



**DERİ LEZYONLARININ DERİN ÖĞRENME YÖNTEMLERİ İLE
SEGMENTASYONU**

YÜKSEK LİSANS TEZİ

Sezin BARIN

Danışman

Dr. Öğr. Üyesi Gür Emre GÜRAKSIN

BİYOMEDİKAL MÜHENDİSLİĞİ

ANABİLİM DALI

Haziran 2021

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**DERİ LEZYONLARININ DERİN ÖĞRENME YÖNTEMLERİ İLE
SEGMENTASYONU**

Sezin BARIN

Danışman
Dr. Öğr. Üyesi Gür Emre GÜRAKSIN

BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI

Haziran 2021

ÖZET
Yüksek Lisans Tezi

**DERİ LEZYONLARININ DERİN ÖĞRENME YÖNTEMLERİ İLE
SEGMENTASYONU**

Sezin BARIN

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Gür Emre GÜRAKSIN

Cilt kanseri tüm kanser türleri arasında en yaygın olanlardan biridir ve tüm dünyada birçok insanın ölümüne sebep olan ve son yıllarda etki ettiği popülasyon sayısında önemli ölçüde artış olan bir kanser türüdür. En tehlikeli tipi olan melanom erken teşhis edildiğinde tedavi edilebilirlik oranı en yüksek olan kanser türlerinden biridir. Cilt lezyonlarının morfolojik yapıları gereği teşhisleri zordur. Bu nedenle bilgisayar destekli otomatik teşhis sistemlerinde elde edilecek başarılı sonuçlar oldukça önemlidir. Daha önce yapılan çalışmalar cilt lezyonlarının başarılı segmentasyonunun oluşturulacak otomatik teşhis sistemlerinin doğruluk değerlerinde artış sağladığını göstermiştir. Bu problemleri göz önünde bulundurarak cilt lezyonlarının otomatik segmentasyonu üzerine yapılmış bu çalışma iki aşamadan oluşmaktadır. İlk aşamasında Evrişimli Sinir Ağı tabanlı derin segmentasyon mimarilerinin yapısında ve eğitiminde kullanılan bazı hiper parametrelerin cilt lezyon segmentasyonu performansına etkileri değerlendirilmiştir. İkinci aşamasında ise cilt lezyon segmentasyonu için FCN-ResAlexNet olarak tanımlanan hibrit bir Tam Evrişimli Ağ tabanlı segmentasyon mimarisi tasarlanmıştır. Elde edilen sonuçlar değerlendirildiğinde önerilen mimari literatürde en popüler segmentasyon mimarilerinden daha iyi performans göstermiş ayrıca literatürde yapılan diğer çalışmalar ile karşılaştırıldığında elde edilen performanslar ile öncü çalışmalar arasına girmiştir.

2021, x + 78 sayfa

Anahtar Kelimeler: Cilt Lezyon Segmentasyonu, Evrişimli Sinir Ağları, Derin Öğrenme, Transfer Öğrenme, FCN-AlexNet, ResNet-18

ABSTRACT
M.Sc. Thesis

**AN AUTOMATIC SKIN LESION SEGMENTATION SYSTEM WITH HYBRID
FCN-RESALEXNET**

Sezin BARIN

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Biomedical Engineering

Supervisor: Asst. Prof. Gür Emre GÜRAKSIN

Skin cancer is one of the most common of all types of cancer and has caused the death of many people worldwide and has had a significant increase in the number of populations it has affected in recent years. When diagnosed early, melanom, the most dangerous type, is a cancer type with the highest curability rate. Diagnosis of skin lesions is difficult due to their morphological nature. For this reason, successful results to be achieved in computer-aided automatic diagnosis systems are very important. Previous studies have shown that successful segmentation of skin lesions increases the accuracy achieved by automatic diagnosis systems. Considering these problems, this study on automatic segmentation of skin lesions consists of two stages. In the first stage, the effects of some hyperparameters used in the structure and training of Convolutional Neural Network based deep segmentation architectures on skin lesion segmentation performance were evaluated. In the second phase, a hybrid Fully Convolutional Network based segmentation architecture defined as FCN-ResAlexNet was designed for skin lesion segmentation. When the results were evaluated, the proposed architecture performed better than the most popular segmentation architectures in the literature. It was among the pioneering studies with the performances obtained when compared with other studies in the literature.

2021, x + 78 pages

Keywords: Skin Lesion Segmentation, Convolutional Neural Networks, Deep Learning, Transfer Learning, FCN-AlexNet, ResNet-18

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın hocam Dr. Öğr. Üyesi Gür Emre GÜRAKSIN' a;

Sahip olduğu bilgi birikimleri ve zengin hayat tecrübeleri ile kazandırdığı bakış açısı için Sayın hocam Prof. Dr. Mehmet Emin YÜKSEL'e;

Araştırma ve analiz süresince yardımlarını esirgemeyen sevgili dostlarım Pratima UPRETEE'e, Afrah Elfatih Farah MALİK'e, Derek Kweku DEGBEDZUI'e ve Tacettin Utku Süer'e;

Her konuda öneri ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma;

Yaşamımın her anında maddi, manevi desteği ile sürekli yanımda olan ve bugünlere gelmem de büyük katkısı bulunan annem Gülay BARIN, babam Hilmi BARIN, abim Fatih BARIN, teyzelerim Zeliha TEKİN, Gülsün BAYRAK ve diğer aile üyelerine sonsuz teşekkürü bir borç bilirim.

Sezin BARIN
AFYONKARAHİSAR, 2021

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ.....	ix
RESİMLER DİZİNİ	x
1. GİRİŞ.....	1
2. GENEL BİLGİLER VE LİTERATÜR İNCELEMESİ.....	4
2.1 Cilt Kanseri	4
2.2 Cilt Kanseri Sebepleri	5
2.3 Teşhis Yöntemleri.....	5
2.4 Yapay Zekâ	6
2.5 Derin Öğrenme	7
2.6 Evrişimli Sinir Ağları.....	12
2.6.1 Evrişim(Convolution) Katmanı.....	13
2.6.2 Havuzlama (Pooling) Katmanı.....	15
2.6.3 Tam Bağlantılı Katman	16
2.6.4 Ters Evrişim Katmanı (Deconvolution Layer)	17
2.6.5 Seyreltme (Dropout) Katmanı.....	18
2.6.6 Yığın Normalizasyon Katmanı (Batch Normalization Layer)	19
2.6.7 ESA Eğitim Hiperparametreleri	19
2.6.7.1 Kayıp fonksiyonu (loss function)	19
2.6.7.2 Öğrenme Oranı	21
2.6.7.3 Mini-Yığın Boyutu (Mini-Batch Size)	22
2.6.7.4 Epok Sayısı.....	22
2.7 Transfer Öğrenme	23
2.8 Segmentasyon İşlemlerinde Derin Öğrenme Mimarilerinin Kullanımı	24
2.9 Cilt Lezyonlarının Segmentasyonunda Kullanılan Veri Setleri.....	31

2.10 Literatür İncelemesi	33
3. MATERYAL VE METHOD	38
3.1 Materyal	39
3.2 Metot	40
3.2.1 Ön işlem	40
3.2.2 Segmentasyon	42
3.2.2.1 Hiper Parametrelerin Belirlenmesi	43
3.2.2.2 Çalışmada Kullanılan Derin Öğrenme Mimarileri ve Hibrit Mimari Tasarımı	46
4. BULGULAR.....	51
5. SONUÇLAR VE TARTIŞMA.....	62
6. KAYNAKLAR.....	64
ÖZGEÇMİŞ.....	78

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

n_{cl}	Bulunan toplam sınıf sayısı
n_{ij}	j sınıfına ait olduğu tahmin edilen i sınıfının piksel sayısı
t_i	i sınıfına ait toplam piksel sayısını

Kısaltmalar

ADAM	Adaptive Moment Estimation-Uyarlanabilir Moment Tahmini
ASPP	Boşluklu Uzamsal Piramit Havuzlama-Atrous Spatial Pyramid Pooling
BM	Boltzmann Makineleri
DO	Derin Otokodlayıcı
DİA	Derin İnanç Ağları
DBN	Deep Belief Network-Derin İnanç Ağları
DNN	Deep neural network
ESA	Evrişimli Sinir Ağları
FCN	Tam Evrişimli Ağ-Fully Convolutional Network
FN	Yanlış Negatif
FP	Yanlış Pozitif
GAN	Generative Adversarial Networks
IARC	International Agency for Research on Cancer-Uluslararası Kanser Araştırma Ajansı
IoU	Intersection over Union-Birleşim Üzerindeki Kesişme
KSAHE	Kontrast Sınırlı Adaptif Histogram Eşitleme
RBM	Restricted Boltzmann Machine
RMSProb	Root Mean Square Error Propability
RNN	Tekrarlayan Sinir Ağları-Recurrent Neural Network
SBM	Sınırlandırılmış Boltzmann Makineleri
SGD	Stochastic Gradient Descent- Rastgele Gradyan İniş
SGDM	Stochastic Gradient Descent with Momentum-Momentumlu Rastgele Gradyan İniş
TEA	Tam Evrişimli Ağ
TF	Doğru Negatif
TP	Doğru Pozitif
TSA	Tekrarlayan Sinir Ağları
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 Cilt anatomisi ve epidermis tabakasında bulunan melanosit hücrelerinin gösterimi (İnt.Kyn.8.).....	5
Şekil 2.2 Son 6 yılda yapılan otomatik cilt kanseri teşhisi yayın istatistikleri (İnt.Kyn.10).....	6
Şekil 2.3 Biyolojik Nöron ve YSA Yapısı (Kawaguchi 2000, Keskenler ve Keskenler 2017)	8
Şekil 2.4 En sık kullanılan aktivasyon fonksiyonları (Kurt 2018).....	9
Şekil 2.5 Örnek Yapay Sinir Ağı	9
Şekil 2.6 Yapay Sinir Ağları Sınıflandırma	10
Şekil 2.7 Tek Katmanlı YSA ve Derin YSA Mimarisi Örneği (İnt.Kyn.12).....	11
Şekil 2.8 Örnek ESA mimarisi (Hidaka ve Kurita 2017).....	13
Şekil 2.9 Bilgisayarlar Nasıl Görür?	13
Şekil 2.10 2 boyutlu bir görüntü için evrişim işlemi (Fathi ve Maleki Shoja 2018).....	14
Şekil 2.11 Renkli görüntülerde evrişim işlemi (Li vd. 2016).....	15
Şekil 2.12 Maksimum havuzlama katmanında gerçekleşen işlem örneği (Verschoof-van der Vaart ve Lambers 2019).....	16
Şekil 2.13 Tam Bağlantılı Katman Örneği (İnt.Kyn.15, Escontrela 2018).....	17
Şekil 2.14 Örnek ters evrişim işlemi	18
Şekil 2.15 Normal Sinir Ağı ve Seyreltme (Dropout) Katmanı Kullanılmış Sinir Ağı .	19
Şekil 2.16 2018 yılına kadar sunulan modellerin bir değerlendirmesi (Bianco vd. 2018)	24
Şekil 2.17 Zaitoun ve Aqel tarafından yapılan segmentasyon sınıflandırması (Zaitoun ve Aqel 2015).....	25
Şekil 2.18 2014-2020 yılları arasında geliştirilen segmentasyon mimarileri (Minaee vd. 2020)	26
Şekil 2.19 TEA model yapısı (Long vd. 2015b)	27
Şekil 2.20 Deeplab V3+ mimarisi (Chen vd. 2018a)	28
Şekil 2.21 SegNet mimarisi (Badrinarayanan vd. 2017).....	29
Şekil 2.22 U-Net mimari yapısı (Ronneberger vd. 2015)	30
Şekil 2.23 ÜÇA yapısı (Liu vd. 2021)	31

Şekil 2.24 Cilt kanseri çalışmalarında en yaygın kullanılan veri setleri (Valle vd. 2020)	33
Şekil 3.1 Çalışmaya ait akış diyagramı	38
Şekil 3.2 ISIC2017 veri seti örnek görüntüleri ve gerçek referans (ground truth) görüntüleri	39
Şekil 3.3 ISIC2017 örnek veri seti görüntüleri ve uygulanan Gray World algoritmasının görüntüler üzerine etkileri	41
Şekil 3.4 Orijinal ve KSAHE uygulanan ISIC2017 örnek veri seti görüntüleri ve histogram grafikleri	42
Şekil 3.5 FCN-AlexNet Mimarisi	46
Şekil 3.6 Artık Blok Yapısı	47
Şekil 3.7 ResNet-18 Derin Öğrenme Ağına Ait Mimari	48
Şekil 3.8 Önerilen FCN-ResAlexNet Derin Öğrenme Ağına Ait Mimari	50
Şekil 4.1 Önerilen hibrit mimari ile veri setinde bulunan gerçek referans değerlerinin karşılaştırması	58

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 Segmentasyon Mimarilerinde Kullanılan Kayıp Fonksiyonları (Jadon 2020).....	20
Çizelge 4.1 Farklı giriş boyutlarına sahip FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları.....	53
Çizelge 4.2 Farklı optimizasyon algoritmaları kullanılarak eğitilmiş FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları.....	54
Çizelge 4.3 Farklı kayıp fonksiyonlar (loss functions) kullanılarak düzenlenmiş FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları	54
Çizelge 4.4 Farklı görüntü ön işleme teknikleri uygulanarak elde edilmiş görüntüler kullanılarak eğitilmiş FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları.....	55
Çizelge 4.5 Farklı decoder yapılarına sahip FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları.....	56
Çizelge 4.6 FCN-ResNet ve FCN-AlexNet segmentasyon mimarilerinin 30 epok eğitimi için geçen süre	56
Çizelge 4.7 Farklı Segmentasyon Mimarileri İçin Değerlendirme Metrikleri	57
Çizelge 4.8 Literatür Çalışmaları ile Karşılaştırma.....	59

RESİMLER DİZİNİ

Sayfa

Resim 2.1 Cilt lezyonu görüntülerindeki artefaktlar a. Kahverengi lezyon b. Siyah kıllar c. Kahverengi lezyonlu siyah tüyler d. İşaretçiler e. Lezyon üzerinde beyaz kalıntılar f. Lezyon üzerindeki beyaz kalıntılar g. Beyaz ve belirsiz lezyonlar h. Belirsiz lezyonlar	37
--	----



1. GİRİŞ

Cilt, insan vücudunun çevreye karşı kontrol ve korunma mekanizmasıdır. Cilt lezyonları, cildin etrafındaki bölgelere göre anormal yapıya ve görünüme sahip kısımdır. Bazı cilt lezyonları sadece fiziksel olarak kötü bir görünüme sebep olurken bazıları kanser özelliği taşıyabilmektedir. Cilt kanserleri temelde tehlikeli tür olan melanom ve melanom olmayan olmak üzere iki ana türe ayrılır. Cilt kanseri vakalarının özellikle melanom olmayan türlerinin birçok ülkede tam olarak kayıtları tutulmamaktadır (İnt.Kyn.1). Buna rağmen Uluslararası Kanser Araştırma Ajansı (IARC) tarafından 2018 yılında yayınlanan GLOBOCAN 2018 verilerine bakıldığında bir yıl içerisinde 60.700'i ölümle sonuçlanan 287.700 yeni melanom ve 65.200'ü ölümle sonuçlanan 1.042.100 melanom olmayan vaka olduğu raporlanmıştır (Bray vd. 2018). Özellikle son on yılda melanom cilt kanserinden ölüm oranı her yıl yaklaşık % 50 oranında artış göstermiştir (İnt.Kyn.2). Bu veriler göstermiştir ki cilt kanseri insan hayatı için oldukça tehlikelidir ve bu tehlike her yıl daha da tehdit edici bir hal almaktadır.

Melanom cilt kanseri erken tespit edilirse tedavi edilebilirliği en yüksek kanser türlerinden biridir (İnt.Kyn.2). Ancak melanom cilt kanserlerine ait görüntülerde lezyonlu bölge ile lezyon olmayan bölge arasındaki düşük kontrast, teşhis koyma yöntemlerinin uygulanmasında uzmanlık gerektirmekte ve dermatologlar arasında görecelik içermektedir. Bunun yanı sıra insan cildinin, coğrafi ve iklimsel etkiler, pürüzlülük, ton çeşitliliği, saç ve buna benzer birçok karmaşık yapıya sahip olması ve düşük kontrast probleminden dolayı otomatik olarak analiz edilmesi oldukça zordur (Shamsul Arifin vd. 2012). Ancak oluşturulacak başarılı bir otomatik analiz sistemi dermatologların teşhis koymalarında oldukça yardımcı olacak ve süreci hızlandıracaktır. Ferrante di Ruffano L ve arkadaşlarının (Ferrante di Ruffano vd. 2018) yaptığı incelemede otomatik tanı sistemlerinin yüksek duyarlılık gösterdiğini ve uzman teşhisleri için yararlı olduklarını göstermiş olmaları bu öngörüğü desteklemektedir. Cilt lezyonlarının morfolojik olarak birbirlerine benzerlikleri otomatik olarak sınıflandırma yöntemlerinin başarısını oldukça etkilemektedir. Bu nedenle otomatik cilt lezyon teşhisleri, başarılı sonuçlar elde edilmiş olursa da beklenen başarılar elde edilemediği için hala çözülmesi gereken problemler arasındadır.

Otomatik cilt lezyonu analizleri genellikle ön işleme, segmentasyon, özellik çıkarımı ve sınıflandırma olmak üzere 4 aşamadan oluşmaktadır (Pereira vd. 2020). Sınıflandırma sonuçlarının başarılı olması ilk aşamalardan elde edilen sonuçlara yüksek oranda bağlıdır. Bu çalışmada otomatik cilt lezyon analizinin en önemli adımlarından birisi olan segmentasyon için önerilerde bulunulmuştur. Yıllar içinde farklı algoritmik yöntemler kullanılarak birçok klasik görüntü segmentasyon yöntemi önerilmiştir, ancak optimum performans hala ideal seviyelerden uzaktır.

Bu çalışmada, cilt lezyon görüntülerinden lezyon segmentasyonu için literatürde uygulanan görüntü işleme yöntemlerinin, piksel sınıflandırma katmanlarında kullanılan kayıp fonksiyonlarının (loss function) ve derin evrişimli sinir ağı (ESA) mimarilerinin eğitiminde kullanılan optimizasyon algoritmalarının derin segmentasyon mimarisi üzerindeki performansları değerlendirilmiştir. Çalışmanın temel motivasyon kaynağını matematiksel olarak hesaplama yükünü arttırmadan derin ESA tabanlı segmentasyon mimarisinin performansını arttırmak oluşturmaktadır. Bu nedenle yapılan değerlendirmeler yapısal olarak basit, çok fazla matematiksel hesaplama maliyeti oluşturmayan diğer yandan segmentasyon işlemlerinde başarılı sonuçlar elde eden FCN-AlexNet mimarisi kullanılarak yapılmıştır. Çalışmada görüntü işleme teknikleri olarak görüntü yeniden boyutlandırma, renk sabitleme ve histogram eşitleme algoritması; kayıp fonksiyon olarak Çapraz Entropi (Cross-Entropy), Ağırlıklı Çapraz Entropi (Weighted Cross Entropy) ve Tversky fonksiyonları; optimizasyon algoritması olarak da ADAM (Adaptive Moment Estimation), SGDM (Stochastic Gradient Descent with Momentum) ve RMSProp (Root Mean Square Error Propability) algoritmaları uygulanmış ve sonuçlar değerlendirilmiştir. Bu değerlendirmelerin yanı sıra bu çalışmada FCN-AlexNet mimarisinin yapısı baz alınarak matematiksel olarak ekstra hesaplama maliyeti gerektirmeyen görece daha kompleks yapıya sahip yeni bir hibrit segmentasyon mimarisi olan FCN-ResAlexNet mimarisi önerilmiştir. Elde edilen sonuçlar değerlendirildiğinde önerilen mimarinin literatürde önerilen segmentasyon mimarilerine göre daha iyi performans gösterdiği görülmüştür. Elde edilen performans ölçütleri ile deri lezyonlarının segmentasyonu için önerilen yöntemin literatüre önemli bir katkı sağlayacağı düşünülmektedir.

Tez Organizasyonu

Bu tez řu řekilde d zenlenmiřtir:

Genel Bilgiler ve Literat r İncelemesi b l m nde, cilt kanseri, cilt kanseri teřhis y ntemleri, yapay zek , yapay sinir aęları, derin  ęrenme, derin  ęrenme mimarilerinin segmentasyon iřlemlerinde kullanımı, cilt kanseri  alıřmalarında kullanılan veri setleri hakkında detaylı bir bilgilendirme sunduktan sonra cilt kanserinin segmentasyonunda uygulanan mevcut derin  ęrenme uygulamalarının kapsamlı bir literat r incelemesini sunar.

Materyal ve Metot b l m nde, bu tez projesinde kullanılan metodoloji hakkında ayrıntılı bilgi saęlar.  alıřmada kullanılan veri seti, uygulanan  n iřlemler, kullanılan derin  ęrenme mimarisi, derin  ęrenme mimarisinin performansını etkileyen hiper parametrelerin uygulanma ařamaları ve  nerilen derin  ęrenme mimarisi detaylı bir řekilde a ıklanır.

Bulgular b l m nde,  alıřmada kullanılan derin  ęrenme mimarileri, deęerlendirilen hiper parametrelerin sonu ları ve  nerilen yeni derin segmentasyon mimarisinin deneysel sonu ları ve bu sonu ların istatistiksel performans analizleri sunulur ve yorumlanır.


Sonu lar ve Tartıřma b l m nde deneysel tartıřması sunulmuř ve bu b l m bu tez projesinin gelecekteki olası uzantılarıyla sonu landırılmıřtır.

2. GENEL BİLGİLER VE LİTERATÜR İNCELEMESİ

2.1 Cilt Kanseri

Kanser, büyüme fonksiyonları bozulmuş vücut hücrelerinin kontrolsüz şekilde çoğalarak diğer dokuları işgal etmesi veya oluştuğu bölgeden daha uzak bir yere çeşitli yollar ile (kan-lenf) yayılması sonucu oluşan bir hastalıktır (İnt.Kyn.9, Kizilbey ve Akdeste 2013). Normal vücut hücreleri, orijinal yapılarını korurken kanser hücreleri saldırgan bir tablo çizerler (İnt.Kyn.9).

Cilt dıştan içe doğru epidermis, dermis ve deri altı hücreleri olmak üzere 3 tabakadan meydana gelir (bkz. Şekil 2.1). Cilt kanseri epidermiste bulunan 3 farklı hücrede oluşmaya başlar ve oluştukları hücrelere göre türlere ayrılırlar. Bunlar epidermisin üst katmanında bulunan ince, düz yapıdaki skuamöz hücrelerinde oluşan skuamöz hücreli karsinoma, skuamöz hücrelerin altında bulunan bazal hücrelerde oluşan bazal hücreli karsinoma, ve epidermisin alt kısmında bulunan deriye renk veren melanosit hücrelerinde (bkz. Şekil 2.1) oluşan melanomdur (İnt.Kyn.8). Skuamöz hücreli karsinoma ve bazal hücreli karsinoma, melanomaya göre daha yaygındırlar ancak tedavi edilebilirlikleri oldukça yüksektir. Melanom, epidermisin alt tabakasında bulunması nedeniyle yakındaki dokulara ve vücudun diğer bölgelerine yayılma olasılığı daha yüksektir ve tedavisi daha zor olabilmektedir. Kanserli formdaki melanositler sağlıklı hücrelerin/dokuların yerini alarak veya fonksiyonunu bozarak hızla yayılabilir. Melanom erken teşhiste iyileşme ihtimali en yüksek kanser türüdür ancak cildin iç tabakasına yayılması durumunda tehlikeli boyutlara ulaşmaktadır (İnt.Kyn.2).



Şekil 2.1 Cilt anatomisi ve epidermis tabakasında bulunan melanosit hücrelerinin gösterimi (İnt.Kyn.8.).

2.2 Cilt Kanseri Sebepleri

Cilt kanseri, oluşumunda genetik ve çevresel faktörlerin rol aldığı ancak özellikle güneş ışınlarında bulunan ultraviyole B radyasyonun etkili olduğu bir kanser türüdür (Türkmen vd. 2010). Yapılan araştırmalar özellikle açık tenli, çok sayıda leke ve benleri olan, güneş yanığı geçmişi olan ve uzun süre güneşe maruz kalan kişilerin cilt kanserine yakalanma riskinin daha fazla olduğunu göstermiştir (Wingo vd. 2002, Uysal vd. 2004). İlk zamanlarda cilt kanserlerinden ölüm oranlarının düşük olduğu rapor edilirken günümüzde her yıl cilt kanserinden ölen insan sayısının giderek arttığı raporlanmıştır (İnt.Kyn.2, Karagas vd. 2009, Guy ve Ekwueme 2011, Sümen ve Öncel 2014) .

2.3 Teşhis Yöntemleri

Tıpta cilt kanserinin ilk teşhis aşamasında ABCD kuralına dayanan çıplak göz muayenesi veya invazif olmayan bir görüntüleme yöntemi olan dermoskopi kullanılmaktadır (İnt.Kyn.5). Bu aşamadan sonra uzmanın mevcut lezyonunun kanser olmasından şüphe etmesi durumunda lezyonun durumuna göre farklı yöntemler ile biyopsi uygulanabilir. Cilt kanseri teşhisi için başka bir yöntem ise henüz çok yaygın olmayan, yeni bir teknoloji olan ve lezyonların incelemesini geliştirebilecek konfokal

taramalı lazer mikroskobudur (İnt.Kyn.5). Bahsi geçen yöntemlerin ortak bir yanı vardır bu da her durumda uzman yorumu oldukça önemlidir.

Yukarıda belirtilen biyopsi ve göreceli uzman yorumları gibi dezavantajlar göz önüne alınarak, son yıllarda otomatik cilt kanser teşhisi yapan yeni sistemler geliştirilmiş ve geliştirilmeye devam etmektedir. Gelişen bilgisayar sistemleri sayesinde bu yöntemler arasına her gün yeni çalışmalar eklenmektedir.

Şekil 2.2 (İnt.Kyn.10) son 6 yılda otomatik cilt kanseri teşhisi için literatürde gerçekleştirilen çalışmaların istatistiklerini göstermektedir.



Şekil 2.2 Son 6 yılda yapılan otomatik cilt kanseri teşhisi yayın istatistikleri (İnt.Kyn.10).

2.4 Yapay Zekâ


Otomatik cilt kanseri teşhisinde en yaygın kullanılan yöntemlerden bir tanesi yapay zekâ teknikleridir. Yapay zekâ yöntemleri son yıllarda meydana gelen hızlı gelişmeler ve elde ettikleri başarılar sayesinde ekonomiden sanata, askeriyeden eğitime birçok alanda varlığını giderek arttırmaktadır. Popülerliğini en hızlı şekilde arttırdığı alanlardan birisi olan tıbbi görüntüleme tekniklerine getirdiği farklı bakış açıları ile tıpta oldukça geniş bir kullanım alanına sahiptir.

Yapay zekâyı insana özgü olan algılama, öğrenme, düşünme, çıkarım yapma, sorun çözüme, iletişim kurma gibi bilişsel fonksiyonların veya otonom davranışların yazılımlar aracılığıyla bilgisayar veya bilgisayar kontrollü robotların benzer şekilde yerine getirmesi olarak tanımlamak mümkündür (İnt.Kyn.7, Aybars ve Kınacı 2006). Cilt kanserinin yapay zekâ kullanımı ile otomatik teşhisi ise uzmanlar yerine oluşturulan matematiksel sistemlerin, algoritmaların veya bilgisayar sistemlerinin lezyon görüntülerini kullanarak kanser teşhisi koyması olarak adlandırılabilir.


2.5 Derin Öğrenme

Makine öğrenmesi yapay zekânın sayısal öğrenme ve model tanıma çalışmalarından geliştirilmiş alt dallarından biridir (Kayıran ve Gökalp 2021). Derin öğrenme ise yapay sinir ağları (YSA) temeline dayanan bir makine öğrenmesi yöntemidir. Derin öğrenmenin makine öğrenmesinde kullanılan YSA'dan farkı çok sayıda katman veya katman içinde katman olarak oluşturulan derin YSA mimarisidir.

YSA'lar biyolojik sinir ağlarından esinlenerek oluşturulmuş çok sayıda nörona sahip, oldukça fazla sayıda basit işlemci ihtiva eden paralel hesaplama sistemleridir (Keleşoğlu ve Fırat 2006, Gupta 2013). Biyolojik sistemler ile YSA yapıları karşılaştırıldıklarında oldukça benzer yanlarının olduğu görülmektedir. Şekil 2.3'de biyolojik sinir ağı ve bir yapay sinir ağı yapısı görülmektedir. Şekil incelendiğinde biyolojik nöron yapısındaki dentrit, YSA'da ki bir nöronun/perseptronun toplama fonksiyonuna; hücre gövdesi, transfer fonksiyonuna; aksonlar, yapay nöron çıkışına; sinapslar ise ağırlıklara karşılık gelmektedir (Koç vd. 2004, Kurt 2018).



1. Akson 2. Çekirdek 3. Gövde 4. Dentrit 5. Akson tepesi 6. Sinapslar
Biyolojik Sinir Ağı Yapısı



YSA Nöron/Perseptron Yapısı


Şekil 2.3 Biyolojik Nöron ve YSA Yapısı (Kawaguchi 2000, Keskenler ve Keskenler 2017).

Şekil 2.3'deki gibi ifade edilen bir nöronda gerçekleştirilen işlemin matematiksel formülasyonu Denklem 2.1'de verilmiştir.


$$y = \varphi((\sum_{k=1}^m x_k * w_k) + b) \quad (2.1)$$

Literatürde ilk ortaya atılan YSA mimarilerinden bir tanesi perseptronlardır (Rosenblatt 1958). Bir perseptronda birden fazla giriş ağırlıklarla çarpılarak tüm sonuçlar toplanır ve elde edilen sonuçlar bir aktivasyon fonksiyonuna/ transfer fonksiyonuna tabi tutularak çıktılar oluşturulur. Aktivasyon fonksiyonu, lineerlikten kurtardığı perseptron çıkışını eşik değerini de kullanarak sonraki nörona aktarılıp aktarılmayacağını belirlenmesini sağlar. Bu nedenle aktivasyon fonksiyonuna karar verilirken lineer olmaması ve öğrenme işleminin gerçekleşebilmesi için türevinin kolay alınabilmesi önemli kriterler arasındadır. Şekil 2.4'de en yaygın kullanılan aktivasyon fonksiyonları verilmiştir. Evrişim katmanında ReLU, çıkış katmanında ise Softmax en çok tercih edilen aktivasyon fonksiyonları arasındadır.

Tek bir perseptron yapısı kompleks problemler için yeterli olmamaktadır. Bu nedenle bir yapay sinir ağı Şekil 2.5'de görüldüğü gibi birçok perseptron ve gizli katmandan oluşmaktadır. Bu sayede doğrusal olmayan problemlerin de çözümü sağlanmaktadır (Küçük ve Arıcı 2018).




Şekil 2.4 En sık kullanılan aktivasyon fonksiyonları (Kurt 2018).



Şekil 2.5 Örnek Yapay Sinir Ağı.

YSA'ları, Şekil 2.6'da görüldüğü üzere ağ yapılarına ve uygulanan eğitim algoritmalarına göre sınıflandırmak mümkündür (Svozil vd. 1997, Levent KOÇ vd. 2004). Ağ yapılarına göre ileri beslemeli ve geri beslemeli olarak ikiye ayrılan YSA'lar, öğrenme şekillerine göre denetimli, denetimsiz ve yarı denetimli olarak 3'e ayrılmıştır.



Şekil 2.6 Yapay Sinir Ağları Sınıflandırma.

İleri beslemeli ağlarda, girişten gizli ve çıkış katmanlarına doğru ileri yönde bir hareket vardır. Sistem belleksizdir. Öğrenme aşamasında çıktı yalnızca o anki girişin değerlerine bağlıdır ve geriye bir bildirim söz konusu değildir. İleri beslemeli sinir ağları YSA'ların ilk geliştirilen en basit türüdür.


Geri beslemeli ağlarda ise çıkış ve ara katlardaki çıkışlardan önceki katmanlara bir geri besleme söz konusudur. Sistemin dinamik hafızaları vardır (Aşkin vd. 2011). Çıkış hem o anki girişe hem de önceki giriş değerlerine bağlıdır. Bundan dolayı, bu ağ yapısı özellikle tahmin uygulamaları için uygundur (MacKay 1992, Aşkin vd. 2011).

Denetimsiz YSA'lar da ise algoritmalar yalnızca giriş verileri kullanılarak eğitilir. YSA algoritması mevcut giriş verilerinden ortak özellikler veya çıkarımlar yaparak verileri gruplara ayırır. Denetimsiz YSA'lar genellikle kümeleme çalışmalarında özellikle de etiketli çıkış verisi bulunmayan çalışmalarda kullanılmaktadır (Donalek 2011, Berry vd. 2019).

Denetimli YSA’larda algoritmalar giriş verileri ve etiketli çıkış verilerini kullanarak eğitilir. Denetimli YSA’larda elde edilen çıkışlar gerçek çıkış verilerinin etiketleri ile karşılaştırılır ve bir hata oranı hesaplanır. Elde edilen hataya göre ağırlıklar optimize edilir. Genellikle sınıflandırma ve regresyon çalışmalarında yaygın olarak kullanılmaktadırlar (Donalek 2011, Berry vd. 2019).

Yarı Denetimli YSA’larda ise hem etiketli hem de etiketsiz çıkış verileri kullanılarak eğitim gerçekleştirilmektedir. Etiketli veri ihtiyacını azaltmak için tercih edilmektedir.

Derin öğrenme, mevcut YSA’lara ileri düzey bir bakış açısıdır. Mevcut YSA’lar da bulunan gizli katmanların sayısının zamanla artırılması ile elde edilen başarının arttığı fark edilmiştir. Bu nedenle giderek daha fazla gizli katmandan oluşan derin YSA yapıları oluşturulmuştur. Başka bir bakış açısıyla derin öğrenme mimarileri birbirine bağlı ağırlıklar ile oluşturulan çok fazla gizli katmandan oluşan çok katmanlı perseptron yapısına sahiptirler (Deng ve Yu 2013a). Şekil 2.7’de temel bir YSA ve bir derin öğrenme mimarisi örneği verilmiştir. Şekilde de görüldüğü üzere derin öğrenme mimarisinde kullanılan çoklu gizli katman yapısı ile adından da anlaşılacağı üzere oldukça derin bir ağ yapısına sahiptir. Bu derin ağ yapısının dezavantajı çok fazla veriye ihtiyaç duymasındır.



Şekil 2.7 Tek Katmanlı YSA ve Derin YSA Mimarisi Örneği (İnt.Kyn.12).

Hem denetimli hem de denetimsiz öğrenme tekniği kullanılabilen derin YSA mimarileri, yaygın olarak sınıflandırma ve regresyon çalışmalarında kullanılsa da

kümeleme çalışmalarında da tercih edilmektedirler.


Temelde kullanılan birkaç farklı derin öğrenme yöntemi vardır. Bunlar (Deng ve Yu 2013b, Küçük ve Arici 2018, Sundararajan ve Woodard 2018);

- Derin İnanç Ağları (DİA) (Deep Belief Networks)
- Boltzmann Makineleri (BM) (Boltzmann Machines)
- Sınırlandırılmış Boltzmann Makineleri (SBM) (Restricted Boltzmann Machines)
- Derin Sinir Ağları (DSA) (Deep Neural Networks)
- Derin Otokodlayıcılar (DA) (Deep Autoencoders)
- Yinelenen Sinir Ağları (TSA) (Recurrent Neural Networks)
- Evrişimli Sinir Ağları (ESA) (Convolutional Neural Networks)

2.6 Evrişimli Sinir Ağları

Derin öğrenmenin en popüler yöntemlerinden birisi olan ESA özellikle görsel verilerin analizinde oldukça başarılıdır. Geleneksel sinir ağlarının iki boyutlu yapısı nedeniyle görüntü analizi için elverişli olmayan bu yapıların aksine ESA'lar üç boyutlu katman yapısı sayesinde görüntü analizi için oldukça elverişlidir. Bunun sebebi ESA katmanları yapı gereği uzunluk ve genişliğin yanı sıra derinlik boyutunda da analiz yapmaktadırlar (Karakullukçu 2020). İlk olarak Kunihiro Fukushima tarafından ortaya atılan bu yöntem elle yazılmış sayıların sınıflandırılmasında ESA kullandıkları çalışmaları ile Yann LeCun ve arkadaşları tarafından popüler olmuştur (Fukushima 1980, Cun vd. 1990, Coşkun vd. 2017). ESA'lar görüntü, video, ses gibi giriş verilerinde nesne, desen, yüz veya belli bir ânı filtreler aracılığı ile ağırlıklandırarak başarılı olarak diğerlerinden ayırabilmektedir. Daha basit yöntemlerde bu filtreler elle üretilirken, ESA'lar derin katmanlı yapısı sayesinde farklı özellikleri tespit edebilen birçok filtreyi öğrenme yeteneğine sahiptir (Saha 2018). ESA'ların en önemli özelliklerinden bir diğeri ise ham yani üzerinde işlem yapılmamış veriler ile de oldukça başarılı sonuçlar elde edebilmesidir.


Bir ESA mimarisi temel olarak konvolüsyon/evrişim, havuzlama (Pooling) ve tam bağlantılı katmandan oluşur. Şekil 2.8'de örnek bir ESA mimarisi verilmiştir.



Şekil 2.8 Örnek ESA mimarisi (Hidaka ve Kurita 2017).

2.6.1 Evrişim (Convolution) Katmanı

Bilgisayarlar için görüntüler birer matris formlarıdır. Şekil 2.9'da görüldüğü gibi bir görüntü bilgisayar için birçok pikselden oluşan matris formundadır.




Şekil 2.9 Bilgisayarlar Nasıl Görür?

Evrişim katmanı ESA mimarisinin en temel yapı taşıdır. Evrişim katmanı bahsedilen matris formatında görüntülerden öğrenebilir parametrelere sahip filtreleri kullanarak özellikler çıkartır. Bunun için belirli boyutlarda filtreleri görüntü üzerinde piksel piksel kaydırarak görüntü ile evrişim işlemine tabi tutar.

Şekil 2.10'da 2 boyutlu gri formdaki görüntü için uygulanan evrişim işlemi görülmektedir. Şekil üzerinden örnek ile açıklayacak olursak 5x5 formatındaki bir


görüntü üzerinde 3x3 boyutlarındaki filtre kaydırılarak filtre ile üst üste gelen görüntü pikselleri evrişim işlemine tabi tutulmaktadır. Bu işlem sonucunda oluşan matris özellik haritası olarak adlandırılmaktadır. Ayrıca evrişim işlemi sırasında kullanılan filtre ve kaydırma miktarı sabit değildir. Yazılımcı bu değerleri değiştirerek optimum performansı gösteren boyut ve kaydırma oranını seçebilir.



Şekil 2.10 2 boyutlu bir görüntü için evrişim işlemi (Fathi ve Maleki Shoja 2018).

Günümüzde kullanılan ESA mimarilerinde genellikle renkli yani RGB formatında görüntü girişi uygulanmaktadır. Renkli görüntülerde evrişim işlemi gri formatındaki görüntülere benzer şekilde gerçekleştirilmektedir.


Şekil 2.11 renkli görüntülerde gerçekleştirilen evrişim işlemi göstermektedir. Resimde de görüldüğü üzere renkli görüntülerde her renk katmanı için (RGB) ayrı ayrı evrişim işlemi uygulanmakta ve toplanmaktadır.



Şekil 2.11 Renkli görüntülerde evrişim işlemi (Li vd. 2016).

2.6.2 Havuzlama (Pooling) Katmanı

ESA mimarilerinin en temel katmanlarından birisi de havuzlama katmanıdır. Havuzlama katmanında kademeli olarak uzamsal boyut azaltma işlemi yapılmaktadır (Li vd. 2016). Başka bir deyişle katmanın amacı örnekleme yaparak ağdaki parametre ve hesaplama miktarını azaltmanın yanı sıra ezberlemeyi (Overfitting) engellemek içinde etkilidir. Evrişim katmanından sonra oluşan özellik haritaları üzerine uygulanır. Havuzlama katmanında, belli boyuttaki pencere/filtre, özellik haritası üzerinde kaydırılarak pencere içerisinde kalan piksellere havuzlama işlemi uygulanır. Havuzlama için maksimum havuzlama ve ortalama havuzlama olarak 2 yaygın yöntem vardır. Maksimum havuzlamada pencere içerisinde kalan piksellerden maksimum değer alınırken, ortalama havuzlama yönteminde pencere içerisindeki piksel değerlerinin ortalaması alınarak çıkışa yansıtılır.




Şekil 2.12 Maksimum havuzlama katmanında gerçekleşen işlem örneği (Verschoof-van der Vaart ve Lambers 2019).

Şekil 2.12 evrişim işlemi sonrası oluşan bir 4x4 boyutundaki özellik haritasına 2x2 boyutundaki pencerenin 2 adım kaydırılarak uygulanan maksimum havuzlama işlemini göstermektedir. Pencere kırmızı renkteki piksel üzerine geldiğinde en büyük değer 4 olduğu için ilk olarak 4 değerini çıkışa aktarmıştır, diğer adımda yeşil renkteki piksellerin üzerine gelen pencere en büyük değer yine 4 olduğu için çıkışa tekrar 4 aktarmıştır. Bu işlem tüm özellik haritası tamamlanana kadar devam etmektedir.

2.6.3 Tam Bağlantılı Katman

Genellikle bir ESA mimarisinin son katmanını oluşturur. Tam bağlantılı katmandan sonra bir evrişim katmanı kullanılamaz. Bu katmandan önceki katmanlardan gelen çıktılar, giriş verilerindeki yüksek seviyeli özellikleri temsil eder. Tam bağlantılı katman önceki katmandaki tüm nöronları bünyesindeki nöronlara bağlayarak düzleştirir ve daha sonra çıkış katmanına bağlar. Bu aslında özelliklerin doğrusal olmayan kombinasyonlarını öğrenmenin düşük maliyetli bir yoludur (Coşkun vd. 2017). Bir ESA mimarisindeki son tam bağlantılı katmanın çıkış nöron sayısı sınıf sayısı kadardır ve olasılık değerleri toplamı kullanılan aktivasyon fonksiyonu sayesinde 1'dir. Tam bağlantılı katmanda genellikle Softmax aktivasyon fonksiyonu tercih edilmektedir. Şekil 2.13'de 5 sınıflı bir çıkışa sahip ESA mimarisindeki tam bağlantılı katman yapısı gösterilmektedir. Şekilde bahsedildiği üzere kendinde ki önceki katmanların nöronlarını


tek boyutlu hale getiren tam bağlantılı katmanın çıkışı giriş verilerinin etiketlerine ait 5 sınıf olmuştur.



Şekil 2.13 Tam Bağlantılı Katman Örneği (İnt.Kyn.15, Escontrela 2018).

2.6.4 Ters Evrişim Katmanı (Deconvolution Layer)

Bu katman bir üst örnekleme katmanıdır. Şimdiye kadar bahsedilen katmanların hepsi giriş görüntülerinde ki temel özellikleri temsil eden daha küçük boyutlu yapılara dönüştürmek için uygulanmaktadırlar. Ancak bu katman özellik haritalarını daha yüksek boyutlu bir uzaya yansıtma ihtiyacı için kullanılmaktadır. Otokodlayıcıların kod çözücü (decoder) yapılarında, bazı Generative Adversarial Networks (GAN) türlerinin jeneratör yapılarında, derin segmentasyon mimarilerinin kod çözücü (decoder) yapılarında giriş katmanına uygulanan veri ile aynı boyuta yükseltmek için kullanılmaktadırlar. Üst örnekleme işlemleri için enterpolasyon, ters havuzlama (unpooling) gibi yöntemlerin yanı sıra yaygın olarak eğitilebilir parametrelere sahip olan ters evrişim yöntemi tercih edilmektedir. Ters evrişim yöntemini evrişim işleminin tersi olarak düşünmek mümkündür. Evrişim katmanına benzer şekilde eğitilebilir parametrelere sahip olan bir filtre özellik haritası üzerinde dolaştırılmaktadır ancak evrişim katmanının aksine, her bir piksel filtre boyutu kadar genişletilmektedir. Örnek bir ters evrişim işlemi Şekil 2.14’de verilmiştir. Şekilde de görüldüğü üzere 2x2 boyutuna sahip bir özellik haritasının her pikseline ayrı ayrı 3x3 boyutundaki bir filtre birer adım kaydırma ile uygulanarak 4x4 boyutunda genişletilmiş bir özellik haritası oluşturulmuştur.




Şekil 2.14 Örnek ters evrişim işlemi.

2.6.5 Seyreltme (Dropout) Katmanı

Derin sinir ağlarının temel problemlerinden birisi de aşırı öğrenme veya ezberlemedir (Overfitting). Büyük sinir ağları nispeten küçük veri setleri ile eğitildiklerinde veri setini ezberleme eğilimine gitmektedir. Bunun sonucunda model eğitim setinde yüksek başarılar elde ederken eğitim verileri dışında oldukça düşük başarılar göstermesine neden olmaktadır. Seyreltme (Dropout) katmanı modelin ezberleme ve aşırı genelleme problemini kaldırmak için kullanılan hesaplı ve etkili bir yöntemdir. Eğitim sırasında rastgele düğümlerin ağırlıklarının 0 olarak ayarlanması mantığıyla çalışır.

Şekil 2.15’de seyreltme (dropout) katmanı uygulanmış bir ağın normal bir ağ yapısı ile kıyaslaması görülmektedir. Bu katman evrişim katmanlarının fonksiyonelliğini azaltması yönünden genellikle evrişim katmanlarından ziyade tam bağlantılı katmanlardan sonra tercih edilmektedirler. Tam bağlı katmanlardaki bazı bağların koparılması nöronların birbirlerine etkilerini azaltmakta ve bu sayede farklı şekillerde ağ yapısına sahip olacak modelin ezberlemesi engellenecektir.



Şekil 2.15 Normal Sinir Ağı ve Seyreltme (Dropout) Katmanı Kullanılmış Sinir Ağı.

2.6.6 Yığın Normalizasyon Katmanı (Batch Normalization Layer)

Yığın normalizasyon katmanı, her yığın grubu için katmanların girdilerini standartlaştırarak daha hızlı ve daha kararlı hale getirmek için kullanılan bir yöntemdir. Bir sinir ağının eğitiminde her yığın grubu değişiminde, önceki katmanlardan gelen girdiler ağırlık güncellemelerinden sonra değişebilir. Bu durum öğrenme algoritmasının hareketli bir hedefi sonsuza kadar kovalaması anlamına gelir. Bir katmanın aktivasyonlarına veya doğrudan girdilere uygulanarak ağ katmanlarının girişlerini standartlaştırmak için kullanılan bir tekniktir (Brownlee 2019). Yığın normalizasyon katmanı, öğrenme sürecini stabilize etme, ağdaki aşırı büyüklükteki ağırlıkları dengeleme ve derin ağları eğitmek için gereken eğitim dönemi sayısını önemli ölçüde azaltma etkisine sahiptir.

2.6.7 ESA Eğitim Hiper Parametreleri

Bir sinir ağında ağırlıkların eğitilmesi bir optimizasyon problemidir. Bu nedenle oluşturulan ESA modelinin eğitiminden önce eğitimde kullanılan bazı parametrelerin belirlenmesi gerekmektedir. Bu parametreler eğitim performansı üzerinde oldukça etkilidir.

2.6.7.1 Kayıp fonksiyonu (Loss Function)

Bir ESA'nın ağırlıklarının eğitilmesinin optimizasyon problemi olduğunu belirtmiştik. Modelin eğitiminde elde edilen çıktıların istenilen çıktılara yaklaşma miktarını gösteren

hata değerini ölçmek için kayıp fonksiyonları kullanılmaktadır. ESA modelinin eğitiminde temel amaç kullanılan kayıp fonksiyonu sonucunda elde edilen değeri minimize veya maksimize edene kadar ağırlıkları optimize etmektir. Bu sayede elde edilen sonuç, istenilen sonuca ideal seviyede yaklaşacaktır. Kullanılan birçok kayıp fonksiyonu bulunmaktadır ancak bu çalışma bir segmentasyon çalışması olduğu için Çizelge 2.1’de segmentasyon ağlarında kullanılan kayıp fonksiyonları (loss functions) gösterilmiştir.

Çizelge 2.1 Segmentasyon Mimarilerinde Kullanılan Kayıp Fonksiyonları (Jadon 2020).

Kayıp Fonksiyon	Formülasyon
İkili Çapraz Entropi (Binary Cross-Entropy)	$L_{BCE}(y, \hat{y}) = -(y \log(\hat{y}) + (1 - y) \log(1 - \hat{y}))$
Ağırlıklı Çapraz Entropi (Weighted Cross-Entropy)	$L_{w-BCE}(y, \hat{y}) = -(\beta * y \log(\hat{y}) + (1 - y) \log(1 - \hat{y}))$
Dengeli Çapraz Entropi (Cross-Entropy)	$L_{BCE}(y, \hat{y}) = -(\beta * y \log(\hat{y}) + (1 - \beta)(1 - y) \log(1 - \hat{y}))$
Merkezi (Focal)	$p_t \begin{cases} p, & \text{if } y = 1 \\ 1 - p, & \text{otherwise} \end{cases}$ $FL(p_t) = -a_t(1 - p_t)^y \log(p_t)$
Hassasiyet-Duyarlılık (Sensitivity-Specificity)	$SSL = w * \text{hassasiyet} + (1 - w) * \text{duyarlılık}$ $\text{hassasiyet} = \frac{TP}{TP + FN}$ $\text{duyarlılık} = \frac{TN}{TN + FP}$
Hausdorff Uzaklığı (Hausdorff Distance)	$d(X, Y) = \max_{x \in X} \min_{y \in Y} \ x - y\ _2$
Kombinasyon (Combo)	$L_{m-bce} = -\frac{1}{N} \sum_i \beta(y - \log(\hat{y})) + (1 - \beta)(1 - y) \log(-\hat{y})$ $CL(y, \hat{y}) = aL_{m-bce} - (1 - a)DL(y, \hat{y})$
Mesafe haritası kaynaklı kayıp ceza süresi (Distance map derived loss penalty term)	$L(y, p) = \frac{1}{N} \sum_{i=1}^N (1 + \odot)(\odot)L_{CE}(y, p)$
Zar Benzerlik Katsayısı (Dice)	$DL(y, \hat{p}) = 1 - \frac{2y\hat{p} + 1}{y + \hat{p} + 1}$
Tversky	$TL(p, \hat{p}) = 1 - \frac{1 + p\hat{p}}{1 + p\hat{p} + \beta(1 - p)\hat{p} + (1 - \beta)p(1 - \hat{p})}$
Merkezi Tversky (Focal Tversky)	$TI(p, \hat{p}) = \frac{p\hat{p}}{p\hat{p} + \beta(1 - p)\hat{p} + (1 - \beta)p(1 - \hat{p})}$ $FTL = \sum_c (1 - TI_c)^y$

Çizelge 2.1 (Devam) Segmentasyon Mimarilerinde Kullanılan Kayıp Fonksiyonları (Jadon 2020).

Kayıp Fonksiyon	Formülasyon
Şekle Duyarlı (Shape Aware)	$E_i = D(\hat{C}, C_{GT})$
	$L_{shape-aware} = -\sum_i CE(y, \hat{y}) - \sum_i i E_i CE(y, \hat{y})$
Üstel Logaritmik (Exponential Logarithmic)	$L_{Exp} = w_{Dice} L_{Dice} + w_{cross} L_{cross}$
	$L_{Dice} = E(-\ln(DC)^{y_{Dice}})$
	$L_{cross} = E(w_1(-\ln(p_t))^{y_{cross}})$
Lovász-Softmax	$loss(f) = \frac{1}{ C } \sum_{c \in C} \Delta_{J_c}(m(c))$

2.6.7.2 Öğrenme Oranı

Bir ESA modelinin eğitiminde kayıp fonksiyonu sonucunda elde edilen değere göre modelin ağırlıkları geri yayılım ile optimize edilmektedirler. Bu ağırlıkların güncellenmeleri belli değerlerde olmaktadır. Bu değerlere öğrenme oranı denilmektedir. 0-1 arasında küçük pozitif bir değer olan bu oran için önerilen 0.1^6 -1.0 aralığından bir değer seçmektir (Reed ve Marks 1999). Öğrenme oranı çok büyük olduğunda, öğrenme hızlı olacaktır ancak optimum değerlere yaklaşmak mümkün olmayacağı gibi bu değerlerden hızla uzaklaşma ihtimali oldukça fazladır. Öğrenme oranının çok düşük olması ise eğitim süresini arttırmasının yanı sıra optimizasyon fonksiyonu lokal optimum değerlere takılıp global bir optimum değer elde edemeyebilir ve yüksek eğitim hatasında sıkışıp kalabilmektedir. (Goodfellow vd. 2020). Bu nedenle mevcut sistemlerde eğitim sırasında değişken öğrenme oranları kullanılmaktadır. Örneğin başlangıçta yüksek seçilen öğrenme oranı belli aralıklarla azaltılabilmektedir veya uyarlanabilir öğrenme algoritmaları kullanılabilir. Uyarlanabilir öğrenme algoritmalarında eğitim performansı kontrol edilmekte ve öğrenme oranı buna göre ayarlanabilmektedir.

2.6.7.3 Mini-Yığın Boyutu (Mini-Batch Size)

Derin öğrenme modellerinin eğitiminde çok büyük veriler ile çalışıldığı için verilerin aynı anda eğitilmesi oldukça büyük bellek maliyeti gerektirebilmektedir. Bu nedenle ağırlıkları güncellemek için veri seti parçalar/yığınlar halinde eğitime dahil edilmektedir. Bir modelin ağırlıklarının güncellenmesi için bir iterasyonda modele verilen veri sayısına mini yığın boyutu denilmektedir. Mini yığın boyutu kullanmanın avantajları;

- Model daha az veri kullanarak eğitildiği için, genel eğitim prosedürü daha az bellek gerektirir.
- Her iterasyondan sonra ağırlıklar güncellendiği için eğitim daha hızlı tamamlanır.

Mini yığın boyutunun küçük seçilmesi eğitimin daha küçük bellek boyutu ile daha hızlı gerçekleşmesini sağlayacaktır. Öte yandan bu durum ağırlıkların sık güncellenmesi anlamına geldiği için optimum model parametrelerinin ve dolayısıyla minimum model hatasının elde edilmesini zorlaştırabilmektedir. Mini yığın boyutunun büyük seçilmesi ise büyük bellek ve daha yavaş bir eğitim sürecine sebep olur. Ancak minimum model hatasına yavaşça yakınsayan bir öğrenme süreci sağlar. Bu nedenle optimum bir mini yığın değeri belirlemek oldukça önemlidir (Brownlee 2020). Mini yığın değerinin toplam eğitim verisine eşit olması yığın yöntemi, mini yığın değerinin 1 olması ise rasgele (stochastic) yöntem olarak adlandırılır.

2.6.7.4 Epok Sayısı


Derin öğrenme modellerinin eğitimi yinelemeli bir süreçtir. Yani modeli veri seti ile bir kez eğitmek yeterli değildir. Derin öğrenme modelinin tüm veri seti ile kaç kez eğitileceğini epok sayısı ifade eder. İlk epokta yani ilk eğitimde büyük olması beklenen hata değerinin ilerleyen epoklarda azalması gerekmektedir. Ancak epok sayısının optimum değerden fazla olması yani modelin gereğinden fazla aynı veri seti ile eğitilmesi modelin ezberleme problemine neden olmaktadır. Bu süreç bir öğrencinin

eđitimine benzetilebilir. Bir konuyu öđrencinin anlayabilmesi için birçok kez örneklerle pekiştirilmesi gerekmektedir. Ancak öđrencinin aynı örnekler ile konuyu geređinden fazla tekrar etmesi, öđrencinin örnekleri sadece ezberlemesine ve farklı örnekler ile karşılaştığında yorum yapamamasına neden olacaktır. Eđitim için optimum epok değerin bulunmasında belirli bir yöntem yoktur. Ancak eđitime dahil edilecek validasyon verileri ile sistemin ezberleme eğilimi kontrol edilebilir. Validasyon verileri eğitim verilerinden farklı olarak eğitim sürecinde belli aralıklar ile modeli test etmek için kullanılırlar. Validasyon verilerine göre modelin ağırlıkları güncellenmez yani bu veriler modelin eğitimine dahil edilmemektedirler. Sonuç olarak eğitim sürecinde belli aralıklarla modeli validasyon verileri ile kontrol ederek validasyon hata değeri yükselmeye başladığında eğitimi durdurmak mümkündür.

2.7 Transfer Öğrenme

Elde edilen deneyimler sonucunda ESA'da katman sayısını belli oranda arttırmak modelin performansını oldukça arttırabilmektedir. Ancak sıfırdan bir ESA modelini oluşturup eğitmek oldukça maliyetlidir. Çünkü derin öğrenme modellerinin dezavantajlarından birisi eğitim için oldukça fazla veriye ihtiyaç duymalarıdır. Bu nedenle çalışmalarda, yoğunlukla daha önce ImageNet gibi büyük veriler ile eğitilmiş ve oldukça başarılı sonuçlar elde etmiş mimariler kullanılmaktadır. Bu önceden eğitilmiş modeller görüntüyü nasıl analiz edeceğini öğrenmiştir ve bu modellerin özellik haritaları kullanılarak kendi problemlerimiz için daha az veri ile modeli yeniden eğitip kullanmak mümkündür (İnt.Kyn.12). Bu sayede daha az hesaplama maliyeti ile daha başarılı sonuçlar elde edilebilmektedir. Bu yönetime transfer öğrenme denilmektedir. Şekil 2.16 Bianco ve arkadaşları (Bianco vd. 2018) tarafından hazırlanmıştır ve 2018 yılına kadar sunulan modellerin bir değerlendirmesini göstermektedir. Şekle bakıldığında mimarinin parametre sayısı veya kompleksliği arttığında başarının arttığı genellemesini yapmak çok yanlış olmayacaktır. Ancak bazı çalışmalar her problem için Şekil 2.16'da verilen başarı sıralamasının elde edilmeyeceğini göstermektedir. Örneğin şekilde ImageNet veri seti için Top-1 doğruluk değeri en düşük olan AlexNet mimarisi iken Dođan ve Türkođlu (Dođan ve Türkođlu 2018)'nun yaptığı çalışmada AlexNet mimarisinin GoogleNet, Vgg16, Vgg19, ResNet50 mimarilerinden daha iyi performans

gösterdiği görülmektedir. Bu nedenle uygulanacak transfer öğrenme yönteminde birkaç modeli test etmek doğru bir yöntem olacaktır.




Şekil 2.16 2018 yılına kadar sunulan modellerin bir değerlendirmesi (Bianco vd. 2018).

2.8 Segmentasyon İşlemlerinde Derin Öğrenme Mimarilerinin Kullanımı

Otomatik analiz sistemleri genellikle ön işleme, segmentasyon, özellik çıkarımı ve sınıflandırma olmak üzere 4 aşamadan oluşmaktadır (Pereira vd. 2020). Ancak ESA mimarilerinde özellik çıkarma işlemi mimari tarafından otomatik olarak gerçekleştirilmektedir. Analiz sisteminin temeli sınıflandırma aşaması gibi görünse de sınıflandırma basamağında kullanılacak verilerin niteliği bu aşamanın başarısı için oldukça önemlidir. Ön işlem basamağında yapılacak işlemler elde edilecek özelliğin belirleyiciliğini arttırabilirken, segmentasyon basamağı belirleyici olmayan gürültü özellikleri engelleyecektir.

Segmentasyon, ilgilenilen bir bölgeyi çıkartmak için bir görüntünün belirli bir özelliğe dayalı olarak birkaç alt bölgeye bölündüğü bir işlemdir. Görüntü segmentasyonunun çıktısı özellikle görüntü tanıma sistemlerinde oldukça önemlidir. Segmentasyon görüntünün daha kolay analizini sağlarken bir diğer yandan segmentasyondan elde edilecek başarılı veya başarısız sonuçlar, özellik çıkarma ve sınıflandırma aşamalarına aktarılacaktır. Literatürde birçok çalışma segmentasyon işlemini kendisine göre farklı sınıflandırmıştır. Bunlardan bazıları aşağıda listelenmiş ve Zaitoun ve Aqel tarafından yapılan sınıflandırma ise Şekil 2.17’de verilmiştir;


- Kenar Tabanlı , Eşikleme Tabanlı, Bölge Tabanlı , Özellik Tabanlı Kümeleme (Mariyammal ve Sasireka 2018)
- Kenar Tabanlı , Eşikleme Tabanlı, Bölge Tabanlı, Fuzzy Yöntemi , Kümeleme, Yapay Zekâ Teknikleri (Sonawane ve Dhawale 2015)



Şekil 2.17 Zaitoun ve Aqel tarafından yapılan segmentasyon sınıflandırması (Zaitoun ve Aqel 2015).

Görüldüğü üzere segmentasyon yöntemlerinin temel bir sınıflandırma şekli yoktur ancak görüntü segmentasyonunda kullanılan birçok yöntem mevcuttur. Son yıllarda yapılan çalışmalardan birisi olan Adegun ve Viriri (Adegun ve Viriri 2020) yaptıkları

araştırmalar sonucunda cilt lezyonu segmentasyon işlemlerini eşikleme ve kümeleme tabanlı (Yüksel ve Borlu 2009, Ms.S.Premalatha 2020, ŞAHİN ve ALPASLAN 2020), kenar ve bölge tabanlı (Abbas vd. 2011, Ashour vd. 2021), geleneksel zekâ tabanlı (Ms.S.Premalatha 2020, Ashour vd. 2021) ve derin öğrenme yöntemleri olarak 4 sınıfta incelemiş ve literatürdeki çalışmaları analiz ederek her yöntemin avantaj ve dezavantajlarını sunmuşlardır. Araştırmacıların sundukları analizlere bakıldığında ilk 3 yöntemin dezavantajları segmentasyon performansı üzerinde etkili olan sebepler iken derin öğrenme tabanlı yöntemlerin segmentasyon sonucunu etkileyecek bir dezavantajı bulunmadığı görülmektedir. Ayrıca derin öğrenme yöntemleri, karmaşık yapıya sahip problemleri geleneksel yöntemlerden daha iyi analiz edebilmektedirler. Daha önce yapılan çalışmalarda tıbbi görüntü analizlerinde oldukça fazla analitik yaklaşım bulunmaktadır ancak son yıllarda analiz edilebilecek verilerin artması ve bilgisayar donanım sistemlerindeki gelişmeler sayesinde derin öğrenme yöntemleri tıbbi görüntü analizlerinde büyük bir gelişme göstermiş ve elde ettiği yüksek doğruluk değerleri sayesinde en çok kullanılan ve geliştirilen yöntemler haline gelmiştir. Örneğin Minaee ve arkadaşları (Minaee vd. 2020) tarafından hazırlanan Şekil 2.18’de 2014’den 2020 yılına kadar geliştirilen bazı derin segmentasyon mimarileri yer almaktadır.




Şekil 2.18 2014-2020 yılları arasında geliştirilen segmentasyon mimarileri (Minaee vd. 2020).

Liu ve arkadaşları (Liu vd. 2021a) tıbbi görüntü segmentasyonu için sıkça tercih edilen derin öğrenme tabanlı yöntemleri Tam Evrişimli Ağlar (TEA), U-Net ve GAN olmak üzere üç kategoriye ayırmıştır.

TEA modeli (Long vd. 2015a) mimarisindeki son evrişim katmanının özellik haritasını


yukarı örneklemek ve bu sayede giriş görüntüsü ile aynı boyuta getirebilmek için sınıflandırma ağının tamamen bağlantılı katmanı yerine ters evrişim katmanını kullanır. Böylece, orijinal girdi görüntüsünde uzamsal bilgi korunurken, her piksel için ayrı ayrı sınıflandırma yapılarak bir tahmin üretilebilir. Yukarı örneklemenin boyut artırma oranına göre TEA mimarileri FCN-32, FCN-16 ve FCN-8 olarak ayrılmıştır. TEA modellerinin genel yapısı Şekil 2.19'da verilmiştir.



Şekil 2.19 TEA model yapısı (Long vd. 2015b).


TEA mimarisini öneren araştırmacılar yüksek özellik haritası elde etmek için ilk evrişim katmanında görüntüye 100 birim dolgu (padding) ekleme işlemi uygulamışlardır, bu durumun çok fazla gürültü getireceğini düşünen Chen ve ekibi (Chen vd. 2018) Deeplab segmentasyon mimarilerini önermişlerdir. Deeplab segmentasyon mimarileri seri halinde birbirlerinin dezavantajlarını gidermek üzere oluşturulmuş 4 versiyon içermektedir. DeepLabV3+ mimarisi Google araştırmacıları Chen ve ekibi (Chen vd. 2018) tarafından önerilen DeepLabV1 mimarisinin geliştirilmiş en güncel versiyonudur. VGG-19 mimarisi temel alınarak oluşturulan DeepLabV1 mimarisinde TEA mimarisinin ilk evrişim katmanına uygulanan 100 birimlik dolgu işlemi yerine 1 birim padding uygulanırken, havuzlama katmanında uygulanan 2 birim kaydırma işlemi 1 birime düşürülmüştür, ayrıca atrous evrişim katmanları kullanılmaktadır ve bu sayede normalde boyutu azalan görüntü haritalarının boyutlarının azalması parametre sayısı ve hesaplama maliyetini arttırmadan önlenmiştir. Ayrıca piksel düzeyinde sınıflandırma yerel ayrıntılarda çok yetersiz kalmaktadır. Bu nedenle koşullu rastgele alan yöntemi ile ayrıntılı bilgileri optimize etmişlerdir. Daha karmaşık ve etkili bir mimari olan ResNet-

101 mimarisi temeli tercih edilen DeepLabV2 (Chen vd. 2018b) mimarisinde tanıtılan Boşluklu Uzamsal Piramit Havuzlama (Atrous Spatial Pyramid Pooling-ASPP) yapısı ağlara birden çok ölçekte segmentlere ayırabilme özelliği katmıştır (Menteşe vd. 2020). Bunun yanı sıra derin öğrenme mimarilerinde alt örnekleme ve havuzlama katmanlarının neden olduğu çözünürlük kaybını azaltmak için son maksimum havuzlama katmanlarındaki alt örnekleme kaldırılmışlar ve bunun yerine, daha yüksek örnekleme yoğunluğuna sahip özellik haritalarını hesaplamak için atrous konvolusyon katmanı kullanmışlardır. Ayrıca, ağdaki tamamen bağlı katmanı çıkarmışlar ve segmentasyon sınırının doğruluğunu artırmak için koşullu bir rastgele alan kullanarak onu tamamen evrişimli bir katmanla değiştirmişlerdir. DeepLabV3 mimarisinde DeepLabV2 mimarisinde kullanılan Boşluklu Uzamsal Piramit Havuzlama (ASPP) modülü görüntü düzeyi özelliği ile genişletilmiştir ve çok ölçekli segmentasyon problemi için kademeli veya paralel bir evrişim modülü uygulanmıştır. DeepLabV3+ (Chen vd. 2018) mimarisinde ise çıktı segmentasyon sonuçlarını iyileştirmek için basit ve etkili bir kod çözücü (decoder) modülü eklenmiştir. Çıktı görüntüsünün etkisini büyütmek ve iyileştirmek için, orta katmanın özellik haritaları kullanılmıştır. Şekil 2.20’de Deeplab V3+ mimarisi görülmektedir.



Şekil 2.20 Deeplab V3+ mimarisi (Chen vd. 2018a).


Bir diğer TEA temeline dayalı segmentasyon mimarisi, uçtan uca piksel düzeyinde görüntü segmentasyonu gerçekleştirmek için kodlayıcı (encoder)-kod çözücü (decoder) simetrik yapısına sahip SegNet (Badrinarayanan vd. 2017)'dir. Kodlayıcıda (encoder) VGG-19 mimari yapısı temel alınırken kod çözücü (decoder) bölümünde her piksel, nesne bilgisine karşılık gelen renk veya etiketle temsil edilir. TEA mimarisinden farkı, kod çözücünün (decoder) giriş özelliği haritasını doğrusal olmayan bir şekilde yukarı örneklemek için kodlayıcıdan (encoder) iletilen daha büyük bir havuzlama indeksi kullanması ve bu sayede daha düşük çözünürlükle üst örnekleme biçiminde yapmasıdır. Ayrıca yoğun bir özellik haritası oluşturmak için eğitilebilir evrişim çekirdeği kullanılmaktadır. Şekil 2.21'de SegNet mimarisinin (Badrinarayanan vd. 2017) yapısı görülmektedir.



Şekil 2.21 SegNet mimarisi (Badrinarayanan vd. 2017).

U-Net mimarisi ilk olarak Ronneberger ve arkadaşları (Ronneberger vd. 2015) tarafından önerilen özellikle biyomedikal görüntülerinin segmentasyonunda yaygın olarak kullanılan ve U şeklinde kanal ve atlama bağlantısına sahip bir mimaridir. U kanalı, SegNet'in kodlayıcı (encoder)-kod çözücü (decoder) yapısına benzer. Kodlayıcı (encoder) yapısı, her biri iki evrişim katmanı ve ardından bir havuzlama katmanı içeren dört alt modüle sahiptir. Kod çözücü (decoder) yapısı da benzer şekilde dört alt modül içerir. Çözünürlük, örnekleme ile art arda artırılır. Ardından her piksel için tahminler verir. Tam bağlı katman içermeyen mimaride, ayrıca üst örnekleme sonucunu kodlayıcıdaki (encoder) bir alt modülün çıkışıyla bağlayan ve aynı çözünürlüğe sahip kod çözücü (decoder) alt modül girişine uygulayan bir atlama bağlantısı kullanılır. Şekil 2.22'de U-Net mimari yapısı görülmektedir. Mimarinin tıbbi görüntü segmentasyonu

için uygun olmasının temel nedeni, hem düşük seviyeli hem de yüksek seviyeli bilgileri birleştirebilmesidir (Liu vd. 2021b).




Şekil 2.22 U-Net mimari yapısı (Ronneberger vd. 2015).

Milletari ve arkadaşları (Milletari vd. 2016) U-Net yapısından temel alarak 3 boyutlu U-Net mimarisi olan V-Net mimarisini önermişlerdir. Mimaride temel olarak görüntü evrişim işlemleri için 3 boyutlu evrişim çekirdeği (kernel) ve kanal boyutunu azaltmak için $1 \times 1 \times 1$ evrişim çekirdeği (kernel) kullanılmıştır, ayrıca çapraz entropi (cross-entropy) kayıp fonksiyonu yerine Dice kayıp fonksiyonu tercih edilmiştir. Bunların yanı sıra retina kan damarları görüntü segmentasyonu için kullanılan Res-UNet (Xiao vd. 2018) ve kontrastlı CT görüntülerinden karaciğer ve karaciğer tümörünü segmentlere ayırmak için kullanılan H-DenseUNet (Li vd. 2018) (hibrit yoğun bağlı U-Net) sırasıyla artık (residual) bağlantılardan ve yoğun (dense) bağlantılardan esinlenmiş diğer U-Net mimarileridir.

Son temel yapı Goodfellow ve arkadaşları (Goodfellow vd. 2014) tarafından önerilen Üretken Çekişmeli Ağlar (ÜÇA) literatürde bilinen ismiyle Generative Adversarial Network-GAN'dır. 2 bölümden oluşan ÜÇA yapısında ilk bölümü, rastgele bir gürültü

aracılığıyla bir görüntü oluşturan üretim ağı, ikinci bölüm ise bir görüntünün gerçek mi yoksa sahte mi olduğunu karar vermeye çalışan karar ağıdır. Üretici ağ, sahte veriler üretirken; karar ağı, verinin gerçekliğini belirlemek için bir ayırıcı kullanarak gerçek mi sahte mi karar verir (Liu vd. 2021). Şekil 2.23 ÜÇA yapısının bir blok şemasını göstermektedir.



Şekil 2.23 ÜÇA yapısı (Liu vd. 2021).

ÜÇA yapısı ile segmentasyon çalışmaları yapan ilk araştırmacılar, anlamsal evrişimli segmentasyon ağını ve ÜÇA'nın özelliklerini birleştiren Luc ve arkadaşları (Luc vd. 2016) olmuştur. Daha sonra ÜÇA yapısını kullanan birçok segmentasyon çalışması literatüre eklenmiştir. Bunlara U-Net mimarisini ÜÇA yapısında üretici olarak kullanan Xue ve arkadaşları (Xue vd. 2018) tarafından üretilen SegAN mimarisi, Dai ve arkadaşları (Dai vd. 2018) tarafından göğüs X-Ray görüntülerinde akciğer alanını ve kalbi segmentlere ayırmak için önerilen SCAN mimarisi ve Khosravan ve arkadaşları (Khosravan vd. 2019) tarafından etkili ve hesaplama maliyeti düşük 3 boyutlu segmentasyon için önerilen PAN mimarisi örnek olarak verilebilir.


2.9 Cilt Lezyonlarının Segmentasyonunda Kullanılan Veri Setleri

Cilt kanserlerinin analizinde literatürde yaygın olarak kullanılan veri setleri bulunmaktadır. Valle ve arkadaşları (Valle vd. 2020) yaptıkları incelemeler ile Şekil 2.24'deki veri setlerinin cilt kanseri çalışmalarında en yaygın olan veri setleri olduğunu belirtmişlerdir. Literatürde cilt lezyon çalışmalarında kullanılan veri setleri ve içerikleri şu şekilde sıralanabilir;

- DermQuest (İnt.Kyn.13): 73 melanom, 61 melanom olmayan görüntüsünden oluşan oldukça küçük bir veri setidir.

- DermIS (Almansour vd. 2016): 43 melanom , 26 melanom olmayan görüntüsü içerir.
- Dermofit (Ballerni vd. 2013): 239 Basal cell carcinoma , 78 intraepithelial carcinoma, 45 actinic keratosis, 331 melanosit nevus, 257 seborrheic keratosis, 96 emangioma, 88 squamous cell carcinoma, 24 pyogenic granuloma, 65 dermatofibroma, 76 melanom olmak üzere 1300 görüntüden oluşur.
- PH2 (Mendonca vd. 2013) : 80 common nevi, 80 atypical nevi ve 40 melanom olmak üzere toplam 200 görüntü içerir.
- EDRA Interactive Atlas of Dermoscopy (Argenziano vd. 2002): 270 melanoms, 49 seborrheic keratoses içeren 1000'den fazla görüntü içermektedir.
- ISIC2017 (Codella vd. 2018): 374 melanom, 254 seborrheic keratosis ve 1372 benign nevi olmak üzere 2000 görüntüden oluşur.
- ISIC 2018 (Codella vd. 2018, Tschandl vd. 2018): 327 actinic keratoses, 514 basal cell carcinoma, 1099 benign keratosis lezyon, 115 dermatofibroma, 1113 melanom, 6705 melanosit nevi, 142 vascular lezyon görüntüsü içeren 10015 görüntüden oluşmaktadır.
- ISIC 2019 (Combalia vd. 2019): 867 actinic keratoses, 3323 basal cell carcinoma, 2624 benign keratosis lezyonlar, 239 dermatofibroma, 4522 melanom, 12875 melanosit nevi, 253 vascular lezyonlar, 628 squamous cell carcinoma görüntüsü içeren 25332 görüntüden oluşmaktadır.

Ancak belirtilen veri setlerinin tamamı segmentasyon çalışmaları için uygun değildir. Veri setinin denetimli derin öğrenme yöntemlerinde segmentasyon amacı ile kullanılabilmesi için gerçek referans değer (ground truth) görüntülerini içermesi gerekmektedir. Yapılan literatür taraması cilt lezyonlarının segmentasyon çalışmaları için özellikle The International Skin Imaging Collaboration (ISIC) Dermoskopi arşivi ve PH2 veri seti kullanıldığını göstermektedir.



Şekil 2.24 Cilt kanseri çalışmalarında en yaygın kullanılan veri setleri (Valle vd. 2020).

2.10 Literatür İncelemesi

Şekil 2.18’de görüldüğü üzere ilk olarak Long ve arkadaşları (Long vd. 2015) CNN tabanlı segmentasyon modellerinden biri olan TEA derin öğrenme modelini önermişlerdir. Bu modelin yeniliği piksel bazlı çıktının sınıflandırılabilmesi için aktivasyon haritalarının üst örneklemesini içeren bir katman içermesidir. Derin öğrenme mimarilerinin segmentasyon çalışmalarında kullanılabileceğinin anlaşılması ile bu alanda yapılan çalışmalar giderek hız kazanmıştır. Bunun sonucunda derin segmentasyon mimarilerinin elde ettiği başarılar diğer segmentasyon yöntemlerini geçerek literatürde oldukça geniş bir yer edinmişlerdir.

Son yıllarda yapılan derin öğrenme tabanlı cilt lezyonu segmentasyonu çalışmalarına bakıldığında farklı yaklaşımlar görmek mümkündür. Zafar ve arkadaşları (Zafar vd. 2020) çalışmalarında eğitim için ISIC2017 eğitim setini (Gutman vd. 2016), test için ise ISIC2017 test seti (Gutman vd. 2016) ile birlikte PH2 (Mendonça vd. 2013) veri setlerini kullanmışlardır. Görüntüler için normalizasyon, standardizasyon, yeni bir saç giderme algoritması ve yeniden boyutlandırma ön işlemlerini kullanan araştırmacılar, segmentasyon işlemi için U-Net ve ResNet derin öğrenme mimarilerinin kombinasyonundan oluşan bir mimari önermişlerdir.

Hasan ve arkadaşları (Hasan vd. 2020) yaptıkları çalışmada eğitim için ISIC2017 açık erişimli eğitim verilerini kullanırken test için ISIC2017 (Gutman vd. 2020) ve PH2 (Mendonça vd. 2013) veri setlerini kullanmışlardır. Görüntülerdeki cilt lezyonlarının segmentasyonu için parametre sayısını azaltmak amacıyla derinlemesine ayrılabilir bir evrişim mimarisi kullanarak DSNet adını verdikleri bir derin öğrenme mimarisini önermişlerdir.

Goyal ve arkadaşları (Goyal vd. 2020) çalışmalarında ISIC2017 veri setini (Gutman vd. 2020) kullanmışlardır. Çok sınıflı segmentasyon mimarisi tasarlayan araştırmacılar, mimari tasarımında FCN-AlexNet, FCN-32s, FCN-16s ve FCN-8s derin öğrenme mimarileri kullanmışlardır. Ayrıca segmentasyon işlemini çok sınıflı yapabilmek için veri setindeki gerçek referans değer (ground truth) verilerini 8-bit paletli ve RGB formatında tanımlamışlardır.

Xie ve arkadaşlarının (Xie vd. 2020) yaptıkları çalışmada ise eğitim için ISIC2017 eğitim (Gutman vd. 2020), test için ISIC2017 test (Gutman vd. 2020), ISIC2016 ve PH2 (Mendonça vd. 2013) veri setlerini kullanmışlardır. Araştırmacılar çalışmalarında cilt lezyon segmentasyonu için tasarladıkları 3 farklı yüksek çözünürlüklü özellik bloklarını (high-resolution feature block) kullanarak bir ESA mimarisi tasarlamışlardır. Görüntüleri derin öğrenme mimarisine vermeden önce yeniden boyutlandırmışlar ve çevirme, döndürme (flip ve rotation) veri arttırma tekniklerini kullanarak veri sayısını arttırmışlardır.

Liu ve arkadaşları (Liu vd. 2019) ISIC2017 veri setini kullandıkları çalışmalarında, U-Net mimarisi temelini kullanarak yeni bir segmentasyon mimarisi önermişlerdir. Orijinal U-Net mimarisinden farklı olarak aşırı uyum sorununu önlemek için yığın normalizasyon katmanı ve çözünürlüğü kaybetmeden algılama alanını genişletmek için genişletilmiş konvolüsyon katmanı uygulamışlardır. Ayrıca veri arttırma yöntemi ile görüntü sayısını 2000'den 48000'e çıkaran araştırmacılar, eğitimi RGB ve HSV renk kanallarını kullanarak gerçekleştirmişlerdir.

Öztürk ve Özkaya (Öztürk ve Özkaya 2020), ISIC2017 veri setini kullandıkları çalışmalarında TEA mimarisinden esinlenerek tasarladıkları bir ESA segmentasyon mimarisi önermişlerdir. Segmentasyon işlemi olumsuz etkileyecek faktörlerin etkisini ortadan kaldırmak için görüntülerin RGB renk uzayına ek olarak, HSV renk uzayından S bileşeni, YIQ renk uzayından I bileşeni, YCbCr renk uzayından Cb bileşeni ve XYZ renk uzayından Z bileşenini çalışmalarında kullanmışlardır. Araştırmacılar, RGB renk uzayının R bileşeninde lezyon alanlarının olmadığı, R bileşeninin saç ve koyu renkli işaretlerin belirlenmesinde uygun olduğunu, G bileşeninin lezyon örneklerindeki dalgalanma için yararlı olduğunu, B bileşeninin ise lezyonun lokasyonunu belirlemede faydalı olduğunu; HSV uzayının, S bileşeninin epilasyon sonrası lezyonu açıkça gösterdiğini; YIQ renk uzayının, I bileşeninin lezyon görüntülerinde koyu renkli işaretçileri bulmak için kullanışlı olduğunu; YCbCr uzayının Cb bileşeninin, lezyonun daha spesifik sayılarda görünmeyen kısımlarını ortaya çıkardığını; XYZ uzayının Z bileşeninin, lezyonun tüm kenar ayrıntılarını içerdiğini belirtmişlerdir. ESA mimarisinin kod çözücü (decoder) bölümünde kenar bilgisini korumak için daha yoğun bir ters evrişim tekniği uygulamışlardır. Önerilen mimaride 13 evrişim, 5 havuzlama, 2 tam bağlantılı katman içeren kodlayıcı bölümünü, 3 ters evrişim katmanı içeren kod çözücü (decoder) bölümü takip etmektedir. Görüntü ön işleme uygulamayan araştırmacıların oldukça başarılı sonuçlar elde ettikleri görülmektedir. Sarker ve arkadaşlarının (Sarker vd. 2018) ISIC2017 ve ISIC2016 veri setlerini kullandıkları çalışmalarında kodlayıcı (encoder) kısmında genişletilmiş artık (residual) ağı ve kod çözücü (decoder) kısmında piramit havuzlama ağını birleştiren bir model önermişlerdir. Genişletilmiş artık ağı ile piramit havuzlama ağlarının bu birleşiminin görüntülerden çıkartılan özellik miktarını artırdığını belirten araştırmacıların önerdikleri modelin son kısmında iki sınıflı segmentasyonda başarılı olan Negatif Log Olasılık (Negative Log Likelihood) fonksiyonu ve melanom sınırlarını korumak için içerik kaybı fonksiyonu olarak Bitiş Noktası Hatasını (End Point Error) birleştiren yeni bir kayıp fonksiyonu kullanmışlardır.


Bi ve arkadaşları (Bi vd. 2019) ISIC2017, ISIC2016 ve PH2 veri setlerini kullandıkları çalışmalarında ResNet tabanlı TEA modelini temel alan yeni bir sınıfa özgü segmentasyon mimarisi önermişlerdir. Araştırmacılar eş zamanlı olarak melanom,

melanom olmayan ve tüm verilerle; ayrı ayrı eğitilen 3 ResNet tabanlı TEA mimarisi ve dermoskopik görüntülerin ayrımı için ResNet tabanlı bir CNN mimarisini kullanarak hibrit bir mimari oluşturmuşlardır.

Al-Masni ve arkadaşları (Al-masni vd. 2018) cilt lezyon segmentasyonu için ISIC2017 ve PH2 veri setlerini kullanarak yaptıkları çalışmada giriş verilerinin her bir pikselinin tüm çözünürlük özelliklerini doğrudan öğrenen tüm çözünürlüklü CNN (FrCN) mimarisi önermişlerdir. ISIC2017 veri seti görüntülerinin RGB renk uzayının yanı sıra HSV renk uzayını da çalışmaya dahil eden ve 0,90,180,270 derece döndürme işlemi uygulayarak veri artırma yöntemi uygulayan araştırmacılar eğitim için 16000 görüntü kullanmışlardır. VGG-16 mimarisinden esinlenen araştırmacılar mimarideki tüm alt örnekleme katmanlarını kaldırmış ve mimarinin son kısmında bulunan 3 tam bağlantılı katman yerine evrişim katmanı ekleyerek kod çözücü (decoder) kısmı olmayan bir segmentasyon mimarisi önermişlerdir.

Ren ve arkadaşları (Ren vd. 2021) ISIC2017 veri setini kullandıkları cilt lezyonlarının segmentasyonu için yaptıkları çalışmada DenseASPP (Yang vd. 2018) modeline mekânsal özellikleri ve katman özelliklerini birbirlerine bağımlı olacak şekilde bir araya getiren iki dikkat modülü ekleyerek yeni bir segmentasyon mimarisi önermişlerdir.

Yuan ve arkadaşları (Yuan vd. 2017, Yuan ve Lo 2019) ISIC2017 veri setini kullanarak yaptıkları çalışmalarda uçtan uca (end-to-end) yöntemini kullanarak 19 katmanlı derin evrişimli segmentasyon mimarisi önermişlerdir. Çalışmada HSV ve CIELAB renk uzaylarının daha etkili bir eğitim elde etmek için ağa ek bir girdi olarak kullanımının etkisini incelemiş bunun yanı sıra ön plan ve arka plan piksel oranlarının dengesizliğini ortadan kaldırmaya yardımcı olan, Jaccard mesafesine dayalı yeni bir kayıp fonksiyonu tasarlamışlardır.




Resim 2.1 Cilt lezyonu görüntülerindeki artefaktlar a. Kahverengi lezyon b. Siyah kıllar c. Kahverengi lezyonlu siyah tüyler d. İşaretçiler e. Lezyon üzerinde beyaz kalıntılar f. Lezyon üzerindeki beyaz kalıntılar g. Beyaz ve belirsiz lezyonlar h. Belirsiz lezyonlar (Öztürk ve Özkaya 2020).

Cilt lezyonlarının segmentasyonu karmaşık cilt koşulları ve bulanık sınırları nedeniyle hala zorlu bir görevdir. Öztürk ve arkadaşlarının (Öztürk ve Özkaya 2020) yaptığı çalışmada cilt lezyonlarının segmentasyonunu zorlaştıran problemler Resim 2.1'de verilmiştir. Cilt lezyonlarının segmentasyonu bu nedenle literatürde hala güncel bir problemdir. Ayrıca yapılan çalışmalar incelendiğinde oluşturulan segmentasyon mimarilerinin performansını arttırmak için uygulanan yöntemler matematiksel hesaplama maliyetini arttırmakta ve uygulanabilmesi için daha gelişmiş bilgisayar sistemlerine ihtiyaç duyulmaktadır. Bu çalışmanın amacı hesaplama maliyetinde büyük bir ihtiyaç oluşturmadan cilt lezyon segmentasyonunun performansını arttıracak yöntemler uygulamaktır.

3. MATERYAL VE METHOT


Bu çalışmada cilt lezyonlarının tam otomatik segmentasyonu için FCN-AlexNet mimarisi temel alınarak yeni bir segmentasyon mimarisi tasarlanmış ve mimarinin performansını arttırmaya yönelik farklı görüntü ön işleme teknikleri ve hiper parametreler denenerek değerlendirilmiştir. Gerçekleştirilen çalışma basamakları Şekil 3.1'deki akış şemasında da sunulduğu gibi görüntü ön işleme, segmentasyon ve segmentasyon sonuçlarının karşılaştırmasından oluşmaktadır.



Şekil 3.1 Çalışmaya ait akış diyagramı.

3.1 Materyal

Çalışmada eğitim ve test aşamaları için daha önce yapılan segmentasyon çalışmalarının büyük bir oranında tercih edilen ISIC2017 (Gutman vd. 2020) veri seti kullanılmıştır. Uluslararası Cilt Görüntüleme İş Birliği (The International Skin Imaging Collaboration| ISIC), melanom ve diğer cilt kanserlerinin otomatik bilgisayar destekli teşhis yöntemlerini desteklemek için farklı ülkelerdeki uzmanlar tarafından analiz edilmiş dijital cilt lezyonu görüntülerinden oluşan farklı veri setlerini her yıl araştırmacıların kullanımına sunarak yarışmalar düzenlemektedir. Açık erişimli olarak cilt lezyonlarının hem segmentasyonunu hem de sınıflandırmasını yapmaya uygun şekilde araştırmacıların kullanımına sunulan veri setlerinden ISIC2017 derin öğrenme mimarilerinin eğitiminde literatürde en çok kullanılan veri setidir. ISIC2017 veri seti 2000 eğitim, 150 validasyon ve 600 test görüntüsü içeren farklı boyutlara sahip toplam 2750 görüntüden oluşmaktadır. Veri seti melanosit naevus, melanom ve seborrhoeic keratosis olarak 3 sınıftan oluşan cilt görüntülerinden oluşmaktadır. Şekil 3.2 veri setinden alınan farklı sınıflara ait birer örnek görüntüyü ve bu görüntülere ait gerçek referans (ground truth) segmentasyon görüntülerini göstermektedir.



Şekil 3.2 ISIC2017 veri seti örnek görüntüleri ve gerçek referans (ground truth) görüntüleri.

3.2 Metot


3.2.1 Ön işlem

Daha önce yapılan çalışmalar göstermiştir ki görüntü kalitesinin iyileştirilmesi için yapılan ön işleme yöntemleri segmentasyon işlemlerinin performansını arttırmaktadır (Bow 2002, Sudeep ve Pal 2017, Uysal ve Güraksin 2020). Bu nedenle mimarilerin performanslarını arttırmak için bu çalışmada görüntülere farklı boyutlarda yeniden boyutlandırma, renk sabitleme ve kontrast sınırlı adaptif histogram eşitleme (KSAHE) gibi ön işlem basamakları uygulanarak performans üzerine etkileri değerlendirilmiştir.

Çalışmada FCN-AlexNet mimarisinin giriş katmanı 448x448x3, 224x224x3, 360x480x3 gibi farklı boyutlara ayarlanarak görüntü boyutlarının segmentasyon mimarisi üzerine etkisi değerlendirilmiştir. Bu nedenle görüntülere, segmentasyon mimarisinin eğitiminden önce mimarinin giriş boyutuna uygun boyutlara getirmek için yeniden boyutlandırma işlemi uygulanmıştır. Yeniden boyutlandırma dışında görüntülere KSAHE, Gray World algoritması tabanlı renk sabitleme gibi görüntü iyileştirme algoritmaları uygulanmıştır.


Görüntülerde renk sabitliği, elde edilecek özellikler için oldukça önemlidir. Renk sabitleme işlemlerinin amacı farklı ışık kaynaklarının görüntüler üzerindeki etkilerini minimize etmektir. Bunun için kullanılan birçok renk sabitleme algoritması bulunmaktadır. Bu algoritmalar arasından Gray World algoritması (Finlayson vd. 1998) düşük matematiksel hesaplama maliyeti sayesinde en çok tercih edilen yöntemlerden biridir (Van De Weijer ve Gevers 2005). Gray World algoritması Denklem 3.1'de görüldüğü gibi tüm renk kanallarının piksel ortalamasının her renk kanalının ayrı ayrı piksel ortalamasına bölünmesi ile formüle edilmektedir. Şekil 3.3'de algoritmanın görüntüler üzerindeki etkisi görülebilmektedir.

$$(I'_R, I'_G, I'_B) = ((I_R * \frac{\text{ortalama}(I_{RGB})}{\text{ortalama}(I_R)}), (I_G * \frac{\text{ortalama}(I_{RGB})}{\text{ortalama}(I_G)}), (I_B * \frac{\text{ortalama}(I_{RGB})}{\text{ortalama}(I_B)})) \quad (3.1)$$



Şekil 3.3 ISIC2017 örnek veri seti görüntüleri ve uygulanan Gray World algoritmasının görüntüler üzerine etkileri.

Görüntülerde histogram, renk değerlerinin dağılımını gösteren istatistiksel bir yöntemdir. Renk dağılımı düzenli olmayan görüntülerde histogram eşitleme yöntemi basit ve düşük hesaplama yüküne sahip olmasından dolayı görüntü kontrastını geliştirmek için sıklıkla tercih edilmektedir (Uysal ve Güraksin 2020). KSAHE algoritması görüntüyü parçalara ayırarak belirlediği eşik değerine göre histogram eşitlemesi uygular. Daha sonra bu parçaları birleştirerek histogram eşitlenmiş görüntüleri oluşturur. Bu çalışmada da yaygın olarak tercih edilen KSAHE histogram eşitleme yöntemi uygulanmış ve cilt lezyonlarının segmentasyonu üzerine etkisi incelenmiştir. Şekil 3.4’de verilen örneklerde görüntülerin her renk kanalına ayrı ayrı uygulanan KSAHE yönteminin görüntüler üzerinde etkisi ve histogram grafiklerinde meydana gelen değişimler gösterilmiştir.



Şekil 3.4 Orijinal ve KSAHE uygulanan ISIC2017 örnek veri seti görüntüleri ve histogram grafikleri.

3.2.2 Segmentasyon

Segmentasyon aşaması cilt görüntülerindeki lezyon bölgesinin çıkartılması için uygulanan işlemlerden oluşur. Bu aşamanın amacı uygulanacak teşhis işleminin görüntülerde bulunan diğer lezyon dışı yapılardan etkilenmesinin önüne geçmek ve teşhis aşamasının performansını ve doğruluğunu arttırmaktır. Çalışmamızda medikal görüntülerin segmentasyonunda en çok kullanılan derin öğrenme mimarilerinden birisi olan AlexNet tabanlı TEA mimarisi olan FCN-AlexNet ile farklı çalışmalar yapılarak mimarinin performansının maksimize edilmesi amaçlanmıştır. Çalışmada FCN-AlexNet

seçilmesinin en temel amacı yapı olarak diğer segmentasyon mimarilerine göre daha basit ancak segmentasyon performansı olarak diğerleri ile yarışacak seviyelerde sonuçlar ortaya koymasıdır. Kaymak ve arkadaşlarının (Kaymak vd. 2020) yaptıkları çalışmada da belirttikleri gibi farklı mimarilere ait eğitim sürelerinde, FCN-AlexNet mimarisinin yapısının basit olması, hesaplama maliyetinde yaklaşık %80 oranında avantaj sağlamaktadır. Bu avantajı da göz önüne alarak gerçekleştirdiğimiz çalışmamızda FCN-AlexNet performansını etkileyecek hiper parametrelerindeki optimum tercihleri belirledikten sonra cilt lezyonlarının tam otomatik tespiti için FCN-AlexNet mimarisinin performansını arttırmaya yönelik yeni bir hibrit yöntem önerilmiştir. FCN-ResAlexNet olarak tanımladığımız bu hibrit yöntem öncelikle görüntü ön işlem adımları ile görüntülerin iyileştirilmesi ve sonrasında AlexNet mimarisi ile ResNet-18 mimarilerinin entegrasyon işlemlerine dayanmaktadır. Ayrıca önerilen mimarinin diğer başarılı derin öğrenme tabanlı segmentasyon mimarileri ile karşılaştırmasını yapabilmek için U-Net ve DeepLabV3+ mimarileri de eğitilerek önerilen mimari ile performans karşılaştırması gerçekleştirilmiştir. Oluşturulan mimarilerin eğitiminde FCN-AlexNet mimarisinde en başarılı sonuç veren görüntü ön işleme teknikleri ve eğitim hiper parametreleri kullanılmıştır.

3.2.2.1 Hiper Parametrelerin Belirlenmesi

FCN-AlexNet mimarisinin performansını maksimize etmek üzere mimarinin eğitiminde aşağıda verilen farklı teknikler denenmiş ve mimarinin performansı üzerine etkileri araştırılmıştır.

1. Mimariye verilen giriş görüntü boyutları ön işlem aşamasında açıklandığı üzere değiştirilmiş ve verilen görüntü boyutunun performansa olan etkisi gözlenmiştir.
2. Eğitim sırasında SGDM, ADAM, RMSProp olmak üzere 3 farklı eğitim optimizasyon algoritması denenmiştir.
3. Segmentasyon için uygun olan 3 farklı kayıp fonksiyonuna sahip 3 farklı piksel sınıflandırma katmanı denenmiştir.
4. Mimariye verilen görüntüler üzerinde Gray World algoritması kullanılarak renk sabitleme ve KSAHE algoritması kullanılarak histogram eşitleme yapılarak

görüntü iyileştirme işlemleri uygulanmış ve performansa etkileri değerlendirilmiştir.

Derin öğrenme mimarilerinde katmanlar arasındaki nöronların ağırlıklarının eğitiminde daha önce öğrenme oranı bölümünde bahsedildiği üzere optimizasyon algoritmaları kullanılmaktadır. Yapılan çalışmada en yaygın kullanılan SGDM, ADAM ve RMSProp olmak üzere 3 optimizasyon algoritmasının segmentasyon mimarisi üzerinde başarıları değerlendirilmiştir. Bunlar kısaca şu şekilde açıklanabilirler.

1. Momentumlu Rastgele Gradyan İniş (Stochastic Gradient Descent with momentum | SGDM) (Robert 2014, İnt.Kyn.3), amaç fonksiyonlarını yinelemeli bir yöntem ile optimize eden fonksiyondur. Gradyan iniş optimizasyonunun (SGD) rastgele bir yaklaşımı olarak düşünülebilir. SGD algoritmasından farkı kullanılan momentum parametresidir. SGDM algoritmasındaki bu parametre gradyan vektörlerini doğru yönlerde hızlandırmaya yardımcı olur ve böylece daha hızlı yakınsamaya yol açar. Momentum parametresinin yüksek boyutlu optimizasyon problemlerinde hesaplama yükünü azalttığı bilinmektedir.
2. Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation | ADAM), araştırmacı Kingma ve Ba (Kingma ve Ba 2014) tarafından literatüre kazandırılmış RMSProp ve momentum yöntemlerinin avantajlı yönlerinin birleştirilmesi ile önerilen gradyan iniş algoritmasıdır. Birinci dereceden gradyanlar gerektiren, her parametre için uyarlanabilir öğrenme hızlarını hesaplayan bir optimizasyon yöntemidir.
3. RMSProp (Tieleman ve Hinton 2012, İnt.Kyn.4), araştırmacı Tieleman ve Hinton tarafından literatüre kazandırılmıştır. Eğitim aşamasında her parametre için yeni bir öğrenme hızının hesaplandığı yöntemdir. Mimarideki bir ağırlığın öğrenme oranı, o ağırlık için son gradyanların büyüklüklerinin değişen ortalamasına bölünmesi ile elde edilir.

Literatürde segmentasyon çalışmalarında kullanılan farklı kayıp fonksiyonlar mevcuttur (Jadon 2020). Bu çalışmada literatürde kullanılan 3 farklı kayıp fonksiyonu denenerek segmentasyon işlemindeki performansları karşılaştırılmıştır. Bu 3 farklı kayıp fonksiyonu şunlardır:

1. Çapraz Entropi (Cross Entropy) (Yi-de vd. 2004), derin öğrenme mimarilerinde en yaygın kullanılan kayıp fonksiyondur. Sınıflandırma ve segmentasyon çalışmalarında başarılı sonuçlar vermektedir. Dağılım tabanlı olan fonksiyon matematiksel olarak Denklem 3.2'deki gibi ifade edilmektedir (Jadon 2020) (T:Target, P: Predict).

$$\text{Çapraz Entropi} = -(T * \log(P) + (1 - T) * \log(1 - P)) \quad (3.2)$$

2. Ağırlıklı Çapraz Entropi (Weighted Cross Entropy) (Pihur vd. 2007), Çapraz Entropi (Cross Entropy)'nn bir varyantıdır. Ağırlıklı Çapraz Entropi fonksiyonunda pozitif örnekler bir katsayı ile ağırlıklandırılmaktadır (Jadon 2020). Çalışmada ağırlık olarak sınıf dağılımları kullanılmıştır. Dağılım tabanlı olan fonksiyon matematiksel olarak Denklem 3.3'deki gibi ifade edilmektedir.

$$\text{Ağırlıklı Çapraz Entropi (Weighted Cross Entropy)} = -(W * T * \log(P) + (1 - T) * \log(1 - P)) \quad (3.3)$$


3. Tversky (Salehi vd. 2017); Dice katsayısı, görüntüler arasındaki benzerliği hesaplamak için segmentasyon sonuçlarını değerlendirmede yaygın olarak kullanılan bir metriktir. Daha sonra kayıp fonksiyon olarak da kullanılan bu metriğin genelleştirilmiş formu olan tversky kayıp fonksiyonunda yanlış değerler (False Pozitif, False Negatif) bir katsayı ile çarpılmaktadır. Bölge tabanlı olan bu fonksiyon Denklem 3.4'deki gibi formüle edilmektedir (Jadon 2020). (p = pikselin lezyon olma ihtimali, $\hat{p}$ = piksel gerçekten lezyon ise 1, değil ise 0)

$$Tversky = \frac{\sum p \hat{p}}{\sum p \hat{p} + \beta_1 \sum (1 - p) \hat{p} + \beta_2 \sum p (1 - \hat{p})} \quad (3.4)$$

3.2.2.2 Çalışmada Kullanılan Derin Öğrenme Mimarileri ve Hibrit Mimari Tasarımı


Daha önceki basamaklarda bahsedildiği üzere çalışmanın ana mimarileri FCN-AlexNet ve FCN-ResAlexNet'tir. Ancak uygulanan yöntemlerin performansının karşılaştırılması için çalışmada literatürde en çok kullanılan segmentasyon mimarilerinden olan U-Net ve DeeplabV3+ mimarilerinin de eğitimi gerçekleştirilmiştir. Bu iki mimarinin temel yapıları “Genel Bilgiler ve Literatür İncelemesi” bölümünde detaylı olarak verildiği için bu kısımda çalışmanın temel mimarileri FCN-AlexNet ve FCN-ResAlexNet yapıları detaylandırılacaktır.

FCN-AlexNet ilk olarak Long ve arkadaşları (Long vd. 2015b) tarafından ortaya atılmış TEA tabanlı ve oldukça popüler derin öğrenme mimarisi olan AlexNet kullanarak oluşturulmuş bir segmentasyon mimarisidir. Diğer TEA tabanlı derin öğrenme segmentasyon mimarilerinde olduğu gibi kodlayıcı (encoder) – kod çözücü (decoder) yapılarından oluşmaktadır. FCN-AlexNet segmentasyon mimarisinin kodlayıcı (encoder) yapısını AlexNet derin öğrenme mimarisi oluşturmaktadır. 1000 sınıflı ImageNet görüntü veri seti ile eğitilmiş ESA tabanlı bir derin öğrenme mimarisine sahip olan AlexNet, Krizhevsky ve arkadaşları (Krizhevsky vd. 2012) tarafından tasarlanmıştır. Kodlayıcı (encoder) yapısında, basit ancak yüksek doğruluk oranlarına sahip AlexNet mimarisi tercih edilen segmentasyon mimarisinin; kod çözücü (decoder) kısmında 1 adet evrişim ve 1 adet ters evrişim katmanını kullanılmıştır. Şekil 3.5’de FCN-AlexNet derin sinir ağının mimarisi görülmektedir.



Şekil 3.5 FCN-AlexNet Mimarisi.

ResNet mimarileri He ve arkadaşları (He vd. 2016) tarafından literatüre sunulan ve sınıflandırma çalışmalarında yaygın olarak kullanılan derin öğrenme mimarileridir. ResNet (He vd. 2016) mimarisinde kendinden önceki mimarilerden farklı olarak katman sayısı arttığında meydana gelen, geri yayılımda katmanlar arasındaki gradyan kaybolması sorununu ortadan kaldırmak için artık blok yapıları kullanılmıştır. Şekil 3.6'da verilen artık blok şemasında görüldüğü üzere bu yapıda bir katmanın çıktısı hem kendinden sonraki katmanı hem de kendinden 2 veya 3 sonraki katmanı beslemektedir. Bu sayede daha önceki katmanlardaki bilgiler bir sonraki katmanlara aktarılarak veri kaybı azaltılabilmekte ayrıca mimarinin ezberlemesine de engel olunabilmektedir.




Şekil 3.6 Artık Blok Yapısı.

Literatürde farklı derinliklerde ResNet mimarileri bulunmaktadır. Çalışmamızda 18 katmandan oluşan en basit ResNet-18 mimarisi kullanılmıştır. ResNet-18 mimarisinin seçilmesinin sebebi en basit ResNet mimarisi olması ve bundan dolayı matematiksel olarak hesaplama maliyeti en düşük olan ResNet mimarisi olmasıdır. ResNet-18 mimarisinin yapısı Şekil 3.7 'de verilmiştir. Şekilde de görüldüğü üzere mimari 20 evrişim, 2 havuzlama ve 1 tam bağlantılı katmana sahiptir.

Daha önce bahsedildiği üzere FCN-AlexNet, yapısı gereği basit ancak başarılı ve hesaplama maliyeti düşük bir segmentasyon mimarisidir. Bu çalışmada FCN-AlexNet ile sınıflandırmada başarılı mimarilerden birisi olan ResNet mimarilerinden en basit yapıya sahip ResNet-18 mimarisi birleştirilerek hibrit bir model oluşturulmuştur. Modelin temel motivasyonu basit dolayısıyla hesaplama maliyeti düşük iki mimarinin birleştirilerek matematiksel hesaplama maliyetini çok arttırmadan segmentasyon performansını arttırmaktır. 23 katmandan oluşan hibrit model mimarisi Şekil 3.8’de verilmiştir. Şekilde görüldüğü üzere ResNet-18 ve AlexNet mimarileri oluşturulan hibrit FCN mimarisinin kodlayıcı (encoder) yapısını oluştururken, kod çözücü (decoder) yapısını ise 1 adet evrişim ve 3 adet ters evrişim katmanları oluşturmaktadır. Ters evrişim katmanlarında kullanılan filtre boyutu 4x4 olarak ayarlanmıştır. Mimarinin kod çözücü (decoder) yapısı performans karşılaştırması için aynı zamanda 1 evrişim ve 1 ters evrişim katmanı kullanılarak da tasarlanmıştır. Bu tasarımda kullanılan ters evrişim katmanında filtre boyutu 64x64 olarak ayarlanmıştır.

Çalışmada kullanılan tüm mimarilerin eğitiminde eğitim parametresi olarak 4 batch size (yığın sayısı), 30 epok, 0.0001 öğrenme oranı (learning rate) kullanılmıştır. En başarılı sonucu “ADAM” eğitim optimizasyon fonksiyonu verdiği için eğitim optimizasyon fonksiyonlarının karşılaştırmasının yapıldığı çalışmalar dışındaki eğitimlerde “ADAM” optimizasyon fonksiyonu tercih edilmiştir.



Şekil 3.8 Önerilen FCN-ResAlexNet Derin Öğrenme Ağına Ait Mimari.

4. BULGULAR

Bu çalışmada, lezyonlu cilt görüntülerinden lezyonlu bölgenin segmentasyonu için literatürde en yaygın kullanılan ESA tabanlı segmentasyon mimarilerinden birisi olan FCN-AlexNet mimarisi kullanılmıştır. Çalışmanın ilk aşamasında FCN-AlexNet mimarisinin en optimum performans gösterdiği hiper parametreleri öğrenmek için görüntü giriş boyutu, optimizasyon algoritması, piksel sınıflandırma katmanında kullanılan kayıp fonksiyonu için farklı alternatifler denenerek en iyi performansı sağlayan parametreler seçilmiştir. Çalışmanın ikinci aşamasında ise FCN-AlexNet ve ResNet-18 derin öğrenme mimarileri kullanılarak hibrit bir segmentasyon mimarisi oluşturulmuştur. Oluşturulan hibrit segmentasyon mimarisinin performansını değerlendirmek için ise literatürde kullanılan diğer popüler segmentasyon mimarilerinden olan U-Net ve DeeplabV3+ mimarileri FCN-AlexNet ile aynı parametreler ile eğitilmişlerdir.

Yapılan çalışma, işletim sistemi ve diğer donanım destekleri Windows 10, Intel Core i7-8750H işlemci, 16GB RAM, Nvidia GTX 1060 GPU olan bir sistem üzerinde MATLAB ortamında gerçekleştirilmiştir.

Çalışmada kullanılan modellerin performanslarını değerlendirmek için (Capobianco vd. 2018, Mongkhonthanaphon ve Limpiyakorn 2018) ve (Long vd. 2015b) çalışmalarında önerilen Piksel Doğruluğu, Ortalama Doğruluk, Ortalama IoU (Intersection over Union) ve Frekans Ağırlıklı IoU segmentasyon değerlendirme metrikleri kullanılmış ve bunların yanı sıra literatürdeki diğer segmentasyon çalışmaları ile karşılaştırabilmek için Dice, Jaccard Index, Sensitivity (Hassasiyet) ve Specificity (Duyarlılık) metrikleri de değerlendirme aşamasına dahil edilmiştir. Değerlendirme metriklerine ait matematiksel formüller sırasıyla Denklem 4.1-4.8’de verildiği gibi ifade edilmektedir. Formülasyonların anlaşılması için bazı terimlerin açılımının bilinmesi gerekmektedir. Bunlar;

n_{ij} : j sınıfına ait olduğu tahmin edilen i sınıfının piksel sayısı

n_c : bulunan toplam sınıf sayısı

$t_i = \sum_j n_{ij}$: i sınıfına ait toplam piksel sayısı.

TP (Doğru Pozitif): Gerçekte lezyon olarak etiketli olan ve tahmin sonucunda da lezyon olarak saptanmış piksellerin toplam sayısı.

TF (Doğru Negatif): Gerçekte arka plan olarak etiketli olan ve tahmin sonucunda da arka plan olarak saptanmış piksellerin toplam sayısı.

FP (Yanlış Pozitif): Gerçekte lezyon olarak etiketli olan ve tahmin sonucunda arka plan olarak saptanmış piksellerin toplam sayısı.

FN (Yanlış Negatif): Gerçekte arka plan olarak etiketli olan ve tahmin sonucunda lezyon olarak saptanmış piksellerin toplam sayısı.

Genel Doğruluk:

$$= \frac{\sum_i n_{ii}}{\sum_i t_i} \quad (4.1)$$

Ortalama Doğruluk:

$$= \frac{1}{n_{cl}} \sum_i \frac{n_{ii}}{t_i} \quad (4.2)$$

Ortalama IoU:

$$= \frac{1}{n_{cl}} \sum_i \frac{n_{ii}}{t_i + \sum_j (n_{ji} - n_{ii})} \quad (4.3)$$

Frekans Ağırlıklı IoU:

$$= \frac{1}{\sum_k t_k} \sum_i \frac{t_i n_{ii}}{t_i + \sum_j (n_{ji} - n_{ii})} \quad (4.4)$$

Hassasiyet:

$$= \frac{TP}{TP+FN} \quad (4.5)$$

Duyarlılık:

$$= \frac{TN}{TN+TP} \quad (4.6)$$

Dice:

$$= \frac{2*TP}{2*TP+FP+FN} \quad (4.7)$$

Jaccard:

$$= \frac{TP}{TP+FP+FN} \quad (4.8)$$

Çalışmada ilk olarak giriş görüntü boyutlarının derin öğrenme mimarisi performansına etkisi değerlendirilmiştir. Bunun için FCN-AlexNet mimarisi giriş boyutu 224x224x3, 448x448x3, 480x360x3 olarak 3 farklı boyuta ayarlanmıştır. Görüntüler her giriş boyutu için uygun olarak yeniden boyutlandırılarak mimarilere verilmiş ve eğitim performansları karşılaştırılmıştır.

Çizelge 4.1 Farklı giriş boyutlarına sahip FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları.

Giriş Boyutu	Genel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Frekans Ağırlıklı IoU
448x448x3	92,23	89,78	81,41	87,52
360x480x3	92,68	86,54	80,83	86,32
224x224x3	93,12	89,10	82,42	87,29

Çizelge 4.1’de verilen değerler sırasıyla farklı giriş boyutlarına sahip mimarilerin performans değerlerini göstermektedir. Çizelge 4.1’de elde edilen sonuçlar incelendiğinde görüntü boyutunun arttırılması ortalama doğruluk ve frekans ağırlıklı IoU değerlerinde küçük artışlar sağlarken, genel doğruluk ve ortalama IoU değerlerinde yaklaşık %1’lik bir azalmaya sebep olmuştur. Elde edilen sonuçlardan yola çıkarak bundan sonraki aşamalarda hem göreceli olarak daha iyi performans göstermesi, hem de matematiksel hesaplama yükünün daha az olmasından dolayı derin öğrenme mimarilerinin giriş boyutları 224x224x3 olarak ayarlanmıştır.

Mimarilerin giriş boyutu belirlendikten sonra eğitim için uygulanabilecek ADAM, SGDM ve RMSProp olmak üzere en yaygın 3 optimizasyon algoritması segmentasyon mimarisinin performansına etkileri değerlendirmek üzere FCN-AlexNet mimarisinin eğitiminde kullanılmış ve sonuçlar Çizelge 4.2’de verilmiştir.

Çizelge 4.2 Farklı optimizasyon algoritmaları kullanılarak eğitilmiş FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları.

Optimizasyon Algoritmaları	Genel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Frekans Ağırlıklı IoU
SGDM	91,22	88,89	79,08	84,44
RMSProp	92,50	86,83	80,56	86,10
ADAM	<u>93,12</u>	<u>89,10</u>	<u>82,42</u>	<u>87,29</u>

Çizelge 4.2’de verilen farklı optimizasyon algoritmaları ile eğitilmiş mimarilerin performansları incelendiğinde ADAM optimizasyon algoritmasının tüm parametrelerde diğerlerinden daha iyi sonuçlar verdiği rahatlıkla görülmektedir. Bu nedenle bundan sonraki eğitimlerin tamamı ADAM optimizasyon algoritması kullanılarak yapılmıştır.

Çalışmanın diğer aşamasında segmentasyon mimarilerinde kullanılabilen 3 farklı kayıp fonksiyonu kullanılan 3 farklı piksel sınıflandırma katmanı denenmiştir. Şekil 3.5’de de görülebilen FCN-AlexNet mimarisi sınıflandırma katmanı için çapraz entropi (Cross-Entropy), ağırlıklı çapraz entropi (Weighted Cross Entropy) ve Tversky fonksiyonları kullanılarak yeniden düzenlenmiş ve katmanların performansları karşılaştırılmıştır. Çizelge 4.3’de farklı piksel sınıflandırma katmanlarına sahip FCN-AlexNet mimarilerinin performans değerleri görülebilmektedir.

Çizelge 4.3 Farklı kayıp fonksiyonlar (loss functions) kullanılarak düzenlenmiş FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları.

Kayıp Fonksiyonları	Genel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Frekans Ağırlıklı IoU
Ağırlıklı Çapraz Entropi (Weighted Cross Entropy)	90,46	89,97	75,71	82,59
Tversky	91,79	83,81	78,16	84,63
Çapraz Entropi (Cross-Entropy)	<u>93,12</u>	<u>89,10</u>	<u>82,42</u>	<u>87,29</u>

Çizelge 4.3’de verilen performans değerlerine bakıldığında sınıflandırma mimarilerinde en iyi sonuçları elde eden çapraz entropi (cross-entropy) kayıp fonksiyonu segmentasyon mimarisinde de gözle görülür bir başarı elde etmiştir. Daha çok veri dağılımı dengesiz olan verilerde başarı sağladığı düşünülen Ağırlıklı Çapraz Entropi (Weighted Cross Entropy) (Jadon 2020) fonksiyonu lezyon olmayan piksel sayısı,

lezyon olan piksel sayısından oldukça fazla olmasına rağmen istenilen başarıyı gösterememiştir. Ayrıca bir segmentasyon değerlendirme kriteri olan Dice katsayısı tabanlı Tversky fonksiyonundan da beklenen başarı elde edilememiştir. Bu nedenle çalışmanın piksel sınıflandırma katmanında çapraz entropi (Cross-Entropy) kayıp fonksiyonu kullanılmıştır.

Mimarilerin giriş boyutu, eğitim optimizasyon algoritması ve piksel sınıflandırma katmanında uygulanacak kayıp fonksiyon belirlendikten sonra görüntülerin kalitelerini arttırmak için Gray World algoritması kullanılarak renk sabitleme ve KSAHE algoritması ile histogram eşitleme olmak üzere 2 farklı görüntü işleme tekniği cilt görüntülerine uygulanmıştır. Bahsedilen bu 2 görüntü işleme tekniği görüntülere hem ayrı ayrı hem de birlikte uygulanmış ve elde edilen sonuçlar değerlendirilmiştir. Çizelge 4.4’de verilen segmentasyon performans değerleri cilt görüntülerine uygulanmış görüntü işleme tekniklerinden elde edilen sonuçları göstermektedir.

Çizelge 4.4 Farklı görüntü ön işleme teknikleri uygulanarak elde edilmiş görüntüler kullanılarak eğitilmiş FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları.

Görüntü Ön İşleme Yöntemleri	Genel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Frekans Ağırlıklı IoU
KSAHE+ Gray World	92.73	86.69	80.97	86.41
KSAHE	92.61	87.74	81.06	86.36
Gray World	93.24	89.60	82.81	87.54
Filtresiz	93.12	89.10	82.42	87.29

Çizelge 4.4’de elde edilen sonuçlar değerlendirildiğinde Gray World algoritması uygulanan görüntülerle eğitilen mimarinin performans değerlerinin daha iyi olduğu görülmüştür. Buna karşın KSAHE uygulanan görüntüler ile eğitilen FCN-AlexNet mimarisinin performansının düştüğü gözlenmiştir. Ayrıca KSAHE algoritmasının Gray World ile birlikte kullanımında da performansın düştüğü Çizelge 4.4’de görülmektedir.

FCN AlexNet üzerinde uygulanan farklı yöntemler değerlendirildikten sonra, görüntülerden özellik haritalarını çıkartan kodlayıcı (encoder) yapısı matematiksel hesaplama maliyeti arttırılmadan mimarinin performansını arttırmak için yeniden geliştirilmeye karar verilmiştir. Bunun için Şekil 3.8’de mimarisi verilen FCN-

ResAlexNet mimarisinde görüldüğü gibi kodlayıcı (encoder) yapısı AlexNet ve ResNet-18 mimarilerinin entegrasyonu ile geliştirilmiştir. Decoder (kod çözücü) yapısında ise 2 farklı mimari yapısı denenmiştir. İlkinde orjinal FCN-AlexNet yapısında kullanılan 64x64 boyutunda filtre kullanan tek ters evrişim katmanı ile tasarlanan yapı, ikincisinde ise 4x4 boyutunda filtre kullanarak 3 aynı ters evrişim katmanından oluşan yapı uygulanmıştır. Çizelge 4.5’de önerilen iki farklı decoder (kod çözücü) yapısına sahip FCN-ResAlexNet ve FCN-AlexNet segmentasyon mimarilerine ait performans değerleri verilmiştir. Çizelge 4.5’deki veriler incelendiğinde 3 ters evrişim katmanı ile oluşturulan decoder (kod çözücü) yapısına sahip segmentasyon mimarisinin diğer mimarilerden daha iyi performans gösterdiği görülmektedir. Ayrıca Çizelge 4.6’da 3 ters evrişim katmanına sahip FCN-ResAlexNet ve FCN-AlexNet mimarilerinin 30 epok eğitimi için geçen süreler verilmiştir. Verilen eğitim sürelerine bakıldığında daha derin bir yapıya sahip FCN-ResAlexNet mimarisinin eğitim süresinin FCN-AlexNet mimarisinin eğitim süresinden sadece 21 dakika fazla olduğu görülmüştür.

Çizelge 4.5 Farklı decoder (kod çözücü) yapılarına sahip FCN-AlexNet mimarisinin segmentasyon değerlendirme sonuçları.

Segmentasyon Mimarisi	Genel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Frekans Ağırlıklı IoU
3 Ters evrişim Katmanı bulunan FCN-ResAlexNet	<u>93,47</u>	<u>88,52</u>	<u>82,95</u>	<u>87,76</u>
Tek Ters evrişim Katmanı bulunan FCN-ResAlexNet	93,19	87,33	82,03	87,19
FCN-AlexNet	93,12	89,10	82,42	87,29

Çizelge 4.6 FCN-ResNet ve FCN-AlexNet segmentasyon mimarilerinin 30 epok eğitimi için geçen süre.

Segmentasyon Mimarisi	30 epok eğitim için geçen süre
3 Ters evrişim Katmanı bulunan FCN-ResAlexNet	10 saat 50 dakika
FCN-AlexNet	10 saat 29 dakika


Çalışmada önerilen FCN-ResAlexNet mimarisinin tasarımından sonra literatürde yaygın olarak kullanılan diğer segmentasyon mimarileri ile karşılaştırmak için U-Net ve DeepLabV3+ mimarileri de çalışmaya dahil edilmişlerdir. Çizelge 4.7 bu mimarilerin ve FCN-AlexNet, FCN-ResAlexNet mimarilerinin eğitiminden elde edilen performans

değerlerini göstermektedir. Sonuçlar incelendiğinde ortalama doğruluk değeri dışındaki 3 performans kriteri içinde FCN-ResAlexNet mimarisinin daha başarılı sonuçlar verdiği görülmektedir. En düşük performans gösteren U-Net segmentasyon mimarisi aynı zamanda eğitim aşaması en uzun süren mimari olmuştur.

Çizelge 4.7 Farklı Segmentasyon Mimarileri İçin Değerlendirme Metrikleri.

Segmentasyon Mimarileri	Genel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Frekans Ağırlıklı IoU
FCN-ResAlexNet	<u>93,47</u>	88,52	<u>82,95</u>	<u>87,76</u>
FCN-AlexNet	93,12	<u>89,10</u>	82,42	87,29
DeepLabV3+	91,96	84,68	78,81	85,01
U-Net	89,62	84,32	75,97	83,63

Yukarıda değerlendirme sonuçları verilen önerilen hibrit mimariden elde edilen segmentasyon görüntüleri Şekil 4.1’de verilmiştir. 3. Sütunda verilen gerçek referans görüntüleri ile 4. sütunda verilen mimariden elde edilen görüntülere bakıldığında mimarinin performansının optimum değerlere oldukça yakın olduğu görülmektedir. Özellikle melanom görüntüsünün segmentasyon sonuçlarına bakıldığında, referans görüntünün daha geniş kapsamlı bir segmentasyon görüntüsü varken önerilen mimariden elde edilen segmentasyon görüntüsünün lezyon kenarlarına daha yakın bir görüntü oluşturduğu görülmektedir.



Şekil 4.1 Önerilen hibrit mimari ile veri setinde bulunan gerçek referans değerlerinin karşılaştırması.

Geleneksel mimariler ile karşılaştırılan ve performans olarak oldukça başarılı sonuçlar elde edilen mimarinin literatürdeki konumunu belirlemek için şimdiye kadar yapılmış çalışmaların ortak bir tablosu oluşturulmuştur (Çizelge 4.8). Önerilen mimari dışında 28 mimari bulunan tabloda; Dice indeks sıralamasında ilk 3’de olan mimarimiz, Jaccard indeks değerleri sıralamasında en iyi sonucu veren ilk 5 mimari arasındadır. Oldukça geniş bir mimari skalası içeren tabloya özellikle literatürde en iyi sonuçları elde eden mimariler eklenmiştir. Önerdiğimiz mimariden daha iyi sonuçlar elde eden çalışmalar tezin literatür inceleme kısmında detaylandırılmıştır. Liu ve arkadaşlarının (Liu vd. 2019) yaptığı çalışmada veri artırma yöntemleri ve farklı renk uzayları kullanarak eğitim verilerini oldukça arttırdıkları ayrıca tarafımızca test edilen ve FCN-AlexNet mimarisinden oldukça uzun sürede eğitimi tamamlanan U-Net mimari tabanlı bir mimari kullandıkları görülmektedir. Öte yandan Dice indeks değerlerinin mimarimizin performansından daha düşük olduğu görülmektedir. Öztürk ve Özkaya (Öztürk ve Özkaya 2020) çalışmalarında verilerini farklı renk uzaylarını kullanarak arttırmışlar ve

TEA tabanlı bir mimariye farklı katmanlarda bu renk uzaylarını dahil ederek mimari yapısını geliştirmişlerdir. Sarker ve arkadaşlarının yaptıkları çalışmada ISIC2017 ve ISIC 2016 veri setlerinin birlikte kullanıldıkları görülmektedir. Oluşturulan mimarinin kompleksliği hakkında hesaplama maliyetine dair yorum yapmak mümkün görünmektedir. Bi ve arkadaşlarının yaptıkları çalışmada ise TEA tabanlı bir mimari kullanan araştırmacılar 3 segmentasyon işlemi ve 1 sınıflandırma işlemi olmak üzere 4 farklı ResNet mimarisi eğitmişlerdir. Daha iyi sonuçlar elde eden çalışmalara bakıldığında tamamının literatüre katkıları göz ardı edilemeyecek kadar önemlidir ancak yapılan işlemler hesaplama maliyetinde önemli seviyelerde artışa sebep olacaktır. Daha önce belirtildiği üzere çalışmanın amacı hesaplama maliyetini çok arttırmadan mimari performansını arttırmaktır. Çalışma sonucu göstermiştir ki TEA tabanlı mimarilerde kodlayıcı (encoder) yapısında uygulanacak hibrit sistem yapıları mimari performansını arttırabilmektedir.

Çizelge 4.8 Literatür Çalışmaları ile Karşılaştırma.

Çalışmalar	Doğruluk%	Dice%	Jaccard%	Hassasiyet%	Duyarlılık%
Thao ve Quang (Thao ve Quang 2017)	87,72	63,17	50,65	65,13	94,21
Öztürk vd. (U-Net) (Öztürk ve Özkaya 2020)	90,14	76,27	61,64	67,17	97,24
Kaul vd. (U-Net) (Kaul vd. 2019)	92,0	76,8	65,1	85,3	95,7
Garcia-Arroyo vd. (eVida) (Garcia-Arroyo ve Garcia-Zapirain 2019)	88,4	76,0	66,5	86,9	92,3
Li vd. (FCN-8s) (Li ve Shen 2018)	93,3	78,3	69,6	80,6	95,4
Öztürk vd. (SegNet) (Öztürk ve Özkaya 2020)	91,76	82,09	69,63	80,05	95,37
Wen vd. (II-FCN) (Wen 2017)	92,9	79,4	69,9	84,1	98,4
Badrinarayanan vd. (SegNet) (Badrinarayanan vd. 2017)	91,7	79,7	70,0	81,5	97,4
Ren vd. (SegNet) (Ren vd. 2021)	91,7	79,16	70,12	77,77	97,68
Ren vd. (Deeplabv3+) (Ren vd. 2021)	92,13	80,43	70,77	76,48	96,51

Çizelge 4.8 (Devam) Literatür Çalışmaları ile Karşılaştırma.

Çalışmalar	Doğruluk%	Dice%	Jaccard%	Hassasiyet%	Duyarlılık%
Öztürk vd.(FCN) (Öztürk ve Özkaya 2020)	92,72	83,83	72,17	79,98	96,66
Unver ve Ayan (Unver ve Ayan 2019)	93,39	84,26	74,81	90,82	92,68
Jeremy Kawahara (FCN) (Kawahara ve Hamarneh 2019)	93,0	83,7	75,2	81,3	97,6
Menegola vd. (RECOD Titans) (Menegola vd. 2017)	93,1	83,9	75,4	81,7	97,0
Kaul vd. (FocusNet) (Kaul vd. 2019)	92,14	83,15	75,62	76,73	98,96
Abhishek vd. (Abhishek vd. 2020)	92,22	83,86	75,70	87,06	95,16
He vd. (He vd. 2017)	93,8	84,3	75,8	-	-
Bi vd. (USYD-BMIT) (Bi vd. 2017)	93,4	84,4	76,0	80,2	98,5
Yuan vd.(Yuan 2017)	93,4	84,9	76,05	82,5	97,5
Li vd. (Li ve Shen 2018)	93,2	84,7	76,2	82,0	97,8
Mt. Sinai (Yuan vd. 2017)	93,4	84,9	76,5	82,5	97,5
Ren vd. (SANet) (Ren vd. 2021)	93,43	85,23	76,92	85,43	96,83
Al-Masni vd.(Al-masni vd. 2018)	94,03	87,08	77,11	85,40	96,69
Bi vd. (Bi vd. 2019)	94,08	85,66	77,73	86,2	96,71
Sarker vd. (Sarker vd. 2018)	93,6	87,8	78,20	81,6	98,3
Öztürk vd. (iFCN) (Öztürk ve Özkaya 2020)	95,3	88,64	78,34	85,44	98,08
Liu vd. (Liu vd. 2019)	94,32	87,13	79,46	88,76	96,51
DeeplabV3+	91,96	82,27	69,88	71,08	98,27
FCN-AlexNet	93,12	84,62	73,34	81,60	96,60
Önerilen Yöntem	93,47	87,35	77,54	79,25	97,8

Çalışma genel olarak değerlendirildiğinde aşağıdaki sonuçlara varılmıştır.

1. Segmentasyon mimarisine verilen görüntü boyutunun arttırılması veya asimetrik boyutta görüntü verilmesi mimarinin performansını ve matematiksel hesaplama maliyetini olumsuz yönde etkilemiştir.
2. FCN-AlexNet mimarisinin eğitiminde kullanılan optimizasyon algoritmalarından ADAM optimizasyon algoritması diğer optimizasyon algoritmalarına göre oldukça yüksek başarı göstermiştir. FCN-AlexNet mimarisinin yapısında bulunan piksel sınıflandırma katmanında kullanılan çapraz entropi (cross-entropy) kayıp fonksiyonu en iyi performans değerlerini veren fonksiyon olmuştur.
3. Segmentasyon mimarisinin girişine uygulanan görüntülere uygulanan görüntü işleme tekniklerinden KSAHE algoritması beklenenin aksine kötü sonuç verirken, Gray World algoritması eğitim performansında artışa sebep olmuştur.
4. FCN-AlexNet mimarisinin performansını arttırmaya yönelik yapılan çalışmalar dışında FCN-AlexNet mimarisinin tasarımı baz alınarak oluşturulan FCN-ResAlexNet mimarisi eğitim süresinde belirgin bir artış sağlamadan performans değerlerinde %0,35-0,53 performans artışı sağlamıştır.
5. Literatürde kullanılan geleneksel segmentasyon mimarileri ile karşılaştırıldığında önerilen mimarinin daha yüksek performans gösterdiği görülmüştür.
6. Literatürde yapılan 28 mimari ile karşılaştırıldığında önerilen mimari Dice indeksinde ilk 3, Jaccard indeksinde ilk 5 mimari arasında yer almaktadır.

5. SONUÇLAR VE TARTIŞMA

Günümüzde cilt kanseri tüm dünyayı tehdit eden ve büyüyen bir tehlikedir. Cilt kanserinin özellikle melanom türünün erken teşhisi tedavinin olumlu sonuçlanmasında oldukça kritik bir öneme sahiptir. Tıbbi görüntülerin yorumlanması genellikle doktorlar tarafından yapılmaktadır. Ancak cilt lezyon görüntülerinin pigmentli yapısı, kontrast düşüklüğü, insan teninin saç, renk gibi değişen tonlamalı yapısı gibi sahip olduğu dezavantajlı yapılar teşhislerin konulmasında uzmanlık gerektirmekte bunun yanı sıra koyulan teşhislerde değişkenlik göstermektedir. Ayrıca teşhis koymanın zorluğu ya da yanlış teşhislerin getirdiği sonuçlar ölümlerle ya da ciddi mali kayıplarla sonuçlanabilmektedir.

Bilgisayar destekli algoritmalarda görüntülerin işlenmesi için geliştirilen ESA tabanlı derin öğrenme mimarilerinin önerilmesi medikal alanda devrim niteliğinde başarılı sonuçlar elde etmiştir. Cilt lezyon görüntülerinin tespitinde de yaygın olarak kullanılan bu algoritmaların sayıları elde ettikleri başarılar sayesinde giderek artmaktadır. Cilt lezyonlarının otomatik tespitinde lezyonlu bölgenin doğru segmentasyonu, yapılacak teşhis basamağı için oldukça önemlidir. Yapılacak yüksek doğruluğa sahip segmentasyon işlemi uzmanların teşhis koymasını kolaylaştırırken aynı zamanda otomatik cilt kanseri teşhisinin doğruluğunu arttıracaktır.

Bu çalışmada ISIC-2017 veri seti kullanılarak cilt lezyonlarının segmentasyonu için popüler segmentasyon mimarilerinden birisi olan FCN-AlexNet mimarisinin performansını arttırmaya yönelik farklı görüntü işleme teknikleri, derin öğrenme hiper parametreleri değerlendirilmiştir. Uygulanan bu yöntemlerin mimarinin performansına etkileri değerlendirilmiş ve en başarılı yöntemler belirlenmiştir. Bu değerlendirmelerin ardından FCN-AlexNet mimarisi temel alınarak kodlayıcı (encoder) yapısında AlexNet ve ResNet-18 derin CNN mimarilerinin entegrasyonu ile hibrit bir yapıya sahip FCN-ResAlexNet mimarisi tasarlanmıştır. Oluşturulan mimarinin kod çözücü (decoder) yapısında birçok derin segmentasyon mimarisinin yapısını oluşturan ters evrişim katmanı kullanılmıştır.

Yapılan çalışmanın sonuçları genel olarak değerlendirildiğinde mimarinin giriş boyutu

arttırıldığında mimarinin performansında artış gözlenmemiş; uygulanan kayıp fonksiyonlarından en iyi performans gösteren, sınıflandırma çalışmalarında kullanılan derin öğrenme mimarilerinde de en iyi performans gösteren çapraz entropi (cross-entropy) fonksiyonu olmuş; segmentasyon mimarisinin eğitiminde en iyi sonuç veren optimizasyon algoritması, ADAM optimizasyon algoritması olmuş ve görüntü işleme tekniklerinden biri olan Gray World algoritması tabanlı renk sabitleme işlemi uygulanan görüntüler segmentasyon performansında artış sağlamıştır. Önerilen yeni segmentasyon mimarisi FCN-ResAlexNet, matematiksel olarak hesaplama maliyetinde kayda değer bir artış getirmezken performans değerlendirme kriterlerinde önemli ölçüde artışlar sağladığı görülmüştür. Ayrıca literatür çalışmaları ile yapılan karşılaştırmada önerilen mimarinin Dice indeksinde ilk 3, Jaccard indeksinde ilk 5 mimari arasında olduğu gözlenmiştir. Bu bağlamda cilt lezyonlarının derin öğrenme yöntemleri ile otomatik segmentasyonunda yapılacak gelecekteki çalışmaların, değerlendirilen bu kriterleri göz önünde bulundurarak gerçekleştirilebileceği ve önerilen yeni hibrit segmentasyon mimarisinin farklı hibrit yöntemlerin oluşumu için bir referans niteliği taşıyabileceği düşünülmektedir.

6. KAYNAKLAR

- Abbas Q, Celebi M E, Fondón García I, Rashid M, 2011, Lesion Border Detection in Dermoscopy Images Using Dynamic Programming, *Skin Research and Technology*, 17, 91–100.
- Abhishek K, Hamarneh G, Drew M S, 2020, Illumination-based Transformations Improve Skin Lesion Segmentation in Dermoscopic Images, In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, June 14.15.19, China, 728–729.
- Adegun A, Viriri S, 2020, Deep Learning Techniques For Skin Lesion Analysis and Melanom Cancer Detection: A Survey of State-of-the-Art, *Artificial Intelligence Review*, 1–31.
- Al-masni M A, Al-antari M A, Choi M T, Han S M, Kim T S, 2018, Skin Lesion Segmentation in Dermoscopy Images via Deep Full Resolution Convolutional Networks, *Computer Methods and Programs in Biomedicine*, 162, 221–231.
- Almansour E, Arfan Jaffar M, Imam Mohammad A, 2016, Classification of Dermoscopic Skin Cancer Images Using Color and Hybrid Texture Features, *IJCSNS International Journal of Computer Science and Network Security* .
- Argenziano G, Soyer PH, De VG, Carli P, Delfino M, 2002, *Interactive Atlas of Dermoscopy CD*, EDRA Medical Publishing & New Media.
- Ashour A S, Nagieb R M, El-Khobby H A, Abd Elnaby M M, Dey N, 2021, Genetic Algorithm-Based Initial Contour Optimization for Skin Lesion Border Detection, *Multimedia Tools and Applications*, 80, 2583–2597.
- Aşkin D, İskender İ, Mamizadeh A, 2011, Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 26, 905–913.
- Aybars U, Kınacı A C, 2006, Yapay Zekâ Teknikleri Ve Yapay Sinir Ağları

Kullanılarak Web Sayfalarının Sınıflandırılması, XI. Türkiye'de İnternet Konferansı, 21-23 Aralık, 1-4.

Badrinarayanan V, Kendall A, Cipolla R, 2017, SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, IEEE Transactions on Pattern Analysis and Machine Intelligence, 39, 2481-2495.

Ballerini L, Fisher RB, Aldridge B, Rees J, 2013, A Color and Texture Based Hierarchical K-NN Approach to The Classification of Non-Melanoma Skin Lesions, In Color Medical Image Analysis, 63-86.

Berry M W, Mohamed A, Yap W B, 2019, Supervised and Unsupervised Learning for Data Science , 2020, Springer Nature Switzerland AG.

Bi L, Kim J, Ahn E, Feng D, 2017, Automatic Skin Lesion Analysis Using Large-scale Dermoscopy Images and Deep Residual Networks, arXiv:1703.04197.

Bi L, Kim J, Ahn E, Kumar A, Feng D, Fulham M, 2019, Step-Wise Integration of Deep Class-Specific Learning for Dermoscopic Image Segmentation, Pattern Recognition, 85, 78-89.

Bianco S, Cadene R, Celona L, Napoletano P, 2018, Benchmark Analysis of Representative Deep Neural Network Architectures, IEEE Access, 6, 64270-64277.

Bow ST, 2002, Pattern Recognition and Image Preprocessing, CRC press, 11 January, Boca Raton.

Bray F, Ferlay J, Soerjomataram I, Siegel R L, Torre L A, Jemal A, 2018, Global Cancer Statistics 2018: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries, CA: A Cancer Journal for Clinicians, 68, 394-424.

Capobianco S, Scommegna L, Marinai S, 2018, Historical Handwritten Document Segmentation By Using A Weighted Loss, In IAPR Workshop on Artificial Neural Networks in Pattern Recognition, 395-406.

- Chen L-C, Papandreou G, Schroff F, Adam H, 2017, Rethinking Atrous Convolution for Semantic Image Segmentation, arXiv:1706.05587 .
- Chen L-C, Zhu Y, Papandreou G, Schroff F, Adam H, 2018a, Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, In Proceedings of the European conference on computer vision (ECCV), September 8 - 14, Munich, Germany, pp. 801-818. 2018 .
- Chen L C, Papandreou G, Kokkinos I, Murphy K, Yuille A L, 2018b, DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs, IEEE Transactions on Pattern Analysis and Machine Intelligence, 40, 834–848.
- Codella N C F, Gutman D, Celebi M E, Helba B, Marchetti M A, Dusza S W, Kalloo A, Liopyris K, Mishra N, Kittler H, Halpern A, 2018, Skin Lesion Analysis Toward Melanom Detection: A Challenge at The 2017 International Symposium On Biomedical Imaging (ISBI), Hosted By The International Skin Imaging Collaboration (ISIC), 168–172.
- Combalia M, Codella N C F, Rotemberg V, Helba B, Vilaplana V, Reiter O, Carrera C, Barreiro A, Halpern A C, Puig S, Malvehy J, 2019, BCN20000: Dermoscopic Lesions in the Wild, arXiv:1908.02288.
- Coşkun M, Yildirim Ö, Uçar A, Demir Y, 2017, An Overview of Popular Deep Learning Methods, European Journal of Technic EJT, 7, 165–176.
- Cun L, Henderson J, Le Cun Y, Denker J S, Henderson D, Howard R E, Hubbard W, Jackel L D, 1990, Handwritten Digit Recognition with a Back-Propagation Network, In Advances in Neural Information Processing Systems, 396–404.
- Dai W, Dong N, Wang Z, Liang X, Zhang H, Xing E P, 2018, Scan: Structure Correcting Adversarial Network for Organ Segmentation in Chest X-Rays, In Deep Learning in Medical Image Analysis and Multimodal Learning For Clinical Decision Support, 63–273.
- Deng L, Yu D, 2013a, Deep Learning: Methods and Applications Foundations and

- Trends R in Signal Processing, Signal Processing, 7, 197–387.
- Doğan F, Türkoğlu İ, 2018, Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması The Comparison of Leaf Classification Performance of Deep Learning Algorithms, Sakarya University Journal of Computer and Information Sciences, 1, 10–21.
- Donalek C, 2011, Supervised and Unsupervised Learning, In Astronomy Colloquia, 27,USA .
- Fathi E, Maleki Shoja B, 2018, Deep Neural Networks for Natural Language Processing, Handbook of Statistics Elsevier B.V., 229–316.
- Ferrante di Ruffano L, Takwoingi Y, Dinnes J, Chuchu N, Bayliss S E, Davenport C, Matin R N, Godfrey K, O’sullivan C, Gulati A, Chan S A, Durack A, O’connell S, Gardiner M D, Bamber J, Deeks J J, Williams H C, 2018, Computer-Assisted Diagnosis Techniques (Dermoscopy And Spectroscopy-Based) for Diagnosing Skin Cancer in Adults, Cochrane Database of Systematic Reviews, 12 .
- Finlayson G D, Schiele B, Crowley J L, 1998, Comprehensive Colour Image Normalization, In European Conference on Computer Vision, 475–490.
- Fukushima K, 1980, Neocognitron: A Self-Organizing Neural Network Model For A Mechanism of Pattern Recognition Unaffected By Shift In Position, Biological Cybernetics, 36, 193–202.
- Garcia-Arroyo J L, Garcia-Zapirain B, 2019, Segmentation of Skin Lesions In Dermoscopy Images Using Fuzzy Classification of Pixels and Histogram Thresholding, Computer Methods and Programs in Biomedicine, 168, 11–19.
- Goodfellow IJ, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, Courville A, Bengio Y, 2014, Generative Adversarial Networks, Advances in Neural Information Processing Systems, 27.
- Goodfellow I, Bengio Y, Courville A, 2020, Deep Learning (Adaptive Computation and Machine Learning Series), The MIT Press, 321-359, Cambridge Massachusetts.

- Goyal M, Yap H, Hassanpour S, 2020, Multi-class Semantic Segmentation of Skin Lesions via Fully Convolutional Networks, arXiv:1711.10449.
- Gupta N, 2013, Artificial neural network, Network and Complex Systems Artificial Neural Network, 3, 24-28.
- Gutman D, F Codella N C, Celebi E, Helba B, Marchetti M, Mishra N, Halpern A, 2016, Skin Lesion Analysis toward Melanom Detection, A Challenge at the International Symposium on Biomedical Imaging (ISBI) 2016, hosted by the International Skin Imaging Collaboration (ISIC), arXiv:1605.01397.
- Guy G P, Ekwueme D U, 2011, Years of Potential Life Lost and Indirect Costs of Melanom and Melanom Olmayan Skin Cancer: A Systematic Review of The Literature, Pharmacoeconomics, 29, 863–874.
- Hasan M, Dahal L, Samarakoon PN, Tushar FI, Martí R, 2020, DSNet: Automatic Dermoscopic Skin Lesion Segmentation, Computers in Biology and Medicine, 120.
- He K, Zhang X, Ren S, Sun J, 2016, Deep Residual Learning for Image Recognition, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 27-30 June, Las Vegas, 770-778.
- He X, Yu Z, Wang T, Lei B, 2017, Skin Lesion Segmentation Via Deep RefineNet, In Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, 303–311.
- Hidaka A, Kurita T, 2017, Consecutive Dimensionality Reduction by Canonical Correlation Analysis for Visualization of Convolutional Neural Networks, Proceedings of the ISCIE International Symposium on Stochastic Systems Theory and its Applications, November 3-4, Hiroshima, 160–167.
- Jadon S, 2020, A Survey of Loss Functions for Semantic Segmentation, In 2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology, October 27-29, Online, 1-7.

- Karagas M R, Weinstock M A, Nelson H H, 2009, Keratinocyte Carcinomas (Basal and Squamous Cell Carcinomas of The Skin), Cancer Epidemiology and Prevention; Oxford University Press.
- Karakullukçu E, 2020, Yanık Görüntülerinin Çok Değişkenli İstatistiksel Yöntemler Ve Derin Öğrenme Yaklaşımları İle Analizi, Karadeniz Teknik Üniversitesi, Ddoktora Tezi, 124s, Trabzon.
- Kaul C, Manandhar S, Pears N, 2019, Focusnet: An Attention-Based Fully Convolutional Network for Medical Image Segmentation, In 2019 IEEE 16th International Symposium on Biomedical Imaging, April 8-11, Venice, 455–458.
- Kawahara J, Hamarneh G, 2019, Fully Convolutional Neural Networks to Detect Clinical Dermoscopic Features, IEEE Journal of Biomedical and Health Informatics, 23, 578–585.
- Kaymak R, Kaymak C, Ucar A, 2020, Skin Lesion Segmentation Using Fully Convolutional Networks: A Comparative Experimental Study, Expert Systems with Applications, 161, 113742.
- Keleşoğlu Ö, Fırat A, 2006, İç Basınç Altında İnce Cidarlı Kabukların Yapay Sinir Ağları ile Çözümü, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi;10(3):447-51 .
- Keskenler M F, Keskenler E F, 2017, Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi, Takvim-i Vekayi, 5, 8–18.
- Khosravan N, Mortazi A, Wallace M, Bagci U, 2019, PAN: Projective Adversarial Network for Medical Image Segmentation, In International Conference on Medical Image Computing and Computer-Assisted Intervention, 13-17 October, Shenzhen, China, 68–76.
- Kingma D P, Ba J, 2014, Adam: A Method for Stochastic Optimization, Arxiv Preprint, arXiv:1412.6980.
- Kizilbey K, Akdeste Z M, 2013, Melanom Cancer, Sigma: Journal of Engineering &

- Krizhevsky A, Sutskever I, Hinton G E, 2012, ImageNet Classification with Deep Convolutional Neural Networks, Advances In Neural Information Processing Systems, 25, 1097–1105.
- Küçük D, Arici N, 2018, Doğal Dil İşlemede Derin Öğrenme Uygulamaları Üzerine Bir Literatür Çalışması, International Journal of Management Information Systems and Computer Science, 2, 76–86.
- Kurt F, 2018, Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi Analysis of The Effects of Hyperparameters In Convolutional Neural Networks, Hacettepe Üniversitesi, Yüksek Lisans, 130, Ankara.
- Levent KOÇ M, Balas C E, Arslan A, 2004, Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı 1, Teknik Dergi , 15, 225.
- Li F, Karpathy A, J J-N, 2016, Stanford University CS231n: Convolutional Neural Networks for Visual Recognition (1).
- Li X, Chen H, Qi X, Dou Q, Fu C W, Heng P A, 2018, H-DenseUNet: Hybrid Densely Connected UNet for Liver and Tumor Segmentation from CT Volumes, IEEE Transactions on Medical Imaging, 37, 2663–2674.
- Li Y, Shen L, 2018, Skin Lesion Analysis Towards Melanom Detection Using Deep Learning Network, Sensors (Switzerland), 18, 1–16.
- Liu L, Mou L, Zhu X X, Mandal M, 2019, Skin Lesion Segmentation Based on Improved U-Net, 2019 IEEE Canadian Conference of Electrical and Computer Engineering (CCECE), 5-8 May, Edmonton, Canada, 1-4.
- Liu X, Song L, Liu S, Zhang Y, 2021, A Review of Deep-Learning-Based Medical Image Segmentation Methods, Sustainability (Switzerland), 13, 1–29.
- Long J, Shelhamer E, Darrell T, 2015, Fully Convolutional Networks For Semantic Segmentation, In Proceedings of The IEEE Conference on Computer Vision and

- Pattern Recognition, 3431–3440.
- Luc P, Couprie C, Chintala S, Verbeek J, 2016, Semantic Segmentation Using Adversarial Networks, arXiv:1611.08408.
- MacKay D J C, 1992, Bayesian Interpolation, Neural Computation, 4, 415–447.
- Makalesi A, Menteşe E, Hançer E, 2020, Histopatoloji Görüntülerde Derin Öğrenme Yöntemleri ile Çekirdek Segmentasyonu, European Journal of Science and Technology Special Issue, 95–102.
- Mariyammal C, Sasireka S, 2018, Survey on Image Segmentation Methods, International Advanced Research Journal in Science, Engineering and Technology (IARJSET), 5(11), 23-26, 5 .
- Mendonça T, Ferreira P M, Marques J S, Marcal A R, Rozeira J, 2013 , PH2 - A Dermoscopic Image Database for Research and Benchmarking, In 2013 35th Annual International Conference of The IEEE Engineering In Medicine and Biology Society (EMBC), 3-7 July, Osaka, Japan 5437-5440 .
- Menegola A, Tavares J, Fornaciali M, Li L T, Avila S, Valle E, 2017, RECOD Titans at ISIC Challenge 2017, arXiv preprint arXiv:1703.04819.
- Milletari F, Navab N, Ahmadi SA, 2016, V-net: Fully Convolutional Neural Networks For Volumetric Medical Image Segmentation, In 2016 Fourth International Conference on 3D Vision (3DV), 25-28 October 2016, Stanford, 565–571.
- Minaee S, Boykov Y, Porikli F, Plaza A, Kehtarnavaz N, Terzopoulos D, 2020, Image Segmentation Using Deep Learning: A Survey, IEEE Transactions on Pattern Analysis and Machine Intelligence .
- Mongkhonthanaphon S, Limpiyakorn Y, 2018, Classification of Titanium Microstructure with Fully Convolutional Neural Networks, Journal of Physics: Conference Series, Volume 1195, 11th International Conference on Computer and Electrical Engineering 12–14 October , Tokyo, Japan ,1195,12022.

- Ms.S.Premalatha, 2020, Segmentation of Skin Lesion and Cancer Using Fast Fuzzy C Means Clustering, Solid State Technology, 5517–5525.
- Öztürk Ş, Özkaya U, 2020, Skin Lesion Segmentation with Improved Convolutional Neural Network, Journal of Digital Imaging, 33, 958–970.
- Pereira P M M, Fonseca-Pinto R, Paiva R P, Assuncao P A A, Tavora L M N, Thomaz L A, Faria S M M, 2020, Dermoscopic Skin Lesion Image Segmentation Based on Local Binary Pattern Clustering: Comparative Study, Biomedical Signal Processing and Control, 59, 101924.
- Pihur V, Datta S, Datta S, 2007, Weighted Rank Aggregation of Cluster Validation Measures: A Monte Carlo Cross-Entropy Approach, Bioinformatics, 23, 1607–1615.
- Reed R D, Marks R J, 1999, Neural Smithing: Supervised Learning in Feedforward Artificial Neural Networks, Mit Press, London, England.
- Ren Y, Yu L, Tian S, Cheng J, Guo Z, Zhang Y, 2021, Serial Attention Network for Skin Lesion Segmentation, Journal of Ambient Intelligence and Humanized Computing, 1, 3.
- Robert C, 2014, Machine Learning, A Probabilistic Perspective, Chance, Vol. 27, 62-63.
- Ronneberger O, Fischer P, Brox T, 2015, U-Net: Convolutional Networks for Biomedical Image Segmentation, In International Conference on Medical Image Computing and Computer-Assisted Intervention, 13-17 Oct, Shenzhen, China, 234-241 .
- Rosenblatt F, 1958, The Perceptron: A Probabilistic Model for Information Storage and Organization in The Brain, Psychological Review, 65, 386.
- Şahin N, Alpaslan N, 2020, Cilt Lezyon Bölütlemesi İçin Metasezgisel Temelli Otsu Eşikleme Yöntemi, Türk Doğa Ve Fen Dergisi, 9, 42–48.
- Salehi S S M, Erdogmus D, Gholipour A, 2017, Tversky Loss Function for Image

- Segmentation Using 3D Fully Convolutional Deep Networks, In International Workshop on Machine Learning in Medical Imaging, 10 Sept., Quebec, Canada 379–387.
- Sarker M M K, Rashwan H A, Akram F, Banu S F, Saleh A, Singh V K, Chowdhury F U H, Abdulwahab S, Romani S, Radeva P, Puig D, 2018, SLSDeep: Skin Lesion Segmentation Based On Dilated Residual and Pyramid Pooling Networks, International Conference on Medical Image Computing and Computer-Assisted Intervention, 16-20 Sept., Granada, Spain, 21–29.
- Shamsul Arifin M, Golam Kibria M, Firoze A, Ashraful Amini M, Yan H, 2012, Dermatological Disease Diagnosis Using Color-Skin Images, In 2012 International Conference on Machine Learning and Cybernetics, 15-17 July, Xian, Shaanxi, China, 1675–1680.
- Sonawane M S, Dhawale C A, 2015, A Brief Survey on Image Segmentation Methods, International Journal of Computer Applications, 975–8887.
- Sudeep K S, Pal K K, 2017, Preprocessing for Image Classification By Convolutional Neural Networks, In 2016 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT) , 1778–1781.
- Sümen A, Öncel S, 2014, Deri Kanseri ve Güneşten Korunma Deri Kanseri ve Güneşten Korunmaya Yönelik Öğrencilerle İlgili Yapılan Çalışmalar: Literatür İncelemesi, Dokuz Eylül Üniversitesi Hemşirelik Yüksekokulu Dergisi, C7/S2.
- Sundararajan K, Woodard D L, 2018, Deep Learning for Biometrics: A Survey, ACM Computing Surveys, 51, 1–34.
- Svozil D, Kvasnicka V, Pospichali J, 1997, Introduction to Multi-Layer Feed-Forward Neural Networks, Chemometrics and Intelligent Laboratory Systems , 39, 43–62.
- Thao L T, Quang N H, 2017, Automatic Skin Lesion Analysis Towards Melanom Detection, In 2017 21st Asia Pacific Symposium on Intelligent and Evolutionary Systems, Nov. 15 - 17, Hanoi, Vietnam, 106–111.

- Tieleman T, Hinton G, 2012, Lecture 6.5. RMSPROP: Divide The Gradient By A Running Average of Its Recent Magnitude, COURSERA: Neural Networks for Machine Learning, 242-86.
- Tschandl P, Rosendahl C, Kittler H, 2018, Data descriptor: The HAM10000 Dataset, A Large Collection of Multi-Source Dermatoscopic Images of Common Pigmented Skin Lesions, Scientific Data, 5, 1–9.
- Türkmen A, Berberoğlu Ö, Bekerecioğlu M, Mutaf M, 2010, Deri Kanseri: 10 Yıllık Değerlendirme, Gaziantep Tıp Dergisi, 16, 11–15.
- Ünver H M, Ayan E, 2019, Skin Lesion Segmentation In Dermoscopic Images with Combination of Yolo and Grabcut Algorithm, Diagnostics, 9, 72.
- Uysal A, Özsoy S A, Ergül Ş, 2004, Öğrencilerin Cilt Kanseri Risklerinin Ve Güneş Işınlardan Korunmaya Yönelik Uygulamalarının Değerlendirilmesi, Ege Tıp Dergisi, 43, 95–99.
- Uysal E, Güraksin G E, 2020, Computer-Aided Retinal Vessel Segmentation In Retinal Images: Convolutional Neural Networks, Multimedia Tools and Applications, 80, 3505–3528.
- Valle E, Fornaciali M, Menegola A, Tavares J, Vasques Bittencourt F, Li L T, Avila S, 2020, Data, Depth, and Design: Learning Reliable Models For Skin Lesion Analysis, Neurocomputing, 383, 303–313.
- Verschoof-van der Vaart W B, Lambers K, 2019, Learning to Look at LiDAR: The Use of R-CNN in the Automated Detection of Archaeological Objects in LiDAR Data from the Netherlands, Journal of Computer Applications in Archaeology, 2, 31–40.
- Van De Weijer J, Gevers T, 2005, Color Constancy Based on The Grey-Edge Hypothesis, In IEEE International Conference on Image Processing, 11-14 Sept., Genoa, Italy, 722–725.
- Wen H, 2017, II-FCN for Skin Lesion Analysis Towards Melanom Detection, arXiv preprint arXiv:1702.08699.

- Wingo P A, Davis K J, Cokkinides V E, Weinstock M A, O'connell M C, 2002, Summer Sunburn and Sun Exposure Among US Youths Ages 11 to 18: National Prevalence and Associated Factors, *Pediatrics*, 110, 27–35.
- Xiao X, Lian S, Luo Z, Li S, 2018, Weighted Res-UNet for High-Quality Retina Vessel Segmentation, In 2018 9th International Conference on Information Technology in Medicine and Education (ITME), 19-21 Oct., Hangzhou, China 327–331.
- Xie F, Yang J, Liu J, Jiang Z, Zheng Y, Wang Y, 2020, Skin Lesion Segmentation Using High-Resolution Convolutional Neural Network, *Computer Methods and Programs in Biomedicine*, 186, 105241.
- Xue Y, Xu T, Zhang H, Long L R, Huang X, 2018, SegAN: Adversarial Network with Multi-scale L1 Loss for Medical Image Segmentation, *Neuroinformatics*, 16, 383–392.
- Yang M, Yu K, Zhang C, Li Z, Yang K, 2018, DenseASPP for Semantic Segmentation in Street Scenes, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 18-22 June, Salt Lake City, UT, USA ,3684–3692.
- Yi-de M, Qing L, Zhi-Bai Q, 2004, Automated Image Segmentation Using Improved PCNN Model Based on Cross-Entropy, In Proceedings of 2004 International Symposium on Intelligent Multimedia, Video and Speech Processing, October 20-22, Hong Kong, 743–746.
- Yuan Y, 2017, Automatic Skin Lesion Segmentation with Fully Convolutional-Deconvolutional Networks, arXiv preprint arXiv:1703.05165.
- Yuan Y, Chao M, Lo Y C, 2017, Automatic Skin Lesion Segmentation Using Deep Fully Convolutional Networks with Jaccard Distance, *IEEE Transactions on Medical Imaging*, 36, 1876–1886.
- Yuan Y, Lo Y C, 2019, Improving Dermoscopic Image Segmentation with Enhanced Convolutional-Deconvolutional Networks, *IEEE Journal of Biomedical and Health Informatics*, 23, 519–526.

Yüksel M E, Borlu M, 2009, Accurate Segmentation of Dermoscopic Images By Image Thresholding Based on Type-2 Fuzzy Logic, IEEE Transactions on Fuzzy Systems, 17, 976–982.

Zafar K, Gilani S O, Waris A, Ahmed A, Jamil M, Khan M N, Kashif A S, 2020, Skin Lesion Segmentation from Dermoscopic Images Using Convolutional Neural Network, Sensors, 20, 1601.

Zaitoun N M, Aqel M J, 2015, Survey on Image Segmentation Techniques, Procedia Computer Science, 797–806.

İnternet Kaynakları

1- <https://www.wcrf.org/dietandcancer/cancer-trends/skin-cancer-statistics>, 23.12.2020.

2-https://melanopatients.org.au/wp-content/uploads/2020/04/2020-campaign-report-GC-version-MPA_1.pdf, 24.12.2020 .

3-<https://mitpress.mit.edu/books/parallel-distributed-processing-volume-1>, 04.03.2021.

4-http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf, 04.03.2021.

5-<https://www.cancer.net/cancer-types/melanom/screening>, 19.04.2021.

6-<https://d74ec2d6f7db4603480eca467de32d3f06478210.vetisonline.com>

7-<https://web.archive.org/web/20150223155232/>

8-<http://www.ncbi.nlm.nih.gov/pubmed/26389182>, 21.04.2021.

9-<https://www.nccih.nih.gov/health/cancer-in-depth>, 21.04.2021.

12-<https://www.scopus.com>

- 11-http://osp.mans.edu.eg/rehan/ann/2_2%20Biological%20Neural%20Networks.html,
22.04.2021.
- 12-<https://soyleki.com/yapay-zekâ-nedir-nasil-calisir-insan-gibi-dusunen-makine/>,
26.04.2021.
- 13- <http://www.dermquest.com> /29.04.2021
- 14-<https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>,04.05.2021.
- 15-<https://cambridgespark.com/content/tutorials/convolutional-neural-networks-with-keras/index.html>,05.05.2021.