5.2'deki sonuçlara göre, basınç yaralarının segmentasyon başarılarının en kötü olduğu durumlar VGG16 kod çözücü mimarisinin FCN8-16-32 segmentasyon modelleri ile elde edildiği görülmektedir. Aynı şekilde VGG16-UNet ve VGG-SegNet modelleri de düşük performans sergilemiştir. Bu modellerin basınç yara görüntüleri özelliklerini karakterize edemeyeceğini ve basınç yarası tespitinde dikkate değer bir hata olduğunu göstermektedir.

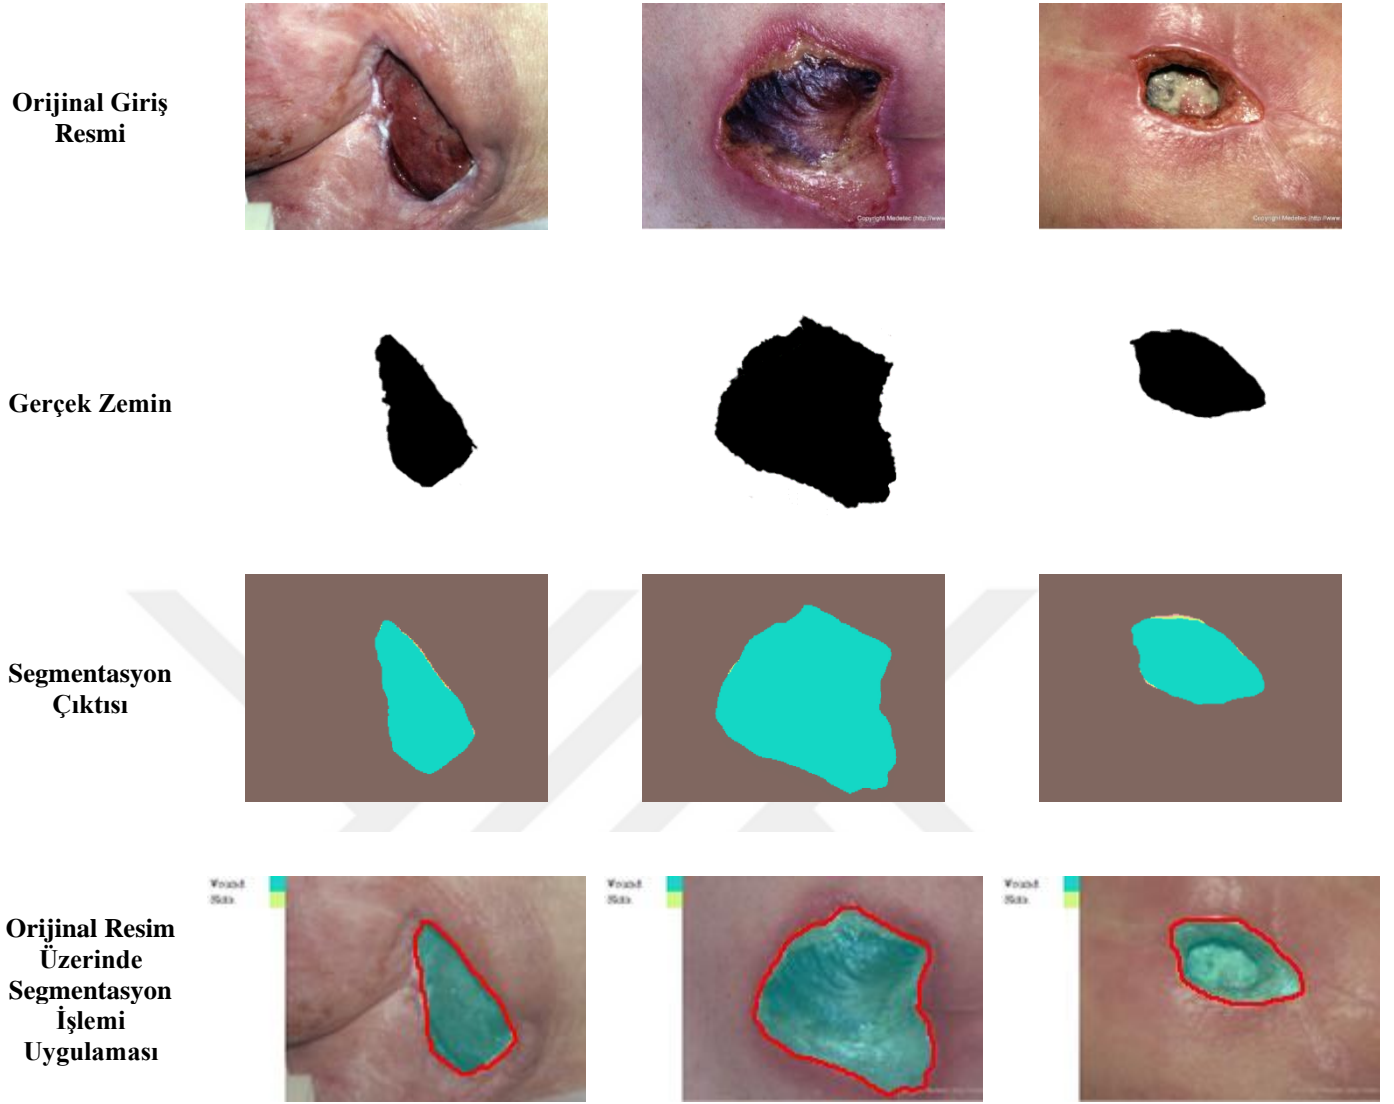
Çizelge 5.2'deki sonuçlarda en iyi ikinci sonuçlar MCC metriği dışında diğer 6 metrikte, ResNet-UNet modelinde elde edilmiştir. MCC metriğinde ise EfficientNet-UNet modelinde elde edilmiştir. Çizelge 5.2'deki sonuçlarda üçüncü en iyi sonuçlar 4 metrik için (doğruluk, mIoU, F1-skor ve özgüllük) EfficientNet-UNet modelinde,

duyarlılık metriğinde de CNN-UNet modelinde, hassaslık metriğinde EfficientNet-UNet modelinde, MCC metriğinde ise VGG16-UNet modelinde elde edilmiştir.

Çalışmada tasarlanan Vanilla CNN mimarisi eğitilerek elde edilen sonuçlarda ayrıca değerlendirilmiştir. Vanilla CNN mimarisi açısından Çizelge 5.2'deki veriler ele alındığında, (doğruluk, F1-skor, duyarlılık ve duyarlılık) UNet segmentasyon modeliyle bir arada kullanıldığı CNN-UNet mimarisi ile en iyi sonuçlar elde edilmiştir. Diğer 3 metrikte ise (meanIoU, hassaslık ve MCC) FCN32 segmentasyon modeliyle bir arada kullanıldığı CNN- FCN32 mimarisinde en iyi sonuçlar elde edilmiştir.

Şekil 5.2'de MobileNet-Unet modelinin deneysel sonuçlar sonrası ürettiği segmentasyon çıktısı ve bu çıktının orijinal resim üzerinde yara alanını uygun bir şekilde yara bölgesini tanıdığı gösterilmiştir.





Şekil 5.2. Segmentasyon çıktılarının orijinal resimlere uygulanması (Eldem ve ark., 2023c)

Kronik yara resimlerinin kodlayıcı-kod çözücü tabanlı mimariler ile segmentasyon başarısında en iyi sonuçların elde edildiği MobileNet-UNet modeli, literatürde yer alan benzer çalışmalarla da karşılaştırılarak Çizelge 5.3'te gösterilmiştir. Sadece basınç yarası segmentasyonu üzerine yapılan (Zahia ve ark., 2020a) çalışmasının yanı sıra DFU, kronik ve karışık (mixed) yara görüntüleri segmentasyonu yapan diğer çalışmalarla da sonuçlar karşılaştırılmıştır. Çizelge 5.3'te farklı tür yara görüntüleri üzerinde yapılan çalışmalarda, görüntü özellikleri açısından benzerlik taşıdığından, kıyaslamada dikkate alınmıştır. Çizelge 5.3'te çalışmalarda kullanılan resim sayısına da yer verilmiştir.

Çizelge 5.3. Segmentasyon işlemi deneysel sonuçları literatür karşılaştırması * (Eldem ve ark., 2023c)

Model Adı	Veri seti Boyutu	Doğruluk	Mean IoU (mIoU)	dice=F1-skor	Duyarlılık	Özgüllük	Hassaslık	Matthews Korelasyon Katsayısı (MCC)
MobileNet-UNet	1416 (Basınç)	99.67	98.49	99.09	99.38	99.12	99.52	97.27
(Goyal ve ark., 2017)	705 (DFU)	-	-	89.90	90.40	99.00	-	89.10
(Wang ve ark., 2015b)	650 (karişik)	95.00	47.30	-	-	-	-	-
(Liu ve ark., 2017)	950 (Karişik)	98.18	85.06	91.93	90.58	-	93.31	-
(Li ve ark., 2018)	950 (Karişik)	-	85.88	-	-	-	94.69	-
(Zahia ve ark., 2020a)	210 (Basınç)	-	-	83	85	-	87	-
(Ohura ve ark., 2019)	440 (Karişik)	97.82	-	85	85.8	98.8	98.8	84.6
(Chang ve ark., 2022)	755 (Karişik)	99.11	97.45	98.67	98.67	-	98.68	-
(Niri ve ark., 2021)	270 (DFU)	-	77.09	86.33	-	-	-	-
(Scebba ve ark., 2022)	53 (Karişik)	-	83	-	-	-	-	90
(Ong ve ark., 2020)	583 (Kronik)	94.1	86.9	-	-	-	-	-

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Çizelge 5.3'te bu çalışmada ele alınan yöntemlerden en iyi olan MobileNet-UNet mimarisinin sonuçları literatürde yara görüntüleri üzerinde segmentasyon konulu diğer çalışmaların sonuçlarıyla karşılaştırılmıştır. MobileNet-UNet mimarisinin sonuçları, basınç yara resimleri üzerine segmentasyon yapan (Zahia ve ark., 2020a) çalışmaya göre oldukça başarılıdır. Ayrıca MobileNet-UNet mimarisinin sonuçları Çizelge 5.3'teki tüm değerlendirme metriklerinde, literatürdeki çalışmalardan daha iyi sonuçlar elde etmiştir. Basınç yarası segmentasyonunda Mobile-Unet sonuçları, DFU segmentasyonu yapan (Goyal ve ark., 2017) ve (Niri ve ark., 2021) çalışmalara göre oldukça önemli sonuçlar sağlamıştır.

Karişik yara resimlerden oluşan veri setleri üzerinde yapılan çalışmalardan (Chang ve ark., 2022) sonuçları, tez kapsamındaki sonuçlarla kıyaslandığında oldukça rekabetçidir. (Liu ve ark., 2017) ve (Ohura ve ark., 2019) çalışmalarının doğruluk

değerlendirme metriği sonucu her ne kadar çalışmamıza yakın sonuçlar elde etse de diğer metriklerde daha düşük sonuçlar elde etmiştir.

5.2.1. Tartışma

Tez çalışmasının ilk adımında yara bakımının ilk ve en önemli adımlarından biri olan yara bölgesinin tespitini yapabilmek için görüntü üzerinde segmentasyon işlemi kullanılan, kodlayıcı-kod çözücü tabanlı derin öğrenme mimarilerinde, backbone network ve segmentasyon model arasındaki performans analizi ve en iyi yöntem belirlenmesi incelenmiştir. Backbone ve segmentasyon modellerinin uygun olan eşleriyle oluşturulan 20 farklı modelin basınç yarası segmentasyonundaki başarıları incelenmiştir. Ayrıca transfer öğrenme ile mimarilerin ön eğitilmiş mimarilerinde eğitilen ağırlıklarının transfer edilmesiyle başarı oranlarının artırılması sağlanmıştır. Yapılan deneylerde, tüm metriklerde MobileNet-UNet (Kodlayıcı: MobileNet and Kod çözücü: UNet) modelinin en başarılı sonuçlara ulaştığı görülmektedir. Bu çalışmada önerilen yöntemlerin performans analizleri yapılmasının yanı sıra literatürdeki benzer çalışmalarının sonuçlarıyla da karşılaştırılmıştır. MobileNet-UNet mimarisinin basınç, DFU, kronik vb. yara segmentasyonu çalışmalarına nazaran oldukça başarılı bir performans sergilediği görülmüştür.

Çalışmada, piksel tabanlı kodlayıcı-kod çözücü segmentasyon modellerinin basınç yarası segmentasyonu üzerindeki başarımları literatüre katkı olarak sunulmuştur. Bilindiği kadarıyla bu, çalışmada kullanılan segmentasyon modellerinin basınç yarası görüntüsünde uygulanmasına dair ilk girişimdir. Özellikle medikal alanda yara görüntülerinin kolayca elde edilememesi, literatürde bu alanda hala kısıtlı verinin olması problemleriyle karşılaşılan bu durumlarda transfer öğrenmenin etkisinden faydalanılması büyük katkı sunacaktır. Ayrıca literatürde gelecekte geliştirilecek derin öğrenme yöntemlerinin adil bir karşılaştırmaya tabi tutulabilmesi için benchmark veri setlerine ihtiyaç bulunmaktadır. Bu çalışmanın açık kaynak Medetec veri setindeki basınç yarası resimleri kullanarak bu açıdan da bir farkındalık oluşturmuştur. Bu sayede, yara bölgesini objektif olarak değerlendirebilecek, tıp alanında ciddi bir maliyet ve iş gücü gerektiren yara bakımının kolaylaştırılmasına katkı sunulmuştur.

5.3. Sınıflandırma Deneysel Analiz Sonuçları

Tez çalışmasının bu bölümünde yara görüntülerinin başarılı bir şekilde sınıflandırılmasının elde edilebilmesi için, farklı derin öğrenme mimarileri farklı parametrelerle test edilerek mimarilerin durum tespiti yapılmıştır. ESA model eğitim parametrelerinden maksimum devir sayısı (maximum epoch-ME), yığın boyutu (örnek sayısı (minibatch size-MBS)) ve öğrenme hızının (learning rate-LR) yara sınıflandırma üzerindeki etkileri deneysel sonuçlarla gösterilmiştir. Deneysel çalışmalarda, modellerin başarımlarının ölçülebilmesi ve karşılaştırılması için, Doğruluk, Dice (f1 score), duyarlılık (recall), özgüllük ve hassaslık olmak üzere 5 adet ölçüm metriği kullanılmıştır. Deneysel çalışmalarda kullanılan ön eğitilmiş modellere ait bilgiler Çizelge 4.2’de verilmiştir.

Derin öğrenme mimarilerinde parametrelerin değerleri sonuçlar üzerinde doğrudan etkilidir. Bazı çalışmalarda sabit değerler kullanılırken bazılarında da uygun değerler örnek bir model üzerinden belirlenir. Bu nedenle başlangıçta, çalışmada yara görüntülerinin sınıflandırılmasında başarıyı en iyi bulan epok sayısı, yığın boyutu ve öğrenme hızı bulunması hedeflenmiştir. Parametre belirleme deneylerinde, %70 eğitim %30 test verisi olarak hold-out yöntemi ile ayrılan veriseti sınıflandırmasında, öğrenme hızı düşürme oranı (drop factor) 0.5, öğrenme hızı düşürme periyodu (drop period) ise 5 olarak alınmıştır. Epok sayıları, örnek sayısı ve öğrenme hızı parametreleri önce rastgele belirlenmiştir. İlk olarak 10 epok, 32 örnek sayısı (batch size) ve $1e-4$ öğrenme hızı parametreleri kullanılarak deneyler yapılmıştır. Çizelge 5.4’teki parametre değerleri, aynı şekilde Çizelge 4.2’de verilen tüm modellere uygulanmıştır.

Resimler ön-işleme adımında, her bir ESA modelinin resim giriş boyutuna göre 224x224, 227x227, 256x256, 299x299 ve 331x331 pixel olarak yeniden boyutlandırılmıştır.

Çizelge 5.4. Model ve uygun parametre belirleme deneylerinde kullanılan başlangıç hiperparametre değerleri

Hiperparametre	Değer
Başlangıç öğrenme hızı	1e-4
Her bir devirde kullanılacak görüntü sayısı (mini batch size)	32
Devir sayısı (Epok)	10
Öğrenme hızı düşürme oranı	0.5
Öğrenme hızı düşürme periyodu	5
Optimizasyon algoritması	SGDM
Çalışma ortamı	Multi-GPU
Momentum katsayısı	0.9

Modellerin, Çizelge 5.4'teki parametrelerle elde ettikleri değerlendirme metriklerindeki sonuçları Çizelge 5.5'te verilmiştir.

Çizelge 5.5. Sabit Parametreler ile Modellerin Performansı

Model No	ESA Modeli	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
1	GoogleNet	75.0000	76.4706	97.0588	75.0000	64.7059
2	Densenet201	72.9167	71.4706	97.0588	66.6667	61.9048
3	Mobilenetv2	72.9167	71.4706	80.6452	59.0909	66.6667
4	Resnet18	81.2500	71.4706	88.2353	69.2308	66.6667
5	Resnet50	75.0000	64.7059	94.1176	66.6667	58.8235
6	Resnet101	79.1667	70.5882	88.2353	69.2308	61.5385
7	Shufflenet	68.7500	47.0588	88.2353	42.8571	40.0000
8	Nasnetmobile	68.7500	52.9412	85.2941	44.4444	41.8605
9	Efficientnetb0	68.7500	76.4706	85.2941	54.1667	63.4146
10	Vgg16	77.0833	70.5882	88.2353	63.6364	60.0000
11	Vgg19	81.2500	82.3529	90.3226	70.0000	70.0000
12	SqueezeNet	66.6667	70.5882	82.3529	52.1739	60.0000
13	AlexNet	89.5833	71.4286	97.0588	90.9091	80.0000
14	Darknet19	83.3333	70.5882	94.1176	70.0000	66.6667
15	Darknet53	64.5833	64.2857	80.6452	45.4545	51.4286
16	Inceptionv3	62.5000	41.5966	70.9677	62.9032	37.2727
17	Xception	70.8333	64.7059	97.0588	50.0000	46.8085
18	Inceptionresnetv2	58.3333	35.2941	79.4118	30.0000	32.4324
19	Nasnetlarge	72.9167	64.7059	85.2941	54.5455	56.4103

* En iyi ve en iyi ikinci sonuçlar kalın yazı tipi ile gösterilmiştir. Tüm değerler % şeklindedir.

Çizelge 5.5'teki değerlendirme metrikleri incelendiğinde, Doğruluk, Özgüllük, Hassaslık ve F1-Skor ile en fazla metrikte, AlexNet mimarisinde en iyi sonuçlar elde edilmiştir. Duyarlılık, Özgüllük ve Hassaslık metriklerinde ise GoogleNet mimarisi en iyi ikinci sonuçları elde etmiştir. Özgüllük metriğinde, Densenet201, Xception mimarileri, AlexNet ve GoogleNet ile eşit olarak elde edilmiş ancak diğer metriklerde daha düşük

ölçülmüştür. Bu nedenle parametre optimizasyonu için, tüm modeller arasında sayıca daha fazla iyi değer üreten AlexNet ve GoogleNet mimarileri seçilmiştir.

En iyi diğer parametreleri bulmak için 2. test senaryosunda farklı epok sayısı ve yığın boyutu değerleri ile testler yapılmıştır. İlk olarak bu iki mimari 10, 25, 50, 100, 150, 200, 250 ve 300 epok çalıştırılarak sonuçlar elde edilmiş ve sonuçları Çizelge 5.6'da gösterilmiştir.

Çizelge 5.6. GoogleNet ve AlexNet Mimarilerinin Farklı Epoklardaki Sonuçları

	Epok Sayısı	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
GoogleNet	10	83.3333	88.2353	93.1176	80.0000	75.0000
	25	77.0833	57.1429	90.3226	75.0000	62.0690
	50	79.1667	71.4286	83.8710	64.2857	66.6667
	100	77.0833	76.4706	85.2941	61.5385	66.6667
	150	85.4167	82.3529	94.1176	81.8182	75.6757
	200	85.4167	64.7059	87.0588	88.8889	69.5652
	250	81.2500	70.5882	87.0968	75.0000	72.7273
	300	72.9233	76.4629	83.8710	72.2200	74.2857
AlexNet	10	89.5833	71.4286	97.0588	90.9091	80.0000
	25	85.4167	78.5714	93.5484	84.6154	75.8621
	50	83.3333	85.7143	90.3226	76.9231	75.0000
	100	87.5000	76.4706	97.0588	90.0000	75.0000
	150	95.8333	94.1176	97.0588	94.1176	94.1176
	200	81.2500	70.5882	91.1765	72.7273	66.6667
	250	83.3333	76.4706	88.2353	76.4706	76.4706
	300	87.5000	88.2353	97.0588	90.0000	76.9231

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Çizelge 5.6 'daki değerlendirme metrikleri incelendiğinde, GoogleNet mimarisi Doğruluk, Özgüllük ve F1-Skor olmak üzere 3 metrikle en fazla iyi sonuçları 150 epokta, AlexNet mimarisi ise tüm metriklerde en iyi sonuçları 150 epokta elde etmiştir. AlexNet mimarisinde Özgüllük metriğinde 10,100,150 ve 300 epoklarda eşittir. Bu iki modelde en iyi sonuçlarda sayıca en fazla değer üreten 150 epok sayısı diğer testlerde kullanılmıştır.

Her iki modelde en iyi sonuçların elde edilmesinde etkili MBS ve LR' lerin bulunmasında, sonraki aşamada her iki model 150 epok (ME) çalıştırılmıştır. Her iki mimari 2, 4, 8, 16, 32, 64, 128 ve 256 MBS alınarak 3 farklı LR (1e-3, 1e-4, 1e-5) parametreleri ile test edilmiştir. AlexNet mimarisi için elde edilen sonuçlar Çizelge 5.7'de, GoogleNet Mimarisi için elde edilen sonuçlar Çizelge 5.8'de verilmiştir.

Çizelge 5.7. AlexNet Mimarisinin Farklı MBS ve LR parametrelerindeki sonuçları (ME=150)

LR	MBS	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
1e-3	2	56.9444	33.3333	66.6667	35.4167	52.3077
	4	56.9444	33.3333	66.6667	35.4167	52.3077
	8	56.9444	33.3333	66.6667	35.4167	52.3077
	16	56.9444	33.3333	66.6667	35.4167	52.3077
	32	68.7500	52.9412	76.4706	47.3684	50.0000
	64	93.7500	78.5714	100.0000	100.0000	88.0000
	128	83.3333	71.4286	88.2353	71.4286	71.4286
	256	83.3333	92.8571	87.0968	65.0000	76.4706
1e-4	2	70.8333	94.1176	66.6667	50.0000	50.7937
	4	77.0833	64.7059	83.8710	68.7500	66.6667
	8	85.4167	85.7143	90.3226	78.5714	77.4194
	16	91.6667	88.2353	97.0588	91.6667	84.6154
	32	95.8333	94.1176	97.0588	94.1176	94.1176
	64	79.1667	71.4286	87.0968	66.6667	66.6667
	128	91.6667	94.1176	96.7742	92.3077	88.8889
	256	89.5833	82.3529	94.1176	84.6154	81.4815
1e-5	2	81.2500	70.5882	88.2353	69.2308	66.6667
	4	83.3333	82.3529	96.7742	90.9091	71.7949
	8	91.6667	78.5714	97.0588	91.6667	84.6154
	16	91.6667	88.2353	100.0000	100.0000	83.3333
	32	83.3333	64.7059	91.1765	75.0000	69.2308
	64	77.0833	92.8571	87.0968	66.6667	70.2703
	128	87.5000	76.4706	100.0000	100.0000	72.7273
	256	72.9167	70.5882	90.3226	62.5000	52.1739

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Çizelge 5.8. GoogleNet Mimarisinin Farklı MBS ve LR parametrelerindeki sonuçları (ME=150)

LR	MBS	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
1e-3	2	83.3333	82.3529	83.8710	73.6842	77.7778
	4	89.5833	94.1176	96.7742	88.8889	83.8710
	8	91.6667	92.8571	93.5484	85.7143	86.6667
	16	83.3333	76.4706	91.1765	75.0000	70.2703
	32	89.5833	88.2353	94.1176	87.5000	84.8485
	64	85.4167	76.4706	90.3226	81.2500	78.7879
	128	81.2500	88.2353	97.0588	83.3333	70.9677
	256	85.4167	76.4706	82.7957	74.0476	70.2703
1e-4	2	85.4167	71.4286	91.1765	76.9231	74.0741
	4	81.2500	70.5882	78.4946	71.0648	66.6667
	8	81.2500	82.3529	88.2353	70.0000	75.6757
	16	79.1667	76.4706	88.2353	68.4211	72.2222
	32	85.4167	82.3529	94.1176	81.8182	75.6757
	64	83.3333	82.3529	94.1176	80.0000	77.7778
	128	75.0000	64.7059	94.1176	66.6667	55.5556
	256	85.4167	71.4286	91.1765	76.9231	74.0741
1e-5	2	70.8333	64.7059	87.0968	63.6364	50.0000
	4	85.4167	82.3529	94.1176	81.8182	75.6757
	8	77.0833	64.7059	85.2941	64.7059	64.7059
	16	75.0000	64.7059	85.2941	66.6667	62.5000
	32	72.9167	58.8235	85.2941	54.5455	55.5556
	64	54.1667	47.0588	77.4194	33.3333	39.0244
	128	65.2778	46.3586	73.1183	62.9630	54.5455
	256	75.0000	58.8235	83.8710	57.1429	57.1429

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Çizelge 5.7'deki AlexNet sonuçlarını değerlendirebilmek için, en iyi değerler ve ortalama değerler açısından MBS ve LR parametrelerine ait özet bilgiler Çizelge 5.9 ve Çizelge 5.10'da sunulmuştur.

Çizelge 5.9. AlexNet Mimarisinin Yığın boyutu (MBS) ve Öğrenme Hızı (LR) parametrelerindeki en iyi Sonuçları

Epok	LR	MBS	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
150	1e-3	64	93.7500		100.0000	100.0000	88.0000
		256		92.8571			
	1e-4	32	95.8333	94.1176	97.0588	94.1176	94.1176
	1e-5	8	91.6667				84.6154
		16	91.6667		100.0000	100.0000	
		64		92.8571			
En iyi			95.8333	94.1176	100	100	94.1176

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Çizelge 5.9'daki AlexNet sonuçları, en iyi değerler üreten MBS ve LR parametreleri bulunması için 2 farklı açıdan değerlendirilmiştir. İlk olarak tüm değerlerin en iyileri bulunmuştur. Burada 3 metrikle (Doğruluk, Duyarlılık ve F1-Skor), en iyi sonuçlar 1e-4 LR parametresiyle elde edilmiştir. Özgüllük ve Hassaslık metriklerinde ise 1e-3 ve 1e-5 LR parametresinde elde edilmiştir. Bulunan en fazla en iyi sonuçlar 1e-4 LR parametresinde 32 MBS ile elde edilmiştir. Diğer en iyi iki sonuç 1e-3 LR parametresinde 64 MBS ile, 1e-5 LR parametresinde 16 MBS ile elde edilmiştir. En iyi sonuçlar açısından 32 MBS parametre değerinin optimum olduğu görülmektedir. İkinci olarak, her bir LR sonuçlarının ürettiği ortalama değerler Çizelge 5.10'da verilmiştir. Bu sonuçlar incelendiğinde ise ortalama değerlerde 3 metrikte (Doğruluk, Duyarlılık ve F1-Skor) 1e-4 LR parametresinde en iyi sonuçların elde edildiği görülmektedir. Dolayısıyla AlexNet mimarisi için 32 MBS ve 1e-4 LR parametrelerinin optimum olarak bulunduğu değerlendirilmiştir.

Çizelge 5.10. AlexNet mimarisinin MBS ve LR parametrelerindeki ortalama sonuçları

Epok	Öğrenme Hızı	Ortalama Doğruluk	Ortalama Duyarlılık	Ortalama Özgüllük	Ortalama Hassaslık	Ortalama F1-Skor
150	1e-3	69.6180	53.6414	77.3087	53.1830	61.8912
	1e-4	85.1563	84.3487	89.1208	78.3369	76.3312
	1e-5	83.5938	78.0462	93.8330	81.9966	71.3516

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Çizelge 5.8'deki GoogleNet sonuçlarını değerlendirebilmek için, en iyi değerler ve ortalama değerler açısından MBS ve LR parametrelerine ait özet bilgiler Çizelge 5.11 ve Çizelge 5.12'de özetlenmiştir.

Çizelge 5.11. GoogleNet Mimarisinin Yığın boyutu (MBS) ve Öğrenme Hızı (LR) parametrelerindeki en iyi Sonuçları

Epok	Öğrenme Hızı	Yığın boyutu	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
150		4		94.1176		88.8889	
	1e-3	8	91.6667				86.6667
		128			97.0588		
	1e-4	32	85.4167	82.3529	94.1176	81.8182	77.7778
		64					
	1e-5	4	85.4167	82.3529	94.1176	81.8182	75.6757
En iyi			91.6667	94.1176	97.0588	88.8889	86.6667

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Çizelge 5.11'deki GoogleNet sonuçları, en iyi değerler üreten MBS ve LR parametreleri bulunması AlexNet değerlendirmesindeki gibi yapılmıştır. İlk olarak tüm değerlerin en iyileri bulunmuştur. Tüm metriklerde en iyi sonuçlar 1e-3 LR parametresiyle elde edilmiştir. Bunların ikisi MBS 4, diğer ikisi MBS 8 ve bir tanesi de MBS 128 iken elde edilmiştir. Maksimum sonuçlar açısından MBS parametresine özgün, belirgin bir ayırım yapılamamaktadır. İkinci olarak, her bir öğrenme hızı sonuçlarının ürettiği ortalama değerler Çizelge 5.12'de verilmiştir.

Çizelge 5.12. GoogleNet Mimarisinin Yığın boyutu ve Öğrenme Hızı parametrelerindeki ortalama sonuçları

Epok	Öğrenme Hızı	Ortalama Doğruluk	Ortalama Duyarlılık	Ortalama Özgüllük	Ortalama Hassaslık	Ortalama F1-Skor
150	1e-3	86.1979	84.4013	91.2081	81.1773	77.9325
	1e-4	82.0313	75.2101	89.9589	73.9771	71.4652
	1e-5	71.9618	60.9419	83.9382	60.6015	57.3937

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Bu sonuçlar incelendiğinde ise ortalama değerlerde tüm metriklerde 1e-3 LR parametresinde en iyi sonuçların elde edildiği görülmektedir. Dolayısıyla GoogleNet mimarisi için MBS açısından net bir şey söylenemezken, 1e-3 LR parametrelerinin optimum olarak bulunduğu değerlendirilebilir.

Bu aşamada her iki model bir arada değerlendirildiğinde LR açısından 3 değerle en fazla 1e-4 ile elde edildiğinden, tüm modellerde kullanılmak üzere LR 1e-4

belirlenmiştir. Bu 3 en iyi değer, 32 MBS ile elde edildiğinden, ayrıca her iki model birlikte ele alındığında bundan daha fazla en iyi değer üreten bir MBS olmadığından 32 MBS parametresi optimum olarak kabul edilmiştir.

5.3.1. Optimum Parametreler Kullanılarak Mimarilerin Performans Testleri

Parametre optimizasyonu yapıldıktan sonra, diğer tüm modeller bu iki parametre esas alınarak çalıştırılmıştır. Tüm modeller için kullanılan nihai parametreler Çizelge 5.13'te toplu bir şekilde verilmiştir. Mimarilerin çalıştırılmasıyla elde edilen sonuçlar Çizelge 5.14'te verilmiştir.

Çizelge 5.13. Model ve uygun parametre belirleme deneylerinde kullanılan başlangıç hiperparametre değerleri

Hiperparametre	Değer
Başlangıç öğrenme hızı	1e-4
Her bir devirde kullanılacak görüntü sayısı (mini batch size)	32
Devir sayısı (Epok)	150
Öğrenme hızı düşürme oranı	0.5
Öğrenme hızı düşürme periyodu	5
Optimizasyon algoritması	SGDM
Çalışma ortamı	Multi-GPU
Momentum katsayısı	0.9

Çizelge 5.14. MBS=32 LR=1e-4 parametreleri ile elde edilen derin öğrenme mimari sonuçları

Model No	ESA Modeli	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
1	GoogleNet	85.4167	82.3529	94.1176	81.8182	75.6757
2	Densenet201	79.1667	76.4706	85.2941	68.4211	72.2222
3	Mobilenetv2	79.1667	70.5882	97.0588	83.3333	64.8649
4	Resnet18	75.0000	70.5882	82.3529	63.1579	66.6667
5	Resnet50	83.3333	82.3529	85.2941	73.6842	77.7778
6	Resnet101	72.9167	58.8235	82.3529	55.5556	57.1429
7	Shufflenet	68.7500	58.8235	76.4706	52.6316	55.5556
8	Nasnetmobile	64.5833	47.0588	76.4706	50.0000	48.4848
9	Efficientnetb0	66.6667	58.8235	79.4118	47.6190	52.6316
10	Vgg16	89.5833	76.4706	97.0588	90.9091	80.0000
11	Vgg19	77.0833	82.3529	91.1765	66.6667	70.0000
12	Squeezenet	79.1667	52.9412	91.1765	70.0000	58.3333
13	AlexNet	95.8333	94.1176	97.0588	94.1176	94.1176
14	Darknet19	81.2500	76.4706	94.1176	77.7778	72.2222
15	Darknet53	72.9167	70.5882	91.1765	61.1111	62.8571
16	Inceptionv3	75.0000	52.9412	91.1765	62.5000	48.6486
17	Xception	68.7500	64.7059	88.2353	55.0000	59.4595
18	Inceptionresnetv2	64.5833	64.7059	85.2941	46.6667	51.1628
19	Nasnetlarge	79.1667	76.4706	91.1765	70.0000	63.4146

* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Çizelge 5.14'teki bulunan sonuçlar incelendiğinde, tüm metriklerde en iyi değerlerin AlexNet mimarisi ile elde edildiği görülmektedir. Özgüllük metriğinde ise en iyi değer AlexNet'le birlikte Mobilenetv2 ve Vgg16 mimarileri tarafından da elde edilmiştir. En iyi ikinci sonuçlar ise Doğruluk, hassaslık ve F1-Skor metriklerinde Vgg16 mimarisinde elde edilmiştir.


Son olarak, rastgele belirlenen parametrelere göre Çizelge 5.5'te sonuçları verilen ön testlerle Çizelge 5.14'teki nihai sonuçlar mimariler bazında karşılaştırılarak hangisinin optimize edilen parametrelere göre nasıl bir performans sergilediği incelenmiştir. Sonuçlar Çizelge 5.15'te verilmiştir.

Çizelge 5.15. İlk testler ile optimize parametrelerle yapılan testler arasındaki değişim

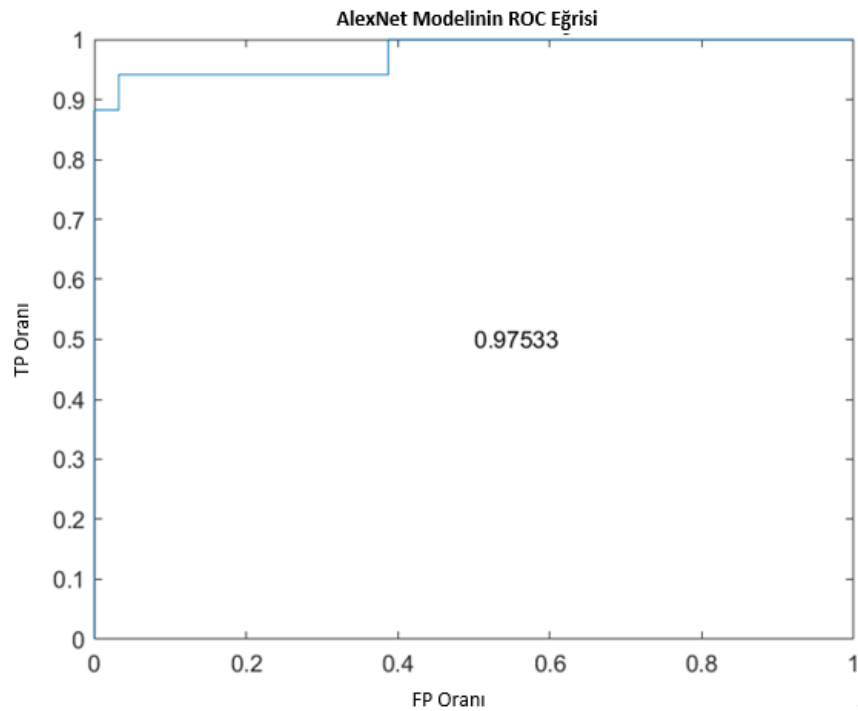
Model No	ESA Modeli	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
1	GoogleNet	↑	↑	↓	↑	↑
2	Densenet201	↑	↑	↓	↑	↑
3	Mobilenetv2	↑	↓	↑	↑	↓
4	Resnet18	↓	↓	↓	↓	↑
5	Resnet50	↑	↑	↓	↑	↑
6	Resnet101	↓	↓	↓	↓	↓
7	Shufflenet	↑	↑	↓	↑	↑
8	Nasnetmobile	↓	↓	↓	↑	↑
9	Efficientnetb0	↓	↓	↓	↓	↓
10	Vgg16	↑	↑	↑	↑	↑
11	Vgg19	↓	↑	↑	↓	↑
12	SqueezeNet	↑	↓	↑	↑	↓
13	AlexNet	↑	↑	↑	↑	↑
14	Darknet19	↓	↑	↑	↑	↑
15	Darknet53	↑	↑	↑	↑	↑
16	Inceptionv3	↑	↑	↑	↓	↑
17	Xception	↓	↑	↓	↑	↑
18	Inceptionresnetv2	↑	↑	↑	↑	↑
19	Nasnetlarge	↑	↑	↑	↑	↑

Çizelge 5.15'teki sonuçlar değerlendirildiğinde toplam 95 (19x5) metrik üzerinden 64 tanesinde artış gözlenmiştir. Toplamda 15 mimari (GoogleNet, Densenet201, Mobilenetv2, Resnet50, Shufflenet, Vgg16, Vgg19, SqueezeNet, AlexNet, Darknet19, Darknet53, Inceptionv3, Xception, Inceptionresnetv2 ve Nasnetlarge) sonuçları artış göstermiştir. Resnet18, Resnet101, Nasnetmobile ve Efficientnetb0 mimarilerinin sonuçları optimize edilmiş parametrelerle eğitildiğinde sonuçlarında azalış göstererek kötü performans sergilemişlerdir.

Son olarak Şekil 5.3'te bu çalışmada yer alan 19 mimariye ait ROC Eğrileri, Şekil 5.4'te ise bu çalışmada en iyi değerlerin elde edildiği AlexNet mimarisine ait ROC eğrisi hesaplanmıştır.



Şekil 5.3. Çalışmada Kullanılan 19 ESA Mimarisinin ROC Eğrileri



Şekil 5.4. Çalışmada en iyi yöntem olan AlexNet modelinin ROC Eğrisi

5.3.2. Tartışma

Tez çalışmasının bu aşamasında 19 ESA mimarisinin diyabetik ve basınç yarısı sınıflandırmasındaki başarıları incelenmiştir. Ayrıca görüntülerin granül, nekrotik ve slough sınıflarındaki başarılarının incelenmesinde ESA mimarilerinin eğitim parametrelerinin etkileri de incelenmiştir.

Parametre optimizasyonunda ilk olarak rastgele seçilen 10 epok, 32 yığın boyutu ve $1e-4$ öğrenme hızı parametreleri kullanılarak deneyler yapılmıştır. Bu testlerde sonuçların iyi çıktığı AlexNet ve GoogleNet mimarileri üzerinde farklı epok sayıları ile testler yapılmıştır. En iyi değerlerin üretildiği 150 ME ile farklı LR ve MBS parametreleri denenmiş ve yorumlanmıştır. Bu iki parametrede en iyi değerleri üreten $LR=1e-4$ ve $MBS=32$ parametreleri son adımda çalışmada belirtilen 19 ESA mimarisinde kullanılarak deneyler yapılmıştır. Bu deneylerde AlexNet aynı şekilde tüm metriklerde en iyi sonuçları elde etmiştir. AlexNet in yanı sıra Mobilenetv2 ve Vgg16 mimarileri Özgüllük metriğinde en iyi değerleri elde etmiştir. En iyi ikinci sonuçlar ise Doğruluk, hassaslık ve F1-Skor metriklerinde Vgg16 mimarisinde elde edilmiştir.

Testlerde optimum parametre değerlerinin bulunmasında ikinci olan GoogleNet mimarisi açısından sonuçlar değerlendirildiğinde; Doğruluk metriğinde AlexNet ve Vgg16 nın ardından üçüncü sıradadır. Duyarlılık metriğinde Vgg16, Resnet50 ile birlikte en iyi ikinci değere sahiptir. Özgüllük metriğinde ortak en iyi değeri üreten AlexNet, Vgg16 ve Mobilenetv2 nin ardından, diğer mimarilere göre en iyi ikinci değere sahiptir. Hassaslık ve F1-Skor metriklerinde ise AlexNet, Vgg16 ve Resnet50 mimarilerinin ardından dördüncü sıradadır.

Tüm mimarilerde üretilen metrik sonuçları değerlendirildiğinde Nasnetmobile ve Efficientb0 mimarilerinin sonuçlarının kötü olduğu görülmektedir. Son testler, ilk test sonuçlarıyla kıyaslandığında İnceptionresnetv2 ve Vgg16 mimarileri toplamda metrik değerlerini en fazla artıran mimarilerdir. Aynı şekilde Resnet101 ve Efficientnetb0 mimarilerinin metrik değerleri en fazla azalan mimariler olmuştur.

Tez çalışmasının bu bölümünde, gerçek veriler üzerinde eğitilen mimarilerin doğrulukları araştırılarak AlexNet mimarisinin yara görüntüleri açısından yüksek oranda sınıflandırma başarısı elde ettiği yapılan deneylerle ortaya konulmuştur.

5.4. AlexNet Mimarisinde Parametre Optimizasyonu

Tez çalışmasının bu bölümünde yara görüntüleri veri seti üzerinde AlexNet ESA mimarisinin sınıflandırma başarımları incelenmiştir. AlexNet ESA mimarisinde kullanılan eğitim parametrelerinin optimizasyonu ele alınmıştır. Etkisi incelenen parametreler ve değişken değerleri Çizelge 5.16’da verilmiştir.

Çizelge 5.16. Deneylerde etkisi araştırılan hiperparametre değerleri

Hiperparametreler	Değişken Değer Sayısı	Hiperparametre Değişkenleri				
Optimizasyon (O)	3	sgdm	rmsprop	adam		
Yığın Boyutu (MBS)	5	8	16	32	64	128
Maksimum Epok (ME)	5	10	25	50	100	150
Öğrenme Hızı (LR)	5	1e-2	1e-3	1e-4	1e-5	1e-6
Öğrenme Hızı Zamanlaması (LRS)	2	none	piecewise			

Optimizasyon algoritması (O) olarak sgd, rmsprop ve adam optimizasyon yöntemleri kullanılmıştır. Yığın boyutu (MBS) olarak deneylerde 8, 16, 32, 64 ve 128 değerleri kullanılmıştır. Maksimum epok (ME) parametresinde ise tüm parametre eşleri makalelerde sıklıkla kullanılan 10,25, 50, 100 ve 150 epok çalıştırılmıştır. Ayrıca 1e-2, 1e-3, 1e-4, 1e-5 ve 1e-6 öğrenme hızı (LR) parametre değerleri, Öğrenme hızı Zamanlaması (LearnRateSchedule LRS), “none” ve “piecewise” eşlerinde çalıştırılmıştır. LRS parametresinin piecewise olduğu durumlarda etki eden öğrenme hızı düşürme oranı (LearnRateDropFactor) parametresi 0.9, öğrenme hızı düşürme periyodu (LearnRateDropPeriod) parametresi ise 5 olarak sabit tutulmuştur (Uyar ve ark., 2021).

Yukarıda verilen her bir parametre eşleri deneylerde kullanılarak toplamda 750 (3x5x5x5x2) adet eğitim yapılmıştır. Model sınıflandırma başarımlarının karşılaştırılmasında doğruluk, duyarlılık, özgüllük, hassaslık ve F1-Skor ölçüm metrikleri kullanılmıştır. En başarılı parametre eşleri bulunmasında kıstas olarak tüm metriklerde en iyi olan parametre kümesi seçilmiştir. AlexNet mimarisi için yapılan tüm deneylerde elde edilen en iyi sonuçlar, Çizelge 5.17’deki parametre değerleri ile elde edilmiştir.

Çizelge 5.17. Optimum sonuçların bulunduğu parametreler ve değerlendirme metrik sonuçları

En iyi değerleri bulan Parametre Değerleri	Elde Edilen Metrik Değerleri	
(O) = SGDM	Doğruluk :	95.4861
(MBS) = 16	Duyarlılık :	95.0980
(ME) = 150	Özgüllük:	97.3593
(LR) = 1e-4	Hassaslık:	95.0000
(LRS) = none	F1-Skor:	95.0980

Yapılan 750 deney sonucunda en iyi sonuçların elde edilmesinde tespit edilen parametre değerleri ele alınmıştır. Tüm deneylerde kullanılan parametre değerleri, başlangıçta Doğruluk metriği dikkate alınarak, standart sapması ve ortalaması açısından ele alınmıştır. Bu sayede verilerin ortalamaya göre ne ölçüde değiştiğini göstererek, sonuçların ele alındığı parametre değerlerinde ne kadar homojen olduğunu göstermek amacıyla standart sapma değerleri de hesaplanmıştır.

Deneylerde kullanılan Farklı LR değerleri için elde edilen ortalama doğruluk ve standart sapma Çizelge 5.18’de sunulmuştur.

Çizelge 5.18. LR değerlerine göre ortalama Doğruluk ve Standart Sapma (StdDev)

LR	Ortalama Doğruluk	Standart Sapma (StdDev)
1e-2	57.17	2.228
1e-3	68.17	10.24
1e-4	80.64	5.125
1e-5	77.78	7.016
1e-6	63.47	8.142

Çizelge 5.18’deki sonuçlara göre, LR parametresi açısından doğruluk metriğindeki ortalama değerler ve standart sapmaları bir arada değerlendirildiğinde; standart sapması en düşük olan 1e-2 değerinde ortalama doğruluk, diğerlerine göre daha düşük çıkmaktadır. Bunun dışında standart sapması en düşük olan LR değeri 1e-4 iken bulunmuştur. Bu değerdeki Ortalama Doğruluk metriği %80.64 ile en yüksek değer olarak görülmektedir. Çizelge 5.18’deki Ortalama Doğruluk ve standart sapma değerleri bir arada ele alınırsa LR parametresi 1e-4 iken en optimum sonuçlara ulaşıldığı söylenebilir.

Çizelge 5.16’da aldığı değişken değerlerine göre, deneylerde kullanılan LRS, MBS ve ME parametrelerinin elde ettiği ortalama Doğruluk ve standart sapma değerleri de sırasıyla Çizelge 5.19, 5.20 ve 5.21’lerde verilmiştir.

Çizelge 5.19. LRS değerlerine göre ortalama Doğruluk ve Standart Sapma (StdDev)

LRS	Ortalama Doğruluk	Standart Sapma (StdDev)
None	69.75	11.413
piecewise	69.16	11.150

Çizelge 5.20. MBS değerlerine göre ortalama Doğruluk ve Standart Sapma (StdDev)

MBS	Ortalama Doğruluk	Standart Sapma (StdDev)
8	69.72	12.175
16	69.77	12.513
32	70.39	9.842
64	67.33	9.239
128	70.06	12.000

Çizelge 5.21. ME değerlerine göre ortalama Doğruluk ve Standart Sapma (StdDev)

LR	Ortalama Doğruluk	Standart Sapma (StdDev)
10	66.42	10.811
25	68.50	11.247
50	70.33	11.135
100	70.33	11.145
150	71.69	11.343

Çizelge 5.19’da LRS parametresi açısından ortalama doğruluk ve standart sapma değerleri incelendiğinde none ve piecewise değerlerinde ayırt edici bir fark bulunmamaktadır. Çizelge 5.20’de MBS parametre açısından değerlendirildiğinde, MBS 32 iken, ortalama Doğruluk değeri, %70.39 dir. Ancak diğer Ortalama Doğruluk değerleri ile karşılaştırıldığında ayırt edici bir fark görülmemektedir. Aynı şekilde standart sapma değerleri MBS 32 ve 64 iken kısmen düşük çıkmıştır. Çizelge 5.21’deki ME parametresi açısından değerlendirildiğinde ise, ME 150 iken, Ortalama Doğruluk %71.69 ile ilk sıradadır. Ancak standart sapma değerleri arasında gözlenen çok büyük bir fark oluşmamıştır. Çizelge 5.19, 5.20 ve 5.21’lerdeki LRS, MBS ve ME parametrelerinde verilen Ortalama Doğruluk ve Standart Sapma değerlerine göre bu parametreler için kesin bir kanıya varılamamaktadır.

Parametre optimizasyon deneylerinde, Doğruluk metriği ele alındığında sadece LR parametresi açısından bir tespit yapılabilmektedir. Eğitim esnasında kullanılan parametreler, ayrıca Çizelge 5.16’da verilen diğer değerlendirme metrikleri açısından da değerlendirilmiştir. Doğruluk metriğinde olduğu gibi metriklerin ortalama değerleri ve standart sapması bulunarak yorumlanmıştır. İlk olarak, LR değerleri için, Duyarlılık, Özgüllük, Hassaslık ve F1-Skor metriklerinin ortalama değerleri ve standart sapmaları Çizelge 5.22’de verilmiştir.

Çizelge 5.22. Diğer metrikler için LR nin ortalama değerleri ve standart sapmaları

LR	Duyarlılık		Özgüllük		Hassaslık		F1-Skor	
	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
1e-2	33.84	3.549	66.91	1.669	35.29	0.875	18.32	6.519
1e-3	51.71	16.154	75.65	7.918	63.53	23.427	46.06	22.75
1e-4	71.20	7.797	85.27	3.931	82.97	9.576	71.04	7.831
1e-5	66.43	10.683	83.05	5.348	79.12	11.822	66.27	11.339
1e-6	44.92	12.257	72.34	6.073	58.01	16.022	44.48	12.816

Çizelge 5.22'deki dört metrik sonuçları bir arada değerlendirildiğinde, her bir metriğin ortalama değerleri açısından, tüm metriklerde ortalama en iyi sonuçlar, LR değeri 1e-4 iken elde edilmiştir. Standart sapmalarına göre değerlendirildiğinde ise tüm metriklerde en düşük değerler 1e-2 iken bulunmuştur. Ancak LR 1e-2 iken elde edilen ortalama metrik değerleri diğerlerine göre oldukça düşüktür. Bu yüzden Ortalama Doğruluk' ta olduğu gibi tüm metriklerde de LR 1e-4 olduğunda optimum sonuçların elde edilebildiği sonucuna varılabilir.

LRS değerleri için, Duyarlılık, Özgüllük, Hassaslık ve F1-Skor metriklerinin ortalama değerleri ve standart sapmaları Çizelge 5.23'de verilmiştir.

Çizelge 5.23. Diğer metrikler için LRS nin ortalama değerleri ve standart sapmaları

LRS	Duyarlılık		Özgüllük		Hassaslık		F1-Skor	
	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
none	54.01	17.718	76.88	8.726	64.56	22.649	49.51	23.384
piecewise	53.22	17.399	76.40	8.617	63.01	21.916	48.95	22.809

Çizelge 5.23'deki LRS sonuçları değerlendirildiğinde, her bir metrikte none ve piecewise parametrelerinin ortalama değerlerinde ve standart sapmalarında ayırt edici bir fark bulunmadığı görülmüştür.

MBS değerleri için, Duyarlılık, Özgüllük, Hassaslık ve F1-Skor metriklerinin ortalama değerleri ve standart sapmaları Çizelge 5.24'te verilmiştir.

Çizelge 5.24. Diğer metrikler için MBS nin ortalama değerleri ve standart sapmaları

MBS	Duyarlılık		Özgüllük		Hassaslık		F1-Skor	
	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
8	53.89	19.050	76.78	9.422	63.66	24.784	47.54	26.253
16	53.78	19.570	76.78	9.669	61.91	22.898	48.36	25.741
32	55.12	15.241	77.40	7.562	66.62	19.136	51.70	20.319
64	50.60	14.347	75.12	7.021	62.26	20.786	47.07	18.967
128	54.70	18.595	77.12	9.187	64.46	23.134	51.47	22.894

Çizelge 5.24'teki MBS sonuçları değerlendirildiğinde, her bir metrikte 8, 16, 32, 64, 128 parametrelerinin ortalama değerlerinde ve standart sapmalarında ayırt edici bir fark bulunmamaktadır. Değerlendirme metriklerinin tümünde, MBS 32 parametresinde kısmen diğerlerine göre daha iyi ortalama metrik değerleri ve standart sapma değeri elde edilmiştir.

ME değerleri için, Duyarlılık, Özgüllük, Hassaslık ve F1-Skor metriklerinin ortalama değerleri ve standart sapmaları Çizelge 5.25'te verilmiştir.

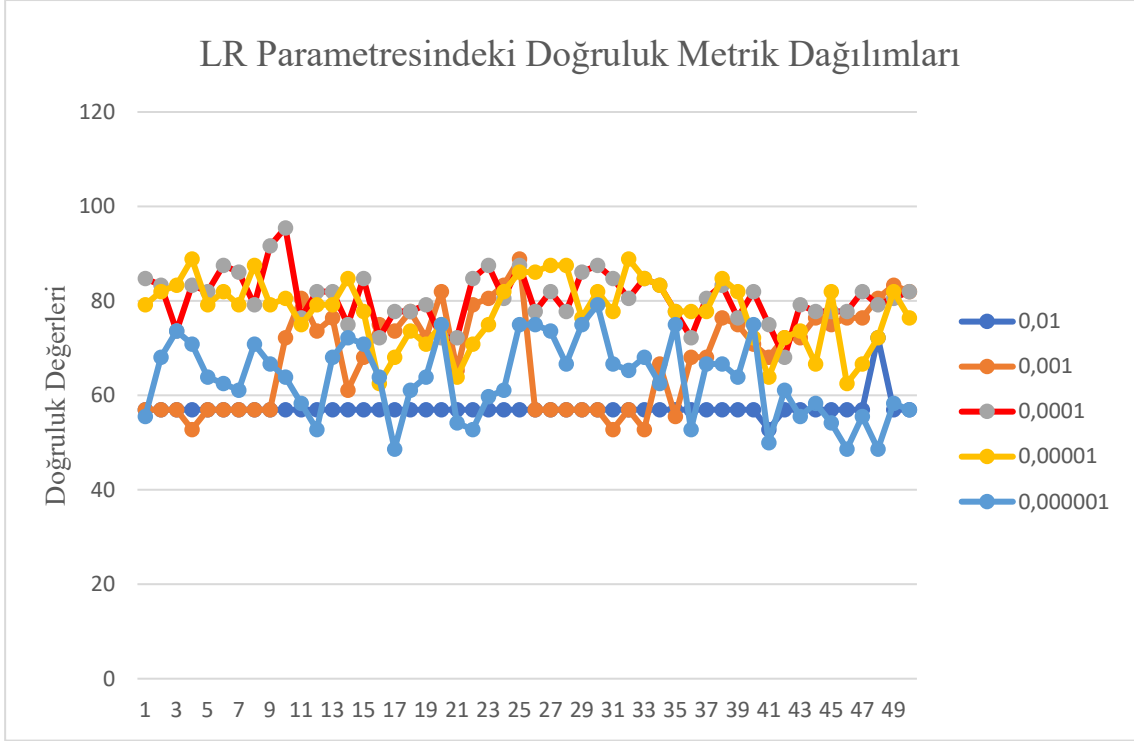
Çizelge 5.25. Diğer metrikler için ME nin ortalama değerleri ve standart sapmaları

ME	Duyarlılık		Özgüllük		Hassaslık		F1-Skor	
	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma	Ortalama	Standart Sapma
10	49.04	16.626	74.39	8.267	60.75	22.562	43.84	21.750
25	52.12	17.538	75.92	8.635	60.58	21.213	47.40	22.919
50	54.90	17.430	77.280	8.615	64.99	23.008	51.03	23.143
100	55.05	17.449	77.364	8.572	65.02	22.504	50.75	23.207
150	56.96	17.664	78.253	8.752	67.57	21.324	53.12	23.291


Çizelge 5.25'teki ME sonuçları değerlendirildiğinde, her bir metrikte 10, 25, 50, 100, 150 parametrelerinin ortalama değerlerinde ve standart sapmalarında ayırt edici bir fark bulunmamaktadır. Değerlendirme metriklerinin tümünde, ME 150 parametresinde kısmen diğerlerine göre daha iyi ortalama metrik değerleri ve standart sapma değeri elde edilmiştir.

Son olarak, LR, LRS, MBS, ME parametreleri için deneylerde elde edilen sonuçların dağılımları sırasıyla Şekil 5.5, 5.6, 5.7 ve 5.8'de gösterilmiştir. Şekil 5.5, 5.6, 5.7 ve 5.8 incelendiğinde Çizelge 5.17'de verilen en iyi parametre değerlerini bulan

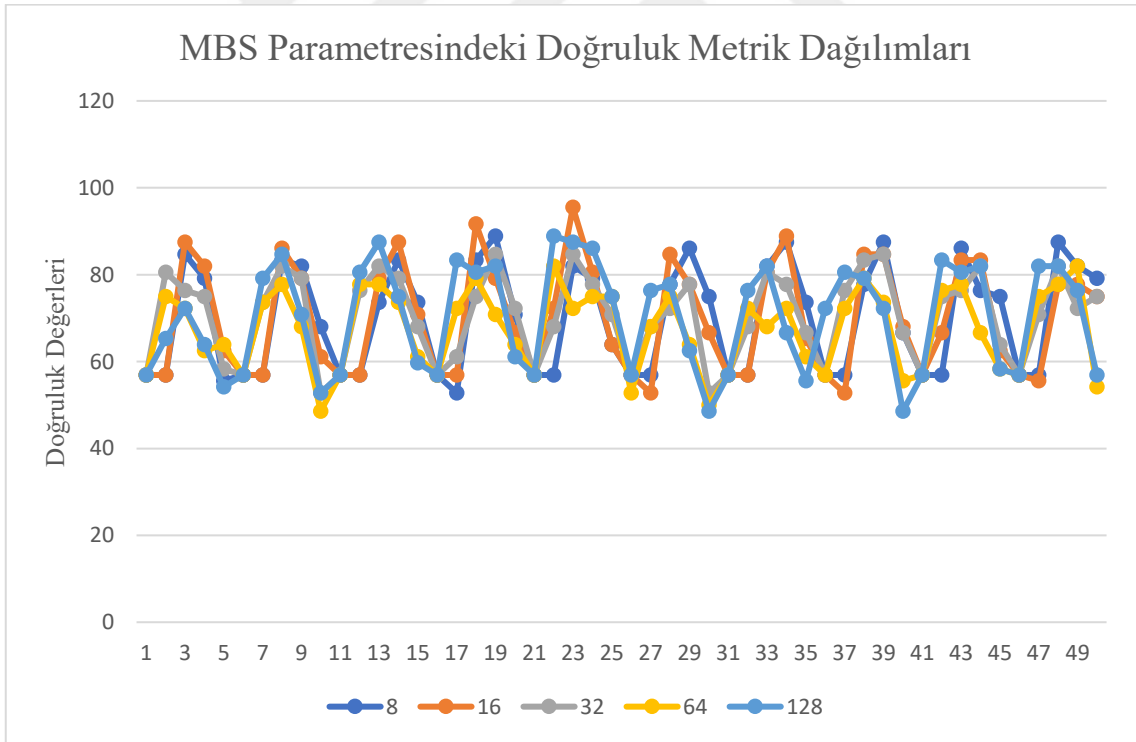
metrikler belirlenebilmektedir. En iyi doğruluk değerleri; Şekil 5.5'teki LR parametresinde $1e-4$ olduğunda (kırmızı çizgi Şekil 5.6'daki LRS parametresinde "none" olduğunda (mavi çizgi), Şekil 5.7'deki MBS parametresinde 16 olduğunda (turuncu çizgi) ve Şekil 5.8'deki ME parametresinde 150 olduğunda (mavi çizgi) elde edildiği görülmektedir.




Şekil 5.5. Deneylerdeki LR Parametre Dağılımları



Şekil 5.6. Deneylerdeki LRS Parametre Dağılımları



Şekil 5.7 Deneylerdeki MSB Parametre Dağılımları



Şekil 5.8. Deneyslerdeki ME Parametre Dağılımları

Ağırlıkların derin öğrenme mimarisinde eğitim esnasında güncellenme miktarını gösteren LR parametre değeri açısından incelendiğinde tüm test senaryolarında en iyi ortalama değerlerin ve dağılımların birbirine en yakın çıktığı değer olarak $1e-4$ tespit edilmiştir. Diğer tüm LR değerlerinde ortalama değerler daha düşük olup dağılımlardaki farkları (Standart Sapması) yüksek çıkmıştır. Optimizer algoritması açısından ele alındığında sgd, rmsprop ve adam algoritmalarının standart sapmaları ve ortalama değerleri birbirine çok yakın olduğundan ayırt edici bir parametre olarak yorumlanamamıştır. Bu yüzden en iyi sonuçların elde edildiği sgd optimizer algoritmasındaki sonuçlar ele alınmıştır.

Diğer parametreler MBS, ME, LRS e göre sonuçlar incelendiğinde de dağılımlarının çok farklı çıkarak hata oranları yüksek olarak görülmüştür. Dolayısıyla LR dışında tüm parametre değerlerinde gruplandırılarak ölçülen değerlerden kesin bir kaniya varılamamıştır. Bu parametre değerlerinin bulunmasında AlexNet mimarisinin başlangıç ağırlık değerlerinin önemli olduğu düşünülmektedir.

5.4.1. Tartışma

Yapılan deneylerde, özgün yara görüntüleri veri seti üzerinde AlexNet mimarisinin başarımı incelenmiştir. Tez çalışmasının bu aşamasında, sgd, rmsprop ve adam optimizasyon yöntemleri kullanılmıştır. MBS parametresi minimum 8, maksimum 128 olmak üzere 2 nin katları olarak, ME parametresi için, 10, 25, 50, 100 ve 150 değerleriyle test edilmiştir. LR değeri olarak $1e-2$, $1e-3$, $1e-4$, $1e-5$ ve $1e-6$ kullanılmıştır. LRS olarak ise “none” ve “piecewise” değerleri alınmıştır. Hangi parametrenin değerlendirme metriğini nasıl etkilediğinin gözlenmesi için 750 adet deney yapılmıştır. Yapılan deneylerde eğitim aşamasında kullanılan parametrelerden sgd, rmsprop ve adam optimizasyon algoritmalarından en iyi sonuçları üreten sgd yönteminde elde edilen sonuçlar ele alınmıştır. Sgd optimizasyon algoritması ile elde edilen sonuçlar, LR, LRS, MBS ve ME parametrelerinin aldığı farklı değerlere göre gruplandırılarak değerlendirilmiştir. Doğruluk, Duyarlılık, Özgüllük, Hassaslık ve F1-Skor değerlendirme metriklerinin ortalama değerleri ve standart sapmaları hesaplanarak yapılan yorumlamalarda sadece LR parametresindeki sonuçlarda belirgin iyi sonuçların gruplandığı tespit edilmiştir. Tüm parametre optimizasyonu deney sonuçlarına göre LR parametresi $1e-4$ değerinde iyi sonuçların elde edilmiştir. Diğer parametrelerin elde ettiği sonuçlarda belirgin sonuç farkları oluşmadığından mimarinin başlangıç ağırlık değerlerinden dolayı benzer sonuçların üretildiği düşünülmektedir.

5.5. Yara Görüntüsü Sınıflandırmada AlexNet Mimarisinin Modifiye Edilmesi

Tez çalışmasının son aşamasında, yara görüntülerinin sınıflandırılması için Bölüm 4.2.3 te detayları verilen en iyi mimarinin performans iyileştirmesi ile ilgili deneysel sonuçlara yer verilmiştir. Bölüm 4.2.3’ te detayları verilen üç modelin performansları uzman doktor aracılığıyla hastalardan toplanan orjinal diyabetik ve basınç yara görüntüleri veri setimiz üzerinde test edilmiştir.

Tüm deneylerde MBS 32, optimizasyon algoritması SGDM, öğrenme hızı düşürme oranı 0.5, öğrenme hızı düşürme periyodu 5 parametreleri, öğrenme hızı $1e-4$ ile kullanılmıştır. Veri setimizdeki görüntülerin %70’i eğitim, %15’i test ve %15’i doğrulama olarak ayrılarak her bir model 150 epok çalıştırılmıştır. Eğitim verileri test ve doğrulama (validation) verisi olarak kullanılmamıştır. Kullanılan parametre değerleri ayrıca Çizelge 5.26’da özetlenmiştir.

Çizelge 5.26. Önerilen AlexNet mimarilerinin eğitiminde kullanılan hiperparametre değerleri

Hiperparametre	Değer
Başlangıç öğrenme hızı	1e-4
Her bir devirde kullanılacak görüntü sayısı (mini batch size)	32
Devir sayısı (Epok)	150
Öğrenme hızı düşürme oranı	0.5
Öğrenme hızı düşürme periyodu	5
Optimizasyon algoritması	SGDM
Çalışma ortamı	Multi-GPU
Momentum katsayısı	0.9

İlk olarak önerilen yöntemler belirlenen deneysel koşullar içinde veri seti üzerinde test edilmiştir. Sonuçlar Çizelge 5.27’de listelenmiştir.

Çizelge 5.27. Önerilen modellerin karşılaştırmalı sonuçları

Sınıflandırıcı	Model	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
Softmax	AlexNet	95.49	95.10	97.36	95.00	95.09
	3Conv	79.17	68.91	84.44	68.47	68.15
	4Conv	89.00	83.07	91.40	85.96	83.95
	6Conv	96.91	97.14	97.02	94.03	95.20
SVM	AlexNet	95.83	94.12	97.06	94.12	94.12
	3Conv	68.06	51.54	75.27	67.75	48.84
	4Conv	80.52	80.52	90.26	80.72	80.49
	6Conv	98.85	98.85	99.42	98.81	98.85


* En iyi sonuçlar kalın yazı tipi ile gösterilmiştir Tüm değerler % şeklindedir.

Çizelge 5.27’ye göre, 3 Evrişim katmanlı model ve 4 Evrişim katmanlı model her iki sınıflandırıcı ile kullanıldığında da kötü performans sergilemiştir (3Conv_Softmax, 3Conv_SVM and 4Conv_Softmax, 4Conv_SVM). Bunun dışında diğer yöntemler %80 üzerinde performans göstermiştir. En iyi sonuçlar, önerilen 6 evrişim katmanlı modelin SVM sınıflandırıcı ile birlikte kullanılmasında (6Conv_SVM) %98 üzerinde başarıyı tüm metriklerde elde edilmiştir.

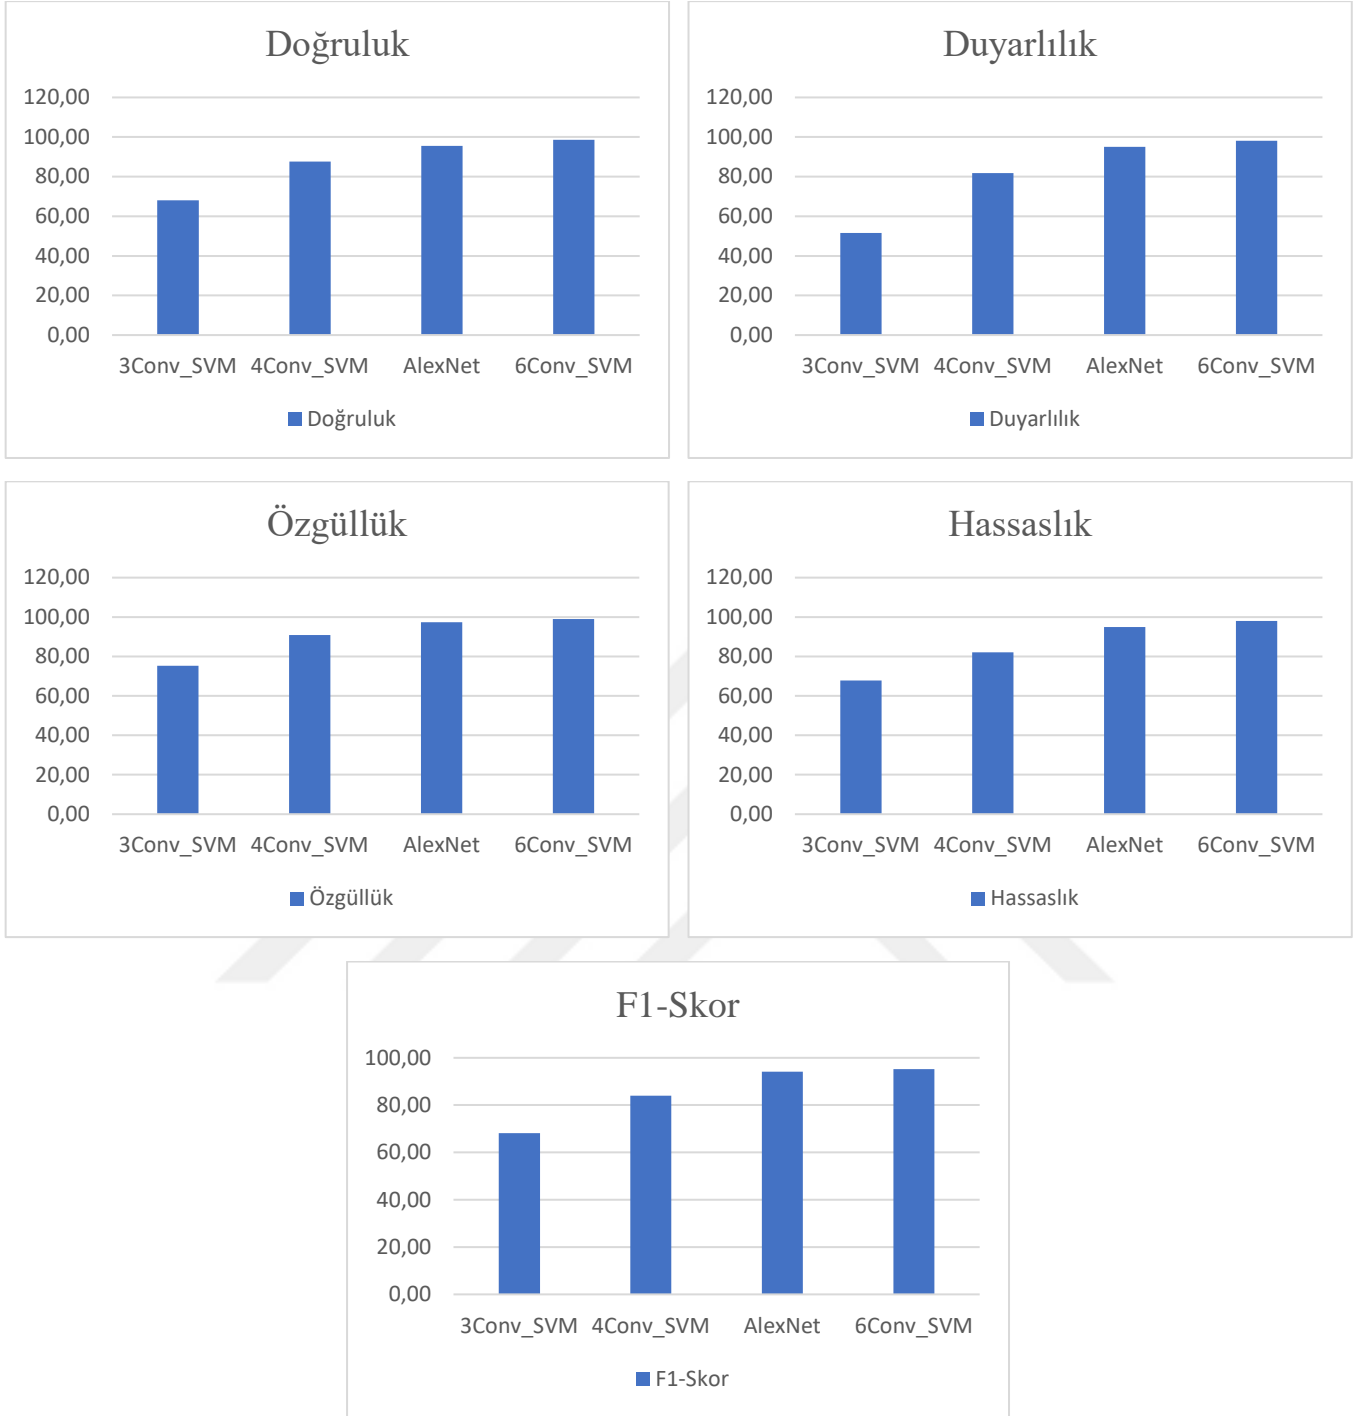
6 Evrişim katmanlı önerilen model, Softmax sınıflandırıcı ile kullanıldığında da %94 üzerinde bir performans sergilemiştir. Her iki sınıflandırıcı ile yapılan deneylerde evrişim katmanının artırılarak elde edilen 6Conv_Softmax ve 6Conv_SVM modellerinin başarıyı artırdığı görülmektedir. Ayrıca evrişim katmanının artırılarak 7 ve daha fazla evrişim katmanına sahip (en fazla=10) mimariler için benzer deneysel çalışmalar yapılmıştır. Değerlendirme metriklerinde sonuçlarda iyileşme görülmediğinden bu yöntemler ve detaylarına çalışmada yer verilmemiştir.

6Conv_SVM, yara görüntülerinin özelliklerini çok iyi tanımaktadır. Yüksek sınıflandırma oranları elde etmesinden dolayı yara veri seti üzerinde çok etkili bir model olduğu görülmüştür.

Çizelge 5.27'deki SVM sınıflandırıcısı metrik değerlerinin görsel karşılaştırması Şekil 5.9 'da verilmiştir. Ayrıca Softmax sınıflandırıcısına göre daha iyi sonuçlar üreten SVM sınıflandırıcısının sonuçları her bir metrik için Şekil 5.10 'da verilmiştir. Önerilen modellerden en iyisi olan 6Conv_SVM modelinin dengeli ve yüksek sonuçları şekilde gösterilmiştir.



Şekil 5.9. SVM sınıflandırıcısının değerlendirme metrik sonuçlarının grafiksel karşılaştırması



Şekil 5.10. SVM sınıflandırıcısının her bir değerlendirme metrik sonuçlarının grafiksel karşılaştırması

Sınıflandırıcı modellerinin performanslarını değerlendirmek için karmaşıklık matrisleri de Çizelge 5.28, 5.29, 5.30 ve 5.31’de verilmiştir. Karmaşıklık matrisleri, yöntemlerin sınıflandırma performansının test edilmesinde kullanılan görüntülerin, gerçek sınıfa ait olup olmadığına dair bilgi vermektedir. Her bir sütunda gerçek sınıf değerleri, her bir satırda ise model tarafından tahmin sonuçları görülmektedir.

Çizelge 5.28. 3Conv_SVM modelinin sınıflandırma sonucu elde edilen karmaşıklık matrisi

		Gerçek Sınıf		
		Granul	Nekrotik	Slough
Tahmin	Granul	497	105	200
	Nekrotik	103	520	55
	Slough	100	75	445

Çizelge 5.29. 4Conv_SVM modelinin sınıflandırma sonucu elde edilen karmaşıklık matrisi

		Gerçek Sınıf		
		Granul	Nekrotik	Slough
Tahmin	Granul	526	50	55
	Nekrotik	75	575	55
	Slough	99	75	590

Çizelge 5.30. AlexNet modelinin sınıflandırma sonucu elde edilen karmaşıklık matrisi

		Gerçek Sınıf		
		Granul	Nekrotik	Slough
Tahmin	Granul	591	12	15
	Nekrotik	74	664	20
	Slough	35	24	665

Çizelge 5.31. 6Conv_SVM modelinin sınıflandırma sonucu elde edilen karmaşıklık matrisi

		Gerçek Sınıf		
		Granul	Nekrotik	Slough
Tahmin	Granul	690	2	3
	Nekrotik	3	693	4
	Slough	7	5	693

Bu çalışmada en iyi değerleri üreten AlexNet mimarisinin modifiye edilmesiyle önerilen 6Conv_SVM modeli, ayrıca literatürde açık kaynak olarak sunulan Medetec veri seti üzerinde de aynı deneysel koşullarla test edilmiştir. Medetec veri setindeki 177 adet çözünürlükleri farklı (genellikle 560x410) olan basınç yarası ve 49 diyabetik ayak yarası, resimlerinin tümü kullanılmıştır (Steve, 2021b). Sonuçlar Çizelge 5.32’de listelenmiştir.

Çizelge 5.32. 6Conv_SVM modelinin Medetec veri setindeki sonuçları

	Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
6Conv_SVM	95.33	95.33	97.66	95.42	95.34
AlexNet	93.87	90.15	95.05	92.22	92.59

Bu veri seti üzerinde elde edilen değerlendirme metrik sonuçları, özgün veri setindeki sonuçlara göre düşüktür. Görüntü sayısı az olduğundan başarımın düştüğü

gözlenmiştir. Yine de önerilen yöntemler arasında en başarılı olan 6Conv_SVM modeli %95 üzerinde başarı elde etmiştir.

Literatürde yara görüntülerini içeren standart bir veritabanı kullanılmamıştır. Bu nedenle adil bir kıyaslama yapabilmek mümkün değildir. Çalışmalar, kendi topladıkları resim veri seti üzerinde test yapmışlardır. Özellikle diyabetik ayak ülseri ve basınç yarası resimlerinin granül, nekrotik ve slough sınıflarından hangisine ait olduğuna dair bir çalışma bulunmamaktadır. Çalışmalar genellikle, yara görüntüsünün doku sınıflandırmasından ziyade ilgili çalışmada ele alınan yara görüntülerinin o türe ait olup olmadığını gösteren binary bir sınıflandırma üzerinde çıkarım yapmışlardır. (Rostami ve ark., 2021) ise yaranın venöz, diyabetik ve cerrahi sınıflarından hangisine ait olduğu üzerinde çalışmışlardır. Literatür karşılaştırmasında, bu çalışmanın 3-sınıf sınıflandırma başarıları ele alınmıştır.

Çizelge 5.33'te benzer ya da farklı tür yara görüntüleri üzerinde sınıflandırma yapan çalışmalar, görüntü özellikleri açısından benzer olduklarından kıyaslamalarda ele alınmıştır.

Çizelge 5.33 Literatür Karşılaştırması

	Veri Seti Detayları		Doğruluk	Duyarlılık	Özgüllük	Hassaslık	F1-Skor
	Resim Sayısı	Sınıflandırma Şekli					
(Shenoy ve ark., 2018)	1335	2 sınıf (Pozitif / Negatif)	82	93	75		83
(Rostami ve ark., 2021)	400	3 sınıf (Diyabetik, Venöz, Cerrahi)	87.7	87.3		87.98	87.44
(Alzubaidi ve ark., 2020b)	754	2 sınıf (Normal/ Anormal)		93.6		95.4	94.5
(Goyal ve ark., 2018)	397	2 sınıf (DFU, Normal Cilt)	92.5	93.4	91.1	94.5	93.9
(Goyal ve ark., 2020)	1459	2 sınıf (iskemik / İskemik değil)	90.3	88.6	92.1	91.8	90.2
		2 sınıf (Enfeksiyonlu / Enfeksiyonsuz)	72.7	70.9	74.4	73.5	72.2
(Das ve ark., 2021)	397	2 sınıf (Normal/ Anormal)	96.4	98.4	95.1	92.6	95.4
6Conv_SVM	2100	3 sınıf (Granul, Nekrotik ve Slough)	98.85	98.85	99.42	98.81	98.85

Bu çalışmada önerilen modifiye AlexNet mimarilerinden en iyi sonuçları elde eden 6Conv_SVM ile, literatürde benzer yara görüntüleri üzerinde sınıflandırma yapan diğer çalışmaların sonuçları, Çizelge 5.33'te, Doğruluk, Özgüllük, Hassaslık ve F1-Skor değerlendirme metrik sonuçlarıyla sunulmuştur.

Çizelge 5.33'te sunulan karşılaştırmada kullanılan çalışmalardan (Goyal ve ark., 2018; Shenoy ve ark., 2018; Alzubaidi ve ark., 2020b; Goyal ve ark., 2020; Das ve ark., 2021) verisetleri üzerinde ikili (binary) bir sınıflandırma yapmışlardır. Veri setinde 3 sınıfın kullanıldığı (Rostami ve ark., 2021) çalışmada ise yara türlerine göre bir sınıflandırma yapılmıştır.

Çizelge 5.33'teki tüm metrik sonuçları genellikle %70 üzerindedir. Ayrıca çalışmalarda verilen metrik değerleri belirtilmiş diğerleri boş bırakılmıştır. İlk çalışma (Shenoy ve ark., 2018) %93 duyarlılık değeri yüksek iken diğer Doğruluk, Özgüllük,

Hassaslık ve F1-Skor değerleri düşüktür. Diğer bir çalışma da (Rostami ve ark., 2021) toplanılan 400 resim üzerinde değerlendirme metrik sonuçları yaklaşık %87 olarak bulunmuştur. Sadece diyabetik ayak yarası görüntülerinden oluşan 754 resim üzerinde yapılan binary Classification deneylerin yer aldığı çalışma, 754 resim için 95.4 Hassaslık değeri elde etmişlerdir (Alzubaidi ve ark., 2020b). 2018 ve 2022 yıllarında Diyabetik ayak yarası sınıflandırması yapan Goyal ve arkadaşları (Goyal ve ark., 2018; Goyal ve ark., 2020) ilk çalışmada 397 resim üzerinde ikili sınıflandırma ile %92.5 Doğruluk elde etmişlerdir. Diğer çalışmalarında ise 1459 resim üzerinde iskemik/iskemik değil (ischemica/non-ischemica) sınıflandırmalarında %90.3 Doğruluk, enfeksiyonlu enfeksiyonsuz (infection/non-infection) sınıflandırmalarında ise %72.7 Doğruluk elde etmişlerdir. Çizelge 5.33'teki karşılaştırmada kullanılan son çalışmada ise (Das ve ark., 2021) 397 diyabetik ayak yarası görüntü üzerinde yaptıkları deneylerde tüm değerlendirme metriklerinde %92-96 değerler elde etmişlerdir. Literatürden elde edilen sonuçlar ile bu çalışmada önerilen 6Conv_SVM modeliyle elde edilen sonuçlar karşılaştırıldığında, her bir değerlendirme metriğinde %98'in üzerindeki başarı, Çizelge 5.33'teki modellere kıyasla daha iyidir.

5.5.1. Tartışma

Bu çalışmada, normal AlexNet mimarisindeki en son sınıflandırma katmanındaki sınıflandırıcının değiştirilmesi ve farklı konvolüsyon katmanları kullanılarak önerilen ESA mimarilerinin yara görüntüleri üzerindeki sınıflandırma başarısı ele alınmıştır. Önerilen ESA mimarilerinin Softmax sınıflandırma katmanı yerine SVM sınıflandırma algoritması da kullanılmıştır. ESA mimarilerindeki transfer öğrenme başarı performansları da karşılaştırmalı olarak incelenmiştir. Önerilen mimariler yeniden eğitilmiştir. Yara görüntülerinin sınıflandırılması amacıyla önerilen her 3 yöntem (3Conv_Softmax, 4Conv_Softmax and 6Conv_Softmax) ve bu yöntemlerin SVM sınıflandırıcı kullanıldığında (3Conv_SVM, 4Conv_SVM ve 6Conv_SVM) performansları ele alındığında 6Conv_Softmax yöntemi en başarılı değerlendirme sonuçlarını elde ettiği görülmüştür. AlexNet mimarisine eklenen evrişim katmanının, sınıflandırma doğruluğunu artırdığı gözlenmiştir. %98.62 Doğruluk, %98.09 Duyarlılık ve %98.92 Özgüllük değerleriyle önerilen yöntemlerden 6 Evrişim katmanına sahip model (6Conv_Softmax) en başarılı yöntem olmuştur.

6. SONUÇLAR VE ÖNERİLER

Bu tez kapsamında tıbbi yara görüntülerinin ESA mimarileriyle segmentasyonu ve sınıflandırılması ile ilgili bazı yaklaşımlar önerilmiştir. Önerilen bu yaklaşımların performans değerlendirmeleri, özgün olarak hazırlanan veri seti kullanılarak elde edilen sonuçlar üzerinde sunulmuştur.

6.1 Sonuçlar

İnsanların görme, gördüğünü yorumlayabilme ve yorumlar neticesinde karar verme yetenekleri kuvvetli olmasına karşın, özellikle karmaşık olan ve uzmanlık gerektiren durumlarda uzmanlık ve deneyimlere bağlı olarak öznel yorumlamalar söz konusu olabilmektedir. Özellikle tıp alanında doktorların her ne kadar çalıştığı uzmanlık alanında becerileri yüksek olsa da aynı hasta için farklı zamanlarda farklı karar vermeler ve tedavi önermeleri söz konusu olabilmektedir. Bu durum karar verme süreçlerinde gözlemciler arasında farklılıklara yol açabilmektedir. Öznelliklerin azaltılması için, tıp dünyasında, sağlık çalışanlarına yardımcı olabilecek, nicel ölçütlere dayalı, tanı ve tedavi takip sistemlerinin geliştirilmesi çalışmaları gün geçtikçe artmaktadır.

Tıbbi yaralarının iyileşme sürecinde ağrı ve enfeksiyon nedeniyle hastanede kalış süresinin uzaması ve bakım maliyetlerinin artması gibi olumsuz etkiler ortaya çıkmaktadır. Bu etkilerin azaltılması ve en aza indirgenmesi için bilgisayar bilimlerinin sunacağı her bir çalışmanın katkısı büyük önem taşımaktadır. Yaraların düzenli bir şekilde takip edilebilmesi için yara bölgesinin yorumlanması ve izlenebilmesi, hem hastaların sağlık ilerlemesinin iyileştirilmesi hem de ülke ekonomilerine katkı sunabilmesi açısından literatürde önemli bir yer tutmaktadır.

Medikal görüntüler üzerinde otomatik karar vermeye yönelik yeni yöntemlerin tasarlanması ve geliştirilmesi amacıyla, bu tez çalışmasında, tıbbi yara görüntülerinin segmentasyonu ve sınıflandırılmasının sağlanması amacıyla farklı yöntemler önerilmiştir. Anlamsal bölütleme yöntemleriyle yara görüntülerinin mevcut görüntüden ayrıştırılması, ayrıştırılan görüntülerin literatürde güncel derin öğrenme mimarileri ile sınıflandırılması, sınıflandırma aşamasında en iyi sonuçlar veren mimari için parametre optimizasyonunun yapılması ve en başarılı yöntemden yola çıkılarak evrimsel sinir ağları modellerinin tasarlanması tez çalışmasının kapsamını oluşturmaktadır.

İlk çalışmada segmentasyon işlemlerinde 20 farklı kodlayıcı-kod çözücü (encoder-decoder) tabanlı güncel ESA mimarilerinin etkisi araştırılmıştır. Yapılan deneylerde tüm metriklerde MobileNet-UNet modelinin en yüksek doğruluğu elde ettiği görülmüştür. %99.67 gibi çok yüksek bir doğrulukla elde edilen model sonuçları literatür çalışmalarıyla da karşılaştırılmıştır. Segmentasyon işlemlerinde bu tez çalışmasıyla literatüre temel olarak iki farklı katkı sunulmuştur:

- İlk olarak yara görüntüleri üzerinde derin öğrenme segmentasyon mimarilerinden Tam bağlantılı Evrişimsel Sinir Ağları (fully convolutional neural networks (FCN)), Çoklu ölçekli Ağlar (Multi-scale networks) ve Kodlayıcı-Kod çözücü (Decoder-Encoder) tabanlı Sinir Ağları yaklaşımlarının segmentasyon başarıları incelenmiştir.
- İkinci olarak, yara görüntülerinin segmentasyonunda farklı özellik çıkarıcı ESA mimarileriyle (VGG16, ResNet, MobileNet, EfficientNet, Vanilla CNN.) bir arada kullanıldıklarında, bu yaklaşımların piksel tabanlı (pixel-based) sınıflandırmaya etkileri incelenerek derin öğrenmenin bu alanda nasıl bir performans sergilediği ele alınmıştır. Böylece ana model (base-backbone model) lerin segmentasyon başarıları da incelenmiştir.
- Ayrıca sonuçları en başarılı olan yaklaşımlar, parametre optimizasyona tabi tutularak nihai performansları değerlendirilmiştir. Sonuçta her bir yara dokusu türünde yara bölgesinin yüksek başarıyla objektif olarak tespit edilmesine katkı sağlanması amaçlanmıştır.
- Literatür karşılaştırmalarında tespit edildiği kadarıyla, bu çalışma kodlayıcı-kod çözücü anlamsal bölütleme yöntemleri ile tıbbi yaraların segmentasyonunun yapıldığı ilk çalışmadır.

İkinci çalışmada tıbbi yaralarının, yüksek doğrulukta otomatik olarak sınıflandırılmasını sağlayan derin öğrenme yaklaşımlarının tespit edilmesi ele alınmıştır. Parametrelerin, Derin Öğrenme mimarilerin başarılarına etki ettikleri bilinmektedir. Bu nedenle görüntülerin granül, nekrotik, slough sınıflarındaki başarılarının incelenmesinde mimarilerinin eğitim parametrelerinin etkileri de tez kapsamında incelenmiştir. İlk olarak rastgele eğitim parametreleri ile 19 ESA mimarisi kullanılarak veri seti üzerinde deneyler yapılmıştır. Deneylerde başarılı sonuçlar elde eden AlexNet ve GoogleNet mimarileri üzerinde; farklı epoklarda, farklı LR ve MBS parametreleri ile detaylı deneyler yapılarak, her koşulda sonuçları en iyi artıran AlexNet mimarisi sonraki aşamalarda ele alınmıştır.

Mimarinin optimize parametrelerle elde ettiği doğruluk oranı %95.83 tür. Ayrıca üçüncü çalışmada da, AlexNet mimarisinin yara görüntüleri üzerinde optimum sonuçların bulunmasında hangi parametrelerin etkili olduğu incelenmiştir. Parametre etkilerinin araştırıldığı deneylerde veri seti üzerinde, LR parametresi $1e-4$ değerinde iken iyi sonuçların elde edildiği tespit edilmiştir. Sadece LR parametresi ile sonuçların ayırt edici bir şekilde gruplanabildiği tespit edilmiş olup diğer parametrelerle ilgili genel bir kaniya varılamamıştır.

Son olarak Evrişim, Havuzlama, Doğrultulmuş Lineer Aktivasyon (Rectified Linear Activation (ReLU)) katmanlarının farklı sayıda uygulanması ile oluşturulan AlexNet mimari varyasyonları kullanılarak (3Conv_Softmax, 3Conv_SVM, 4Conv_Softmax, 4Conv_SVM, 6Conv_Softmax, 6Conv_SVM) basınç ve diyabetik yara görüntülerinin yüksek düzeyde bir doğrulukla sınıflandırılabilmesine odaklanılmıştır. Önerilen modellerde, AlexNet mimarisinin sınıflandırma katmanında Softmax sınıflandırıcısı ve Destek Vektör Makinesi (SVM) sınıflandırıcısı da ayrı ayrı kullanılarak performansları incelenmiştir. Yapılan deneysel çalışmalar sonucunda, kendi oluşturduğumuz özgün yara görüntüleri veriseti için elde edilen sonuçlara göre %98.85 doğruluk değerine önerilen yöntemlerden 6 Evrişim katmanına sahip (6Conv_SVM) modeliyle ulaşılmıştır. Ayrıca önerilen yöntem literatürde açık kaynak Medetec veriseti üzerinde de test edilerek %95.33 doğruluk değeri elde edilmiştir. Önerilen yöntem, literatürdeki benzer çalışmalarla da birlikte değerlendirildiğinde, kullanılan tüm ölçüm metriklerinde en başarılı sonuçları elde etmiştir.

6.2 Öneriler

Derin öğrenme son yıllarda araştırmacılar tarafından oldukça popüler bir çalışma alanıdır. Tüm dünya problemlerine hızlı ve kabul edilir çözümler sunabilen ESA'ların, yapısıyla, katmanlarıyla, öğrenme parametreleriyle, eğitim süreçleriyle kapsamlı bir şekilde ele alınması oldukça önemlidir. Segmentasyon ve sınıflandırma problemlerinde uygun ESA mimarilerini tasarlamak, çeşitli veri setleri üzerinde deneysel çalışmalar yapmak ve bu mimarilerin birbirinden bağımsız ne tür verilerde ortak karar verebileceğini araştırmak gelecek çalışmalar için bir ilham kaynağı oluşturabilir.

Gelecekteki çalışmalarda yara bölgesinin segmentasyonu bir otomasyon sistemi yardımıyla takip edilerek yaradaki iyileşmeye göre uygulanan tedavi yöntemlerinin avantaj/dezavantajları yorumlanabilir. Hastane ortamında kurulan görüntüleme donanım

alt yapısı ile elde edilen veriler çalışmada ele alınan yöntemlerle işlenerek yara takibi otomasyonu oluşturulabilir. Segmente edilen yara bölgesinde derin öğrenme yöntemleriyle yapılan görüntü yorumlama ile klinik olarak iyileşmeler takip edilebilir ve incelenebilir. Bu sayede hastane dışındaki klinik ortamlarda kronik yaraların tıbbi tedavisi için önemli ölçüde bir takip ve izleme olanağına sahip olunacaktır. Gelecek çalışmalarda farklı katmanlarla tasarlanan ESA mimarilerinin segmentasyon başarımını artırıcı yönleri irdelenebilir. Ayrıca, bu tür analizlerin ilerleyen çalışmalarda hastalar üzerinde iyileşme etkinliğinin hesaplanarak mevcut yara bakım ürünlerin etkinliğinin değerlendirilmesi gözlemlenebilir.

İlerleyen çalışmalarda parametre optimizasyonunun yanı sıra, veri setinde başarı gösteren mimarilerde iyileştirmeler yapılarak daha performanslı sınıflandırma başarısı elde edilmesi amaçlanmalıdır. Ayrıca farklı tür yara görüntüleri üzerinde de ortaya konan derin öğrenme yöntemlerinin uygulanabilirliği araştırılabilir. Farklı ESA mimarileri de, farklı tür yara görüntüleri üzerindeki sınıflandırma başarılarının incelenmesi amacıyla ele alınabilir. Ele alınacak yeni yöntemler üzerinde optimum parametre belirleme deneyleri yapılabilir.

Yara görüntülerinin tanımlanmasında, en popüler (state-of-the-art) modellerde yapılan parametre optimizasyon deneylerinde öne çıkan AlexNet mimarisi, yara görüntülerinin özelliklerini yüksek doğrulukta çıkarması nedeniyle, bu alanda gelecekteki çalışmalarda kullanılabilir. Ayrıca gelecek çalışmalarda performansları AlexNet mimarisine yakın olan diğer yöntemler üzerinde modifikasyonlar ya da iyileştirmeler yapılarak performans artırımını hedeflenebilir.

KAYNAKLAR

- Ahn, E., Kumar, A., Feng, D., Fulham, M. ve Kim, J., 2019, Unsupervised deep transfer feature learning for medical image classification, *2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)*, 1915-1918.
- Alamri, N. M. H., Packianather, M. ve Bigot, S., 2022, Deep learning: parameter optimization using proposed novel hybrid bees Bayesian convolutional neural network, *Applied Artificial Intelligence*, 1-26.
- Alderden, J., Rondinelli, J., Pepper, G., Cummins, M. ve Whitney, J., 2017, Risk factors for pressure injuries among critical care patients: A systematic review, *International journal of nursing studies*, 71, 97-114.
- Alebiosu, D. O. ve Muhammad, F. P., 2019, Medical Image Classification: A Comparison of Deep Pre-trained Neural Networks, *2019 IEEE Student Conference on Research and Development (SCOReD)*, 306-310.
- Alipoor, E., Mehrdadi, P., Yaseri, M. ve Hosseinzadeh-Attar, M. J., 2021, Association of overweight and obesity with the prevalence and incidence of pressure ulcers: A systematic review and meta-analysis, *Clinical Nutrition*, 40 (9), 5089-5098.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Van Esesn, B. C., Awwal, A. A. S. ve Asari, V. K., 2018, The history began from alexnet: A comprehensive survey on deep learning approaches, *arXiv preprint arXiv:1803.01164*.
- Altındağ, E., 2022, X-ray Görüntülerinde Derin Öğrenme Yöntemleri ile Tehdit Tespiti.
- Alzubaidi, L., Fadhel, M. A., Al-Shamma, O., Zhang, J., Santamaría, J., Duan, Y. ve R. Oleiwi, S., 2020a, Towards a better understanding of transfer learning for medical imaging: a case study, *Applied Sciences*, 10 (13), 4523.
- Alzubaidi, L., Fadhel, M. A., Oleiwi, S. R., Al-Shamma, O. ve Zhang, J., 2020b, DFU_QUTNet: diabetic foot ulcer classification using novel deep convolutional neural network, *Multimedia Tools and Applications*, 79 (21), 15655-15677.
- Alzubaidi, L., Al-Amidie, M., Al-Asadi, A., Humaidi, A. J., Al-Shamma, O., Fadhel, M. A., Zhang, J., Santamaría, J. ve Duan, Y., 2021a, Novel transfer learning approach for medical imaging with limited labeled data, *Cancers*, 13 (7), 1590.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M. ve Farhan, L., 2021b, Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions, *Journal of Big Data*, 8 (1), 1-74.
- Alzubaidi, L., Fadhel, M. A., Al-Shamma, O., Zhang, J., Santamaría, J. ve Duan, Y., 2022, Robust application of new deep learning tools: an experimental study in medical imaging, *Multimedia Tools and Applications*, 81 (10), 13289-13317.
- Andrearczyk, V. ve Whelan, P. F., 2017, Deep Learning in Texture Analysis and Its Application to Tissue Image Classification, In: *Biomedical Texture Analysis*, Eds, p. 95-129.
- Anisuzzaman, D., Wang, C., Rostami, B., Gopalakrishnan, S., Niezgoda, J. ve Yu, Z., 2020, Image Based Artificial Intelligence in Wound Assessment: A Systematic Review, *arXiv preprint arXiv:2009.07141*.
- Aslan, M., 2021, Derin Öğrenme ile Şeftali Hastalıklarının Tespiti, *Avrupa Bilim ve Teknoloji Dergisi* (23), 540-546.
- Azevedo-Marques, P. M., Pereira, S. M., Frade, M. A. ve Rangayyan, R. M., 2013, Segmentation of dermatological ulcers using clustering of color components, *2013 26th IEEE Canadian conference on electrical and computer engineering (CCECE)*, 1-4.

- Azizi, S., Mustafa, B., Ryan, F., Beaver, Z., Freyberg, J., Deaton, J., Loh, A., Karthikesalingam, A., Kornblith, S. ve Chen, T., 2021, Big self-supervised models advance medical image classification, *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 3478-3488.
- Badrinarayanan, V., Kendall, A. ve Cipolla, R., 2017, Segnet: A deep convolutional encoder-decoder architecture for image segmentation, *IEEE transactions on pattern analysis and machine intelligence*, 39 (12), 2481-2495.
- Bauer, K., Rock, K., Nazzal, M., Jones, O. ve Qu, W., 2016, Pressure Ulcers in the United States' Inpatient Population From 2008 to 2012: Results of a Retrospective Nationwide Study, *Ostomy/wound management*, 62 (11), 30-38.
- Bhandary, A., Prabhu, G. A., Rajinikanth, V., Thanaraj, K. P., Satapathy, S. C., Robbins, D. E., Shasky, C., Zhang, Y.-D., Tavares, J. M. R. ve Raja, N. S. M., 2020, Deep-learning framework to detect lung abnormality—A study with chest X-Ray and lung CT scan images, *Pattern Recognition Letters*, 129, 271-278.
- Bose, S., Chowdhury, R. S., Das, R. ve Maulik, U., 2022, Dense Dilated Deep Multiscale Supervised U-Net for biomedical image segmentation, *Computers in Biology and Medicine*, 143, 105274.
- Boudiaf, A., Benlahmidi, S., Harrar, K. ve Zaghdoudi, R., 2022, Classification of surface defects on steel strip images using convolution neural network and support vector machine, *Journal of Failure Analysis and Prevention*, 22 (2), 531-541.
- Boudouh, S. S. ve Bouakkaz, M., 2022, Breast Cancer: Using Deep Transfer Learning Techniques AlexNet Convolutional Neural Network For Breast Tumor Detection in Mammography Images, *2022 7th International Conference on Image and Signal Processing and their Applications (ISPA)*, 1-7.
- Bozkurt, F., 2021, Derin Öğrenme Tekniklerini Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti, *Avrupa Bilim ve Teknoloji Dergisi* (24), 149-156.
- Bozkurt, F. ve Yağanoğlu, M., 2021, Derin evrişimli sinir ağları kullanarak akciğer X-Ray görüntülerinden COVID-19 tespiti, *Veri Bilimi*, 4 (2), 1-8.
- Bulut, E., 2019, İç Hastalıkları Yoğun Bakım Kliniklerinde Yatan Yaşlı Hastalarda Basınç Yarası Gelişimini Etkileyen Faktörler, Sıklığı ve Arayüz Basıncının Yordayıcı Değeri, Yüksek Lisans, *Aydın Adnan Menderes Üniversitesi, Aydın Adnan Menderes Üniversitesi Sağlık Bilimleri Enstitüsü*.
- Canatalay, P. C., 2022, Derin öğrenme yöntemleri kullanılarak meme kanseri teşhisi.
- Canbay, Y., İsmetoğlu, A. ve Canbay, P., 2021, COVID-19 HASTALIĞININ TEŞHİSİNDE DERİN ÖĞRENME VE VERİ MAHREMİYETİ, *Mühendislik Bilimleri ve Tasarım Dergisi*, 9 (2), 701-715.
- Cao, C., Liu, F., Tan, H., Song, D., Shu, W., Li, W., Zhou, Y., Bo, X. ve Xie, Z., 2018, Deep Learning and Its Applications in Biomedicine, *Genomics Proteomics Bioinformatics*, 16 (1), 17-32.
- Chakraborty, C., Gupta, B., Ghosh, S. K., Das, D. K. ve Chakraborty, C., 2016, Telemedicine Supported Chronic Wound Tissue Prediction Using Classification Approaches, *J Med Syst*, 40 (3), 68.
- Chakraborty, C., 2019, Computational approach for chronic wound tissue characterization, *Informatics in Medicine Unlocked*.
- Chang, C. W., Christian, M., Chang, D. H., Lai, F., Liu, T. J., Chen, Y. S. ve Chen, W. J., 2022, Deep learning approach based on superpixel segmentation assisted labeling for automatic pressure ulcer diagnosis, *PloS one*, 17 (2), e0264139.

- Chen, H.-C., Widodo, A. M., Wisnujati, A., Rahaman, M., Lin, J. C.-W., Chen, L. ve Weng, C.-E., 2022a, AlexNet convolutional neural network for disease detection and classification of tomato leaf, *Electronics*, 11 (6), 951.
- Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K. ve Yuille, A. L., 2017, Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs, *IEEE transactions on pattern analysis and machine intelligence*, 40 (4), 834-848.
- Chen, X., Wang, X., Zhang, K., Fung, K.-M., Thai, T. C., Moore, K., Mannel, R. S., Liu, H., Zheng, B. ve Qiu, Y., 2022b, Recent advances and clinical applications of deep learning in medical image analysis, *Medical Image Analysis*, 102444.
- Chen, Z. ve Ho, P.-H., 2019, Global-connected network with generalized ReLU activation, *Pattern Recognition*, 96, 106961.
- Cheng, D., Liao, R., Fidler, S. ve Urtasun, R., 2019, Darnet: Deep active ray network for building segmentation, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 7431-7439.
- Chollet, F., 2017, Xception: Deep learning with depthwise separable convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-1258.
- Cicero, M., Bilbily, A., Colak, E., Dowdell, T., Gray, B., Perampaladas, K. ve Barfett, J., 2017, Training and validating a deep convolutional neural network for computer-aided detection and classification of abnormalities on frontal chest radiographs, *Investigative radiology*, 52 (5), 281-287.
- Çalışkan, D. ve Demir, Ö., 2022, Derin Öğrenme Yöntemleri ile Şüpheli Davranış Tespiti, *International Periodical Of Recent Technologies In Applied Engineering*, 3 (1), 26-41.
- Dalianis, H. ve Dalianis, H., 2018, Evaluation metrics and evaluation, *Clinical text mining: secondary use of electronic patient records*, 45-53.
- Das, S. K., Roy, P. ve Mishra, A. K., 2021, DFU_SPNet: A stacked parallel convolution layers based CNN to improve Diabetic Foot Ulcer classification, *ICT Express*.
- Demir, F. B. ve Yılmaz, E., 2022, X-Ray Görüntülerinden COVID-19 Tespiti için Derin Öğrenme Temelli Bir Yaklaşım, *Avrupa Bilim ve Teknoloji Dergisi* (32), 627-632.
- Dong, X., Niu, J., Cui, J., Fu, Z. ve Ouyang, Z., 2020, Fast Segmentation-Based Object Tracking Model for Autonomous Vehicles, *International Conference on Algorithms and Architectures for Parallel Processing*, 259-273.
- Dorileo, É. A., Frade, M. A., Rangayyan, R. M. ve Azevedo-Marques, P. M., 2010, Segmentation and analysis of the tissue composition of dermatological ulcers, *CCECE 2010*, 1-4.
- Eker, A. G. ve Nevcihan, D., 2021, Medikal görüntü işlemede derin öğrenme uygulamaları, *Acta Infologica*, 5 (2), 459-474.
- El-Shazli, A. M. A., Youssef, S. M. ve Soliman, A. H., 2022, Intelligent Computer-Aided Model for Efficient Diagnosis of Digital Breast Tomosynthesis 3D Imaging Using Deep Learning, *Applied Sciences*, 12 (11), 5736.
- Eldem, H., Ülker, E. ve Işıklı, O. Y., 2022, Classification of Pressure and Diabetic Chronic Wound Tissue Images with Deep Learning Methods (Hakem Değerlendirmesinde).
- Eldem, H., Ülker, E. ve Işıklı, O. Y., 2023a, Alexnet architecture variations with transfer learning for classification of wound images (Hakem Değerlendirmesinde).
- Eldem, H., Ülker, E. ve Işıklı, O. Y., 2023b, Effects of training parameters of AlexNet architecture on wound image classification, *Traitement du Signal*, 811-817.

- Eldem, H., Ülker, E. ve Yaşar Işıklı, O., 2023c, Encoder–decoder semantic segmentation models for pressure wound images, *The Imaging Science Journal*, 1-12.
- Elmogly, M., Garcia-Zapirain, B., Burns, C., Elmaghraby, A. ve Ei-Baz, A., 2018, Tissues Classification for Pressure Ulcer Images Based on 3D Convolutional Neural Network. 2018 25th IEEE International Conference on Image Processing (ICIP): 3139-3143.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. ve Thrun, S. J. N., 2017, Dermatologist-level classification of skin cancer with deep neural networks, 542 (7639), 115.
- Fauzi, M. F. A., Khansa, I., Catignani, K., Gordillo, G., Sen, C. K., Gurcan, M. N. J. C. i. B. ve Medicine, 2015, Computerized segmentation and measurement of chronic wound images, 60, 74-85.
- Fawcett, T., 2006, An introduction to ROC analysis, *Pattern recognition letters*, 27 (8), 861-874.
- Frykberg, R. G. ve Banks, J., 2015, Challenges in the treatment of chronic wounds, *Advances in wound care*, 4 (9), 560-582.
- Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V. ve Garcia-Rodriguez, J., 2017, A review on deep learning techniques applied to semantic segmentation, *arXiv preprint arXiv:1704.06857*.
- Garcia-Zapirain, B., Shalaby, A., El-Baz, A. ve Elmaghraby, A., 2017, Automated framework for accurate segmentation of pressure ulcer images, *Computers in biology and medicine*, 90, 137-145.
- García-Zapirain, B., Elmogly, M., El-Baz, A., Elmaghraby, A. S. J. M., Engineering, B. ve Computing, 2018, Classification of pressure ulcer tissues with 3D convolutional neural network, 56 (12), 2245-2258.
- Gefen, A., 2022, Alternatives and preferences for materials in use for pressure ulcer prevention: An experiment-reinforced literature review, *International Wound Journal*.
- Ghosh, S., Das, N., Das, I. ve Maulik, U., 2019, Understanding deep learning techniques for image segmentation, *ACM Computing Surveys (CSUR)*, 52 (4), 1-35.
- Ghulnavar, R., Dama, K. K. ve Jagadeesh, A., 2020, Diagnosis of faulty gears by modified AlexNet and improved grasshopper optimization algorithm (IGOA), *Journal of Mechanical Science and Technology*, 34, 4173-4182.
- Goodfellow, I., Bengio, Y. ve Courville, A., 2016, Deep learning, MIT press, p.
- Goyal, M., Yap, M. H., Reeves, N. D., Rajbhandari, S. ve Spragg, J., 2017, Fully convolutional networks for diabetic foot ulcer segmentation, *2017 IEEE international conference on systems, man, and cybernetics (SMC)*, 618-623.
- Goyal, M., Reeves, N. D., Davison, A. K., Rajbhandari, S., Spragg, J. ve Yap, M. H., 2018, Dfunet: Convolutional neural networks for diabetic foot ulcer classification, *IEEE Transactions on Emerging Topics in Computational Intelligence*, 4 (5), 728-739.
- Goyal, M., Reeves, N. D., Rajbhandari, S., Ahmad, N., Wang, C. ve Yap, M. H., 2020, Recognition of ischaemia and infection in diabetic foot ulcers: Dataset and techniques, *Computers in Biology and Medicine*, 117, 103616.
- Guadagnin, R., Neves, R. d. S., Santana, L., Guilhem, D. J. P. r. ve analysis, i., 2014, An image mining based approach to detect pressure ulcer stage, 24 (2), 292-296.
- Gundewar, S. K. ve Kane, P. V., 2021, Bearing Fault Diagnosis in Induction Motor Using Modified AlexNet Algorithm, *Advances in Industrial Machines and Mechanisms: Select Proceedings of IPROMM 2020*, 205-218.

- Gutman, D., Codella, N. C., Celebi, E., Helba, B., Marchetti, M., Mishra, N. ve Halpern, A. J. a. p. a., 2016, Skin lesion analysis toward melanoma detection: A challenge at the international symposium on biomedical imaging (ISBI) 2016, hosted by the international skin imaging collaboration (ISIC).
- Haesler, E., 2014, Prevention and treatment of pressure ulcers: clinical practice guideline, Cambridge media, p.
- Haji, S. H. ve Abdulazeez, A. M., 2021, Comparison of optimization techniques based on gradient descent algorithm: A review, *PalArch's Journal of Archaeology of Egypt/Egyptology*, 18 (4), 2715-2743.
- Handelman, G. S., Kok, H. K., Chandra, R. V., Razavi, A. H., Huang, S., Brooks, M., Lee, M. J. ve Asadi, H., 2019, Peering into the black box of artificial intelligence: evaluation metrics of machine learning methods, *American Journal of Roentgenology*, 212 (1), 38-43.
- Hani, A. F. M., Arshad, L., Malik, A. S., Jamil, A. ve Bin, F. Y. B., 2012, Haemoglobin distribution in ulcers for healing assessment, *2012 4th International Conference on Intelligent and Advanced Systems (ICIAS2012)*, 362-367.
- Hao, S., Zhou, Y. ve Guo, Y., 2020, A brief survey on semantic segmentation with deep learning, *Neurocomputing*, 406, 302-321.
- Havaei, M., Davy, A., Warde-Farley, D., Biard, A., Courville, A., Bengio, Y., Pal, C., Jodoin, P.-M. ve Larochelle, H., 2017, Brain tumor segmentation with deep neural networks, *Medical image analysis*, 35, 18-31.
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Hesamian, M. H., Jia, W., He, X. ve Kennedy, P., 2019, Deep learning techniques for medical image segmentation: achievements and challenges, *Journal of digital imaging*, 32 (4), 582-596.
- Hettiarachchi, N., Mahindaratne, R., Mendis, G., Nanayakkara, H. ve Nanayakkara, N. D., 2013, Mobile based wound measurement, *2013 IEEE Point-of-Care Healthcare Technologies (PHT)*, 298-301.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. ve Adam, H., 2017, Mobilenets: Efficient convolutional neural networks for mobile vision applications, *arXiv preprint arXiv:1704.04861*.
- Hu, Z., Zhang, J. ve Ge, Y., 2021, Handling vanishing gradient problem using artificial derivative, *IEEE Access*, 9, 22371-22377.
- Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K. Q., 2017, Densely connected convolutional networks, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708.
- Hultin, L., Gunningberg, L., Coleman, S. ve Karlsson, A. C., 2022, Pressure ulcer risk assessment—registered nurses' experiences of using PURPOSE T: A focus group study, *Journal of clinical nursing*, 31 (1-2), 231-239.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J. ve Keutzer, K., 2016, SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size, *arXiv preprint arXiv:1602.07360*.
- Im, D. J., Tao, M. ve Branson, K., 2016, An empirical analysis of the optimization of deep network loss surfaces, *arXiv preprint arXiv:1612.04010*.
- Jimenez-del-Toro, O., Otálora, S., Andersson, M., Eurén, K., Hedlund, M., Rousson, M., Müller, H. ve Atzori, M., 2017, Analysis of histopathology images: From traditional machine learning to deep learning, In: *Biomedical Texture Analysis*, Eds: Elsevier, p. 281-314.

- Jing, J., Dong, A., Li, P. ve Zhang, K., 2017, Yarn-dyed fabric defect classification based on convolutional neural network, *Optical Engineering*, 56 (9), 093104-093104.
- Jodheea-Jutton, A., Hindocha, S. ve Bhaw-Luximon, A., 2022, Health economics of diabetic foot ulcer and recent trends to accelerate treatment, *The Foot*, 101909.
- Kamnitsas, K., Ledig, C., Newcombe, V. F., Simpson, J. P., Kane, A. D., Menon, D. K., Rueckert, D. ve Glocker, B., 2017, Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation, *Medical image analysis*, 36, 61-78.
- Kanimozhi, V., Balasubramani, M. ve Anuradha, R., 2021a, Hierarchical Bayes model with AlexNet for characterization of M-FISH chromosome images, *Medical & Biological Engineering & Computing*, 59 (7), 1529-1544.
- Kanimozhi, V., Balasubramani, M. ve Anuradha, R., 2021b, Hierarchical Bayes model with AlexNet for characterization of M-FISH chromosome images, *Medical & Biological Engineering & Computing*, 59 (7-8), 1529-1544.
- Karakurt, M. ve İşeri, İ., 2022, Patoloji Görüntülerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması, *Avrupa Bilim ve Teknoloji Dergisi* (33), 192-206.
- Kaur, M., Kumar, V., Yadav, V., Singh, D., Kumar, N. ve Das, N. N., 2021, Metaheuristic-based deep COVID-19 screening model from chest X-ray images, *Journal of Healthcare Engineering*, 2021.
- Kawahara, J. ve Hamarneh, G., 2016, Multi-resolution-tract CNN with hybrid pretrained and skin-lesion trained layers, *International Workshop on Machine Learning in Medical Imaging*, 164-171.
- Khan, S., Islam, N., Jan, Z., Din, I. U. ve Rodrigues, J. J. C., 2019, A novel deep learning based framework for the detection and classification of breast cancer using transfer learning, *Pattern Recognition Letters*, 125, 1-6.
- Kim, H. E., Cosa-Linan, A., Santhanam, N., Jannesari, M., Maros, M. E. ve Ganslandt, T., 2022a, Transfer learning for medical image classification: a literature review, *BMC medical imaging*, 22 (1), 1-13.
- Kim, J., Lee, J. Y. ve Lee, E., 2022b, Risk factors for newly acquired pressure ulcer and the impact of nurse staffing on pressure ulcer incidence, *Journal of nursing management*, 30 (5), O1-O9.
- Kingma, D. P. ve Ba, J., 2014, Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*.
- Kolesnik, M. ve Fexa, A., 2004a, Segmentation of wounds in the combined color-texture feature space, *Medical imaging 2004: Image processing*, 549-556.
- Kolesnik, M. ve Fexa, A., 2004b, Segmentation of wounds in the combined color-texture feature space, *Medical imaging 2004: Image processing*, 549-557.
- Kolesnik, M. ve Fexa, A., 2005, Multi-dimensional color histograms for segmentation of wounds in images, *International Conference Image Analysis and Recognition*, 1014-1022.
- Kolesnik, M. ve Fexa, A., 2006, How robust is the SVM wound segmentation?, *Proceedings of the 7th Nordic Signal Processing Symposium-NORSIG 2006*, 50-53.
- Kora, P., Ooi, C. P., Faust, O., Raghavendra, U., Gudigar, A., Chan, W. Y., Meenakshi, K., Swaraja, K., Plawiak, P. ve Acharya, U. R., 2021, Transfer learning techniques for medical image analysis: A review, *Biocybernetics and Biomedical Engineering*.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25.

- Kumar, A., Kim, J., Lyndon, D., Fulham, M. ve Feng, D., 2016, An ensemble of fine-tuned convolutional neural networks for medical image classification, *IEEE journal of biomedical and health informatics*, 21 (1), 31-40.
- Lee, K.-S., Ryu, J.-J., Jang, H. S., Lee, D.-Y. ve Jung, S.-K., 2020, Deep convolutional neural networks based analysis of cephalometric radiographs for differential diagnosis of orthognathic surgery indications, *Applied Sciences*, 10 (6), 2124.
- Lei, T., Wang, R., Wan, Y., Du, X., Meng, H. ve Nandi, A. K., 2020, Medical Image Segmentation Using Deep Learning: A Survey, *arXiv preprint arXiv:2009.13120*.
- Li, F., Wang, C., Liu, X., Peng, Y. ve Jin, S., 2018, A composite model of wound segmentation based on traditional methods and deep neural networks, *Computational intelligence and neuroscience*, 2018.
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D. ve Chen, M., 2014, Medical image classification with convolutional neural network, *2014 13th international conference on control automation robotics & vision (ICARCV)*, 844-848.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J., van Ginneken, B. ve Sanchez, C. I., 2017a, A survey on deep learning in medical image analysis, *Med Image Anal*, 42, 60-88.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van Der Laak, J. A., Van Ginneken, B. ve Sánchez, C. I., 2017b, A survey on deep learning in medical image analysis, *Medical image analysis*, 42, 60-88.
- Liu, X., Wang, C., Li, F., Zhao, X., Zhu, E. ve Peng, Y., 2017, A framework of wound segmentation based on deep convolutional networks, *2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, 1-7.
- Long, J., Shelhamer, E. ve Darrell, T., 2015, Fully convolutional networks for semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 3431-3440.
- Lu, S., Lu, Z. ve Zhang, Y.-D., 2019, Pathological brain detection based on AlexNet and transfer learning, *Journal of computational science*, 30, 41-47.
- Mankar, N. B. ve Nagdeve, U. J. I., 2013, Comparison of different imaging techniques used for chronic wounds, 2 (7), 68-70.
- Masters, D. ve Luschi, C., 2018, Revisiting small batch training for deep neural networks, *arXiv preprint arXiv:1804.07612*.
- Menteşe, E. ve Hançer, E., 2020, Histopatoloji görüntülerde derin öğrenme yöntemleri ile çekirdek segmentasyonu, *Avrupa Bilim ve Teknoloji Dergisi*, 95-102.
- Mervis, J. S. ve Phillips, T. J., 2019, Pressure ulcers: Pathophysiology, epidemiology, risk factors, and presentation, *Journal of the American Academy of Dermatology*, 81 (4), 881-890.
- Mesa, H., Veredas, F. J. ve Morente, L., 2008, A Hybrid Approach for Tissue Recognition on Wound Images. 2008 Eighth International Conference on Hybrid Intelligent Systems: 120-125.
- Mikołajczyk, A. ve Grochowski, M., 2018, Data augmentation for improving deep learning in image classification problem, *2018 international interdisciplinary PhD workshop (IIPhDW)*, 117-122.
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N. ve Terzopoulos, D., 2020, Image segmentation using deep learning: A survey, *arXiv preprint arXiv:2001.05566*.
- Morrison, A., Madden, C. ve Messmer, J., 2022, Management of chronic wounds, *Primary Care: Clinics in Office Practice*, 49 (1), 85-98.

- Mukherjee, R., Manohar, D. D., Das, D. K., Achar, A., Mitra, A. ve Chakraborty, C., 2014, Automated tissue classification framework for reproducible chronic wound assessment, *Biomed Res Int*, 2014, 851582.
- Muthiah, M., Logashanmugam, E., Nandhitha, N. ve Hariteja, D., 2020a, Performance evaluation of conventional CNN architectures and modified ALEXNET for the classification of potatoes by thermal imaging, *Russian Journal of Nondestructive Testing*, 56 (9), 718-726.
- Muthiah, M., Logashanmugam, E., Nandhitha, N., Kumar, C. K. ve Hariteja, D., 2020b, Performance evaluation of conventional CNN architectures and modified ALEXNET for the classification of potatoes by thermal imaging, *Russian Journal of Nondestructive Testing*, 56, 718-726.
- Niri, R., Gutierrez, E., Douzi, H., Lucas, Y., Treuillet, S., Castañeda, B. ve Hernandez, I., 2021, Multi-View Data Augmentation to Improve Wound Segmentation on 3D Surface Model by Deep Learning, *IEEE Access*, 9, 157628-157638.
- O'Mahony, N., Campbell, S., Carvalho, A., Harapanahalli, S., Hernandez, G. V., Krpalkova, L., Riordan, D. ve Walsh, J., 2019, Deep learning vs. traditional computer vision, *Science and Information Conference*, 128-144.
- Ogurtsova, K., Guariguata, L., Barengo, N. C., Ruiz, P. L.-D., Sacre, J. W., Karuranga, S., Sun, H., Boyko, E. J. ve Magliano, D. J., 2022, IDF diabetes Atlas: Global estimates of undiagnosed diabetes in adults for 2021, *Diabetes research and clinical practice*, 183, 109118.
- Ohura, N., Mitsuno, R., Sakisaka, M., Terabe, Y., Morishige, Y., Uchiyama, A., Okoshi, T., Shinji, I. ve Takushima, A., 2019, Convolutional neural networks for wound detection: the role of artificial intelligence in wound care, *Journal of wound care*, 28 (Sup10), S13-S24.
- Omonigho, E. L., David, M., Adejo, A. ve Aliyu, S., 2020, Breast cancer: tumor detection in mammogram images using modified alexnet deep convolution neural network, *2020 International Conference in Mathematics, Computer Engineering and Computer Science (ICMCECS)*, 1-6.
- Ong, E. P., Yin, C. T. K. ve Lee, B.-H., 2020, Efficient Deep Learning-based Wound-bed Segmentation For Mobile Applications, *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 1654-1657.
- Ortiz, D. P., Sierra-Sosa, D. ve Zapirain, B. G. J. B. e. o., 2017, Pressure ulcer image segmentation technique through synthetic frequencies generation and contrast variation using toroidal geometry, 16 (1), 4.
- Özkan, İ. ve Ülker, E., 2017, Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.
- Pandya, M. D., Shah, P. D. ve Jardosh, S., 2019, Medical image diagnosis for disease detection: A deep learning approach, In: *U-Healthcare Monitoring Systems*, Eds: Elsevier, p. 37-60.
- Panel, N. P. U. A., 2009, Prevention and treatment of pressure ulcers: clinical practice guideline, Cambridge Media, p.
- Pang, S., Yu, Z. ve Orgun, M. A., 2017, A novel end-to-end classifier using domain transferred deep convolutional neural networks for biomedical images, *Computer methods and programs in biomedicine*, 140, 283-293.
- Parisod, H., Holopainen, A., Kiello-Viljamaa, E., Puukka, P., Beeckman, D. ve Haavisto, E., 2022, Attitudes of nursing staff towards pressure ulcer prevention in primary and specialised health care: A correlational cross-sectional study, *International Wound Journal*, 19 (2), 399-410.

- Perez, A. A., Gonzaga, A. ve Alves, J. M., 2001, Segmentation and analysis of leg ulcers color images, *Proceedings International Workshop on Medical Imaging and Augmented Reality*, 262-266.
- Perez, L. ve Wang, J., 2017, The effectiveness of data augmentation in image classification using deep learning, *arXiv preprint arXiv:1712.04621*.
- Pieper, B., 2012, Pressure ulcers: impact, etiology, and classification, *Acute and Chronic Wounds: Current Management Concepts. 4th ed. St Louis, MO: Mosby*, 123-135.
- Powers, J. G., Higham, C., Broussard, K. ve Phillips, T. J., 2016, Wound healing and treating wounds: Chronic wound care and management, *Journal of the American Academy of Dermatology*, 74 (4), 607-625.
- Qureshi, I., Yan, J., Abbas, Q., Shaheed, K., Riaz, A. B., Wahid, A., Khan, M. W. J. ve Szczuko, P., 2022, Medical Image Segmentation Using Deep Semantic-based Methods: A Review of Techniques, Applications and Emerging Trends, *Information Fusion*.
- Rajkomar, A., Lingam, S., Taylor, A. G., Blum, M. ve Mongan, J., 2017, High-throughput classification of radiographs using deep convolutional neural networks, *Journal of digital imaging*, 30 (1), 95-101.
- Ramachandram, D., Ramirez-GarciaLuna, J. L., Fraser, R. D., Martínez-Jiménez, M. A., Arriaga-Caballero, J. E. ve Allport, J., 2022, Fully Automated Wound Tissue Segmentation Using Deep Learning on Mobile Devices: Cohort Study, *JMIR mHealth and uHealth*, 10 (4), e36977.
- Redmon, J. ve Farhadi, A., 2017, YOLO9000: better, faster, stronger, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 7263-7271.
- Redmon, J. ve Farhadi, A., 2018, Yolov3: An incremental improvement, *arXiv preprint arXiv:1804.02767*.
- Resul, D., Polat, B. ve Tuna, G., 2019, Derin öğrenme ile resim ve videolarda nesnelere tanınması ve takibi, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31 (2), 571-581.
- Ronneberger, O., Fischer, P. ve Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, *International Conference on Medical image computing and computer-assisted intervention*, 234-241.
- Rostami, B., Anisuzzaman, D., Wang, C., Gopalakrishnan, S., Niezgoda, J. ve Yu, Z., 2021, Multiclass Wound Image Classification using an Ensemble Deep CNN-based Classifier, *Computers in Biology and Medicine*, 104536.
- Salih, S. Q., Abdulla, H. K., Ahmed, Z. S., Surameery, N. M. S. ve Rashid, R. D., 2020, Modified alexnet convolution neural network for covid-19 detection using chest x-ray images, *Kurdistan Journal of Applied Research*, 119-130.
- Sameer, S., Niharika, B., Vasavi, S., Rohith, M. ve Abhishek, V., 2021, Pest and Disease Detection from Plant Leaves using Enhanced AlexNet Model, *2021 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*, 01-05.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. ve Chen, L.-C., 2018, Mobilenetv2: Inverted residuals and linear bottlenecks, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4510-4520.
- Scebba, G., Zhang, J., Catanzaro, S., Mihai, C., Distler, O., Berli, M. ve Karlen, W., 2022, Detect-and-segment: a deep learning approach to automate wound image segmentation, *Informatics in Medicine Unlocked*, 29, 100884.
- Sen, C. K., Gordillo, G. M., Roy, S., Kirsner, R., Lambert, L., Hunt, T. K., Gottrup, F., Gurtner, G. C. ve Longaker, M. T., 2009, Human skin wounds: a major and

- snowballing threat to public health and the economy, *Wound repair and regeneration*, 17 (6), 763-771.
- Sen, C. K., 2019, Human wounds and its burden: an updated compendium of estimates, Mary Ann Liebert, Inc., publishers 140 Huguenot Street, 3rd Floor New
- Seo, H., Badiei Khuzani, M., Vasudevan, V., Huang, C., Ren, H., Xiao, R., Jia, X. ve Xing, L., 2020, Machine learning techniques for biomedical image segmentation: An overview of technical aspects and introduction to state-of-art applications, *Medical physics*, 47 (5), e148-e167.
- Shanthi, T. ve Sabeenian, R., 2019, Modified Alexnet architecture for classification of diabetic retinopathy images, *Computers & Electrical Engineering*, 76, 56-64.
- Sheet, D., Karri, S. P. K., Katouzian, A., Navab, N., Ray, A. K. ve Chatterjee, J., 2015, Deep learning of tissue specific speckle representations in optical coherence tomography and deeper exploration for in situ histology, *Biomedical Imaging (ISBI), 2015 IEEE 12th International Symposium on*, 777-780.
- Shen, D., Wu, G. ve Suk, H.-I., 2017, Deep learning in medical image analysis, *Annual review of biomedical engineering*, 19, 221-248.
- Shenoy, V. N., Foster, E., Aalami, L., Majeed, B. ve Aalami, O., 2018, Deepwound: Automated postoperative wound assessment and surgical site surveillance through convolutional neural networks, *2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 1017-1021.
- Shi, J., Zheng, X., Li, Y., Zhang, Q. ve Ying, S., 2018, Multimodal neuroimaging feature learning with multimodal stacked deep polynomial networks for diagnosis of Alzheimer's disease, *IEEE journal of biomedical and health informatics*, 22 (1), 173-183.
- Shorten, C. ve Khoshgoftaar, T. M., 2019, A survey on image data augmentation for deep learning, *Journal of big data*, 6 (1), 1-48.
- Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*.
- Singh, S., Mittal, N., Thakur, D., Singh, H., Oliva, D. ve Demin, A., 2021, Nature and biologically inspired image segmentation techniques, *Archives of Computational Methods in Engineering*, 1-28.
- Song, B. ve Sacan, A., 2012, Automated wound identification system based on image segmentation and artificial neural networks, *2012 IEEE International Conference on bioinformatics and biomedicine*, 1-4.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R., 2014, Dropout: a simple way to prevent neural networks from overfitting, *The journal of machine learning research*, 15 (1), 1929-1958.
- Steve, T., 2021a, Medetec Wound Database, <http://www.medetec.co.uk/files/medetec-image-databases.html>: [2021].
- Steve, T., 2021b, Medetec Pressure Wound Dataset, <http://www.medetec.co.uk/slide-scans/pressure-ulcer-images-a/index.html>, <http://www.medetec.co.uk/slide-scans/pressure-ulcer-images-b/index.html>:
- Stojnic, R., Taylor, R., Kerkez, V. ve Viaud, L., Papers with code, state of the art models on the imagenet dataset, 2020.
- Suganyadevi, S., Seethalakshmi, V. ve Balasamy, K., 2022, A review on deep learning in medical image analysis, *International Journal of Multimedia Information Retrieval*, 11 (1), 19-38.
- Sullivan, N. ve Schoelles, K. M., 2013, Preventing in-facility pressure ulcers as a patient safety strategy: a systematic review, *Annals of internal medicine*, 158 (5_Part_2), 410-416.

- Sun, H., Saeedi, P., Karuranga, S., Pinkepank, M., Ogurtsova, K., Duncan, B. B., Stein, C., Basit, A., Chan, J. C. ve Mbanya, J. C., 2022a, IDF Diabetes Atlas: Global, regional and country-level diabetes prevalence estimates for 2021 and projections for 2045, *Diabetes research and clinical practice*, 183, 109119.
- Sun, Y., Ma, L., Ji, M. ve Wang, Z., 2022b, Evidence map of recommendations on diabetic foot ulcers care: A systematic review of 22 guidelines, *Journal of Tissue Viability*.
- Sundelius, C., 2018, Deep Fusion of Imaging Modalities for Semantic Segmentation of Satellite Imagery.
- Sunitha Nandhini, A., Manoj Aiyer, R., Pramoth Kumar, V. ve Rishi Nithin, E., 2022, Pancreases Segmentation and Classification Based on RCNN and AlexNet, *International Conference on Computing, Communication, Electrical and Biomedical Systems*, 457-466.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z., 2016, Rethinking the inception architecture for computer vision, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826.
- Szegedy, C., Ioffe, S., Vanhoucke, V. ve Alemi, A. A., 2017, Inception-v4, inception-resnet and the impact of residual connections on learning, *Thirty-first AAAI conference on artificial intelligence*.
- Şişmanoğlu, G., Koçer, F., ÖNDE, M. A. ve SAHİNGOZ, O. K., 2020, Derin öğrenme yöntemleri ile borsada fiyat tahmini, *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9 (1), 434-445.
- Tajbakhsh, N., Jeyaseelan, L., Li, Q., Chiang, J. N., Wu, Z. ve Ding, X., 2020, Embracing imperfect datasets: A review of deep learning solutions for medical image segmentation, *Medical image analysis*, 63, 101693.
- Tan, H. H. ve Lim, K. H., 2019, Vanishing gradient mitigation with deep learning neural network optimization, *2019 7th international conference on smart computing & communications (ICSCC)*, 1-4.
- Tan, M. ve Le, Q., 2019, Efficientnet: Rethinking model scaling for convolutional neural networks, *International conference on machine learning*, 6105-6114.
- Titoriya, A. ve Sachdeva, S., 2019, Breast cancer histopathology image classification using AlexNet, *2019 4th International Conference on Information Systems and Computer Networks (ISCON)*, 708-712.
- Toğaçar, M., Ergen, B. ve Sertkaya, M. E., 2019, Zatürre Hastalığının Derin Öğrenme Modeli ile Tespiti, *Firat University Journal of Engineering*, 31 (1).
- Toraman, S., 2018, Derin Öğrenme ile İnsansız Hava Aracı Görüntülerinden Yaya Tespiti, *Journal of Aviation*, 2 (2), 64-69.
- Tripathy, S. ve Singh, R., 2022, Convolutional Neural Network: An Overview and Application in Image Classification, *Proceedings of Third International Conference on Sustainable Computing*, 145-153.
- Tubaishat, A., Papanikolaou, P., Anthony, D. ve Habiballah, L., 2018, Pressure ulcers prevalence in the acute care setting: a systematic review, 2000-2015, *Clinical nursing research*, 27 (6), 643-659.
- Uyar, K., Taşdemir, Ş., Ülker, E., Öztürk, M. ve Kasap, H., 2021, Multi-Class brain normality and abnormality diagnosis using modified Faster R-CNN, *International journal of medical informatics*, 155, 104576.

- Vasconcelos, C. N. ve Vasconcelos, B. N., 2017a, Experiments using deep learning for dermoscopy image analysis, *Pattern Recognition Letters*.
- Vasconcelos, C. N. ve Vasconcelos, B. N. J. a. p. a., 2017b, Convolutional Neural Network Committees for Melanoma Classification with Classical And Expert Knowledge Based Image Transforms Data Augmentation.
- Veredas, F., Mesa, H. ve Morente, L., 2010, Binary tissue classification on wound images with neural networks and bayesian classifiers, *IEEE Trans Med Imaging*, 29 (2), 410-427.
- Veredas, F. J., Luque-Baena, R. M., Martín-Santos, F. J., Morilla-Herrera, J. C. ve Morente, L. J. N., 2015, Wound image evaluation with machine learning, 164, 112-122.
- Voulodimos, A., Doulamis, N., Doulamis, A. ve Protopapadakis, E., 2018, Deep learning for computer vision: A brief review, *Computational intelligence and neuroscience*, 2018.
- Wagle, S. A., 2021, Comparison of Plant Leaf Classification Using Modified AlexNet and Support Vector Machine, *Traitement du Signal*, 38 (1).
- Wang, C., Yan, X., Smith, M., Kochhar, K., Rubin, M., Warren, S. M., Wrobel, J. ve Lee, H., 2015a, A unified framework for automatic wound segmentation and analysis with deep convolutional neural networks, *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, 2415-2418.
- Wang, C., Yan, X., Smith, M., Kochhar, K., Rubin, M., Warren, S. M., Wrobel, J. ve Lee, H., 2015b, A unified framework for automatic wound segmentation and analysis with deep convolutional neural networks, *2015 37th annual international conference of the ieee engineering in medicine and biology society (EMBC)*, 2415-2418.
- Wang, G., Li, W., Ourselin, S. ve Vercauteren, T., 2017, Automatic brain tumor segmentation using cascaded anisotropic convolutional neural networks, *International MICCAI brainlesion workshop*, 178-190.
- Wang, L., Pedersen, P. C., Agu, E., Strong, D. M. ve Tulu, B., 2016, Area determination of diabetic foot ulcer images using a cascaded two-stage SVM-based classification, *IEEE Transactions on Biomedical Engineering*, 64 (9), 2098-2109.
- Wang, R., Lei, T., Cui, R., Zhang, B., Meng, H. ve Nandi, A. K., 2022, Medical image segmentation using deep learning: A survey, *IET Image Processing*, 16 (5), 1243-1267.
- Wang, W., Liang, D., Chen, Q., Iwamoto, Y., Han, X.-H., Zhang, Q., Hu, H., Lin, L. ve Chen, Y.-W., 2020, Medical image classification using deep learning, In: *Deep Learning in Healthcare*, Eds: Springer, p. 33-51.
- Wannous, H., Treuillet, S. ve Lucas, Y., 2007, Supervised tissue classification from color images for a complete wound assessment tool, *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 6031-6034.
- Wantanajittikul, K., Auephanwiriyakul, S., Theera-Umpon, N. ve Koanantakool, T., 2012, Automatic segmentation and degree identification in burn color images, *The 4th 2011 Biomedical Engineering International Conference*, 169-173.
- Wikipedia, 2019, Machine learning, https://en.wikipedia.org/wiki/Machine_learning: [Ziyaret Tarihi: 15 Mart 2019].
- Xie, D., Chatterjee, P., Liu, Z., Roy, K. ve Kossi, E., 2020, Deepfake detection on publicly available datasets using modified AlexNet, *2020 IEEE symposium series on computational intelligence (SSCI)*, 1866-1871.

- Xu, Y., Wang, Y. ve Razmjoo, N., 2022, Lung cancer diagnosis in CT images based on Alexnet optimized by modified Bowerbird optimization algorithm, *Biomedical Signal Processing and Control*, 77, 103791.
- Yadav, M. K., Manohar, D. D., Mukherjee, G. ve Chakraborty, C., 2013a, Segmentation of chronic wound areas by clustering techniques using selected color space, *Journal of Medical Imaging and Health Informatics*, 3 (1), 22-29.
- Yadav, M. K., Manohar, D. D., Mukherjee, G., Chakraborty, C. J. J. o. M. I. ve Informatics, H., 2013b, Segmentation of chronic wound areas by clustering techniques using selected color space, 3 (1), 22-29.
- Yang, S., Xiao, W., Zhang, M., Guo, S., Zhao, J. ve Shen, F., 2022, Image data augmentation for deep learning: A survey, *arXiv preprint arXiv:2204.08610*.
- Yeh, J.-F., Wang, S.-Y. ve Chen, Y.-P., 2021, Crop disease detection by image processing using modified Alexnet, *2021 IEEE 3rd Eurasia Conference on Biomedical Engineering, Healthcare and Sustainability (ECBIOS)*, 159-160.
- Yilmazer, T. ve Tuzer, H., 2022, The effect of a pressure ulcer prevention care bundle on nursing workload costs, *Journal of Tissue Viability*.
- Yu, X., Wang, J., Hong, Q.-Q., Teku, R., Wang, S.-H. ve Zhang, Y.-D., 2022, Transfer learning for medical images analyses: A survey, *Neurocomputing*, 489, 230-254.
- Zahia, S., Sierra-Sosa, D., Garcia-Zapirain, B. ve Elmaghraby, A., 2018a, Tissue classification and segmentation of pressure injuries using convolutional neural networks, *Comput Methods Programs Biomed*, 159, 51-58.
- Zahia, S., Sierra-Sosa, D., Garcia-Zapirain, B. ve Elmaghraby, A., 2018b, Tissue classification and segmentation of pressure injuries using convolutional neural networks, *Computer methods and programs in biomedicine*, 159, 51-58.
- Zahia, S., Garcia-Zapirain, B. ve Elmaghraby, A., 2020a, Integrating 3D model representation for an accurate non-invasive assessment of pressure injuries with deep learning, *Sensors*, 20 (10), 2933.
- Zahia, S., Zapirain, M. B. G., Sevillano, X., González, A., Kim, P. J. ve Elmaghraby, A., 2020b, Pressure injury image analysis with machine learning techniques: A systematic review on previous and possible future methods, *Artificial intelligence in medicine*, 102, 101742.
- Zhang, R., Tian, D., Xu, D., Qian, W. ve Yao, Y., 2022, A Survey of Wound Image Analysis Using Deep Learning: Classification, Detection, and Segmentation, *IEEE Access*, 10, 79502-79515.
- Zhang, X., Zhou, X., Lin, M. ve Sun, J., 2018, Shufflenet: An extremely efficient convolutional neural network for mobile devices, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 6848-6856.
- Zhang, X. ve Liu, C.-A., 2022, Model averaging prediction by K-fold cross-validation, *Journal of Econometrics*.
- Zhao, H., Shi, J., Qi, X., Wang, X. ve Jia, J., 2017, Pyramid scene parsing network, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2881-2890.
- Zhao, X., Liu, L., Qi, S., Teng, Y., Li, J. ve Qian, W., 2018, Agile convolutional neural network for pulmonary nodule classification using CT images, *International journal of computer assisted radiology and surgery*, 13 (4), 585-595.
- Zhu, Z., Zhuo, L., Qu, P., Zhou, K. ve Zhang, J., 2016, Extreme weather recognition using convolutional neural networks, *2016 IEEE International Symposium on Multimedia (ISM)*, 621-625.

- Zilly, J., Buhmann, J. M. ve Mahapatra, D., 2017, Glaucoma detection using entropy sampling and ensemble learning for automatic optic cup and disc segmentation, *Computerized Medical Imaging and Graphics*, 55, 28-41.
- Zoph, B., Vasudevan, V., Shlens, J. ve Le, Q. V., 2018, Learning transferable architectures for scalable image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 8697-8710.



EKLER**EK-1 Etik Kurulu Raporu**

	T.C. NECMETTİN ERBAKAN ÜNİVERSİTESİ Meram Tıp Fakültesi Dekanlığı	
Sayı : 14567952-050/1760		Tarih : 11 Aralık 2019
Konu :		
Sayın		
Opr. Dr. Osman Yaşar IŞIKLI		
Karaman Devlet Hastanesi		
Kalp ve Damar Cerrahisi Kliniği		
İlgi:03.12.2019 tarihli dilekçeniz;		
"Yara İyileşmesi Süreci için Akıllı Takip Sistemi" başlıklı, Opr. Dr. Osman Yaşar IŞIKLI' nın sorumluluğunda, Öğr. Gör. Hüseyin ELDEM ve Dr. Öğr. Üyesi Ayşe ELDEM' in yardımcı araştırmacısı olduğu araştırma projesi çalışması hakkında Fakültemiz İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurulunun 06 Aralık 2019 tarihinde aldığı 2019/2212 sayılı karar ilişikte gönderilmiştir.		
Bilgilerinizi rica ederim.		
Prof. Dr. Saim AÇIKGÖZOĞULU İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurul Başkanı		

T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ MERAM TIP FAKÜLTESİ
İLAÇ VE TIBBİ CİHAZ DIŞI ARAŞTIRMALAR ETİK KURUL KARARI

Toplantı Sayısı:99

Toplantı Tarihi: 06 Aralık 2019

Karar Sayısı:2019/2212:Karaman Devlet Hastanesi Kalp ve Damar Cerrahisi Kliniğinden Opr. Dr. Osman Yaşar IŞIKLI' nın "Yara İyileşmesi Süreci için Akıllı Takip Sistemi" başlıklı araştırma projesi çalışması ile ilgili 03.12.2019 tarihli dilekçesi ve ekleri görüşüldü, araştırma projesi çalışmasının Karaman Devlet Hastanesi Kalp ve Damar Cerrahisi Kliniğinden Opr. Dr. Osman Yaşar IŞIKLI' nın sorumluluğunda bütçe desteğinin sağlandığına dair belgenin İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kuruluna sunulduktan sonra çalışmanın başlamasının uygun olduğuna oybirliği ile karar verilmiştir.

Not: Çalışma ile ilgili gerekli izin ve yasal sorumluluk araştırmacılara aittir.

Sorumlu Araştırmacı: Opr. Dr. Osman Yaşar IŞIKLI

Yardımcı Araştırmacılar: Öğr. Gör. Hüseyin ELDEM, Dr. Öğr. Üyesi Ayşe ELDEM

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR

Uluslararası hakemli dergilerde yayımlanan makaleler:

1. Eldem, H., Ülker, E. ve Yaşar Işıklı, O., 2023, Encoder–decoder semantic segmentation models for pressure wound images, The Imaging Science Journal, (SCI-E) (Doktora tezinden yapılmıştır).
2. Eldem, H., Ülker, E. ve Yaşar Işıklı, O., 2023, Effects of training parameters of AlexNet architecture on wound image classification, Traitement du Signal, (SCI-E) (Doktora tezinden yapılmıştır).
3. Eldem, H., Ülker, E. ve Yaşar Işıklı, O., 2022, Classification of Pressure and Diabetic Chronic Wound Tissue Images with Deep Learning Methods, Neural Processing Letters, (SCI-E) (Hakem Değerlendirmesinde) (Doktora tezinden yapılmıştır).
4. Eldem, H., Ülker, E. ve Yaşar Işıklı, O., 2023, AlexNet architecture variations with transfer learning for classification of wound images, Engineering Science and Technology, an International Journal, (SCI-E) (Hakem Değerlendirmesinde) (Doktora tezinden yapılmıştır).
5. Eldem, H., & Ülker, E. (2020). A hierarchical approach based on ACO and PSO by neighborhood operators for TSPs solution. International Journal of Pattern Recognition and Artificial Intelligence, 34(11), 2059039. (SCI-E)