

**DEĞİŞTİRİLMİŞ U-NET MODELİ İLE BİYOMEDİKAL
GÖRÜNTÜ SEGMENTASYONU**

UMUT TATLI

ŞUBAT 2024

DİYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DEĞİŞTİRİLMİŞ U-NET MODELİ İLE BİYOMEDİKAL
GÖRÜNTÜ SEGMENTASYONU**

UMUT TATLI

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV
YÖNETMELİĞİNİN BİR PARÇASI OLARAK
BİYOMEDİKAL MÜHENDİSLİĞİ ANA BİLİM DALINDA
YÜKSEK LİSANS TEZİ
OLARAK HAZIRLANMIŞTIR

ŞUBAT 2024

DİYARBAKIR

DEĞİŞTİRİLMİŞ U-NET MODELİ İLE BİYOMEDİKAL GÖRÜNTÜ SEGMENTASYONU

Umut TATLI tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Biyomedikal Mühendisliği Ana Bilim Dalı**'nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ
Müdür, **Fen Bilimleri Enstitüsü**

Doç. Dr. Cafer BUDAK
Danışman, **Elektrik-Elektronik Mühendisliği Bölümü,**
Dicle Üniversitesi

Sınav Jürisi:

Prof. Dr. Mehmet Sıraç ÖZERDEM (*)
Elektrik-Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi

Doç. Dr. Cafer BUDAK (**)
Elektrik-Elektronik Mühendisliği Bölümü,
Dicle Üniversitesi

Doç. Dr. Emrullah ACAR
Elektrik-Elektronik Mühendisliği Bölümü,
Batman Üniversitesi

ONAY

Savunma Tarihi: 26/ 01/ 2024

(*) Jüri Başkanı.

(**) Tez Danışmanı.

Anneme, Babama, Eşime ve Abime...

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılıyıp kaynak gösterdiğimi beyan ederim. Beyanımınla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Umut TATLI

İmza:

TEŞEKKÜR

İlk olarak danışmanım olan Doç. Dr. Cafer BUDAK'a fikir aşamasındaki çalışmalarımı, örnek çalışmalarla deney setleri meydana getirmemde sonuç ve sonuçlardan elde edilen değerlerin çözümlenmesi ve yorumlanmasından tezin taslak halindeki düzenlemelerine kadar göstermiş oldukları sabır, destek ve özveriden ötürü kendilerine teşekkür ederim. Değerli jüri üyelerine de tezin daha nitelikli hale gelmesi hususunda önerileri ve eleştirileri ile ilgili teşekkür ederim.

Çalışmamın tüm aşamalarında yol göstericiliği ve yardımları için Prof. Dr. Abdullah TOPRAK'a çok teşekkür ederim. Tezimi farklı bakış akış açıları ile ele alıp önerilerde bulunan abim Mert TATLİ'ya ve kuzenim Cihangir Yusuf DENLİ'ye de teşekkürü borç bilirim.

En önemlisi, araştırmanın farklı aşamalarında yardımını esirgemeyen, araştırmama heyecan katan, beni motive eden eşim Mizgin DENİZ TATLİ, bize daima inanan ve bizi bugünlere getirerek yanımızda olan annem Hatice Eda TATLİ ve babam Mehmet TATLİ'ya sonsuz teşekkürler...

İÇİNDEKİLER

TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ.....	x
SİMGELER VE KISALTMALAR LİSTESİ	xi
ÖZET.....	xii
ABSTRACT.....	xiii
1. GİRİŞ	1
1.1 Evrişimli Sinir Ağları	4
1.1.1 Konvolüsyon işlemi	6
1.1.2 Maksimum havuzlama	9
1.1.3 Aktivasyon fonksiyonları	10
1.1.4 Aşırı öğrenme	12
1.1.5 Normalizasyon yöntemleri	13
1.1.6 Optimizasyon yöntemleri	16
1.2 Görüntü Segmentasyonu	19
2. ÖNCEKİ ÇALIŞMALAR.....	22
2.1 Yapay Zekâ Tarihçesi.....	22
2.2 Evrişimli Sinir Ağları Tarihçesi	23
2.3 Biyomedikal Alanında Yapay Zekâ	24
2.4 Derin Öğrenme Tarihçesi	27
2.5 Derin Öğrenme Alanında Görüntü Segmentasyonu Çalışmaları	28
2.6 Biyomedikal Alanında U-NET Kullanımı.....	31
2.7 U-Net Modelinden İlham Alan Çalışmalar	32
3. MALZEME VE YÖNTEM	35

3.1	Veri Setleri	35
3.2	U-Net Mimarisi	37
3.3	U-Net İçin Matematiksel Formüller	38
3.4	Önerilen Yöntem	40
3.5	Görüntüleri ön işleme aşamaları (Preprocessing data).....	42
3.6	Kayıp Fonksiyonları	42
4.	BULGULAR VE TARTIŞMA	44
5.	SONUÇLAR	51
	KAYNAKLAR	52
	ÖZGEÇMİŞ	61

ŞEKİLLER LİSTESİ

Şekil 1.1 Yapay zekâ kümeleri.....	2
Şekil 1.2 Derin öğrenme modelleri (Nweke vd., 2018)	3
Şekil 1.3 Makine öğrenmesi yaklaşımları (Mahesh, 2020).....	4
Şekil 1.4 Giriş görüntüsü ve çıkışların çalışma prensibini gösteren klasik bir ESA mimarisi	5
Şekil 1.5 ESA yapısı	6
Şekil 1.6 6x6 Giriş görüntüsüne 3x3 konvolüsyon filtresi uygulama. Adım değeri (Stride) = 1 olarak alınmıştır. Çıkışta ise 4x4'lük bir matris elde edilmiştir	7
Şekil 1.7 5x5 giriş görüntüsüne kenar dolgu işlemi uygulandıktan sonra 3x3 çıkış görüntüsü elde edilmiştir.....	8
Şekil 1.8 3x3 giriş görüntüsüne sıfır dolgu uygulandıktan sonra 5x5 çıkış matrisi elde edilmiştir	9
Şekil 1.9 6x6 görüntüye 3x3 maksimum havuzlama işlemi uygulanarak 2x2'lik çıkış matrisi elde edilmiştir.....	10
Şekil 1.10 Soldan sağa; ReLU, Softmax, Sigmoid ve Leaky ReLU fonksiyonlarının giriş görüntüsüne uyguladığı işlemin grafiksel ve formülleri gösterilmiştir.....	12
Şekil 1.11 (a) Yetersiz öğrenme, (b) aşırı öğrenme ve (c) iyi öğrenme örnekleri	13
Şekil 1.12 (a) Standart bir sinir ağı ve (b) normalizasyon (eleme) yöntemi uygulandıktan sonraki sinir ağı	14
Şekil 1.13 Batch normalization eğitim grafiği	15
Şekil 1.14 Dropout eğitim grafiği	16
Şekil 1.15 Optimizasyon yöntemlerinin evrimsel haritası	17
Şekil 1.16 (a) Görüntü sınıflandırma, (b) nesne tanımlama, (c) semantik segmentasyon, (d) örnek segmentasyon.....	21
Şekil 3.1 (a) Göğüs CT görüntüsü ve akciğerin bulunduğu segmente görüntü (b) meme kanserine sahip doku ve kanserli hücreler (c) doku ve segmente edilmiş hücreler.....	35
Şekil 3.2 Klasik U-Net mimarisi (Ronneberger Olaf and Fischer, 2015).....	37
Şekil 3.3 U-Net mimarisi-kırmızı çizgiyle gösterilen alan önerilen yönteme eklenen kısımdır	40
Şekil 3.4 (a) U-Net7 mimarisi (b) U-Net13 mimarisi	41

Şekil 3.5 Akış şeması	41
Şekil 4.1 (a) U-Net13 modelinin meme kanseri veri seti üzerindeki eğitim ve test başarı sonuçları (b) meme kanseri veri seti üzerindeki modellerin tahmini	44
Şekil 4.2 (a) Meme kanserli doku (b) hücrelerin segment görüntüsü (c) U-Net7 modelinin tahmini (d) U-Net modelinin tahmini (e) U-Net11 modelinin tahmini (f) U-Net13 modelin tahmini	45
Şekil 4.3 Akciğer segmentasyonu veri seti üzerindeki modellerin tahmin oranlarının karşılaştırılması	46
Şekil 4.4 (a) CT görüntüsü (b) görüntünün akciğer segmentasyonu (c) U-Net7 modeli tahmini (d) U-Net modeli tahmini (e) U-Net11 modeli tahmini (f) U-Net13 tahmini modeli.....	47
Şekil 4.5 Hücre çekirdeği segmentasyonu veri seti üzerindeki modellerin tahmin oranlarının karşılaştırılması.....	48
Şekil 4.6 (a) Hücre çekirdeği görüntüsü (b) görüntünün çekirdek segmentasyonu (c) U-Net7 modeli tahmini (d) U-Net modeli tahmini (e) U-Net11 modeli tahmini (f) U-Net13 tahmini modeli.....	49

TABLÖLAR LİSTESİ

Tablo 4.1 U-Net modellerine ait veri setlerine ilişkin eğitim ve test sonuçları	49
Tablo 4.2 Veri setleri üzerindeki karşılaştırma modellerinin sonuçları	50



SİMGELER VE KISALTMALAR LİSTESİ

Simge

Açıklama

%

Yüzde

s

Saniye

ms

Milisaniye

$\cup$

Küme birleşimi

$\cap$

Küme Kesişimi

Kısaltma

Açıklama

GPU

Graphics Processing Unit

ESA

Evrişimsel Sinir Ağları

CNN

Convolution Neural Network

YZ

Yapay Zekâ

MÖ

Makine Öğrenmesi

DÖ

Derin Öğrenme

IoU

Intersection over Union

SGD

Stochastic Gradient Descent

CT

Computer Tomography

TCGA

The Cancer Genome Atlas

ÖZET

DEĞİŞTİRİLMİŞ U-NET MODELİ İLE BİYOMEDİKAL GÖRÜNTÜ SEGMENTASYONU

TATLI, Umut

Yüksek Lisans, Biyomedikal Mühendisliği Bölümü

Danışman: Doç. Dr. Cafer BUDAK

Şubat 2024, 75 sayfa

Görüntü segmentasyonu, görüntü işleme ve bilgisayarlı görmede önemli bir alandır. Görüntü segmentasyonu alanında derin öğrenme yöntemlerinin kullanılması ise özellikle Biyomedikal ve tıbbi alanlardaki uzmanlara yardımcı olacak yöntemlerin geliştirilmesinde, var olan yöntemlerdeki zamandan ve maliyetten tasarruf sağlama konusunda hayati bir rol oynar. Derin öğrenmeyi kullanan görüntü segmentasyonu modelleri arasında yer alan önemli yöntemlerden biri U-Net modelidir. U-Net modeli birçok çalışmaya ilham kaynağı olmuş ve evrimsel sinir ağlarının gelişmesinde faydalı bir model olmuştur. Zaman içerisinde U-Net modelinde farklılıklar oluşturularak U-Net modelinden daha başarılı yöntemler geliştirilmiştir. Bu çalışmada 11 evrimsel katman kullanan ve segmentasyon performansını artırmak için bazı değişiklikler getiren yeni bir U-Net varyantı olan U-Net11'i öneriyoruz. Klasik U-Net modeli geliştirilmiş ve üç farklı veri kümesi üzerinde test edilerek klasik U-Net modelinden daha iyi performans göstermiştir. Önerilen yöntem: Hücre dokularından elde edilen meme kanserli hücre segmentasyonu, bilgisayarlı tomografi görüntülerinden elde edilen akciğer segmentasyonu ve Data Science Bowl 2018 yarışmasından elde edilen hücre çekirdeği segmentasyonu veri kümeleri için değerlendirilmiştir. Bu veri kümeleri, değişen görüntü miktarları ve segmentasyon görevlerindeki değişen zorluk seviyeleri nedeniyle önem içermektedir. Katman farkını gözlemleyebilmek için Klasik U-Net'e katman ekleme-çıkarma işlemi yapılarak U-Net-7, U-Net-13 modelleri geliştirilmiş ve önerilen model ile olan farkı kıyaslanmıştır. Değiştirilmiş U-Net modeli: Hücre dokularından elde edilen meme kanserli hücre segmentasyonu veri kümesinde %69,09, bilgisayarlı tomografi görüntülerinden elde edilen akciğer segmentasyonu veri kümesinde %95,02 ve doku görüntüsünden hücre çekirdeği segmentasyonu veri kümesinde %81,10 DSC puanları elde ederek klasik U-Net modelinden sırasıyla %5, %2 ve %4 oranında daha yüksek bir başarı göstermiştir. Başarı oranlarındaki bu fark özellikle biyomedikal mühendisliği ve tıp alanlarındaki kritik segmentasyon veri kümeleri için büyük öneme sahiptir ve model geliştirilerek daha başarılı sonuçlar elde ederek bu alanlarda büyük tasarruflar sağlayabilir.

Anahtar Kelimeler: Biyomedikal görüntü segmentasyonu, derin öğrenme, U-Net

ABSTRACT

BIOMEDICAL IMAGE SEGMENTATION WITH MODIFIED U-NET

TATLI, Umut

Master of Science in Department of Biomedical Engineering

Supervisor: Assoc. Prof. Dr. Cafer BUDAK

February 2024, 75 pages

Image segmentation has a very significant place in image processing and machine vision. Exclusively, it plays a vital role to improvement of models to help specialist in biomedical and medical areas, saving time and cost in existing methods. Among the most significant image segmentation models utilize deep learning at U-Net model. U-Net model has motivated numerous studies and has been a useful model in development of convolutional neural networks. Scope of the report, we suggest a new version of U-Net, U-Net 11, which utilizes 11 convolutional layers and assert a few modifies to ameliorate to segmentation accuracy. The standard U-Net method was ameliorated and checked on three types of datasets and outperformed the standard U-Net model. U-Net 11 model: Breast tumor cell segmentation from cell tissues, lung tumor segmentation from CT scan figures and cell nucleus segmentation at the Data Science Bowl 2018 rivalry. Abovementioned datasets are significant owing to their alteration quantity of images and changing levels of challenges in segmentation tasks. On the purpose of observe the layer variation, U-Net 13 and U-Net 7 models are generated by adding and removing layers to standard U-Net and compared with the suggested method. A modified U-Net model: 69.09%, 95.02%, and 81.10% DSC accuracy on the breast cancer cell segmentation dataset derived from cell tissues, lung segmentation dataset obtained from computed tomography images, and cell nucleus segmentation dataset obtained from tissue images, which are respectively 5%, 2%, and 4% higher besides standard U-Net model. This variation in accuracy rates is especially important for critical segmentation datasets in biomedical engineering and medicine, and model can be improved to achieve more successful results, leading to significant savings in these fields.


Keywords: U-Net, image segmentation, deep learning, biomedical image

1. GİRİŞ

Biyomedikal arařtırmalar, insan saęlıęı ile ilgili verilerin karmařıklıęını ve çeřitlilięini içermektedir. Bu veriler, genomik sekanslardan hastalık teřhisi için görüntüleme verilerine kadar geniř bir yelpazede yer almaktadır. İnsan vücuduyla ilgili bu büyük ve karmařık veri setlerini anlamak ve bu verileri klinik uygulamalarda kullanmak, geleneksel analiz yöntemleriyle zaman alıcı ve sınırlı sonuçlar üreten bir süreç olabilir. Bu sebeple, biyomedikal alanında yapay zekanın kullanımı büyük bir öneme sahiptir. Yapay zekâ ve biyomedikal bilimler, günümüzde insanlıęın saęlık ve tıp alanındaki en büyük sorunlarını çözmeye yönelik büyük bir potansiyel taşımaktadır. Yapay zekâ: Hastalık tespiti, hızlı karar verme yetisi, hastaya zamanında müdahale, doęru ilaç tespiti gibi kısıtlı zamanda hızlı işlemler yapılmasını gerektiren veya hata riski olmayan işlemleri doktorlar ve uzmanlar için kolaylařtırmıştır. Organ tespiti, hastalık tespiti, kanserli hücre tespiti, hasarlı doku tespiti, anormal doku tespiti, vb. gibi birçok alanda kullanılabilir. Böylece uzmanların iş yükünü ciddi oranda azaltarak daha fazla hastayı tedavi etme imkânı sunmuştur. Özellikle kanser gibi hastalıklarda erken teřhis büyük bir öneme sahiptir. Yapay zekâ, insan algısının fark edemedięi yapıları daha doęru ve hassas bir şekilde saptanabilir ve hasta tedavisinde erken teřhis ederek hastaya erken müdahaleye sebep olur. Ayrıca yapay zekâ büyük veri işleme yetenekleri, derin öğrenme algoritmaları ve özellik mühendislięi ile birleřerek, biyomedikal alanında devrim nitelięindeki keřifler ve inovasyonlar getirmektedir.

Bilgisayar bilimlerinde teknolojinin ilerlemesi ve bilgisayar donanımlarının hızla gelişmesi sebebiyle yapay zekâ kavramı büyük bir öneme sahip olmuştur. Yapay zekâ: insan gibi düşünecek, insan gibi karar verecek ve insanı taklit edecek bilgisayar sistemleri oluřturma bilimi ve mühendislięi olarak tanımlanır (Fetzer, 1990). Yapay zekanın en büyük hedefi ise insan düşünme yapısını ve karar alma/verme yetisini modellemektir. Yapay zekâ insanların, yüz tanıma, otonom araçlar ve akıllı tıbbi tedavi gibi geçtięimiz birkaç yüzyılda imkânsız olduęu düşünölen şeyleri başarmasına olanak saęladı.

Yapay zekâ zaman içerisinde derinleşmiştir. Makine öğrenmesi (Machine Learning) ve Makine Öğrenmesinin alt kırılımı olan Derin Öğrenme (Deep Learning) yapay zekâ kümesinin içinde yer almaktadır. Yapay zekâ ile ilgili kümeler Şekil 1.1’de gösterilmektedir.




Şekil 1.1 Yapay zekâ kümeleri

Yapay zekanın insan beyninden esinlenmesi derin öğrenme tarihi açısından çok önemli bir yere sahiptir. İnsan beyninin örnek alınması “sinir ağı” kavramının oluşmasına sebep olmuştur. Fakat beyin hakkındaki bilgilerimizin sınırlı oluşu ve verilerin azlığı mühendislik uygulamasını zorlaştırmıştır. Ayrıca beyin çalışma sisteminin bilinmeyişi artık derin öğrenmede bir rehberlik sağlayamaz bu sebeple

derin öğrenmedeki biyolojiden esinlenme durumu eskisi kadar vurgulanmamaya başlamıştır. Derin öğrenme artık tek bir alandan esinlenmemekte sinir bilimini aşarak birden fazla alandan ilham almakta ve çok yönlü öğrenmeyi mevcut algoritmalarda uygulamaktadır. Birden daha fazla işlem katmanından meydana gelen, derin öğrenme hesaplama modellerinin, birden daha fazla soyutlama seviyesine haiz veri örneklerini öğrenmesini sağlar. Bu modeller, konuşma tespit etme, görsel nesne algılama ve ilaç tahmini gibi diğer birçok farklı alandaki birçok farklı teknolojiyi önemli ölçüde geliştirmiş ve bu gelişimi büyük düzeyde hızlandırmıştır. Derin öğrenme, geri yayılım algoritması sayesinde bütün katmanlardaki değerleri bir sonraki katmana aktararak veriyi nasıl hesaplayacağını öğrenen parametrelerdeki değişkenliği tespit eder ve “Büyük veri” kümelerindeki karışık algoritmaları analiz eder. Buradaki katmanlı mimari sayesinde büyük veri kümelerindeki değişkenler ve sabitler rahatlıkla keşfedilebilir. Derin öğrenmenin temelleri basit doğrusal modellerdir. Modeller x 'ten meydana gelen bir girişten oluşur ve her biri “ w ” denen ağırlık değerinden oluşan $f(x) = \sum_{i=1}^n w_i \cdot x_i$ denklemini oluşturmuştur. Perceptron ise, $f(x)$ 'in negatif veya pozitif olduğunu tanıyabilen bir testtir (Rosenblatt, 1962).


Şekil 1.2’de Derin öğrenme modellerinin şeması verilmiştir.



Şekil 1.2 Derin öğrenme modelleri (Nweke vd., 2018)

Makine öğrenmesi ise yapay zekanın daha çok matematiksel ve istatistiksel yöntemler kullanarak veri setlerinden çıkarımlar yaparak bu verilere dair tahmin ve analizler yapmayı sağlayan başka bir alt dalıdır. Derin Öğrenme başlangıcından bu yana, neredeyse her uygulama alanında makine öğrenmesinden çok daha fazla başarı göstermiştir (Janiesch vd., 2021).

Şekil 1.3'te Makine öğrenmesi yöntemlerine yer verilmiştir.




Şekil 1.3 Makine öğrenmesi yaklaşımları (Mahesh, 2020)

1.1 Evrişimli Sinir Ağları

Evrişimli sinir ağları (ESA) daha çok görüntü segmentasyonu ve görüntü işleme gibi alanlarda kullanılır. Görüntü işlemedeki iki temel öğrenme paradigması: Gözetimli ve Gözetimsiz öğrenme olarak tanımlanmaktadır (O'Shea ve Nash, 2015). Gözetimli öğrenme: hedef öğrenme bölgesinin önceden etiketlenmiş girdiler aracılığıyla öğrenme şeklidir. Gözetimsiz öğrenmede ise etiketleme yoktur. Gözetimsiz öğrenmenin üç ana hedefi vardır: kümeleme, ilişkilendirme ve boyut azaltma. Öğrenmeyi bu üç hedef ile yapar. Kümeleme, etiketleme yapılmamış verileri

benzerliklerine veya farklılıklarına göre gruplandıran bir tekniktir. Başarı genellikle modelin ilgili maliyet fonksiyonunu azaltıp artıramayacağına göre belirlenir. Gözetimli öğrenme algoritmaları, Gözetimsiz öğrenme modellerine göre daha doğru olma eğiliminde olsa da verileri uygun şekilde etiketlemek için doğrudan insan müdahalesi gerektirir. Ancak bu etiketli veri kümeleri, Gözetimli öğrenme algoritmalarının, amaçlanan sonuçları üretmek için büyük bir eğitim kümesine ihtiyaç duymaması nedeniyle hesaplama karmaşıklığından kaçınmasına olanak tanır.




Şekil 1.4 Giriş görüntüsü ve çıkışların çalışma prensibini gösteren klasik bir ESA mimarisi

ESA, girdi verilerini işleyerek çıktı üretir. Bu girdi verileri üzerinde evrişim işlemi uygulanır. Evrişim işlemi ise verilerin yerel özelliklerini tespit etmede yardımcı olur. Yani görüntünün köşeleri ve sınırları gibi özellikler tespit edilebilir. ESA mimarisi Giriş katmanı, Ara-Gizli katmanlar ve çıkış katmanlarından oluşur. Standart YSA'nın aksine, herhangi bir katmandaki nöronlar, kendisinden önce gelen katmanın yalnızca ufak bir bölgesine bağlanacaktır.

- **Giriş Katmanı:** Dışarıdan gelen verinin herhangi bir işlem yapmadan, direkt bir sonraki katmana iletiildiği katmandır. Giriş katmanındaki her girdi verisi bir sonraki katmandaki her bir veriye (Nörona) tam bağlıdır.
- **Ara-Gizli Katman:** Giriş katmanından gelen bilgilerin işlendiği katmandır. Ara katmanlar tek başına bir katman gibi davranarak işlediği veriyi çıkış katmanına iletir. Birden fazla ara katman olabilir, bunların tamamına gizli katman denir. Ara katmanda bulunan her veri-nöron, diğer bir (sonraki) katmanda yer alan nörona tam bağlıdır.

- Çıkış Katmanı: Gizli katmandan aldığı veriyi işleyerek dışarıya çıktı olarak iletir. Birden fazla çıkış katmanı nöronu bulunabilir. Her bir nöron tek bir çıkış değerini temsil eder.

Şekil 1.5'te ESA'nın katman mimarisi gösterilmiştir.




Şekil 1.5 ESA yapısı

1.1.1 Konvolüsyon işlemi

Evrışimli sinir ağları (Convolutional Neural Network), yapay zekada derin öğrenmenin alanında kullanılan bir yapay sinir ağları modelidir. Yapay sinir ağlarından (YSA) farkı: Girdi verisi; yükseklik, genişlik ve derinlik olmak üzere üç boyutta organize edilen nöronlardan oluşmasıdır (O'Shea ve Nash, 2015). Bu katmanlar $x * x * p$ 'lık bir matrisi olarak örneklenebilir. Buradaki örnekte n yükseklik ve genişlik, p ise derinliği temsil eder. Örnek olarak, bir RGB görüntüde $p = 3$ olarak tanımlanır. Konvolüsyon katmanı $x * x * q$ boyutlarında ve k tane filtreden oluşmaktadır. Filtre görüntünün boyutundan daha küçük olmalıdır. Örneğin; girdi verisi $y * y = 6 * 6$, filtresi ise $x * x = 3 * 3$ boyutlarında bir modele konvolüsyon işlemi uygulanırsa çıkış görüntü boyutu $(y - x + 1) * (y - x + 1) = 4 * 4$ olur. Yani *Görüntü boyutu - Filtre boyutu + Adım miktarı = özellik haritası boyutu*'nu verir. Bunun sebebi: Filtre, girdi verisinin genişliği ve yüksekliği üzerine kaydırıldığında, her bir uzaysal konumda ilgili filtrenin karşılığına

denk gelen her biri $(y - x + 1) * (y - x + 1)$ boyutunda ve k tane iki boyutlu bir aktivasyon haritası üretilir (T. Liu vd., 2015).

ESA'da konvolüsyon işleminin üç adet hiper parametresi vardır. Bunlar: Derinlik, adım ve dolgulamadır. Bu hiper parametreler çıkış hacminin boyutunu denetler. Kullanılan filtre sayısı çıkış hacminin derinliğine karşılık gelir. Her bir filtre giriş görüntüsündeki farklı bir özelliği aramayı öğrenir. Adım ise: filtre ve giriş arasındaki evrilmeyi kontrol eder. Yani Filtre adım sayısı kadar kaydırılarak giriş hacminin etrafında döner. Örneğin Adım 1 olarak alındığında filtreler her defada 1 piksele hareket eder. Adım sayısı arttırıldıkça, elde edilen özellik haritası da küçülecektir.



Şekil 1.6 6x6 Giriş görüntüsüne 3x3 konvolüsyon filtresi uygulama. Adım değeri (Stride) = 1 olarak alınmıştır. Çıkışta ise 4x4'lük bir matris elde edilmiştir

Adım kaydırma ile beraber kullanılan diğer bir Hiperparametre ise dolgulama (padding) işlemidir. Dolgulamanın birden fazla kullanım şekli vardır. Bunlar Kenar Dolgu (Valid Padding) ve Sıfır Dolgu (Zero Padding) olarak bilinir.

1.1.1.1 Kenar dolgu

Yaygın olarak kullanılan bir yöntemdir. Girdi verinin etrafına herhangi bir piksel eklemeyi amaçlar. Ancak bu çıktı verisinin girdi verisinden küçük olacağı anlamına gelir. Kenar dolgu, özellik haritalarını sıkıştırmak ve boyutu azaltılmak istendiğinde kullanılır. Örneğin 5×5 boyutunda bir girdiye kenar dolgu işlemi uygulandığında çıktı 3×3 boyutunda olur. Örneğin: Giriş


görüntüsünün satır ve sütun sayılarına I_w ve I_h , adım sayıları S_w ve S_h , filtre boyutu ise K_h ve K_w olarak adlandırılırsa bu yöntemden sonra çıkış görüntüsünde:

$$\text{Çıkış}_w = \frac{I_w K_w + 1}{S_w} \quad (1.1)$$

$$\text{Çıkış}_h = \frac{I_h K_h + 1}{S_h} \quad (1.2)$$

denklemleri elde edilir.

Şekil 1.7’de kenar dolgusu ile ilgili bir örnek gösterilmiştir.



Şekil 1.7 5x5 giriş görüntüsüne kenar dolgusu işlemi uygulandıktan sonra 3x3 çıkış görüntüsü elde edilmiştir

1.1.1.2 Sıfır dolgu

Başka bir yöntemi ise Sıfır dolgusudur. Bu yöntem “Aynı dolgu” olarak da bilinir. Bu yöntem giriş ile aynı boyutta özellik haritası çıkarmak için kullanılıyor. Sıfır dolgusu: Giriş görüntüsünün çerçevesinin etrafına sıfır değerine sahip hücreler eklenir. Dolgu boyutu filtre boyutuna göre belirlenir. Bu da sınır piksellerin öğrenimini kolaylaştırır. Kenar dolgudan farkı; çıkış görüntüsünün giriş görüntüsünden daha büyük olmasıdır. Bir başka uygulanma şekli sınır piksellerinin simetrisinin alınmasıdır. Örneğin: Giriş görüntüsünün satır ve sütun sayılarına I_w ve


I_h , adım sayıları S_w ve S_h , filtre boyutu ise K_h ve K_w olarak adlandırılırsa bu yöntemden sonra çıkış görüntüsünde

$$\text{Çıkış}_w = \frac{(I_w + 2p)K_w}{S_w} + 1 \quad (1.3)$$

$$\text{Çıkış}_h = \frac{(I_h + 2p)K_h}{S_h} + 1 \quad (1.4)$$

denklemleri elde edilir.


Şekil 1.8’de kenar dolgusu ile ilgili bir örnek gösterilmiştir.



Şekil 1.8 3x3 giriş görüntüsüne sıfır dolgu uygulandıktan sonra 5x5 çıkış matrisi elde edilmiştir

1.1.2 Maksimum havuzlama

Evrişimsel sinir ağları mimarisinde konvolüsyon katmanları arasında maksimum havuzlama katmanı eklemek sıkça karşılaşılan bir yöntemdir (Murray ve Perronnin, 2014). Bu işlemin amacı parametre ve hesaplama miktarını azaltmak ve modelin verileri ezberlemesini önlemektir. Derinliği sabit bırakarak yükseklik ve genişlik üzerinden azaltmalar yaparak modelin özellik haritasındaki en büyük değeri alır. Her maksimum havuzlama katmanında modelin boyutunu yarıya indirilir. Böylece özellik haritasındaki en önemli değerler belirlenmiş olur. Aynı şekilde ortalama havuzlama ve toplam havuzlama gibi yöntemleri de vardır.



Şekil 1.9 6x6 görüntüye 3x3 maksimum havuzlama işlemi uygulanarak 2x2'lik çıkış matrisi elde edilmiştir

1.1.3 Aktivasyon fonksiyonları

Aktivasyon fonksiyonunun seçimi, modelin daha iyi performans göstermesinde önemli parametrelerden biri olma özelliğine sahiptir. Aktivasyon fonksiyonlarının genel olarak amacı, bir nöron çıkışını lineer olmayan bir yapıya getirmektir. Nöronların ağırlıklar toplamalarını hesapladıktan sonra sonuca bias değerini ekleyerek aktiflik/pasiflik durumuna karar verir. Başka bir deyişle nöronun çıkış genliğini sınırlar. En yaygın olan türleri ReLU (Rectified Linear Units Layer- Düzeltilmiş Doğrusal Birimler Katmanı), Sigmoid, Softmax ve Leaky ReLU' dur (Haykin, 1998). Önemli olan nokta, modele uygun aktivasyon fonksiyonu seçmektir.

1.1.3.1 ReLU (Düzeltilmiş doğrusal birimler katmanı)

En sık kullanılan ve en popüler aktivasyon türüdür (Agarap, 2018). İlk kez Richard ve diğerleri (Hahnloser vd., 2000) tarafından kullanılmıştır. ReLU, değer sadece pozitif-negatif durumuna bakar. Gelen işlem negatif bir değerse sıfır, pozitif bir değerse sıkıştırma-değiştirme gibi bir işlem uygulamadan olduğu gibi alır. İşlem yoğunluğu olmadığı için diğer aktivasyon fonksiyonlarından daha hızlı çalışır. Ancak negatif değerleri sıfır olarak aldığı için girdi nöronlarından bazıları kaybedilebiliyor (Nair ve Hinton, 2010).

1.1.3.2 Sigmoid


Girdiyi alır ve her bir elemanını (noktasal) 0 ile 1 arasında bir değere dönüştürür. 1'den yüksek bir değer geldiğinde 1'e yakın, negatif bir değer geldiğinde ise 0'a yakın bir değere konumlandırır. Girdiyi olasılık değerlerine dönüştürmek için kullanıldığı sınıflandırma problemleri için uygundur. Girdinin artmasıyla her zaman artan bir çıktı üretir. Yani, fonksiyon monoton artandır. Sigmoid fonksiyonu, büyük pozitif ve negatif girdilere sahipken, sınırlı bir değeri yaklaşık olarak 1 veya 0'a sönümler. Büyük veriler için Gradyan sönümleme (Vanishing gradient) problemini ortaya çıkaracağı için derin sinir ağlarında veya büyük veri kümelerinde tercih edilmez. Girdinin sınırlarını belirler ve problemin sınıflandırma veya regresyon olasılığını temsil etmesi açısından kullanışlıdır. Bu sebeplerden: yaygın olarak ikili sınıflandırma problemlerinde kullanılır.

1.1.3.3 Softmax

Sigmoid aktivasyon fonksiyonuna benzer şekilde; girdiyi $[0,1]$ aralığında sınırlar. Ayrıca, tüm olasılık değerlerinin toplamı 1'e eşittir. Softmax, çıktıyı sınıflar arasında bir olasılık dağılımı olarak ifade eder. Bu nedenle, her sınıfın olasılığını ölçmek ve hangi sınıfa ait olduğunu tahmin etmek için kullanılır. Genellikle çoklu sınıflandırma problemleri için kullanılır.

1.1.3.4 Leaky ReLU

2013 yılında “Ölü nöron” sorununu ele almak amacıyla Maas ve diğerleri tarafından tanıtıldı (Maas vd., 2013). ReLU aktivasyon fonksiyonuna alternatif olarak, girdinin negatif kısımlarını sıfır yapmak yerine küçük bir pozitif yönlü eğim ile ölü nöronları engellemektedir. Hesaplama açısından verimli ve hızlı bir aktivasyon fonksiyonudur. ReLU gibi, sıfır olmayan girdileri olduğu gibi iletmediği için çok hızlı eğitim süreleri sunar.



Şekil 1.10 Soldan sağa; ReLU, Softmax, Sigmoid ve Leaky ReLU fonksiyonlarının giriş görüntüsüne uyguladığı işlemin grafiksel ve formülleri gösterilmiştir


1.1.4 Aşırı öğrenme

Aşırı öğrenme (Over-fitting) derin öğrenme ve makine öğrenmesi modellerinin eğitimi sırasında çok sık karşılaşılan bir sorundur. Modelin girdi görüntülerine aşırı uyum sağlamasından kaynaklanmaktadır. Literatüre Aşırı uyum veya Ezberleme adlandırmaları ile de geçmiştir. Model, verilerin arkasındaki disiplini öğrenmek yerine, eğitim setindeki kaçınılmaz gürültü de dahil olmak üzere tüm verileri ezberleme eğilimindedir (Budak vd., 2021). Yani, model eğitim verilerine çok yakın ve karmaşık bir şekilde uyum sağladığı için yeni, görmediği veriler üzerinde kötü performans gösterir. Aşırı öğrenme, genellikle çok fazla parametreye sahip veya çok karmaşık bir modelin kullanılması durumunda daha sık görülür. Model, eğitim verilerini çok hassas bir şekilde takip etmeye çalışır. Aşırı öğrenmeyi engellemek için: veri sayısı artırılabilir veya var olan veriler veri çoğaltma yöntemiyle (Data Augmentation) çoğaltılabilir (van Dyk ve Meng, 2001), modelin karmaşıklığı azaltılabilir, Çapraz doğrulama (Cross-Validation) yöntemi ile veri; eğitim kümelerine ayrılarak verinin karmaşıklığı giderilebilir, Optimizasyon yöntemleri gibi birçok farklı teknik vardır. Şekil 1.11’de Aşırı öğrenme, yeterli öğrenme ve yetersiz

öğrenme

grafikleri


verilmiştir.



Şekil 1.11 (a) Yetersiz öğrenme, (b) aşırı öğrenme ve (c) iyi öğrenme örnekleri

1.1.5 Normalizasyon yöntemleri


Makine öğrenimi uygulamalarında sıkça karşılaşılan aşırı öğrenme ve yetersiz öğrenme sorunlarını gidermek için kullanılan bir yöntemdir. Bu yöntemler eğitim sırasında rastgele seçilen birtakım nöronların göz ardı edilmesi prensibine dayanır. Verinin gereğinden fazla veya az öğrenmesi durumunda katsayı tahminlerini sıfıra doğru ayarlayarak modelin daha karmaşık veya esnek bir modeli öğrenmesini engeller. Çeşitli normalizasyon yöntemleri mevcuttur. En popüler yöntemler: Dropout (Srivastava vd., 2014), Batch normalization (Ioffe ve Szegedy, 2015), Group normalization (Y. Wu ve He, 2018), Layer normalization (Ba vd., 2016) yöntemleridir.



Şekil 1.12 (a) Standart bir sinir ağı ve (b) normalizasyon (eleme) yöntemi uygulandıktan sonraki sinir ağı

1.1.5.1 Batch normalization


Eğitim sırasında Ara katmanların giriş dağılımını değiştirir ve giriş dağılımını ortalaması 0'a dönüştürerek varyansını da 1 olarak standart bir dağılıma dönüştürür. Bu yöntem ile, gradyanı genişler ve gradyan problemlerinin ortadan kaldırılmasına yardımcı olunur. Böylece sinir ağının yakınsaması daha hızlı olur ve eğitim daha kısa sürede gerçekleşir.



Şekil 1.13 Batch normalization eğitim grafiği

1.1.5.2 Dropout


Her eğitim adımında, giriş verisi üzerindeki karmaşıklığı önlemek ve genelleme yeteneğinin geliştirilmesine katkıda bulunmak amacıyla, seçilen katmandaki her bir nöronun çıktısını belirli bir olasılıkla sıfırlar. Bu teknik, ağıdaki özellik sensörlerinin birlikte uyarlanmasını önler.



Şekil 1.14 Dropout eğitim grafiği

1.1.6 Optimizasyon yöntemleri

Optimizasyon yöntemleri, modelde oluşan hataları önlemek ve öğrenimi üst seviyeye çıkarmak amacıyla kullanılan bir yöntemlerdir. Optimizasyon yöntemleri adım adım işletilmektedir ve bu işletilme sürecindeki adım miktarı öğrenme hızı (Learning Rate) olarak tanımlanmaktadır. Öğrenme hızı küçük seçilirse çözümleme süreci uzar, büyük seçilmesi durumunda ise minimum noktanın kaybolmasına neden olacaktır. Optimizasyon yöntemleri arasında en çok kullanılan yöntemler: Gradyan İniş (Gradient Descent), Adam algoritmaları, Adagrad, RMSProp ve SGD yöntemleridir.



Şekil 1.15 Optimizasyon yöntemlerinin evrişimsel haritası

1.1.6.1 Gradyan iniş (Gradient descent)

Temelde mevcut parametrelerin, gradıyan vektörü tarafından gösterilen yönde azaltılmasını içerir. Model parametreleri rastgele değerler ile başlayarak modelin kayıp fonksiyonunu minimum seviyeye getirmek için gradıyan vektörünü ve öğrenme hızını kullanarak adımlar atar (Duchi vd., 2011). Gradyan vektörü, her parametre için türev hesaplar ve her bir parametrenin nasıl güncelleneceğini belirler. Öğrenme hızı ise her adımda ne kadar büyük bir adım atılacağını kontrol eder. Dolayısıyla yüksek öğrenme hızı, daha büyük adımlar atılmasına sebep olurken aşırı öğrenme riskini de arttırır. Düşük öğrenme hızında ise daha küçük adımlar atılır fakat istikrarlı bir eğitim sağlanır. Parametreler yine bu iki değer ile güncellenir ve kayıp fonksiyonu minimuma yaklaşına kadar devam eder. Optimal parametre değerleri elde edildiğinde eğitim tamamlanır. Başlangıç değeri θ_0 , yeni parametre değeri θ_1 , öğrenme hızı α ve Gradyan vektörü $\nabla J(\theta_0)$ olarak alındığında:

$$\theta_1 = \theta_0 - \alpha * \nabla J(\theta_0) \quad (1.5)$$

Denklemleri elde edilir (Duchi vd., 2011). Başlangıçta $\theta = \theta_0$ olarak alınacaktır. Her adımda yeni parametre değerleri θ_1 , θ_0 'ın yerine geçer. Kayıp fonksiyonu $J(\theta)$ minimuma yaklaşıncaya kadar döngü devam eder.

1.1.6.2 RMSProp (Root mean square propagation)

2012 yılında Tieleman tarafından bulunan modelin (G. Hinton ve Tieleman, 2012) açılımı Karekök Ortalama Kare İlerleme olarak geçmektedir. Adından da anlaşılacağı gibi RMSProp, gradyanların karesinin karekökünün ortalamasını kullanmaktadır. Bu, gradyanların büyüklüğünü izlemek ve öğrenme hızını ona göre ayarlamak için kullanılır. Ortalanmış versiyon ayrıca gradyanların hareketli ortalamasını korur ve varyansı tahmin etmek için bu ortalamayı kullanır. Genel olarak Gradyan inişi optimizasyonu yöntemine benzer fakat farkı, gradyanların nasıl hesaplandığı ile ilgilidir. n : Öğrenme katsayısı, ϑ_t : Gradyan karelerinin üstel ortalaması ve g_t : ω^i boyunca t anındaki gradyan olarak ifade edilirse RMSProp:

$$\vartheta_t = \rho \vartheta_{t-1} + (1 - \rho) * g_t^2 \quad (1.6)$$

$$\Delta \omega_t = - \frac{n}{\sqrt{\vartheta_t + \epsilon}} * g_t \quad (1.7)$$

$$\omega_{t+1} = \omega_t + \Delta \omega_t \quad (1.8)$$

Denklemleri ile ifade edilebilir (Yilmaz, 2022).

1.1.6.3 Adam algoritmaları (Adaptive moment estimation)

Adam, gradyan inişinin bir varyasyonudur ve eğitim sürecini hızlandırırken öğrenme hızını adaptif bir şekilde ayarlayan bir optimizasyon algoritmasıdır (Kingma ve Ba, 2014). RMSProp aktivasyon yöntemindeki hesaplama ek olarak geçmiş gradyanları karesel olmaksızın hesaplayacak şekilde geliştirilmiştir. Önceki gradyanların kareleri v_t , v_t 'nin karesi alınmadan önce m_t , β_1 ve β_2 hareketli ortalamaların üstel bozulma oranlarını kontrol eden hiper parametreler olarak alınır:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (1.9)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (1.10)$$

$$m = \frac{m_t}{1 - \beta_1^t} \quad (1.11)$$

$$v = \frac{v_t}{1 - \beta_2^t} \quad (1.12)$$

$$\theta_{t+1} = \theta_t - \frac{n}{\sqrt{v_t + \varepsilon}} m_t \quad (1.13)$$

Denklemleri elde edilir (Yazan ve Talu, 2017). β_1 ve β_2 değerleri $[0,1)$ aralığındadır.

1.2 Görüntü Segmentasyonu

Görüntü segmentasyonu, çok sayıda görsel uygulamada önemli bir unsur olarak hizmet eder. Görüntü segmentasyonu, görüntünün analizi ve görüntüyü tanımanın birinci adımıdır. Görüntü analizi veya görüntü tanıma modellerinin kritik ve temel bir elemanıdır, görüntü işlemedeki en zor görevlerden biridir ve analizin nihai sonucunun kalitesini belirler. Temel anlamda görüntüler piksellerden oluşur ve görüntü segmentasyonu, belirli bir sınıfa ait bir görüntüdeki her pikseli sınıflandırma işlemidir ve bu nedenle pikselleri sınıflandırma yöntemi olarak düşünülebilir. Görüntü bölütlemenin temel amacı, bir görüntüyü benzer veya tam olarak aynı özelliklere sahip, anlamlı ve analiz edilebilir birkaç parçaya bölmektir. Görüntü segmentasyonu, görüntü analizi ve görüntü tanımanın temel bir bileşeni olup aynı zamanda ilk adımıdır (Cheng vd., 2001). İki tür segmentasyon yöntemi mevcuttur: Semantik (Semantic) segmentasyon ve Örnek (Instance) segmentasyon yöntemleri.

- **Semantik Segmentasyon (Semantic Segmentation):** Bir görüntüyü piksel düzeyinde bölmek için kullanılan bir görevdir. Yani, bir görüntüdeki her piksele kategorik bir etiket atamayı amaçlamaktadır ancak bu etiket diğerlerinden farklı değildir (P. Wang vd., 2018). Her piksel, görüntüdeki nesnenin veya bölgenin aidiyetini belirleyen bir sınıfa atanır.

- **Örnek Segmentasyon (Instance Segmentation):** Semantik segmentasyonun bir adım ötesine gider. Her görüntüde görünen değişen sayıda örnekle uyum sağlamak için sınıf etiketlerini ve piksel düzeyinde örnek maskeleri tahmin etmeyi amaçlar (S. Liu vd., 2018). Örnek Segmentasyonu semantik segmentasyona göre daha zordur çünkü görüntüdeki bütün nesnelerin. Yani aranan nesneleri tek tek sınıflandırır. Aynı sınıfa ait farklı örnekler birbirinden ayrılır ve her bir örnek ayrı bir kimlik (ID) ile tanımlanır. Nesne tanıma ve takip, otonom sürüş ve robotik gibi uygulamalarda kullanışlıdır.


Bir görüntüde beş farklı renkli araba varsa: örnek segmentasyon beş farklı renk etiketini belirlerken semantik segmentasyon bir etiketi belirler. Semantik segmentasyon sağlık ve tıp ile ilgili alanlarda kullanılırken, örnek segmentasyon daha çok günlük hayatla ilgili alanlarda kullanılmaktadır. Günümüzde semantik segmentasyon biyomedikal alanda sıklıkla kullanılmaktadır. Şekil 1.16'da görüntü segmentasyonun türleri tarif edilmiştir.




(a)



(b)



(c)



(d)

Şekil 1.16 (a) Görüntü sınıflandırma, (b) nesne tanımlama, (c) semantik segmentasyon, (d) örnek segmentasyon

Bu çalışmanın amacı, CT görüntülerden akciğer segmentasyonu veri seti, Hücre görüntülerinden çekirdek segmentasyonu ve doku görüntülerinden meme kanserine sahip hücre segmentasyonu üzerindeki U-Net modelinin katmanları arasındaki farkı test ederek modeller arasındaki başarı oranını ölçmektir. Araştırmada klasik U-Net Modeline iki katman daha eklenerek 11 katmanlı U-Net11 Modeli, U-Net11 Modelinden iki katman daha fazla olan 13 katmanlı U-Net13 Modeli oluşturuldu. Aynı şekilde klasik U-Net Modelinden iki katman çıkarılarak U-Net7 modeli oluşturuldu. Daha sonra oluşturulan modeller arasındaki farklar karşılaştırıldı. Modeller üç farklı veri seti tipinde test edilmiş ve başarı oranları gözlemlenmiştir.

2. ÖNCEKİ ÇALIŞMALAR

2.1 Yapay Zekâ Tarihçesi

Yapay zekâ ilk olarak 1950’de Alan Turing tarafından tanımlandı. “Bilgisayarlar ve Zekâ” kitabında akıllı olup olmadığını belirlemek için daha sonra "Turing testi" olarak anılacak olan basit bir testi tanımladı (Ramesh vd., 2004). 1956 yıllarında John McCarthy ilk kez yapay zekâ terimini kullandı ve “akıllı makineler üretme bilimi ve mühendisliği” tanımını kullandı (Amisha vd., 2019). Yapay zekanın ilk fiziksel örneği ise 1961 yılında General Motors’un otomatik basınçlı döküm robotik kolu oldu (Moran, 2007). 3 yıl sonra 1961 yılında Joseph Weizenbaum, doğal dil işleme kullanarak insan konuşmasını taklit eden bir ELIZA modelini oluşturdu. Bu gelecekteki sohbet robotlarının temeli demektir (Weizenbaum, 1966). 1966 yılında “ilk elektronik insan” olan “Shakey” isimli robot geliştirildi (Kuipers vd., 2017). Yapay zekaya olan ilginin azalması ve mali aksaklıklar yüzünden 1970’lerde bu alanda çok çalışma çıkmamıştır ve bu durum 1980’lere kadar sürmüştür. Bu dönem “Yapay zekâ kışı” olarak bilinmektedir (Haenlein ve Kaplan, 2019). 1980 yılının başlarında Japon hükümetinin yapay zekâyı agresif bir şekilde finans etmesi ile tekrar popüler hale geldi ve İngiliz devleti Japon devletiyle yarışmak için tekrar bu alanı fonladı (Haenlein ve Kaplan, 2019). Bu dönemden sonrası için “Yapay zekânın girişimcilik dönemi” denir ve bu dönem günümüze kadar devam etmektedir (Öztürk ve Şahin, 2018). 1991 yılında Rodney Brooks’un çalışmaları (Brooks, 1991), yapay zekanın geleneksel sembolik yaklaşımlarına alternatif olarak davranış temelli robotlar üzerine odaklanan Yapay Yaşam (Artificial Life) alanının başlangıcını temsil eder. 1997 yılında IBM firmasının geliştirdiği Deep Blue isimli süper bilgisayar, uluslararası satranç şampiyonasını kazanan Garry Kasparov’u yenmiş oldu (McCorduck, 2004). 2005-2010 yıllarında Facebook, Netflix ve Twitter gibi şirketler yapay zekâyı kullanmaya başladı. 2015 yılında Reinforcement learning, özellikle robotik ve otomasyon alanlarında kullanıldı. Endüstriyel robotların yanı sıra drone ve otonom araçlar üzerindeki uygulamalar dikkat çekici oldu (Mnih vd., 2015). 2016 yılında Google şirketinin oluşturduğu DeepMind AlphaGo programının “Go” oyununda dünya şampiyonunu yenmesi yapay zekânın karmaşık stratejik oyunlarda başarı elde ettiğini gösterdi (Beattie vd., 2016). 2018 yılında büyük veri setlerinde önceden eğitilmiş modellerin kullanılması, transfer öğrenme konseptinin önemini

artırdı. BERT (Bidirectional Encoder Representations from Transformers) gibi modeller doğal dil işleme alanında çığır açtı (Devlin vd., 2019).

2.2 Evrişimli Sinir Ağları Tarihçesi

Evrişimli sinir ağlarının ortaya çıkışı yapay zekadan farklı değildir. 1943'te McCulloch ve Pitts nöronun ilk matematiksel modelini, yani M-P modelini önerdikten sonra (McCulloch ve Pitts, 1943) 1950'lerin sonu ve 1960'ların başında Rosenblatt (Rosenblatt, 1958) MP modeline öğrenme yeteneğini ekleyerek tek katmanlı bir algılayıcı modeli önerdi. Ancak tek katmanlı algılayıcı ağ, doğrusal ayrılmaz problemleri (XOR problemleri gibi) çözemediği için 1986 yılında Rumelhart (David E. Rumelhart vd., n.d.) tek katmanlı algılayıcının çözemediği bu sorunları ele alan, geri yayılım algoritmasını tanıtarak, yapay sinir ağlarının ve evrişimsel sinir ağlarının eğitimi geliştiren önemli bir çalışma yapmıştır. 1987'de Waibel ve ark.(Waibel vd., 1989) konuşma tanıma için tek boyutlu bir evrişimli sinir ağı olarak görülebilecek Zaman Gecikmeli Sinir Ağı'nı (TDNN) önerdi. Daha sonra Zhang (Wei Zhang, 1988) ilk iki boyutlu modeli önerdi. İlk “Evrişim” terimi 1989 yılında LeNet'in yapısında LeCun (LeCun vd., 1989) tarafından kullanıldı. Bu çalışmada el yazısıyla posta kodu tanıma başarısı elde edildi. Eğitim başarılı olmuştur fakat eğitimin çok uzun sürmesi, ağı pratik hayatta uygun olmadığından görülmesi açısından önem taşımaktaydı. 1990'larda, Kaotik sinir ağları (Aihara vd., 1990) ve Regresyon sinir ağı (Specht, 1991) gibi çeşitli sığ sinir ağları art arda önerildi. Bunlardan en ünlüsü LeNet-5'tir (Lecun vd., 1998). Bu model yine LeNet'i modelleyen LeCun tarafından bulundu. LeNet-5 modeli birçok bakımdan avantaja sahip olsa da sinir ağlarının katman sayısı arttığında, aşırı öğrenme, gradyan kaybolması ve gradyan patlaması sorunlarıyla karşılaştı. Bu sebeple karmaşık problemlerde iyi performans gösteremedi. 2012 yılında Alex ve ark. ImageNet yarışmasında AlexNet (Krizhevsky vd., 2012) modelini önererek modern ESA'nın gelişimine büyük katkı vermiştir ve yapay sinir ağlarına gizli katmanlar ekleme yöntemi, katman bazında ön eğitim yöntemi sayesinde; aşırı öğrenme, gradyan sönümlenmesi gibi sorunları büyük ölçüde çözmüştür. Bu başarı aynı zamanda “Derin öğrenmenin doğumu” olarak da adlandırılır (Alom, Taha, vd., 2018).

2.3 Biyomedikal Alanında Yapay Zekâ

Mühendislikteki yeniliklere rağmen tıp, yapay zekâyı benimsemekte aynı hızı yakalayamadı (Kaul vd., 2020).

1972 yılında Leeds Üniversitesi'nde De Dombal ve arkadaşları (De Dombal vd., 1972), birtakım hastalıkların tespiti ve semptomları ile ilgili bir araştırma yapmışlardır. Bu hastalıkları incelemek amacıyla, bilgisayar tabanlı klinik karar yardımcı sistemini geliştirmişlerdir. Ancak bu sistem “Bilgisayar teşhisi” değildir. Yarattıkları sistem, klinisyenin kendi tanısına ulaşmasına yardımcı olmak için kullanılabilecek ve uygulandığı takdirde klinisyenin hastasına verebileceği bakımın kalitesini önemli ölçüde artırabilecek bir sistemdir. Oluşturulan sistem, çok sayıda hastadan alınan verileri değerlendirerek elde edilen nitelikli verilerle, koşullar değiştiği takdirde sonuçların ne olacağına dair Bayesian olasılık teorisinden faydalanarak sonuçları yorumlamaktaydı. Kullanılan sistem akut hastalıklardan yedi tanesi üzerinde çalışmıştır bunlar; Safra kesesinde meydana gelen ağrı, apandisit hastalığı, peptik ülser rahatsızlığı ve ince bağırsak hastalıkları, divertikülit ve aynı zamanda sebebi belli olmayan karın ağrısıdır. Araştırmalar karın ağrısı olan 304 hasta üzerinden ilerlemiştir. Kullanılan sistem 279 hastanın teşhisinde kullanılarak %91,8 oranında doğrulukla çalışmış ve başarılı kabul edilmiştir.

Harry E. People ve ark., Pittsburgh Üniversitesi'nde INTERNIST adlı bir proje geliştirmişlerdir. Bu proje daha sonraları CADECEUS adını almış olsa da 1970'li yıllarda karmaşık semptomları olan hastalıkların teşhisi için kullanılan pratik bir yöntem olmuştur (Miller Randolph A. and Pople, 1985).

1950 yılı sonrasında De Dombal ağrı sistemi birden fazla tıbbi alana destek sağlamıştır ve bundan sonra 800'den fazla çalışma yayımlanmıştır. Bilgisayar Tabanlı Tavsiye sistemleri belirli bir mantık sistemi kullanarak kullanıcıya istenilen konularda problemin çözümüne yönelik çıktılar hazırlamaktaydı. Stanford Üniversitesi 1970 yılında Stanley Cohen, Ted Shortlife ve Bruce Buchanan gibi isimlerin ortak çalışmaları ile bir proje meydana getirmiştir. Bu proje MYCIN projesidir Programın temel “Eğer-İse” döngüsü kullanılarak bulaşıcı hastalıkların tanı ve tedavisini dair yardımcı bir sistem olmaktır. Başlangıçta 200 kuralı olan proje

daha sonraları 1978’de 500 kural kullanılarak çalıştırılmıştır. MYCIN, enfeksiyon temelli hastalıklarının tespiti ve tedavisinde danışma amacıyla kullanılan bir projedir. Hastalara yapılması gereken testler uygulanması gereken tedaviler tavsiye niteliği taşımaktadır (Shortliffe, 1976).

1992 yılında deneyimi ve tıbbi bilgisi az olan personele yardımcı olmak amacıyla Poems adında karar destek sistemi oluşturulmuştur. Postop (operasyon sonrası) hastalarda meydana gelen değişikliklerin değerlendirilmesi konusunda önerilerde bulunmak için tasarlanmıştır. Sağlık personelinin kullandığı yöntemleri kullanarak hastanın bilgi ve bulgularını kaydeder. Hastanın bilgilerinin yanında hastalığın öyküsünü ve test sonuçlarını da alır. Bu bilgilerin ışığında sistem teşhis için destek sağlar. POEMS kaydettiği verileri silmez aynı zamanda bunları saklar ve başka bir hastanın verileri ile karşılaştırmak ve yeni teşhislerde destek sağlamak için kullanır. Hastalıkta kullanılan ilaçların da bilgisini saklayan sistem oluşabilecek yan etkilere karşı hatırlatma da yapabilir (Sawar vd., 1992).

2002 yılında ISABEL Klinik Karar Destek Sistemi oluşturulmuştur. Birinci versiyonu pediatri alanı için oluşturulan sistemin daha sonra 2005’te yetişkinler için ona versiyonu yaratılmıştır. 2005 versiyonu dünya çapında kullanılmıştır. Yanlış konulan teşhis sebebi ile ağır bir şekilde rahatsızlanan Isabel’in babası durumdan etkilenmiş ve sistemin fon sağlayıcısı olup sisteme hasta kızının adını vermiştir. Oluşturulan sistemin temel hedefi güncel bir öğretici olmaktır. Daha sonraları teşhis ve veri setinden konuya uygun teşhis çıkarmak gibi görevleri de üstlenmiştir. Bu sistem sonraları muayenehane ve kliniklerde de kullanılmıştır. CT ve X-Ray verilerini saklamak gibi görevleri de yerine getirmiştir ve tüm bu işlemler birbiri ile bağlantılı olarak gerçekleşmektedir. Özellikle Birleşik Krallıkta hekimler tarafından sistemden faydalanılmıştır (Vardell ve Moore, 2011).

Osaka Üniversitesi Online Incident Reporting System (ORIC) adı verilen bir sistem oluşturmuştur. Medical amaçla kullanan bu sisem risk yönetimi ve insan gücünden en yüksek derecede faydalanılması ilkesi ile oluşturulmuştur. Meydana gelebilecek yanlışlar ve hatalı uygulamaların en aza indirilmesi hedeflenmiştir.2000 yılında

kullanılmaya başlanmış ve kalite artırmak için disiplin, günlük risk yönetimi ile ilgili raporlar hazırlamıştır (Takeda vd., 2003).

2004 yılında ise JMAR (Joint Medical Asset Repository) askeriye için tasarlanmıştır. Tasarımı meydana getiren isimler Sloane, Adam ve Roscow'dur. Oluşabilecek ihtiyaçlar ve bunların temin edilmesi, ilaçların dağıtılması konusunda destek sağlamıştır. Olağanüstü hallerde askeri ihtiyaçları kısa zamanda raporlayarak temin edilmesini sağlar ve Oracle tabanlıdır (Sloane vd., 2005).

Galdakao Hastanesi Acil Servisi tarafından oluşturulan GALEKNOW projesi servis çalışanlarının zor ve kritik kararları daha hızlı almasını sağlamak için tasarlanmıştır. Sistem bir bilgi havuzu olarak tasarlanmış ve deneyimleri gerekli zamanlarda kullanarak daha düşük ücretle hizmet vermesi de amaçlanmıştır. Hastaneye gelen hastalar için gerekli uzmanlık alanları tespit etmek ve hastaları ihtiyaç duydukları uzmanlık alanlarına yönlendirmesi amaçlanmıştır. Bu sayede ilk tedavi süreci hızlanmıştır (Gokbay, 2021).

1990 yılında hastaların tıbbi belgelerinin kaydının tutulması ve giyilebilir, hastanın normal hayat akışında takibini sağlayan sistemleri geliştirmek için adım atmıştır. MITHril isimli bir sistem Massachusetts Institute of Technology'de geliştirildi. RS-232 ara yüzü kullanılan sistemde kan şekeri, kalp ritmi ve EEG ölçümleri yapılmıştır. Makina öğrenme yöntemleri, gauss modeli, Markov modeli ile çıkarımlar yapılması sağlanmıştır. Bayesian modeli ile de çıkış verileri elde edilmiştir. Sıklıkla Parkinson hastaları üzerinde kullanılmıştır. (Pentland, 2004).

Son yıllarda kullanılmaya başlanan akıllı saatlerin atası olan AMON sistemi giyilebilir tıbbi uyarı ve izleme sistemi bilek için tasarlanmıştır. Nabız ve EKG'yi tek bir cihaz ile ölçebilen bir sistemdir (Anliker vd., 2004).

2010-2013 yıllarında Türkiye'deki bir AR-GE firması tarafından yapılan ICARDEA implant kalp cihazı takılmış hastaların takibi için oluşturulmuştur. Avrupa Birliği tarafından fon sağlanan çalışmada birçok ülke beraber çalışmıştır. Proje sayesinde aritmi tanısı ve önlemesiyle beraber sağlık harcamalarının azalması konusunda da

fayda sağlamıştır. Cihaz verileri saklayarak elektronik ortamda kullanılması ve klinik takibi konusunda hastalara fayda sağlamaktadır (Anonim, 2013).

2.4 Derin Öğrenme Tarihçesi

Derin öğrenme her ne kadar yeni bir terim olsa da temelleri 1960’larda atılmış bir terimdir. Araştırmacılar araştırmaları doğrultusunda alanı çok farklı şekillerde adlandırmışlardır. Daha önceki adları arasında “paralel dağıtılmış işleme”, “yapay sinir ağları” ve “bağlantıcılık” yer almaktadır.

1965 yıllarında Ivakhnenko, ilk genel derin beslemeye sahip ve çok katmanlı (layer) algılayıcılar(perceptronlar) için öğrenme algoritması yayınlandı (Ivakhnenko ve Lapa, 1973). Geri yayılım (Backpropagation) yöntemi kullanılarak uçtan uca eğitim yapılmamış en küçük kare yöntemi ile daha sonraki katmanlara eğitim uygulanmıştır.

1979 yılında “Neokognitron” mimarisi ise (Ivankhnenko’dan sonra) Fukushima tarafından tavsiye edilmiştir. Denetimsiz öğrenme adı verilen adı verilen ve kendini organize edebilen ağ oluşturulmuştur. Bu ağ modern ağlardaki havuz katmanı ve çoklu bükülme gibi bazı benzer özellikler taşımaktaydı (Fukushima, 1980).

1995 yıllarında oluşturulan Wake-Sleep algoritması (Brendan Frey, Peter Dayan ve Geoffrey Hinton) kullanılmış ve altı tanesi tamamen bağlı çok fazla gizli katman içeren bir ağın eğitiminin mümkün olmasına rağmen bu eğitimin uzun sürdüğü gösterilmiştir (G. E. Hinton vd., 1995).

1997 yılında Hochreiter ve Schmidhuber Long Short-Term Memory (LSTM) adı verilen modeli önermiştir. LSTM modeli, RNN (Recurrent Neural Networks-Tekrarlayan sinir ağı) modelindeki öğrenme sırasında gerçekleşen gradyan kayıpları, zaman gecikmeleri gibi sorunları önlemeyi amaçlamıştır. Öğrendiği bilgileri bir sonraki adıma aktaran bir yapısı vardır. Böylece dizideki herhangi bir bilgi hafızaya alınır ve ihtiyaç olması halinde bu bilgiyi kullanarak taşıyıcı görevi görür (Hochreiter ve Schmidhuber, 1997).

1990 ve 2000 yılları arasında ise yapay sinir ağıları yerine destek vektör makineleri tercih edilmiştir bunun en büyük sebebi yapay sinir ağlarının hesaplama maliyetidir. Destek Vektör Makineleri (Support Vector Machine) dezavantajı ise tek bir soruna özgü olması ve elle hazırlanmalarıdır (Cortes ve Vapnik, 1995).

2000 yılına gelene kasar yapay sinir ağları açısından bir derin öğrenme kavramı yoktu. Bu kavramın kullanılması Igor Aizenberg ve ark. sayesinde olmuştur (Aizenberg vd., 2000).

Sonraki yıllarda hesaplamalarda Graphics Processing Unit (GPU) kullanılması ve bilgisayarların hızının da artması ile beraber çok fazla gelişme yaşanmıştır. Bu 10 yıllık süreçte hesaplama hızı 1000 kat artmıştır. Hesaplama hızının artması yapay sinir ağlarını tekrar vektör destek makineleri ile rekabet edebilir hale getirmiştir (Schmidhuber, 2015). Ön eğitim olmadan ağların eğitilmesi bundan sonraki süreçte GPU hızlarının zamanla artmasıyla olmuştur. Medikal görüntüleme, karakter tanıma, trafik işaretleri gibi konularda yarışmaları kazanan Ciresan ve arkadaşları aynı yöntemi kullanmışlardır (D. Ciresan vd., 2012; D. C. Ciresan vd., 2011). Kazanılan bu ivmelerden sonra Facebook, Google, Microsoft gibi firmalar derin öğrenme alanına ilgi göstermiş ve yatırım yapmaya başlamışlardır.

2012-2017 yılları arasında şirketler derin öğrenme alanında satın almalara başlamış ve gelişmelerin daha da hızlanmasına etki etmiştir. Facebook fotoğraf etiketleme programı olan “face.com” programı satın almıştır ve etiketleme alanında başarı artırmayı amaçlamıştır. Apple ise “Novauris”u satın alarak SİRİ yazılımı ile ilgili iyileştirmeler yapmıştır. Microsoft ise “SwiftKey”i satın almış ve dil işleme, yapay zekâ alanında başarı elde etmiştir.

2.5 Derin Öğrenme Alanında Görüntü Segmentasyonu Çalışmaları

Derin öğrenme tekniklerinin gelişmesiyle beraber birçok farklı görüntü segmentasyonu algoritması ortaya çıktı.

İlk olarak sunulan yöntemlerden biri, 2014 yılında Girshick ve ark. tarafından önerilen R-CNN (Regional convolutional network) yöntemidir (Girshick vd., 2014). R-CNN temelde: Çeşitli bölge önerileri kümesi oluşturmak için renk, doku ve şekil

gibi çeşitli görüntü ipuçlarına dayalı olarak görüntünün bölümlerini birleştirerek veya bölerek çalışır. Bölge önerileri oluşturulduktan sonra giriş görüntüsünü anizotropik olarak bükülür ve daha sonra özelliklerin çıkarılması için ESA'dan geçirir.

Yine 2015 yılında Girshick tarafından R-CNN'in gelişmiş modeli olan Fast R-CNN modeli geliştirildi. R-CNN'deki yoğun hesaplamaya bağlı olarak gerçekleşen yavaş öğrenme sorunu nedeniyle Fast R-CNN modeli önerildi. Fast R-CNN, bütün görüntüyü ve bölge önerilerini ESA mimarisine giriş olarak tek bir ileri yayılımda alır. Ayrıca mimarideki Sınıflandırma- ConvNet gibi bölümleri tek bir mimaride birleştirerek disk alanından tasarruf sağlar ve eğitimi daha hızlı gerçekleştirir (Girshick, 2015).

İlk olarak sunulan diğer yöntemlerden biri de 2015 yılında Long ve ark. tarafından önerilen Tam evrişimli sinir ağlarıdır (Fully Convolutional Network- FCN). ESA'dan farklı olarak, özellik haritalarının Katmanlar arasındaki özellik haritalarının yüksekliğini ve genişliğini giriş görüntüsünün yüksekliğine ve genişliğine dönüştürür. Yani sadece havuzlama (Pooling) ve üst örnekleme (Up-Sampling) gibi sadece bağlantılı katmanlar kullanılır. Bu daha yoğun bir parametre hesaplaması anlamına gelir ve modelin eğitim sürecinin uzamasına neden olur. Model bu sebeplerden 3D görüntülerde başarısız sonuçlar verir (Long vd., 2015).

2015 yılında Liu ve ark. FCN'in dezavantajlarını fark ettiler ve FCN'e alternatif olarak ParseNet'i geliştirdiler. ParseNet, FCN'e yama olarak bir küresel bağlam (Global context) eklenerek görüntüyü bölgelere veya nesnelere bölmek yerine tüm piksel değerlerinin ortak bir tahminini yaparak tutarlılığı sağlamayı amaçlar (W. Liu vd., 2016).

2015 yılında Google aracılığıyla Chen ve ark. tarafından DeepLab modeli geliştirildi. DeepLab, Semantik segmentasyondaki temel problemleri çözmeyi amaçlar. Bunlar: Yoğun tahmin sınırlaması, düşük çözünürlük, kalabalık nesne varlığı ve Derin evrişimsel sinir ağlarının (DCNN) değişmezliği nedeniyle azaltılmış lokalizasyon doğruluğudur. Bu sorunu çözmek için sinir ağındaki son katmanındaki yanıtları tamamen bağlı bir CRF (Conditional Random Field) ile birleştirdiler. Model

PASCAL VOC 2012 veri setinde test edildi ve %79,7 mIoU başarısı elde edilmiştir. Model geliştirilerek yine Chen tarafından 2018 yılında DeepLabv2, DeepLabv3 ve DeepLabV3+ olarak önerilmiştir. Modelin son hali olan DeepLabV3+ PASCAL VOC 2012 %89 mIoU başarı elde etmiştir (Chen vd., 2017; Chen, Papandreou, vd., 2018; Chen, Zhu, vd., 2018).

Aynı yıl içinde Ronneberger ve ark U-Net modelini geliştirdi. Model FCN mantığı ile çalışır. Kodlayıcı ve kod çözücü kısımları ile görüntüyü önce küçültür ve sonrasında genişletir. FCN'den farkı ise mimarinin Kod çözücü kısmından kaynaklanmaktadır. Kod çözücü kısmında, Kodlayıcı kısmındaki referans katmana karşılık gelen katmandaki görüntü ile birleştirilir (Concatenate) ve bu işlem çıkış katmanına kadar devam eder (Ronneberger Olafand Fischer, 2015).

2016 yılında Ren ve ark. tarafından Fast R-CNN'i de geliştirerek Faster R-CNN modeli önerildi. Fast R-CNN'e ek olarak RPN (Region Proposal Network- Bölge Önerisi ağı) kullanılmıştır. Bu yapı, herhangi bir boyuttaki girdiyi alır ve tahmin başarısı skoruna göre; objelere ait olabilecek dikdörtgen teklifleri yapar. Bu öneriler, evrişim katmanında oluşturulan öznetelik haritası üzerindeki adım(stride) değerinde kaydırma yaparak çıkarılır (Ren vd., 2015).

2017 yılında Kirillov ve ark. modelini geliştirdi. Model iki kısımdan oluşur. İlki, standart bir ESA yapısıdır. İkinci kısım ise yeni bir örneğe duyarlı kenar algılama modelinden türetilir. Sonrasında bu iki yöntem MultiCut adı verilen bir formül ile birleştirilir. Bu model R-CNN ile karşılaştırılmış ve daha başarılı bir sonuç verdiği gözlemlenmiştir (Kirillov vd., 2017).

2017 yılında Peng ve ark. tarafından GCN modeli geliştirildi. Bu modelde yüksek boyutlu filtreler yerine küçük ve sık filtreler kullanılarak daha yüksek bir verim sağlanmıştır. Bu yöntem ile, sınıflandırma ve yerelleştirmenin aynı anda yapıldığı durumlarda diğer modellere göre daha fazla başarı sağladığı tespit edilmiştir. Model, PASCAL VOC 2012 veri setinde %82,2 başarı sağlamıştır (Peng vd., 2017).

2020 He ve ark. tarafından Mask R-CNN modeli önerildi. Bu yöntem R-CNN'in en gelişmiş ve en başarılı versiyonuydu. Faster R-CNN' ek olarak sınırlayıcı kutusunu (Bounding Box) tahmin ettiği nesnenin maskesini de tahmin etmeyi amaçlar. Bu sebepten dolayı Mask R-CNN görüntü veya videolardaki Instance Segmentasyon türünü çözmeyi hedefleyen bir modeldir. Mimari VGG 16 ile başlar ve VGG 16 katmanından çıkan görüntü RPN (Region Proposal Network) katmanına girer. Buradaki sınıflandırma işleminden sonra nesnenin varlığı tespit edilir. Tespit edilen nesne Regresyon katmanına geçerek sınırlayıcı kutusu çizilir. Ardından RoIAlign katmanında görüntü, VGG 16 katmanından gelen görüntü boyutu ile aynı boyutta olması sağlanır ve buna ek olarak nesneye maske uygulanır (He vd., 2020).

2021 Zhu ve ark. tarafından INet geliştirildi. Bu çalışmada havuzlama işlemleri, aşağı ve yukarı örnekleme işlemlerinin özellik haritasının çözünürlüğünü değiştirmesiyle ilgili sorunları ele almıştır. Katmanlara Inception işlemi uygulanarak geliştirilen model DeepLabV3 modelinden daha yüksek bir başarı oranı yakalamıştır (Weng ve Zhu, 2021).

2.6 Biyomedikal Alanında U-Net Kullanımı

U-Net Modeli derin öğrenme ile en sık kullanılan görüntü bölütleme yöntemlerinden biridir. Özellikle biyomedikal alanında sıkça U-Net modeli kullanılır.

Dong ve ark. 2017 yılında beynin 3D MRI görüntülerinden tümör tespiti üzerinde çalıştı. Çalışmada BRATS 2015 yarışmasındaki veriler kullanılmıştır. 220 yüksek dereceli beyin tümörü ve 54 düşük dereceli tümör görüntüsünü içeren veri seti U-Net modeli ile eğitilmiş ve %86 DSC oranında başarı elde edilmiştir (Dong Haoand Yang, 2017).

2017 yılında Sevastopolsky göz retinasındaki Glokom hastalığının U-Net ile tespiti için çalıştı. Çalışmada halka açık RIM-ONE v.3, DRIONS-DB, DRISHTI-GS veri tabanlarındaki görüntüler kullanılmış ve hem optik disk hem de çanak segmentasyonu üzerinde çalışarak 0,85 başarı elde edilmiştir (Sevastopolsky, 2017).

2018 yılında Fu ve ark. tarafından yine Glokom hastalığının U-Net ile tespiti üzerinde çalışılmıştır (Fu vd., 2018).

2019 yılında Kurata ve ark. rahim ağzı kanserini U-Net modeli ile tespiti üzerinde çalıştılar. Rahim ağzı kanseri hastalığına sahip 122 kadından alınan görüntüler ile eğitim yapılmış ve tüm hastalar için ortalama %82 DSC oranında başarı elde edilmiştir (Kurata vd., 2019).

2019 yılında Han ve ark. U-Net modeli Placenta görüntülerinden fetüs segmentasyonu üzerinde çalışmışlardır. Çalışma, Fetüsün plasentadayken anormal bir fonksiyonu veya negatif bir gelişiminin sorgulamasını yapmayı hedeflemektedir. 11 hamile kadının doğum öncesi muayenelerinden elde edilen yaklaşık 1.110 görüntü ile eğitim yapılmış ve %98,68 başarı oranı sağlamıştır (M. Han vd., 2019).

2019 yılında Livne ve ark. 2D MRG beyin görüntülerinden damar segmentasyonu üzerinde çalışmışlardır. Çalışma, damar görüntülerini inceleyerek serebrovasküler hastalığının erken teşhisini amaçlamaktadır. 66 hastadan alınan görüntüler U-Net modeli ile eğitilmiş ve %95 DSC başarısı elde edilmiştir (Livne vd., 2019).

2020 yılında Park ve ark. 3D CT akciğer görüntülerinden tam bir akciğer lobunun segmentasyonu üzerinde çalışmışlardır. Üç farklı merkezden alınan 196 normal ve hafif-orta şiddette KOAH hastasının hacimsel göğüs CT taramalarından elde edilen görüntüler U-Net modeli ile eğitilmiş ve %0,97 DSC başarısı elde edilmiştir (Park vd., 2020).

2.7 U-Net Modelinden İlham Alan Çalışmalar

U-Net modeli yayımlandıktan sonra birçok araştırmacıya ilham kaynağı olmuştur. U-Net modelinden esinlenerek U-Net'den daha başarılı modeller geliştirilmiştir.

2017 yılında Jégou ve ark. U-Net modelini ile Yoğun Bağlantılı Evrişim Ağları (YBEA - DenseNets) ile birlikte kullanmıştır. U-Net modelinde yer alan evrişim katmanlarının yerine yığın bloklar kullanarak yeni oluşturdukları mimarinin parametre sayısını düşürdüklerini ifade etmişlerdir. Bu da U-Net mimarisinden daha hızlı eğitimler gerçekleşeceği anlamı taşımaktadır (Jégou vd., 2017).

2018 yılında Zhou ve ark. U-Net++ modelini geliştirmiştir. U-Net modelindeki Kodlayıcı (Encoder) ve Kod Çözücü (Decoder) bölümleri arasındaki atlama bağlantıları yerine iç içe geçmiş evrişim katmanları yer almıştır. Geliştirilen yeni model ile U-Net modelindeki anlamsal boşluğun azaltılması amaçlanmıştır. U-Net++ modeli ile çeşitli veri setlerinde karşılaştırma yapılmış ve U-Net modeline göre %3,9 IoU oranında kazanç sağlanmıştır (Zhou vd., 2018).

2018 yılında Han ve Ye, U-Net modelindeki sınırlamaları kaldırmak amacıyla birden çok çözünürlüğe sahip derin öğrenme algoritmaları gösteren mimariyi önerdiler. CT görüntülerde kenarları daha yüksek bir başarı ile bulabilmek için çift ve sık çerçeveli bir mimarisi olan modelin CT görüntülerinde U-Net modelinden daha yüksek bir başarı edindiği savunulmuştur (Y. Han ve Ye, 2018).

2019 yılında Zhang ve ark. U-Net modeline benzer bir yapıda olan LU-Net modelini geliştirdiler. LU-Net modeli, U-Net modelinden 3 farklı yöntem ile geliştirilmiştir. Bunlardaki ilki: özellik haritasını çıkarırken verimi arttırmak için U-Net ile SE-Net modelini (Hu vd., 2018) birleştirerek oluşturmuşlardır. İkincil olarak, U-Net modeline çoklu skala girişi işlemi uygulanmıştır ve bunun konum eksikliği sorununu gidermek amaçlanmıştır. Sonuncu yöntem ise, klasik U-Net modelinin kod çözücü tarafındaki klasik üst-örneklemenin yerine piksel merkezli ve konum bilgilerini kaybetmeyen üst-örnekleme metodu kullanılmıştır. LU-Net modelinin U-Net modelinden daha başarılı bir performans sergilediği gözlemlenmiştir (J. Zhang vd., 2019).

2019 yılında Xiuqin ve ark. ResUNet modeli ile U-Net modeline artık bir modül eklemişler ve geliştirilen modeli retinal görüntülerde test etmişlerdir. Bu artık modül ResNet modelini içermektedir. ResUNet modeli, retinal görüntüden damar çıkarımı segmentasyonu için denenmiş ve bu veri seti üzerinde uyguladıkları ResUNet modeli ile %96,5 doğruluk elde etmişlerdir (Xiuqin vd., 2019).

2019 yılında Wu ve Zhao tarafından DenseNet ve U-Net modelleri birleştirilerek Dense U-Net modeli geliştirildi. Geliştirilen model U-Net modeli ile karşılaştırıldığında daha az parametre içerdiğinden dolayı daha avantajlı olduğu

gözelemlendi. Geliştirdikleri modeli İris segmentasyonunda denediler ve %98,36 doğruluğa ulaşarak %97,07 F1 puanı elde etmişlerdir (X. Wu ve Zhao, 2019).


2019 yılında Wu ve ark. tarafından SC U-Net modeli geliştirildi. Önerilen bu model U-Net modeline ek olarak atlamalı bağlantı (Skip Connection) içermektedir. Geliştirilen modelin daha hızlı ve daha düşük kayıp oranına sahip olduğunu gözlemlenmiştir. MRG'den elde edilen beyin görüntülerinden beyaz madde hiper yoğunluklarının segmentasyonunu yapan SC U-Net modeli, %78,36 DSC başarı oranına ulaşarak U-Net modelinden %3,37 DSC oranında kazanç elde etmiştir.



3. MALZEME VE YÖNTEM

3.1 Veri Setleri

Çalışmada, Meme kanseri, Akciğer Segmentasyonu ve hücre bölütleme yöntemlerinde sıkça kullanılan veri setlerinden 2018 Data Science Bowl yarışmasının Çekirdek Segmentasyonu veri seti olmak üzere 3 farklı çeşitte veri seti kullanılmıştır. Görüntüler iyi huylu tümöre karşı kötü huylu tümörü bulmayı amaçlamaktadır. Üç veri kümesinin formatları belirtilen değerlerde sabitlendi. Tek kanallı veriyi üç kanala çıkarmanın elbette öğrenme sürecini olumsuz etkilemesi bekleniyordu ancak bu durum, kıyaslama yapılan modeller için geçerli değildi. Çünkü sadece akciğer segmentasyon verilerinde kanal sayısını değiştirdik. Ancak modellerin aynı olumsuz öğrenme süreçlerini yaşaması için verileri standartlaştırmak bizim için önemliydi. Akciğer segmentasyonundaki bu olumsuz durum bütün veri modeller için geçerli olacağı için, bu durumun çalışmamız için olumsuz bir etkisi olmamıştır. Veri setindeki görseller Şekil 3.4'te ifade edilmiştir.



Şekil 3.1 (a) Göğüs CT görüntüsü ve akciğerin bulunduğu segmente görüntü (b) meme kanserine sahip doku ve kanserli hücreler (c) doku ve segmente edilmiş hücreler

Meme kanseri veri seti, Harvard Üniversitesindeki Beck Laboratuvarından alınmış olup, TCGA (The Cancer Genome Atlas - Kanser Genom Atlası) verilerinden seçilen


böbrek karsinomunun yüksek çözünürlüklü histopatolojik görüntülerini içerir (Irshad vd., 2014). TCGA, kanser hastalığının morfolojik özellikleri ve klinik semptomlarını birlikte gözlemleyerek, hesaplamalı patoloji alanındaki uygulamalar için birincil kaynak oluşturmaktadır. TCGA'nın, sık rastlanan 25 kanser türünde yaptığı on binden fazla geniş kapsama sahip moleküler çalışması vardır. Doku görselleri RGB formatında iken maske görselleri sadece siyah beyaz görsellerden oluşmaktadır. Görüntülerde yer alan hücresel dokular patoloji uzmanları tarafından işaretlenmiştir. Histopatolojik görüntülerden 64 adeti çalışma için kullanılmıştır.

Çekirdek Segmentasyonu içeren veri seti Broad Bioimage Benchmark Koleksiyonundan (Ljosa vd., 2012) temin edilebilen Data Science Bowl 2018 yarışmasından alınmıştır. Veri seti 30'dan fazla deneyden elde edilen 841 2D görüntüden ve 37.333 manuel olarak bir uzman tarafından segmente edilmiş çekirdek görüntülerinden oluşur (Caicedo vd., 2019) Veri seti dünyanın farklı noktalarından toplandığı için tek tip veriler değildir. Görüntülerdeki çekirdekler insanlar, fareler ve sinekler de dahil olmak üzere çok çeşitli organizmalardan elde edilmiştir. Bazı görüntüler renkli RGB formatında, bazıları ise siyah beyazdır. Ayrıca farklı mikroskoplardan alındıkları için görüş açıları da farklılık göstermektedir. Bu da modellerin karmaşık ve farklı veriler üzerinde denenmesine olanak sağlayacaktır (Alom, Yakopcic, vd., 2018) Görüntülerdeki çekirdekler farklı koşullar altında görüntülendi ve işlendi; dokular ve embriyolar, hücre bölünmesi ve genotoksik stres dahil olmak üzere çeşitli bağlamlarda ve durumlarda ortaya çıktı. Bu durum da yine modellerin için ek bir zorluk sağlayacaktır.

Akciğer segmentasyonu veri seti, bir veri bilimi web sitesi olan Kaggle'dan alındı. Veri seti, 267 CT göğüs tomografisinden manuel olarak elde edilen bölümlenmiş akciğer görüntülerini içerir. Veri seti 2D ve 3D görüntüleri içeriyor ancak araştırmada doğru bir karşılaştırma sağlamak için 2D görüntüler kullanıldı. Görüntülerin tamamı .tiff formatındadır. Bu veri seti diğer veri setlerine göre çok daha kolay olacaktır.

3.2 U-Net Mimarisi

U-Net, biyomedikal görüntü segmentasyonu alanında kullanılan yaygın yöntemlerden biridir. U-Net, Tam Evrişimli Ağların özel bir türüdür. Tam Evrişimli Sinir Ağları, yoğun katmanlar kullanılmadan yalnızca yerel olarak bağlı katmanlardan oluşur [109]. Bu sayede hesaplanan parametre sayısı azalır ve Model daha kısa sürede daha fazla bilgi öğrenir.



Şekil 3.2 Klasik U-Net mimarisi (Ronneberger Olafand Fischer, 2015)

Şekil 3.1’de ifade edildiği gibi: U-Net mimarisi Kodlayıcı (Encoder) ve Kod Çözücü (Decoder) bölümlerinden oluşur. Mimarinin Encoder tarafında (Bu kısım klasik VGG ağına benzer) görüntünün 3x3 konvolüsyonları alınır ve görüntü her katmandaki 2x2 Maksimum havuzlama işlemi ile sıkıştırılır. Bu konvolüsyonların amacı görüntünün özellik haritasını çıkarmaktır. Giriş görüntüsü renkli ise görüntü üç kanala bölünür (RGB) ve resim üzerinde 3x3’lük filtreler ile görüntünün üzerinde adım (Stride) atarak hangi bölgenin daha fazla önem taşıdığını belirleyen özellik haritasını çıkarır. Filtrelerin katsayıları bütün renk kanallarındaki değerler ile çarpılarak toplamları hesaplanır. Bu işlem her üç kanalda da gerçekleştirildikten sonra, özellik haritasından üç sonuç elde edilir (İnik ve Ülker, 2017). Evrişim işlemi dolgulama (Padding) ile birlikte kullanılır. Dolgu, sınır piksellerini bulmak için kullanılır ancak piksel kaybına neden olur. Konvolüsyon katmanlarından sonra Düzleştirilmiş doğrusal birim katmanı (Rectified Linear Units Layer) işlemi

uygulanır ve aynı zamanda ilgili katmana aktifleştirme katmanı da denir. Giriş görüntüsüne yapmış olduğu etki ile negatif değerleri sıfır olarak sabitler. Konvolüsyon işlemlerinden sonra görüntü doğrusal bir yapıya bürünür ve bu süreç ağı daha hızlı eğiterek ağı tekrar doğrusal olmayan bir yapıya sokar (Singh vd., 2018). Bu işlemlerden sonra 2x2 Maksimum havuzlama işlemi yapılır. Maksimum havuzlama kullanılmasıdaki amaç görüntüdeki pikseller arasındaki en önemli noktalar tespit etmektir. Böylece model görüntünün çerçevesini çizer, başka bir deyişle görüntünün ne olduğunu öğrenmeye çalışır. Kod Çözücü tarafında ise görüntünün 2x2 konvolüsyonları alınır ve görüntü yukarı örnekleme işlemi (Up Sampling) ile genişletilir. Yukarı örnekleme metodunda görüntü örnek bir $l(x, y)$ sürekli görüntüyü daha yüksek oranda $L * f_s$ değeri ile çarparak genişletilir: Burada L değişken bir yukarı örnekleme faktörü, s örneklenen görüntünün f_s ise örneklenen görüntüdür (Singh vd., 2018). Çalışmada bu iş için konvolüsyon metodu kullanılmıştır. İşlem mimarinin Encoder tarafındaki mantık ile örneklendir. Görüntü, yukarı örnekleme ile her katmanda 2 katına çıktıktan sonra ona karşılık gelen kodlayıcı tarafındaki katman ile birleştirilir. Dolayısıyla Model, kod çözücü katmanındaki bilgiyi öğrenemese bile kodlayıcı katmanındaki eski bilgilerle eğitimine devam eder. Birleştirme işlemi derinlik üzerinden yapılır. Son katman, son özellik haritasının tüm bileşenlerini, bir softmax aktivasyon fonksiyonu tarafından tahmin edilmesi gereken iki sınıfa eşler.

3.3 U-Net İçin Matematiksel Formüller

İşlemleri basitleştirmek için n boyutlu uzayda tek boyutlu bir X vektörü tanımlayalım ve bunu Hankel Matrisi ($H_m(X)$) üzerinde gösterelim.

$$X = [x(1), x(2), x(3) \dots x(n)]^T \quad (3.1)$$

$$H_m(X) = \begin{bmatrix} x(1) & x(2) & x(3) & \dots & x(m) \\ x(2) & x(3) & x(4) & \dots & x(m+1) \\ x(3) & x(4) & x(5) & \dots & x(m+2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x(n) & x(1) & x(2) & \dots & x(m-1) \end{bmatrix} \in R^{n \times m} \quad (3.2)$$

Giriş vektörü k kanaldan girildiğinde ise Hankel Matrisi:

$$X_k = [X_1 \dots X_k] = \begin{bmatrix} x_1(1) & x(2) & x(3) & \dots & x(m) \\ x_1(1) & x(2) & x(3) & \dots & x(m+1) \\ x_1(1) & x(2) & x(3) & \dots & x(m+2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_1(1) & x(n) & x(2) & \dots & x(m-1) \end{bmatrix} \in R^{n \times m} \quad (3.3)$$

Denklem 3.3’de $[x_i(1) x_i(2) \dots x_i(n)]$ vektörleri boyut sayısındaki büyümeyi temsil eder. Görüntünün çözüldüğü kısım bu kısımdır. Daha sonra $\bar{A} = [A(m) \dots A(1)]^T$ filtresi giriş vektörü üzerinde adım (Stride) attığında ise:

$$Y = X \otimes \bar{A} = H_m(X)\bar{A} \in R^{n \times 1} \quad (3.4)$$

Denklem 3.4 elde edilir. Hankel Matrisi, giriş vektörünün temel elemanlarının korunmasına izin veren ve giriş vektöründen özellikler çıkaran düşük seviyeli bir yapıya sahiptir

$$y_i = C^T(Y) = C^T H_m(X)A \quad (3.5)$$

$$C_e^T Y = \begin{bmatrix} D \\ E \end{bmatrix} \quad (3.6)$$

y_i değeri sistem çıktısıdır ve D değeri katmanlardaki birleştirme(Concatenate) işlemlerini temsil eder. E değeri ise nitelik çıkarma sürecidir. Denklem 3.3’de evrişim sonucu ilk olarak öznitelikten çıkarılır ve daha sonra maksimum havuzlama işlemiyle boyut olarak küçültülür. Aynı işlem, o katmana eşdeğer olan karşı katmana da uygulanarak birleştirme gerçekleştirilir. Bu denklemleri düzenledikten sonra genelleştirirsek:


$$H_m(X) = \bar{C} C^T H_m(X) A(\bar{A})^T \quad (3.7)$$

$$X = (\bar{C} D) \otimes V(\bar{A}) \quad (3.8)$$

$$D = C^T(Y) \quad (3.9)$$


Sonucu elde edilir. A ve $V(\bar{A})$ değerleri konvolüsyon ve ters konvolüsyonu temsil eder, C havuzlama işlemini $\bar{C}$ yukarı örnekleme işlemini temsil eder.

3.4 Önerilen Yöntem



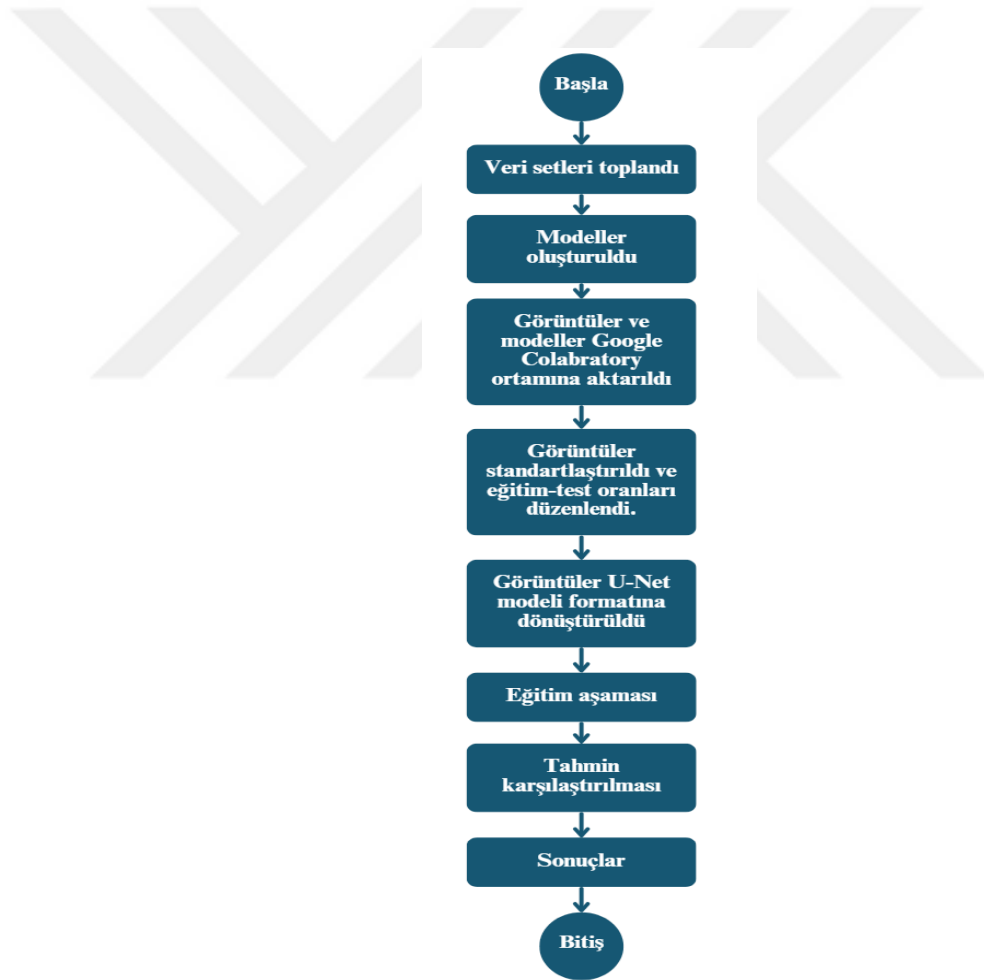
Şekil 3.3 U-Net mimarisi-kırmızı çizgiyle gösterilen alan önerilen yönteme eklenen kısımdır

Şekil 3.2’de U-Net Mimarisi gösterilmektedir; kırmızı çizgi, önerilen yöntemde sunulan ek bileşeni vurgulamaktadır. Klasik U-Net modeline bir kodlayıcı ve bir kod çözücü katmanları eklenerek U-Net’in katmanları arasındaki başarı farkı gözlemlenmiştir. Klasik U-Net’in 9 katmanlı yapısına karşın 11 katmanlı U-Net ve 13 katmanlı U-Net modelleri oluşturulmuş, aynı şekilde katman eksiltmesine gidilerek 7 Katmanlı olmak üzere 4 farklı U-Net modeli üzerinde testler yapılmıştır. Katman sayısı arttıkça aşırı öğrenmenin artacağı riskini önlemek amacıyla kullanılan U-Net modellerinde, her katmanda aşırı uyumun önlenmesi amacıyla Batch Normalization ve Dropout birlikte kullanılmıştır. Aynı şekilde 7 katmanlı ve 13 katmanlı modeller Şekil 3.3’te ifade edilmiştir.



Şekil 3.4 (a) U-Net7 mimarisi (b) U-Net13 mimarisi

Çalışmanın akış şeması şekil 3.4’de gösterilmiştir.



Şekil 3.5 Akış şeması

3.5 Görüntüleri Ön İşleme Aşamaları (Preprocessing)

Meme Kanseri veri setindeki ve Akciğer veri setindeki sırasıyla 64 ve 267 görüntüden %70 kadarı eğitim, %30 kadarı ise test için kullanılmıştır. Çekirdek Segmentasyon veri setinde görüntülerin eğitim ve test verileri daha önceden ayrılmış olduğundan herhangi bir ayırma yapılmamıştır ve %65'i eğitim, %35'i test için kullanılmıştır. Bu durumda Meme kanseri ve akciğer segmentasyonu verilerinin sırasıyla 45'i ve 187'si eğitim için 19'u ve 80'i ise test için kullanılmış olup hücre segmentasyonu için ise 670'i eğitim 65'i ise test için kullanılmıştır. Hücre segmentasyonu verilerinin bir kısmı siyah beyaz bir kısmı ise renkli olmasına rağmen tüm veriler renkli olarak okunmuştur. Kolaylık olabilmesi için veri setlerindeki tüm görseller .png formatında ayarlanmıştır. Modellerin eğitim sürecinde olumsuz bir süreçten geçmesi durumunda aynı olumsuz öğrenme süreçlerini yaşaması için verilerin standartlaştırılması çalışmamız için önemli olacaktır. Modellerin kanserli doku görüntülerindeki kanser hücrelerini daha iyi tespit edebilmesi için görüntülere yakınlaştırma işlemi uygulandı. Böylece kanserli hücre görüntüleri netleşti.

3.6 Kayıp Fonksiyonları

Bu fonksiyonlar, modelin tahminlerinin gerçek değerlerden ne kadar farklı olduğunu ölçerek modelin performansını değerlendirir. Hiper parametreleri ayarlamak ve model karşılaştırmaları yapmak gibi birçok önemli amaç için kullanılır. Farklı alanlar için farklı türlerde kayıp fonksiyonları vardır. Örneğin sınıflandırma için Çapraz Entropi Kaybı (Cross-Entropy Loss), Hinge Kaybı (Hinge Loss), Lojistik Kaybı (Log Loss), Kategorik Çapraz Entropi (Categorical Cross-Entropy) türleri kullanılır. Görüntü segmentasyonu alanında ise çoğunlukla Dice Similarity Coefficient (DSC) ve “Intersection over union (IoU)” yöntemleri kullanılır. Çalışmamızda da bu iki yöntem kullanılmıştır. DSC ve IoU yapılarını kullanmamızın nedeni, segmentasyon görüntülerinde DSC ve IoU'nun diğer kayıp fonksiyonlarına göre daha avantajlı olmasıdır. 3 boyutlu görüntülerde bu durum farklılık gösterirken 2 boyutlu ve asimetrik görüntülerde DSC ve IoU'nun daha başarılı sonuçlar elde ettiği gözlemlenmiştir (Yeung vd., 2022).

3.6.1 Dice similarity coefficient (DSC)

Aynı zamanda F1 skoru olarak da bilinen bir yöntemdir. DSC, iki kümenin benzerliğini ölçen bir kayıp hesaplama yöntemidir. Tıbbi görüntülerde sıklıkla kullanılır ve görüntü segmentasyonunda diğer metriklere göre daha anlamlı sonuçlar verir. Örneğin Meme kanserli hücre segmentasyonu için DSC değeri hesaplanmak istenirse: Modelin eğitim sonunda tahmin ettiği kanserli hücre segmentasyon A, maske verilerindeki kanserli alanın segmentasyonu B olarak düşünüldüğünde,

$$Dice_{Loss} = 1 - \frac{2 * \sum(A * B)}{\sum(A) + \sum(B)} \quad (3.10)$$

3.10 denklemi elde edilir.

3.6.2 Intersection over union (IoU)

Aynı zamanda Jaccard Endeksi olarak da bilinir (van Beers vd., 2019). Tahmin edilen bölge ile toplam referans gösterilen alanlar arasında oranı bulmayı hedefleyen standart bir ölçüdür. Modelin eğitim sonunda tahmin ettiği kanserli hücre segmentasyon alanı A, maske verilerindeki kanserli alanın segmentasyon alanı B olarak düşünüldüğünde,


$$IoU = \frac{TP}{FP + TP + FN} = \frac{A \cap B}{A \cup B} \quad (3.11)$$

3.11 denklemi elde edilir.

4. BULGULAR VE TARTIŞMA

Sonuçlar Python dilinde ve Google Colaboratory ortamında elde edildi. U-Net ve önerilen Model, TensorFlow 2.4.1 ve Keras 2.4.3 kütüphaneleri kullanılarak eğitildi. Model karşılaştırmasında fark yaratmaması için her üç veri seti de $256 \times 256 \times 3$ formatına dönüştürüldü. Data-Science Bowl 2018 veri setindeki hücre görüntüleri birden fazla maske görüntüsünden oluştuğundan, bu maske görüntüleri öncelikle NumPy kütüphanesi ile üst üste bindirilerek her hücre görüntüsü için bir maske görüntüsü elde edildi. Veri seti eğitimi için 25 Epoch değeri ve Epoch başına düşen adım sayısı olarak 200 adım belirlendi. Bu değerlerle adım başına 44 ms, epoch başına 38 s sürecektir.

Meme kanseri verileri, U-Net7, U-Net, U-Net11 ve U-Net13 modellerinin eğitim sonrası sonuçları Şekil 4.1'de gösterilmektedir.




Şekil 4.1 (a) U-Net13 modelinin meme kanseri veri seti üzerindeki eğitim ve test başarı sonuçları (b) meme kanseri veri seti üzerindeki modellerin tahmini

Şekil 4.1-a'da U-Net13 modelinin test ve eğitim verilerini göstermektedir. Eğitim verileri ve test verileri arasındaki fark modelin aşırı öğrenme yaptığını gösteriyor. Test verileri için 4. Epoch'tan sonra eğitime devam edilememiş ve 20-25 arasında ise sabit bir ivme göstermiştir. U-Net11 modelinin klasik U-Net, U-Net7 ve U-Net13 modellerine göre daha başarılı sonuç verdiği görülmektedir. Şekil 4.1-b'de U-Net7 modelinin yeterli başarıyı sağlayamadığı ancak 15. epoch değerinden sonra U-Net13 modeline göre daha iyi sonuçlar elde ettiği görülmektedir. U-Net13 modeli başlangıç epoch değerlerinde klasik U-Net'e göre daha iyi sonuç verirken, epoch değeri arttıkça

başarı oranı düşmektedir. U-Net yapısındaki ağ katmanlarının sayısının daha da artırılması, modelin performansını artırmak yerine aşırı öğrenme sağlamaya neden oluyor.


Şekil 4.2’de segmentasyon tahminlerine yer verilmiştir.



Şekil 4.2 (a) Meme kanserli doku (b) hücrelerin segment görüntüsü (c) U-Net7 modelinin tahmini (d) U-Net modelinin tahmini (e) U-Net11 modelinin tahmini (f) U-Net13 modelin tahmini

Modellerin genel performansına bakılırsa en başarılı tahminlerin U-Net11 tarafından yapıldığı görülüyor. Katmanlar arasındaki fark ele alınırsa: U-Net7 modeli çoğu kanserli hücreyi gözden kaçırır da yine de katman sayısı daha yüksek olan U-Net13 modelinden daha başarılı bir sonuç elde etmiştir. U-Net13 modeli ise neredeyse hiçbir hücreyi saptayamamıştır.


Performansını farklı veri setlerinde görmek için modeller akciğer segmentasyon verileri üzerinde test edildi. Akciğer veri setinin seçilmesinin nedeni, modellerin büyük görüntüdeki küçük tümsekleri seçmedeki başarısını karşılaştırmaktır. Performans analizleri Şekil 4.3’te gösterilmiştir.



Şekil 4.3 Akciğer segmentasyonu veri seti üzerindeki modellerin tahmin oranlarının karşılaştırılması

Şekil 4.3'te görüldüğü gibi 25 epoch değerinin sonundaki başarı oranları arasındaki fark çok yüksek olmasa da U-Net11 modeli 2.epoch değerinden itibaren veri setini öğrenerek diğer modellerin önüne geçmiştir. Bu durum da U-Net11 modelinin daha hızlı öğrendiği anlamına gelir.


Şekil 4.4'te segmentasyon tahminleri gösterilmiştir.



Şekil 4.4 (a) CT görüntüsü (b) görüntünün akciğer segmentasyonu (c) U-Net7 modeli tahmini (d) U-Net modeli tahmini (e) U-Net11 modeli tahmini (f) U-Net13 tahmini modeli


U-Net13 dışındaki modeller çok daha akciğeri başarılı bir şekilde segmente ederken U-Net7 Modelinin akciğerin iç bölgesini ayıramadığı görülmektedir. U-Net11 modeli ise segmente görüntünün sağ tarafındaki parçanın iç kısmını ayırt etmede daha başarılı olduğu görülüyor. U-Net11 dışındaki modellerin segmente görüntüleri birbirine çok yakın olarak görünmektedir.

Modeller son olarak 3. veri seti olan çekirdek segmentasyonu üzerinde test edildi. Veri setinde maske görüntüleri birden fazla görüntüden oluştuğundan işlem yükünü azaltmak ve belleği daha ekonomik kullanmak amacıyla step epoch değeri 100 olarak belirlendi. Sonuçlar Şekil 4.5'te gösterilmiştir. Modellerin öğrenmeye geç başlaması nedeniyle başarıya ulaşmak için daha yüksek dönem değerleri seçilmelidir. Çalışmada yüksek başarıdan ziyade dört modelin karşılaştırılması amaçlandığından 20 Epoch sabit değeri seçilmiştir.



Şekil 4.5 Hücre çekirdeği segmentasyonu veri seti üzerindeki modellerin tahmin oranlarının karşılaştırılması

Şekil 4.6'ya göre en iyi sonuç U-Net11 Modeli ile elde edilmektedir. Akciğer Segmentasyonu veri setinde olduğu gibi başarıdaki fark küçüktür ancak Biyomedikal Görüntü segmentasyonunda bu fark bile çok önemlidir. Bu farkın ne kadar anlamlı olduğu Şekil 9'da görülmektedir. U-Net11 modeline en yakın model olan U-Net13 modelleri arasındaki fark yaklaşık %2 ve klasik U-Net ile aralarındaki fark %4 olmasına rağmen U-Net11 modeli hem U-Net13 hem de klasik U-Net modelinden daha net tahminler yapabilmektedir.



Şekil 4.6 (a) Hücre çekirdeği görüntüsü (b) görüntünün çekirdek segmentasyonu (c) U-Net7 modeli tahmini (d) U-Net modeli tahmini (e) U-Net11 modeli tahmini (f) U-Net13 tahmini modeli

Modellere ait veri setlerine ilişkin sayısal başarı sonuçları Tablo 4.1'de ifade edilmiştir.

Tablo 4.1 U-Net modellerine ait veri setlerine ilişkin eğitim ve test sonuçları

	Meme Kanseri Segmentasyonu		Akciğer Segmentasyonu		Hücre Segmentasyonu	
Hesaplama Metriği	DSC	Validasyon DSC	DSC	Validasyon DSC	DSC	Validasyon DSC
U-Net7	%51,62	%46,87	%92,87	%95,38	%74,72	%70,82
Klasik U-Net	%55,21	%51,22	%93,95	%95,78	%76,56	%72,87
U-Net11 (Önerilen)	%69,08	%53,06	%95,09	%95,97	%79,44	%77,71
U-Net13	%72,26	%44,73	%94,75	%94,26	%74,98	%75,69

Tablo 1'e göre U-Net11 Modeli üç veri setinde en iyi sonucu elde etmiştir. U-Net13 Modelinin eğitim verilerindeki sonucu üç veri setinde de en yüksek olmasına rağmen test verilerinde en düşük değere sahip olması bir süre sonra modelin aşırı öğrenme sağladığını göstermektedir. Katman sayısı arttıkça DSC değeri de artar, ancak aşırı öğrenme meydana gelir, bu nedenle katman sayısını daha da arttırmaya gerek yoktur. Yine 7 katmanlı U-Net7 Modelinde, U-Net13 gibi modelin başarı oranının düşmesinin temel nedeni olarak, katman sayısının azaltılmasının da performansı

düşürdüğü sonucuna varılmıştır. Düşük katmanda da yetersiz öğrenme sorunu oluşmuştur. Önerilen U-Net11 Modeli ile klasik U-Net Modeli karşılaştırıldığında; Önerilen model, meme kanseri veri setinde %5, akciğer segmentasyonu veri setinde %2 ve çekirdek segmentasyonu veri setinde %4 oranında daha iyi bir performans gösterdi.

Tablo 4.2 Veri setleri üzerindeki karşılaştırma modellerinin sonuçları

Veri Setleri	Modeller	DSC	IoU
Akciğer Segmentasyonu	Klasik U-Net	94,74	90,35
	U-Net 11(Önerilen)	95,03	91,55
	ResBCDU-Net (Jalali vd., 2021)	97,16	-
	RU-Net (Z. Zhang vd., 2017)	94,94	-
Hücre Çekirdeği Segmentasyonu	Klasik U-Net	78,31	70,85
	U-Net 11(Önerilen)	81,11	71,91
	ResNet50 + Mask SSD (E. K. Wang vd., 2019)	-	47,63
	U-Net + Deep Watershed Transform (E. K. Wang vd., 2019)	-	50,17
	D-ResNet + Mask RCNN + PA (E. K. Wang vd., 2019)	-	54,41
Meme Kanseri Segmentasyonu	Klasik U-Net	55,21	34,25
	U-Net 11(Önerilen)	69,08	36,11

U-Net11, klasik yöntemlere alternatif olarak önerdiğimiz, görüntü bölütleme için yeni bir yöntemdir. Tablo 4.2’de görüldüğü gibi, yöntemimiz farklı veri setleri üzerinde klasik yöntemlere göre daha yüksek DSC değeri ve IoU puanı elde etmektedir. Ayrıca yöntemimiz Data Science Bowl 2018 yarışması sonuçlarına göre IoU skorunda oldukça iyi bir performans sergileyerek literatürdeki diğer yöntemler arasında etkinliğini ortaya koymaktadır.

5. SONUÇLAR

Bu çalışmada dört farklı modelin (U-Net11, Klasik U-Net, U-Net13 ve U-Net7) performansları çeşitli veri setleri üzerinde karşılaştırılmıştır. Dice Similarity Coefficient ve Jaccard İndeks'i gibi metrikler kullanılarak yapılan değerlendirmelerde U-Net11 modelinin en iyi sonuçları elde ettiği görüldü.

Önerilen U-Net11 modeli, üç veri kümesinde elde ettiği DSC puanları: Meme kanseri segmentasyonu veri kümesinde kanser tespiti için %69,09, akciğer segmentasyonu veri kümesinde organ tespiti için %95,02 ve Hücre çekirdeği segmentasyonu veri kümesinde çekirdek tespiti için %81,10 başarı sağlamıştır.

Veri kümeleri özenle seçilmiştir ve farklı segmentasyon türleri içerirken, veri boyutu küçükten büyüğe değişmektedir. Katman sayısı arttıkça modelde aşırı öğrenme olasılığı artar, katman sayısı azaldıkça başarı oranı ciddi oranda düşer.

U-Net11 modeli hem eğitim hem de test veri setlerinde diğer modellere göre daha yüksek Dice Similarity Coefficient ve Jaccard İndeksi değerlerine sahiptir. Bu durum önerilen modelin biyomedikal görüntü bölütlemeye etkili olduğunu göstermektedir. Ayrıca literatürdeki diğer yöntemlerle karşılaştırıldığında U-Net11 modeli üstün performans göstermiştir. Bu çalışmalar sonucunda klasik U-Net modelinde katman sayısının 9'dan 11'e çıkarılması önerilmiş olup, bu yöntemin klasik U-Net modeline alternatif olarak kullanılabileceği önerilmiştir.

KAYNAKLAR

- Agarap, A. F. (2018). Deep Learning using Rectified Linear Units (ReLU). *Neural and Evolutionary Computing*.
- Aihara, K., Takabe, T., ve Toyoda, M. (1990). Chaotic neural networks. *Physics Letters A*, 144(6), 333–340. [https://doi.org/10.1016/0375-9601\(90\)90136-C](https://doi.org/10.1016/0375-9601(90)90136-C)
- Aizenberg, I. N., Aizenberg, N. N., ve Vandewalle, J. (2000). Multiple-Valued Threshold Logic and Multi-Valued Neurons. In *Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications* (pp. 25–80). Springer US. https://doi.org/10.1007/978-1-4757-3115-6_2
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Van Esesn, B. C., Awwal, A. A. S., ve Asari, V. K. (2018). The History Began from Alexnet: A comprehensive survey on deep learning approaches. *Neural Computation*.
- Alom, M. Z., Yakopcic, C., Taha, T. M., ve Asari, V. K. (2018). Nuclei Segmentation with Recurrent Residual Convolutional Neural Networks based U-Net (R2U-Net). *NAECON 2018 - IEEE National Aerospace and Electronics Conference*, 228–233. <https://doi.org/10.1109/NAECON.2018.8556686>
- Amisha, Malik, P., Pathania, M., ve Rathaur, V. (2019). Overview of artificial intelligence in medicine. *Journal of Family Medicine and Primary Care*, 8(7), 2328. https://doi.org/10.4103/jfmpe.jfmpe_440_19
- Anliker, U., Ward, J. A., Lukowicz, P., Troster, G., Dolveck, F., Baer, M., Keita, F., Schenker, E. B., Catarsi, F., Coluccini, L., Belardinelli, A., Shklarski, D., Alon, M., Hirt, E., Schmid, R., ve Vuskovic, M. (2004). AMON: a wearable multiparameter medical monitoring and alert system. *IEEE Transactions on Information Technology in Biomedicine*, 8(4), 415–427. <https://doi.org/10.1109/TITB.2004.837888>
- Ba, J. L., Kiros, J. R., ve Hinton, G. E. (2016). Layer normalization. *Stat*, 1050, 21.
- Beattie, C., Leibo, J. Z., Teplyashin, D., Ward, T., Wainwright, M., Küttler, H., Lefrancq, A., Green, S., Valdés, V., Sadik, A., Schrittwieser, J., Anderson, K., York, S., Cant, M., Cain, A., Bolton, A., Gaffney, S., King, H., Hassabis, D., Petersen, S. (2016). DeepMind Lab. Computing Research Repository (CoRR), abs/1612.03801.
- Brooks, R. A. (1991). Intelligence without representation. *Artificial Intelligence*, 47(1), 139–159. [https://doi.org/10.1016/0004-3702\(91\)90053-M](https://doi.org/10.1016/0004-3702(91)90053-M)
- Budak, C., Asker, M. E., ve Mençik, V. (2021). Effect on model performance of regularization methods. *Journal*, 12(5), 757–765.
- Caicedo, J. C., Goodman, A., Karhohs, K. W., Cimini, B. A., Ackerman, J., Haghighi, M., Heng, C., Becker, T., Doan, M., McQuin, C., Rohban, M., Singh, S., ve Carpenter, A. E. (2019). Nucleus segmentation across imaging experiments: the 2018 Data Science Bowl. *Nature Methods*, 16(12), 1247–1253.

<https://doi.org/10.1038/s41592-019-0612-7>

- Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K., ve Yuille, A. L. (2018). DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(4), 834–848.
- Chen, L.-C., Papandreou, G., Schroff, F., ve Adam, H. (2017). Rethinking Atrous Convolution for Semantic Image Segmentation. *CoRR*. abs/1706.05587, 2017.
- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., ve Adam, H. (2018). Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. *Computer Vision – ECCV 2018*, 833–851.
- Cheng, H. D., Jiang, X. H., Sun, Y., ve Wang, J. (2001). Color image segmentation: advances and prospects. *Pattern Recognition*, 34(12), 2259–2281. [https://doi.org/10.1016/S0031-3203\(00\)00149-7](https://doi.org/10.1016/S0031-3203(00)00149-7)
- Ciresan, D. C., Meier, U., Gambardella, L. M., ve Schmidhuber, J. (2011). Convolutional neural network committees for handwritten character classification. *2011 International Conference on Document Analysis and Recognition*, 1135–1139.
- Ciresan, D., Giusti, A., Gambardella, L., ve Schmidhuber, J. (2012). Deep Neural Networks Segment Neuronal Membranes in Electron Microscopy Images. *Advances in Neural Information Processing Systems*, 25.
- Cortes, C., ve Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- David E. Rumelhart, Geoffrey Hinton, ve Ronald J. Williams. (n.d.). Learning representations by back-propagating errors. *Nature* 323, 533–536 (1986). <https://doi.org/10.1038/323533a0>.
- De Dombal, F. T., Leaper, D. J., Staniland, J. R., Mccann, A. P., ve Horrocks, J. C. (1972). Computer-aided Diagnosis of Acute Abdominal Pain. *British Medical Journal*, 2(5804), 9–13. <https://doi.org/10.1136/bmj.2.5804.9>
- Devlin, J., Chang, M.-W., Lee, K., ve Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *North American Chapter of the Association for Computational Linguistics*.
- Dong Hao and Yang, G. and L. F. and M. Y. and G. Y. (2017). Automatic Brain Tumor Detection and Segmentation Using U-Net Based Fully Convolutional Networks. *Medical Image Understanding and Analysis*, 506–517.
- Duchi, J., Hazan, E., ve Singer, Y. (2011). Adaptive subgradient methods for online learning and stochastic optimization. *Journal of Machine Learning Research*, 12(7).
- Fetzer, J. H. (1990). *What is Artificial Intelligence?*. Springer.
- Fu, H., Cheng, J., Xu, Y., Wong, D. W. K., Liu, J., ve Cao, X. (2018). Joint Optic

- Disc and Cup Segmentation Based on Multi-Label Deep Network and Polar Transformation. *IEEE Transactions on Medical Imaging*, 37(7), 1597–1605. <https://doi.org/10.1109/TMI.2018.2791488>
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4), 193–202. <https://doi.org/10.1007/BF00344251>
- Girshick, R. (2015). Fast r-cnn. *Proceedings of the IEEE International Conference on Computer Vision*, 1440–1448.
- Girshick, R., Donahue, J., Darrell, T., ve Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 580–587.
- Gokbay, I. (2021). Tıpta Yapay Zeka Uygulamaları - Antik Çağdan Yapay Zekaya Teşhis Ve Tedavi Yöntemlerinin Gelişim Sürecinde Klinik Karar Destek Sistemlerinin Evrimine Genel Bakış (pp. 673–692). <https://doi.org/10.26650/B/ET07.2021.003.33>
- Haenlein, M., ve Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61(4), 5–14. <https://doi.org/10.1177/0008125619864925>
- Hahnloser, R. H. R., Sarpeshkar, R., Mahowald, M. A., Douglas, R. J., ve Seung, H. S. (2000). Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit. *Nature*, 405(6789), 947–951. <https://doi.org/10.1038/35016072>
- Han, M., Bao, Y., Sun, Z., Wen, S., Xia, L., Zhao, J., Du, J., ve Yan, Z. (2019). Automatic Segmentation of Human Placenta Images With U-Net. *IEEE Access*, 7, 180083–180092. <https://doi.org/10.1109/ACCESS.2019.2958133>
- Han, Y., ve Ye, J. C. (2018). Framing U-Net via Deep Convolutional Framelets: Application to Sparse-View CT. *IEEE Transactions on Medical Imaging*, 37(6), 1418–1429. <https://doi.org/10.1109/tmi.2018.2823768>
- Haykin, S. (1998). *Neural Networks: A Comprehensive Foundation* (2nd ed.). Prentice Hall PTR.
- He, K., Gkioxari, G., Dollár, P., ve Girshick, R. (2020). Mask R-CNN. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), 386–397. <https://doi.org/10.1109/TPAMI.2018.2844175>
- Hinton, G. E., Dayan, P., Frey, B. J., ve Neal, R. M. (1995). The “Wake-Sleep” Algorithm for Unsupervised Neural Networks. *Science*, 268(5214), 1158–1161. <https://doi.org/10.1126/science.7761831>
- Hinton, G., ve Tieleman, T. (2012). Rmsprop: Divide the gradient by a running average of its recent magnitude. *coursera: Neural networks for machine learning*. In Tech. Rep., Technical report.
- Hochreiter, S., ve Schmidhuber, J. (1997). Long Short-Term Memory. *Neural*

- Computation, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Anonim. (2013). <https://www.srdc.com.tr/rndprojects/icardea-tr/>. (n.d.). Erişim: 29.10.2023, .
- Hu, J., Shen, L., ve Sun, G. (2018). Squeeze-and-Excitation Networks. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 7132–7141. <https://doi.org/10.1109/CVPR.2018.00745>
- İnik, Ö., ve Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85–104.
- Ioffe, S., ve Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. International Conference on Machine Learning, 448–456.
- Irshad, H., Montaser-Kouhsari, L., Waltz, G., Bucur, O., Nowak, J. A., Dong, F., Knoblauch, N. W., ve Beck, A. H. (2014). Crowdsourcing image annotation for nucleus detection and segmentation in computational pathology: evaluating experts, automated methods, and the crowd. Pacific Symposium on Biocomputing Co-Chairs, 294–305.
- Ivakhnenko, A. G., ve Lapa, V. G. (1973). Cybernetic Predicting Devices. CCM Information Corporation.
- Jalali, Y., Fateh, M., Rezvani, M., Abolghasemi, V., ve Anisi, M. H. (2021). ResBCDU-net: A deep learning framework for lung CT image segmentation. Sensors (Switzerland), 21(1), 1–24. <https://doi.org/10.3390/s21010268>
- Janiesch, C., Zschech, P., ve Heinrich, K. (2021). Machine learning and deep learning. Electronic Markets, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Jégou, S., Drozdal, M., Vazquez, D., Romero, A., ve Bengio, Y. (2017). The one hundred layers tiramisu: Fully convolutional densenets for semantic segmentation. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 11–19.
- Kaul, V., Enslin, S., ve Gross, S. A. (2020). History of artificial intelligence in medicine. Gastrointestinal Endoscopy, 92(4), 807–812. <https://doi.org/10.1016/j.gie.2020.06.040>
- Kingma, D. P., ve Ba, J. (2014). Adam: A method for stochastic optimization. Proc. of ICLR.
- Kirillov, A., Levinkov, E., Andres, B., Savchynskyy, B., ve Rother, C. (2017). InstanceCut: from Edges to Instances with MultiCut. Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-Nov, 7322–7331. <https://doi.org/10.1109/CVPR.2017.774>
- Krizhevsky, A., Sutskever, I., ve Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information

- Kuipers, B., Feigenbaum, E. A., Hart, P. E., ve Nilsson, N. J. (2017). Shakey: From conception to history. In *AI Magazine* (Vol. 38, Issue 1, pp. 88–103). AI Access Foundation. <https://doi.org/10.1609/aimag.v38i1.2716>
- Kurata, Y., Nishio, M., Kido, A., Fujimoto, K., Yakami, M., Isoda, H., ve Togashi, K. (2019). Automatic segmentation of the uterus on MRI using a convolutional neural network. *Computers in Biology and Medicine*, 114, 103438. <https://doi.org/10.1016/j.combiomed.2019.103438>
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., ve Jackel, L. D. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541–551. <https://doi.org/10.1162/neco.1989.1.4.541>
- Lecun, Y., Bottou, L., Bengio, Y., ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. <https://doi.org/10.1109/5.726791>
- Liu, S., Qi, L., Qin, H., Shi, J., ve Jia, J. (2018). Path Aggregation Network for Instance Segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 8759–8768. <https://doi.org/10.1109/CVPR.2018.00913>
- Liu, T., Fang, S., Zhao, Y., Wang, P., ve Zhang, J. (2015). Implementation of Training Convolutional Neural Networks. University of Chinese Academy of Sciences.
- Liu, W., Rabinovich, A., ve Berg, A. C. (2016). ParseNet: Looking Wider to See Better. *International Conference on Learning Representations (ICLR 2016)*.
- Livne, M., Rieger, J., Aydin, O. U., Taha, A. A., Akay, E. M., Kossen, T., Sobesky, J., Kelleher, J. D., Hildebrand, K., Frey, D., ve Madai, V. I. (2019). A U-net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease. *Frontiers in Neuroscience*, 13(FEB). <https://doi.org/10.3389/fnins.2019.00097>
- Ljosa, V., Sokolnicki, K. L., ve Carpenter, A. E. (2012). Annotated high-throughput microscopy image sets for validation. *Nature Methods*, 9(7), 637. <https://doi.org/10.1038/nmeth.2083>
- Long, J., Shelhamer, E., ve Darrell, T. (2015). Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 3431–3440.
- Maas, A. L., Hannun, A. Y., ve Ng, A. Y. (2013). Rectifier nonlinearities improve neural network acoustic models. *Proc. Icml*, 30(1), 3.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*, 9(1), 381–386.
- McCorduck, P. (2004). *Machines Who Think: A Personal Inquiry into the History*

and Prospects of Artificial Intelligence. AK Peters Ltd.

- McCulloch, W. S., ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
- Miller Randolph A. and Pople, H. E. and M. J. D. (1985). INTERNIST-I, An Experimental Computer-Based Diagnostic Consultant for General Internal Medicine. In S. Reggia James A. and Tuhim (Ed.), *Computer-Assisted Medical Decision Making* (pp. 139–158). Springer New York. https://doi.org/10.1007/978-1-4612-5108-8_8
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., ve Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533. <https://doi.org/10.1038/nature14236>
- Moran, M. E. (2007). Evolution of robotic arms. *Journal of Robotic Surgery*, 1(2), 103–111. <https://doi.org/10.1007/s11701-006-0002-x>
- Murray, N., ve Perronnin, F. (2014). Generalized Max Pooling. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2473–2480. <https://doi.org/10.1109/CVPR.2014.317>
- Nair, V., ve Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, 807–814.
- Nweke, H. F., Teh, Y. W., Al-garadi, M. A., ve Alo, U. R. (2018). Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: State of the art and research challenges. *Expert Systems with Applications*, 105, 233–261. <https://doi.org/10.1016/j.eswa.2018.03.056>
- O’Shea, K., ve Nash, R. (2015). *An Introduction to Convolutional Neural Networks*. Computing Research Repository (CoRR).
- Öztürk, K., ve Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ’ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25–36.
- Park, J., Yun, J., Kim, N., Park, B., Cho, Y., Park, H. J., Song, M., Lee, M., ve Seo, J. B. (2020). Fully Automated Lung Lobe Segmentation in Volumetric Chest CT with 3D U-Net: Validation with Intra- and Extra-Datasets. *Journal of Digital Imaging*, 33(1), 221–230. <https://doi.org/10.1007/s10278-019-00223-1>
- Peng, C., Zhang, X., Yu, G., Luo, G., ve Sun, J. (2017). Large kernel matters - Improve semantic segmentation by global convolutional network. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-Janua*, 1743–1751. <https://doi.org/10.1109/CVPR.2017.189>
- Pentland, A. (2004). Healthwear: medical technology becomes wearable. *Computer*, 37(5), 42–49. <https://doi.org/10.1109/MC.2004.1297238>

- Ramesh, A. N., Kambhampati, C., Monson, J. R. T., ve Drew, P. J. (2004). Artificial intelligence in medicine. In *Annals of the Royal College of Surgeons of England* (Vol. 86, Issue 5, pp. 334–338). <https://doi.org/10.1308/147870804290>
- Ren, S., He, K., Girshick, R., ve Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. In C. Cortes, N. Lawrence, D. Lee, M. Sugiyama, ve R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 28). Curran Associates, Inc.
- Ronneberger Olaf and Fischer, P. and B. T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In J. and W. W. M. and F. A. F. Navab Nassir and Hornegger (Ed.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (pp. 234–241). Springer International Publishing.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386.
- Rosenblatt, F. (1962). *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Spartan Books.
- Sawar, M. J., Brennan, T. G., Cole, A. J., ve Stewart, J. (1992). An expert system for postoperative care (poems). *Proceedings of MEDINFO-92*, Geneva, Switzerland.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Sevastopolsky, A. (2017). Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network. *Pattern Recognition and Image Analysis*, 27(3), 618–624. <https://doi.org/10.1134/S1054661817030269>
- Shortliffe, E. (1976). Computer-based medical consultations: MYCIN. *Artificial Intelligence - AI*, 388. <https://doi.org/10.1097/00004669-197610000-00011>
- Singh, R., Dubey, A. K., ve Kapoor, R. (2018). Up sampling of an image using convolution method. 2017 6th International Conference on Reliability, Infocom Technologies and Optimization: Trends and Future Directions, ICRITO 2017, 2018-Janua(6), 636–639. <https://doi.org/10.1109/ICRITO.2017.8342505>
- Sloane, E., Rosow, E., Adam, J., ve Shine, D. (2005). Clinical Engineering Department Strategic Graphical Dashboard to Enhance Maintenance Planning and Asset Management. 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference, 7107–7110. <https://doi.org/10.1109/IEMBS.2005.1616144>
- Specht, D. F. (1991). A general regression neural network. *IEEE Transactions on Neural Networks*, 2(6), 568–576. <https://doi.org/10.1109/72.97934>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., ve Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929–1958.
- Takeda, H., Matsumura, Y., Nakajima, K., Kuwata, S., Zhenjun, Y., Shanmai, J.,

- Qiyang, Z., Yufen, C., Kusuoka, H., ve Inoue, M. (2003). Health care quality management by means of an incident report system and an electronic patient record system. *International Journal of Medical Informatics*, 69, 285–293. [https://doi.org/10.1016/S1386-5056\(03\)00010-8](https://doi.org/10.1016/S1386-5056(03)00010-8)
- van Beers, F., Lindström, A., Okafor, E., ve Wiering, M. (2019). Deep neural networks with intersection over union loss for binary image segmentation. *Proceedings of the 8th International Conference on Pattern Recognition Applications and Methods*, 438–445.
- van Dyk, D. A., ve Meng, X.-L. (2001). The Art of Data Augmentation. *Journal of Computational and Graphical Statistics*, 10(1), 1–50. <https://doi.org/10.1198/10618600152418584>
- Vardell, E., ve Moore, M. (2011). Isabel, a Clinical Decision Support System. *Medical Reference Services Quarterly*, 30(2), 158–166. <https://doi.org/10.1080/02763869.2011.562800>
- Waibel, A., Hanazawa, T., Hinton, G., Shikano, K., ve Lang, K. J. (1989). Phoneme recognition using time-delay neural networks. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 37(3), 328–339. <https://doi.org/10.1109/29.21701>
- Wang, E. K., Zhang, X., Pan, L., Cheng, C., Dimitrakopoulou-Strauss, A., Li, Y., ve Zhe, N. (2019). Multi-Path Dilated Residual Network for Nuclei Segmentation and Detection. *Cells*, 8(5), 499. <https://doi.org/10.3390/cells8050499>
- Wang, P., Chen, P., Yuan, Y., Liu, D., Huang, Z., Hou, X., ve Cottrell, G. (2018). Understanding Convolution for Semantic Segmentation. *Proceedings - 2018 IEEE Winter Conference on Applications of Computer Vision, WACV 2018, 2018-January*, 1451–1460. <https://doi.org/10.1109/WACV.2018.00163>
- Wei Zhang. (1988). Shift-invariant pattern recognition neural network and its optical architecture. *Proceedings of Annual Conference of the Japan Society of Applied Physics*.
- Weizenbaum, J. (1966). ELIZA—a Computer Program for the Study of Natural Language Communication between Man and Machine. *Commun. ACM*, 9(1), 36–45. <https://doi.org/10.1145/365153.365168>
- Weng, W., ve Zhu, X. (2021). INet: Convolutional Networks for Biomedical Image Segmentation. *IEEE Access*, 9, 16591–16603. <https://doi.org/10.1109/ACCESS.2021.3053408>
- Wu, X., ve Zhao, L. (2019). Study on Iris Segmentation Algorithm Based on Dense U-Net. *IEEE Access*, 7, 123959–123968. <https://doi.org/10.1109/ACCESS.2019.2938809>
- Wu, Y., ve He, K. (2018). Group normalization. *Proceedings of the European Conference on Computer Vision (ECCV)*, 3–19.
- Xiuqin, P., Zhang, Q., Zhang, H., ve Li, S. (2019). A Fundus Retinal Vessels Segmentation Scheme Based on the Improved Deep Learning U-Net Model.

IEEE Access, 7, 122634–122643.
<https://doi.org/10.1109/ACCESS.2019.2935138>

Yazan, E., ve Talu, M. F. (2017). Comparison of the stochastic gradient descent based optimization techniques. 2017 International Artificial Intelligence and Data Processing Symposium (IDAP), 1–5.
<https://doi.org/10.1109/IDAP.2017.8090299>

Yeung, M., Sala, E., Schönlieb, C.-B., ve Rundo, L. (2022). Unified Focal loss: Generalising Dice and cross entropy-based losses to handle class imbalanced medical image segmentation. Computerized Medical Imaging and Graphics, 95, 102026. <https://doi.org/10.1016/j.compmedimag.2021.102026>

Yilmaz, C. (2022). Yapay sinir ağları ile Denizli ili doğal gaz tüketim analizi ve tahmini (Master's thesis, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü).

Zhang, J., Du, J., Liu, H., Hou, X., Zhao, Y., ve Ding, M. (2019). LU-NET: An Improved U-Net for Ventricular Segmentation. IEEE Access, 7, 92539–92546.
<https://doi.org/10.1109/ACCESS.2019.2925060>

Zhang, Z., Liu, Q., ve Wang, Y. (2017). Road Extraction by Deep Residual U-Net. IEEE Geoscience and Remote Sensing Letters, 15(5), 749–753.
<https://doi.org/10.1109/LGRS.2018.2802944>

Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., ve Liang, J. (2018). UNet++: A Nested U-Net Architecture for Medical Image Segmentation. Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, 11045(2018), 3–11. <https://doi.org/10.1007/978-3-030-00889-5>

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad

TATLİ, Umut

Web sayfası

(Research Gate, Academia, vs.)

<https://www.linkedin.com/in/umuttatli>

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Yüksek Lisans	Dicle Üniversitesi	2024
Lisans	Dicle Üniversitesi	2019
Lise	80.Yıl Cumhuriyet Anadolu Lisesi	2013

İş Deneyimi

Dönem (Yıl)	Şirket, Kurum	Görev
2021-	Eti Bakır A.Ş.	ERP ve İş Geliştirme Mühendisi

Yabancı Dil

İngilizce

Yayınlar

1. TATLİ U, BUDAK C, Biomedical image segmentation with modified U-Net, Trait Signal 40(2) :523–531, 2023.

Özel İlgiler

Yazılım

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Umut TATLI
Öğrenci No	20824002
Ana Bilim Dalı	Biyomedikal Mühendisliği
Program Türü	Proje ☐ Yüksek Lisans ☐ Doktora ☐
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Doç.Dr. Cafer BUDAK
(Varsa) II. Tez Danışmanı (Ünvanı, Adı, Soyadı)	
Tez Başlığı	Değiştirilmiş U-Net Modeli ile Biyomedikal Görüntü Segmentasyonu
RAPOR BİLGİLERİ	
Raporlama Aşaması	Tez Savunma Sınavı Sonrası
Sayfa Sayısı	75
Raporlama Tarihi	12.02.2024
Benzerlik Oranı (%)	5

Yukarıda bilgileri verilen tez çalışmamın toplam 75 sayfalık kısmına ilişkin, 12/02/2024 tarihinde şahsım/tez danışmanım tarafından **Değiştirilmiş U-Net Modeli ile Biyomedikal Görüntü Segmentasyonu** *TURNITIN* isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 5 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

- ☐Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası, Özet/Abstract) hariç
☐Kaynaklar hariç
☐Alıntılar hariç/dâhil
☐Diğer (Açıklayınız)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Tez benzerlik oranı üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Umut TATLI

Tarih:

İmza:

Danışman Adı, Soyadı: Doç. Dr. Cafer BUDAK

İmza:

Tarih:

Ana Bilim Dalı Başkanı Adı, Soyadı: Doç. Dr. Cafer BUDAK

İmza:

Tarih: