



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



BİLGİSAYARLI TOMOGRAFİ
GÖRÜNTÜLERİNDE DERİN ÖĞRENME
TABANLI ÇOKLU ORGAN
SEGMENTASYONU

Beyza KAYHAN
YÜKSEK LİSANS

Bilgisayar Mühendisliği Anabilim Dalı

Ocak-2022
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Beyza KAYHAN tarafından hazırlanan “Bilgisayarlı Tomografi Görüntülerinde Derin Öğrenme Tabanlı Çoklu Organ Segmentasyonu” adlı tez çalışması 07/01/2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Ahmet BABALIK

.....

Danışman

Dr. Öğr. Üyesi Sait Ali UYMAZ

.....

Üye

Dr. Öğr. Üyesi Ahmet Cevahir ÇINAR

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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

Beyza KAYHAN

Tarih: 24.01.2022

ÖZET**YÜKSEK LİSANS****BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE DERİN ÖĞRENME
TABANLI ÇOKLU ORGAN SEGMENTASYONU****Beyza KAYHAN****Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı****Danışman: Dr. Öğr. Üyesi Sait Ali UYMAZ****2022, 65 Sayfa****Jüri****Dr. Öğr. Üyesi Sait Ali UYMAZ
Doç. Dr. Ahmet BABALIK
Dr. Öğr. Üyesi Ahmet Cevahir ÇINAR**

Gelişen teknoloji ile birlikte sağlık alanındaki en önemli gelişmeler tıbbi görüntüleme teknikleri sayesinde gerçekleştirilmektedir. Vücudumuzun iç yapısının tıbbi görüntüleme teknikleri aracılığıyla detaylı olarak görüntülenmesi sonucu organların durumu hakkında bilgi edinilmektedir. Elde edilen bu görüntüler radyologlar tarafından değerlendirilir ve yorumlanır. Tıbbi görüntü analizinde öncelikli olarak organların ve dokuların tanınması hastalık teşhisi ve tedavi planlamasının ilk aşamasıdır. Fakat tıbbi görüntüler üzerinden organların tanınması oldukça zor ve zaman alıcı bir işlemdir. Bu çalışmada radyologlara yardımcı olması için karın bölgesine ait bilgisayarlı tomografi görüntüleri üzerinde birden fazla organın segmentasyonunu sağlayan bilgisayar destekli otomatik tanı sistemi gerçekleştirilmiştir. Derin Öğrenme modellerinin diğer bilgisayarlı görü alanlarında olduğu gibi segmentasyon alanında da yüksek başarı elde etmesi nedeniyle otomatik çoklu organ segmentasyon işleminde derin öğrenme yöntemi olan tam evrişimli bir sinir ağı kullanılmıştır. Bu çalışmada Vanderbilt Üniversitesinin çoklu organ segmentasyon yarışması (MICCAI 2015 Multi-Atlas Abdomen Labeling Challenge) için sağladığı veri seti kullanılmıştır. Veri setindeki dosyalar NIFTI formatında 3 boyutlu karın tomografi görüntüleridir. Bu görüntülerden HSV renk uzayında görüntü elde edilerek farklı renk uzaylarının birleştiren iki aşamalı 3D U-Net modelinin kullanıldığı füzyon bir yaklaşım önerilmiştir. Önerilen modelin değerlendirilmesi için Dice benzerlik katsayısı kullanılmıştır ve test işlemi sonucunda en yüksek Dice skorunun elde edildiği organ karaciğer ve en düşük skorun elde edildiği organ sol böbrek üstü bezi olarak bulunmuştur. Tüm organların ortalama doğruluk skoruna bakıldığında radyologlara yardımcı olması için gerçekleştirilen otomatik segmentasyon sisteminin başarılı ve umut verici olduğu görülmüştür.

Anahtar Kelimeler: Çoklu Organ Segmentasyonu, Derin Öğrenme, Füzyon Model Yaklaşımı, Tıbbi Görüntü Analizi

ABSTRACT**MS THESIS****DEEP LEARNING BASED MULTI ORGAN SEGMENTATION IN
COMPUTED TOMOGRAPHY IMAGES****Beyza KAYHAN****Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering****2022, 65 Pages****Advisor: Dr. Öğr. Üyesi Sait Ali UYMAZ****Jury****Asst. Prof. Dr. Sait Ali UYMAZ****Doç. Dr. Ahmet BABALIK****Asst. Prof. Dr. Ahmet Cevahir ÇINAR**

With the evolving technology, the most significant advancements in the field of health are happened through medical imaging techniques. As a result of complicated and detailed imaging of the within structure of our body with help of medical imaging techniques, data about the state of the organs is received. These obtained images are read, rendered and interpreted by radiologists. Determination of organs and tissues in medical image analysis is the first step of disease diagnosis and cure planning. It is hard and time-consuming to recognize organs through increasing medical images. In this study, a computer-assisted automatic diagnosis system that provides segmentation of more than one organ on computed tomography images of the abdominal region has been implemented to assist radiologists. A fully convolutional neural network, which is a deep learning method of automatic multi-organ segmentation process, is used since Deep Learning models have accomplished high achievements in the segmentation field same as other computer vision fields. In this study, the data set published for the multi-organ segmentation contest (MICCAI 2015 Multi-Atlas Abdomen Labeling Challenge) from Vanderbilt University has been used. The files in this dataset are 3D abdominal tomography images in NIfTI format. A fusion approach is recommended using a two-stage 3D U-Net model that combines different color spaces by acquiring images in HSV color space from these images. Dice similarity coefficient was used to assess the proposed model, and the organ with the highest Dice score as a result of the test procedure was the liver and the organ with the lowest score was the left adrenal gland. Considering the average accuracy score of all organs, it was seen that the automatic segmentation system implemented to help radiologists is successful and promising.

Keywords: Multi Organ Segmentation, Deep Learning, Fusion Model Approach, Medical Image Analysis

ÖNSÖZ

Bu tez kapsamı teknolojinin gelişimi ile artan tıbbi görüntüler üzerinde organların segmentasyon işleminin bilgisayar destekli otomatik sistemler ile insan gücünü en aza indirerek hata yapma oranının azaltılmasını sağlamaya yöneliktir. Organların büyüklüklerinin ve şekillerinin bireyler arasında farklılık göstermesi otomatik segmentasyon işlemini zorlaştırmaktadır. Bilgisayarlı görü problemlerinde son yıllarda popüler bir çalışma konusu olan derin öğrenme yöntemlerinin üstün başarılar elde etmesi bu çalışmada gerçekleştirilen çoklu organ segmentasyon işleminin gerçekleştirilmesinde derin öğrenme tabanlı bir yöntem kullanılmasına neden olmuştur.

Bu çalışma konusunun belirlenmesinde öncülük eden ve çalışmanın gerçekleştiriminde bilgi ve tecrübelerini benimle paylaşan, araştırmanın her bir aşamasında beni yönlendiren, karşılaştığım zorluklar karşısında yardımlarını esirgemeyen danışman hocam Dr. Öğr. Üyesi Sait Ali Uymaz'a teşekkürlerimi sunarım. Bu süreçte beni destekleyen ve bana her zaman güvenen aileme de teşekkür ederim.

Beyza KAYHAN
KONYA-2022

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	ii
ÖNSÖZ	iii
İÇİNDEKİLER	iv
SİMGELER VE KISALTMALAR	vi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL VE YÖNTEM.....	12
3.1. Veri Seti	12
3.2. Veri Ön İşleme ve Artırma.....	14
3.3. Derin Öğrenme.....	15
3.3.1. Otomatik Kodlayıcı (AE)	16
3.3.2. Kısıtlı Boltzman Makinesi (RBM)	17
3.3.3. Derin İnanç Ağları (DBN).....	18
3.3.4. Yinelene Sinir Ağları (RNN).....	19
3.3.5. Uzun Kısa Süreli Bellek (LSTM).....	20
3.3.6. Evrişimli Sinir Ağı (CNN)	21
3.3.7. Evrişimli Sinir Ağında Kullanılan Katmanlar	22
3.3.7.1. Evrişim (Convolution) Katmanı.....	22
3.3.7.2. Havuzlama (Pooling) Katmanı.....	23
3.3.7.3. Aktivasyon (Activation) Fonksiyonları.....	23
3.3.7.4. Toplu Normalleştirme (Batch Normalization) Katmanı	25
3.3.7.5. Yukarı Örnekleme (Upsampling).....	25
3.3.7.6. Tam Bağlı (Fully Connected) Katman	26
3.3.7.7. Geri Yayılım (Backpropagation) Algoritması	27
3.3.7.8. Sınıflandırma (Classification) Katmanı	28
3.4. Semantik (Semantic) Segmentasyon.....	28
3.4.1. Tam Evrişimli Sinir Ağı (Fully Convolutional Network)	30
3.4.2. U-Net	31
3.5. Füzyon (Fusion) Model Yaklaşımları	32
3.6. Önerilen Model	33
3.7. Değerlendirme Ölçütü	36
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	38
4.1. Araştırma Sonuçları	38
4.2. Tartışma.....	49
5. SONUÇLAR VE ÖNERİLER	50

KAYNAKLAR	51
------------------------	-----------



SİMGELER VE KISALTMALAR

Kısaltmalar

AE	:	Otomatik Kodlayıcı
BT	:	Bilgisayarlı Tomografi
CNN	:	Evrişimli Sinir Ağı
CRF	:	Koşullu Rastgele Alanlar
DBN	:	Derin İnanç Ağı
DR	:	Yoğun Kalıntı
DSC	:	Dice Benzerlik Katsayısı
FCN	:	Tam Evrişimli Sinir Ağı
GPU	:	Grafik İşleme Birimi
LReLU	:	Sızıntı ReLU
LSTM	:	Uzun Kısa Süreli Bellek
MR	:	Manyetik Rezonans
OAR	:	Risk Altındaki Organlar
PA	:	Olasılıksal Atlas
PReLU	:	Parametrik ReLU
RBM	:	Kısıtlı Boltzman Makinesi
ReLU	:	Doğrultulmuş Lineer Birim
RNN	:	Yinelenen Sinir Ağı
US	:	Ultrasonografi

1. GİRİŞ

Son yıllarda teknolojinin gelişmesi ile birlikte görüntü işleme ve bilgisayarlı görme uygulamaları önemli derecede artış göstermektedir. Bilgisayarlı görme, dijital görüntülerden yararlı bilgileri çıkarma ve anlama işlemleri için görüntülerin analizinin bilgisayar destekli sistemler tarafından otomatik yapılmasıdır. Bilgisayarlı görme, analiz edilen verilere ve uygulama alanına göre yöntem belirlemektedir. Görüntü işleme, keskinleştirme, kontrast gibi hesaplamalı dönüşümler uygulanması sonucu istenilen forma dönüştürülen görüntülerden anlamlı bilgilerin çıkarılması işlemidir. Bu iki terim birbirinin yerine kullanılmaktadır ve birçok alanda görülmektedir. Özellikle sağlık alanında tıbbi görüntüler üzerinde farklı yöntemler kullanılmaktadır (Soyhan ve ark., 2021, Wiley ve Lucas, 2018).

Tıbbi görüntüleme, insan vücudunun iç yapısının farklı tekniklerle görüntülenerek organların işleyişi hakkında bilgi sağlanması ve müdahale edilmesi gerekli görülen bölgelerin tespit edilmesi işlemidir. Tıbbi görüntüleme hastalıkların teşhisinde önemli bir rol oynamaktadır, aynı zamanda hastalığın ilerlemesinin ve yayılımının nasıl olduğunun incelenerek tedavi planı gerçekleştirilmesini sağlar (Atlan ve Pençe, 2021). Ayrıca radyolojik yöntem olan röntgen, bilgisayarlı tomografi (BT), manyetik rezonans (MR), ultrasonografi (US), nükleer tıp hastalıklarının tanısının konulmasında kullanılan tıbbi görüntüleme yöntemleridir. Röntgen, X-ışınları kullanılarak gerçekleştirilen ilk medikal görüntüleme yöntemidir. İnsan vücudu en, boy ve derinlik olmak üzere 3 boyutlu (3D) bir yapıya sahiptir. Fakat röntgen filmlerinde elde edilen görüntülerde bu derinlikteki yapılar üst üste düşmektedir. BT görüntüleme yönteminde de röntgen yönteminde olduğu gibi X-ışınları kullanılmaktadır. Bu yöntem vücudu kesitler şeklinde görüntüleyerek üç boyutlu görüntü elde edilmesini sağlar ve röntgen yöntemi ile edilen görüntülerdeki derinlik bilgisinin üst üste düşme problemini ortadan kaldırmaktadır. BT görüntüleme yöntemi, röntgen görüntülemeye göre daha detaylı bilgi sağlamaktadır. MR yönteminde ise BT görüntülerinde olduğu gibi kesitler şeklinde ve radyo dalgaları kullanılarak üç boyutlu görüntü elde edilmektedir. US, yüksek frekanslı ses dalgalarını kullanarak görüntüleme işlemini gerçekleştirmektedir. Nükleer tıp, hastaya ağız veya solunum yoluyla kimyasal bir bileşimin enjekte edilmesi ile yapılır. Bileşimin vücuda yayılması sonucunda radyoaktif bozulma gerçekleşirken yayılan X veya Gama ışınları sayesinde görüntü elde edilmektedir (Özekes, 2006).

Radyolojik yöntemler sayesinde elde edilen görüntüler üzerinde sınıflandırma, nesne algılama ve segmentasyon işlemleri gerçekleştirilir.

Sınıflandırma, nesnelerin şekline, rengine ve dokusuna göre ayrılması işlemidir. (Ragland ve Tharcis, 2014). Nesne algılama, bir görüntüdeki nesnenin hem konumunu hem de sınıfının tespit edilmesidir. Nesnenin konumu, nesnenin etrafına sınırlayıcı kutu çizilerek belirlenmektedir (Pathak ve ark., 2018). Segmentasyon görüntünün piksel bazlı tahmin işleminin gerçekleştirilmesi ile maskesinin çıkarılmasıdır. Semantik ve örnek segmentasyon olmak üzere iki tür segmentasyon vardır. Semantik segmentasyon aynı nesnede bulunan piksellerin aynı etikete sahip olmasıdır. Örnek segmentasyon, aynı nesnelerin farklı örneklerinin farklı etiketlenmesidir (Hafiz ve Bhat, 2020). Sınıflandırma (Türkçetin, 2019), nesne algılama (Lu ve ark., 2019) ve segmentasyon (Xiao ve ark., 2016) işlemlerinin gerçekleştiriminde yüksek başarı göstermesi sebebiyle derin öğrenme mimarileri sıklıkla kullanılmaktadır.

Derin öğrenme, makine öğrenmesinin bir alt sınıfıdır. Klasik makine öğrenmesi teknikleri ham verileri işleme konusunda yetersiz kalmaktadır. Ham verilerden bir özellik vektörü çıkarıcı tasarlamak için uzman kişilere ihtiyaç duyulur. Derin öğrenme yöntemleri ise nesne algılama veya sınıflandırma gibi işlemlerin yapılabilmesi için ham verilerden otomatik olarak özellik vektörü çıkarmaktadırlar. Bu özellik vektörü çıkarma işlemi doğrusal olmayan katmanlar sayesinde gerçekleştirilir. Her bir katmanın çıktısı kendinden sonra gelen katmanın girdisi olarak alınmaktadır. Derin öğrenmede, birden fazla katmanın kullanılması sonucunda verilerden farklı özellikler elde edilmektedir. Üst düzey özellikler, alt düzey özelliklerden türetilir. Çıkarılan özelliklerden bazıları verinin daha iyi anlaşılmasını sağlar. İlk katmanlarda kenar ve desen gibi basit düzeyde özellikler keşfedilir. Alt katmanlara inildikçe bu algılanan desenler birleştirilir ve nesneler bu parçaların birleşimi olarak algılanır. Bu katmanlar sayesinde karmaşık yapıda veriler elde edilmektedir. Derin öğrenme yöntemlerini diğer yöntemlerden ayıran en önemli avantajı özellik vektörlerinin insan gücü kullanılmadan çıkarılmasıdır (Lecun ve ark., 2015, Şeker ve ark., 2017). Derin öğrenme mimarileri yüz tanıma, ses tanıma, robotik uygulamalarda ve özellikle son yıllarda biyomedikal alanda kullanılmıştır. Bu alanda kullanılmasında medikal görüntü elde edilme imkanının geçmişe oranla daha kolay olması ve derin öğrenme mimarilerinin hızlı ve güvenilir sonuç vermesi etkili olmuştur (Toğaçar ve Ergen, 2019).

Tıbbi görüntü cihazlarının hızlı gelişimi ile elde edilen tıbbi görüntüler artmaktadır. Vücudun iç yapısı hakkında ayrıntılı bilgi sağlayan BT görüntülerinin

karmaşık, üç boyutlu ve çok fazla sayıda bulunması sebebiyle organların manuel segmentasyonu çok zaman alır, hastalar arasında organların anatomik değişikliklerin olması hata yapma olasılığını artırmaktadır. Ayrıca değerlendiriciler arası farklılıklar olabilmektedir (Feng ve ark., 2019, Vesal ve ark., 2019). Bu nedenle radyologlara yardımcı olmak ve verimliliği artırmak için bu çalışmada BT görüntüleri kullanılarak bilgisayar destekli otomatik çoklu organ segmentasyonu gerçekleştirilmiştir. Bu otomatik sistemler, segmentasyon sürecini daha hızlı ve daha sağlam hale getirerek farklı hastalık türlerinin tedavisinin temel bir parçası olan radyasyon tedavisinde, hedef ve sağlıklı organların radyasyona maruz kalma süresini kontrol ederek verimli bir şekilde tedavi planının gerçekleştirilmesini ve uygulanmasını aynı zamanda uzman yetiştirilmesi eğitim aşamasında yardım sağlamaktadır (Ogrean ve ark., 2021).

Derin Öğrenme modellerinin diğer bilgisayarlı görü alanlarında olduğu gibi segmentasyon alanında da klasik makine öğrenmesi yöntemlerine göre daha yüksek başarı elde etmesi sebebiyle bu çalışmada gerçekleştirilen otomatik çoklu organ segmentasyon işleminde derin öğrenme yöntemi olan U-Net modelini temel alan farklı renk uzaylarının kullanıldığı iki aşamalı füzyon yaklaşıma sahip bir 3D U-Net model önerilmiştir. Füzyon yaklaşım sayesinde farklı renk uzayına sahip görüntülerin özellikleri kaynaştırılmaktadır. Önerilen model tamamen evrişimli bir yapıya sahiptir ve MICCAI 2015 yarışması için (Multi-Atlas Abdomen Labeling Challenge) yayınlanan veri seti üzerinde uçtan uca eğitilmiştir. Bu veri setinden ayrılan test veri seti ile önerilen model test edildiğinde umut verici sonuçlar elde edilmiştir.

2. KAYNAK ARAŞTIRMASI

Karın bölgesine ait bilgisayarlı tomografi (BT) görüntülerinde çok sınıflı organ segmentasyonu, tıbbi görüntü analizi için önemlidir. Karın iç organları, şekil ve boyut varyasyonları nedeniyle büyük bireysel farklılıklara sahip olabilir, bu da otomatik segmentasyon yöntemlerinin geliştirilmesini zorlaştırmaktadır. Bu nedenle, segmentasyon doğruluğunun iyileştirilmesi aktif bir araştırma alanı olmuştur.

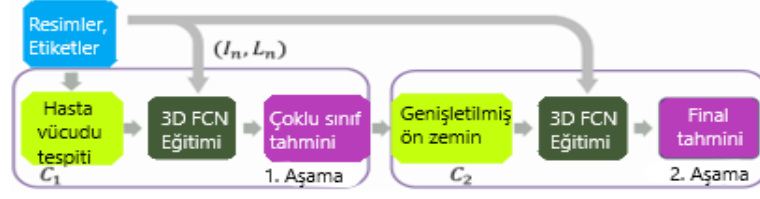
Çoklu organ segmentasyon işleminde derin öğrenme modellerinin gelişiminden önce atlas tabanlı segmentasyon yöntemleri kullanılmıştır (Ren ve ark., 2019). Görüntüler üzerinde segmentasyonu gerçekleştirecek olan kısımların manuel olarak etiketlenmesi sonucu görüntüleri hizalama ve birleştirme işlemi gerçekleştirilerek görüntü kayıtları oluşturulur. Bu görüntü kayıtları üzerinde istatistiksel yöntemlerle segmentasyon işlemi gerçekleştirilmektedir. Atlas tabanlı yöntemler ile çoklu organ segmentasyonu, görüntü kayıtlarındaki organlar arasındaki farklılıklar nedeniyle hesaplama açısından oldukça zorlayıcı bir konudur (Conze ve ark., 2021). Bu zorlayıcı durumun üstesinden gelmek için son yıllarda görüntü kaydı gerektirmeyen derin öğrenmeye dayalı yöntemlerin, tıbbi görüntülerde çoklu organ segmentasyon işleminde yaygın olarak kullanıldığı ve başarılı sonuçlar elde ettiği görülmektedir.

Trullo ve ark. (2017), tarafından risk altındaki organların (OAR) otomatik tanımlanması için yeni bir çerçeve gerçekleştirilmiştir. Yemek borusu, kalp, aort ve soluk borusu dahil olmak üzere tüm organların segmentasyonunu gerçekleştirmek için iki ortak derin mimari önerilmiştir. İki ağı birleştirmenin amacı, her OAR sırayla bölümlere ayrıldığında ikinci ağda kullanılacak olan anatomik kısıtlamaların birinci ağ tarafından öğrenilmesidir. İlk derin mimari, arka plana, yemek borusuna, kalbe, aorta veya soluk borusuna ait her vokselin olasılık haritasını çıkararak ilk segmentasyonu gerçekleştirir. İlk segmentasyon işlemi için düşük seviyeli özelliklerin ve derin yüksek seviyeli temsillerin etkili bir kombinasyonuna izin veren Sharpmask (Pinheiro ve ark., 2016) ağı kullanılmıştır. Organlar arasındaki uzamsal ve yoğunluk ilişkilerini güçlendirmek için ilk bölümleme sonucu Koşullu Rastgele Alanlar (CRF) ile rafine edilmiştir. SharpMask kullanan ikinci derin mimari ise arka plan ile her hedef organı ayırt etmek için eğitilmiştir. Bu mimarinin iki veri seti girdisi vardır. İlki BT görüntüsü ve ikinci girdisi ilk segmentasyon sonuçlarıdır. Bu mimarinin ilk derin mimariye kıyasla temel farkı, son katmanda yalnızca iki çıkış kanalına sahip olmasıdır. Bu çalışmanın amacı ikinci derin mimari sayesinde hedef organ etrafındaki anatomik kısıtlamaların


öğrenilmesi ve böylece daha iyi segmentasyon sonucu üretmeye yardımcı olmasıdır. Yemek borusu, kalp, trake ve aort organları için sırasıyla tahmin sonuçları 0.69, 0.90, 0.87 ve 0.89 olarak bulunmuştur.

Larsson ve ark. (2018), tarafından yapılan çalışmada organ segmentasyonu için daha büyük ve daha karmaşık ağ yapıları tasarlamak yerine, evrişimli sinir ağının çözmesi gereken görevi basit hale getiren iki aşamalı bir yöntem önerilmiştir. Sistemde her organ bağımsız olarak bölümlere ayrılır. Amaç hedef görüntüde organın merkez vokselini bulmaktır. Bu işlem gerçekleştirildiğinde tahmin edilen organ merkezinin etrafına ortalananmış olarak bir tahmin maskesi yerleştirilir. Tahmin maskesi daha sonra, evrişimli sinir ağı ile başlangıçta uygulandığı ilgili bölgeyi tanımlar. Bir başlatma yönteminin kullanılması, vokselin yalnızca belirli bir organ ile arka plan arasında ayrım yapması gereken daha özel veya bölgesel ağı eğitmesini sağlar. Organ merkezinin hedef görüntüdeki konumu, özellik tabanlı bir çoklu atlas yaklaşımı kullanılarak elde edilir. Ardından, voksel bazlı sınıflandırma yapan 3D evrişimli bir sinir ağı (CNN) uygulanır. Evrişimli sinir ağı tam evrişimli katmanlardan oluşur ve hem düşük hem de yüksek çözünürlüklü görüntü verilerini alır. Son bir adım olarak, ikili bir görüntü oluşturmak için, veriden tahmin edilen organa özgü bir değerle, evrişimli sinir ağından gelen olasılıklar eşleştirilir. Tüm organlar için toplam ortalama 0.75 ve safra kesesi, aort ve sağ adrenal bezi olmak üzeri 13 organdan üçü için en yüksek skor elde edilmiştir.

Roth ve ark. (2018a), tarafından yapılan çalışmada, çeşitli anatomik yapıların manuel olarak etiketli BT görüntüleri üzerinde eğitilmiş çok sınıflı bir 3D Tam evrişimli sinir ağı mimarisi (FCN) önerilmiştir. Manuel özelliklerin ve sınıfa özgü modellerin eğitime ihtiyacı ortadan kaldırılmıştır. Şekil 2.1'de görüldüğü gibi iki tane 3D FCN kullanan aşamalı bir yaklaşım önerilmektedir. İlk aşamada hastanın vücudunun bir maskesini elde etmek için morfolojik işlemlerle kombinasyon halinde basit eşikleme uygulanır. Bu maske, ağın kayıp işlevini hesaplamak için gerekli voksel sayısını azaltmak ve eğitim sırasında CNN'de gösterilen giriş 3D bölgelerinin miktarını yaklaşık %40'a düşürmek için ilk aday bölge (C1) olarak kullanılır. Birinci aşama FCN mimarisi eğitildikten sonra, ikinci aşama FCN eğitimi için ikinci aday bölge (C2) kullanılır. Şekil 2.2'de C1 ve C2 adaya bölgeleri gösterilmektedir. Gerçekleştirilen çalışmada 331 adet BT görüntüsünden oluşan eğitim ve doğrulama setlerinden yararlanılmıştır. Bu mimari, üç anatomik organı (karaciğer, dalak ve pankreas) hedefleyen 150 BT taraması içeren, tamamen görünmeyen bir veri seti üzerinde test edilmiştir. Karaciğer, dalak ve pankreas tahmin sonuçları sırasıyla %95.4, %92.8 ve %82.2 olarak elde edilmiştir.



Şekil 2.1. İki kademeli FCN mimarisi (Roth ve ark., 2018a)




Şekil 2.2. C1 ve C2 aday bölgesi (Roth ve ark., 2018a)

Roth ve ark. (2018b), tarafından otomatik segmentasyon işleminin gerçekleştirilebilmesi için 3D görüntüleri işleyebilen 3D tam evrişimli bir ağ (FCN) önerilmiştir. CNN'lerin bir dezavantajı, evrişimli özellikler ağın son tam olarak bağlı katmanlarına beslendiğinde görüntünün uzamsal bilgisinin kaybolmasıdır. Bununla birlikte, uzamsal bilgi özellikle anlamsal bölümlere görevleri için önemlidir. Bu sorunların üstesinden gelmek için bu çalışmada tam evrişimli ağlar (FCN) kullanılmıştır. FCN mimarisinde, ağ içindeki düşük çözünürlüklü özellik haritalarına bir yukarı örnekleme uygulamak için CNN mimarisinin tam bağlantı katmanları ters evrişim katmanları ile değiştirilir. Bu işlem sayesinde aynı anda anlamsal bölümlere gerçekleştirirken girdi görüntüsünün orijinal uzamsal boyutları kurtarılabilmektedir. Kullanılan veri seti mide kanser hastaları ile yapılan bir araştırma çalışmasından elde edilmiştir. Her BT hacmi, 512×512 piksellik 460-1177 dilimden oluşur. Her görüntüde arterler, portal ven, karaciğer, dalak, mide, safra kesesi ve pankreas birkaç eğitimli araştırmacı tarafından etiketlenmiş ve bir uzman tarafından onaylanmıştır. 3D FCN mimarisi ile test verilerinde ortalama 0.89 skor elde edilmiştir.

Roth ve ark. (2018c), tarafından yapılan çalışmada çoklu organ segmentasyonu daha yüksek bir çözünürlükte anlamsal görüntü segmentasyonu gerçekleştirmek için otomatik bağlamli bir ölçek uzay piramiti kullanan ve aynı zamanda daha düşük çözünürlük seviyelerinden gelen büyük bağlamsal bilgileri de göz önünde bulunduran

çok ölçekli bir 3D FCN yaklaşımı önerilmiştir. Daha düşük çözünürlük düzeyindeki 3D FCN tahminleri, daha yüksek çözünürlüklü bir 3D FCN mimarisinin girişleriyle yükseltilir, kırılır ve birleştirilir. Dice kaybı, her seviyede optimizasyon için kullanılır ve eğitim uçtan uca gerçekleştirilir. Bu çalışmadaki çok ölçekli 3D FCN mimarisi Şekil 2.3’de verilmiştir. Bu çalışmadaki model, BT görüntülerinden manuel olarak elde edilen karın bölgesine ait organlar ve damarlardan oluşan geniş bir veri seti üzerinde eğitilmektedir ve tamamen görünmeyen bir veri seti üzerinde değerlendirilmiştir. Sonuç olarak tüm organların ortalamasında 0.86 skor elde edilmiştir.




Şekil 2.3. Çok ölçekli 3D FCN mimarisi (Roth ve ark., 2018c)

Shen ve ark. (2018), tarafından yapılan çalışmada çoklu organ segmentasyon sonuçlarının yalnızca ağ mimarisinin seçimine bağlı olmadığını, aynı zamanda kayıp fonksiyonu seçimine de büyük ölçüde bağlı olduğu gösterilmektedir. Karın bölgesine ait BT görüntülerinden oluşan veri setini kullanarak çoklu organ segmentasyonu için Dice tabanlı kayıp fonksiyonlarının etkileri karşılaştırılmaktadır. Ayrıca tek tip, basit ve kare olmak üzere üç farklı ağırlıklandırma türünün ve farklı başlangıç öğrenme oranlarının segmentasyon üzerindeki etkisi incelenmiştir. Bu ağ mimarisi, uçtan uca görüntü segmentasyonu için tasarlanmış bir tür 3D FCN’dir. Modeller 340 eğitim ve 37 test hastasından oluşan rastgele bir alt küme kullanılarak değerlendirilmiştir. Etiketli karın bölgesine ait organlar arter, portal ven, karaciğer, dalak, mide, safra kesesi ve pankreas olmak üzere yedi tanedir. Ağ çıktısında yedi organ sınıfına ek olarak arka plan dahil edilmiştir ve toplamda sekiz sınıflı tahmin haritası üretilmiştir. Her modelin eğitimi, 8GB belleğe sahip bir NVIDIA GeForce GTX 1080 GPU’da (Grafik İşleme Birimi) yaklaşık iki gün süren 10,000 yineleme için gerçekleştirilmiştir. Ayrıca Adam

(Kingma ve Ba, 2014) optimizasyon algoritması kullanılarak $\mu_1 = 0,001$ ve $\mu_2 = 0,01$ olmak üzere farklı başlangıç öğrenme oranları karşılaştırılmıştır. Ortalama Dice skoru performansları, ilk öğrenme oranı $\mu_1 = 0,001$ olduğunda tek tip için % 88.3, basit için % 74.2 ve kare ağırlık için % 44 olmuştur. İlk öğrenme oranı $\mu_2 = 0,01$ olduğunda, tek tip, basit ve kare için dice puanı sırasıyla % 86.4, % 88.9 ve % 78.9'dur.

Takeya ve ark. (2018), transfer öğrenmeyi kullanarak tam otomatik karın bölgesine ait BT görüntüleri üzerinde çoklu organ segmentasyon işleminin gerçekleştirilmesi için yeni bir derin öğrenme modeli sunmuştur. 3D U-Net hacimsel görüntü segmentasyonu elde edilmesini sağlayan tam evrişimli bir sinir ağıdır. 3D U-Net'in dezavantajı, kararının yalnızca yerel hacimsel verilere dayanması ve bu da kategorileştirmede hatalara yol açmasıdır. Bu sorunun üstesinden gelmek için, sadece ham BT verilerini değil, aynı zamanda organ konumları hakkındaki bilgileri yansıtmak için organların olasılık atlasını da kullanan 3D U-JAPA-Net mimarisi önerilmiştir. Önerilen mimari, geleneksel 2D U-Net ve 3D U-Net dezavantajlarının üstesinden gelmek için sadece CNN'leri değil aynı zamanda olasılıksal atlas (PA) bilgilerini de kullanır. Ayrıca, bu mimari ile daha doğru çoklu organ segmentasyon sonucunun elde edilmesi için PA bilgilerinin etkili bir şekilde kullanılmasını sağlayan transfer öğrenimi gerçekleştirilir. İlk öğrenme aşamasında, her sınıfa karşılık gelen 9 çıkış katmanına (8 organ ve arka plan) sahip bir 3D U-Net, tüm organların sınırlayıcı kutuları içindeki tüm veriler kullanılarak eğitilmiştir. Eğitim verilerine dayanarak her bir organ için PA bilgisi hazırlanmıştır. Şekil 2.4'de görüldüğü gibi ilk eğitim bittikten sonra, bu ağı ağırlıkları her bir organ için her biri 2 çıkış katmanına (organ ve arka plan) sahip o organ için özelleştirilmiş 3D U-Net'e aktarılır. İkinci öğrenme aşamasında, her organ için uzmanlaşmış her uzman 3D U-Net, ilgili organ dahil olmak üzere hacimsel verileri kabul eder ve ağırlıklar gradyan iniş yöntemi ile değiştirilir. Test aşamasında, her organ için uzmanlaşmış eğitilmiş ağ, o organın PA değerleri sıfır olmayan vokseller dahil olmak üzere verileri kabul eder. Çıktı "organ", son katmandaki çıktı "arka planından" daha büyükse, bu vokselle o organın bir parçası olarak etiketlenir. Önerilen yöntemin performansı 47 BT verisi ile test edilmiştir ve geleneksel 2D U-Net ve 3D U-Net'ten daha yüksek Dice puanları elde edilmiştir. Ayrıca, transfer öğrenmenin olumlu bir etkisi, önerilen yöntemle transfer öğrenmesiz yöntem karşılaştırılarak doğrulanmıştır.



Şekil 2.4. 3D U-JAPA-Net mimarisi (Kakeya ve ark., 2018)

Gibson ve ark. (2018), tarafından yapılan çalışmada çoklu organ segmentasyonu işleminin gerçekleştirilebilmesi için kullanılan BT görüntüleri ve bazı bölümlendirmeler halka açık iki veri setinden alınmıştır. Bunlar Pankreas-BT veri setinden pankreas segmentasyonlu kırk üç kişi ve 'Beyond the Cranial Vault' (BTCV) segmentasyon yarışmasından elde edilen onikiparmak bağırsağı hariç tüm organların segmentasyonlarıdır. Bu çalışmada, Dense V-Net mimarisi kullanılmıştır. En yüksek skor %96 ile dalak ve en düşük skor %63 ile onikiparmak bağırsağı olarak tespit edilmiştir.

Vesal ve ark. (2019), tarafından yapılan çalışmada kalp, yemek borusu, trakea ve aort için özel olarak toraks BT görüntülerinde OAR'leri segmentlere ayırmak için bir derin öğrenme mimarisi sunulmuştur. Önceki çalışmalardan esinlenilerek 2D U-Net ve Dense Residual (DR) ağının kombinasyonu önerilmiştir. Sırasıyla kodlayıcı ve kod çözücü mimarilerinde dört alt örnekleme ve yukarı örnekleme evrişim bloğu içerir. Burada sınırlı sayıda eğitim örneği nedeniyle, ağın daha derin bir 2D sürümü kullanılmıştır. Her blok için 3x3 çekirdek boyutuna sahip iki evrişim, ReLU aktivasyon fonksiyonu ve Adam optimizasyon algoritması kullanılmıştır. Öğrenme oranı, eğitim sırasında 0,2'lik bir bozulma faktörü ile 0,0001 ile başlatılmıştır. Doğrulama ve test setleri için veri artırma olmadan 2D U-Net ve DR birleşiminden elde edilen Dice benzerlik katsayısı (DSC) puanları %93.61 ve %88.69 olarak bulunmuştur.

Dandil ve Gültekir (2019), tarafından yapılan çalışmada organ segmentasyonunun gerçekleştirilebilmesi için Daha Hızlı Bölgesel-Evrişimli Sinir Ağları (DHB-ESA, Faster R-CNN) kullanılmıştır. 2D ve 3D karın bölgesine ait görüntüler üzerinde eğitim gerçekleştirilmiştir. Eğitim görüntüleri LabelImg yazılımı

kullanılarak etiketlenmiştir. Verilerin %70'i eğitim ve %30'u test için ayrılmıştır. Modelin başarısı eğitim verilerinde tüm organların için ortalama %87, test verilerinde ise ortalama %65 olarak bulunmuştur.


Mietzner ve Mastmeyer (2020), tarafından yapılan çalışmanın amacı BT taramalarında karın bölgesinde bulunan organları otomatik olarak tespit etmek ve segmentasyon gerçekleştirmektir. Özellikle seçilen organ grubunda pankreas tespitinde zorluk teşkil etmektedir. Sınırlayıcı kutuları tespit etmek ve beş karın organı (karaciğer, böbrekler, dalak, pankreas) için segmentasyon maskeleri oluşturmak için rastgele regresyon orman yöntemi ve 2D U-Net mimarisinin bir kombinasyonu kullanılmıştır. Eğitim ve test için kullanılan veri seti, farklı kaynaklardan elde edilen 50 BT taramasından oluşmaktadır. Bu veri setleri sadece karın bölgesine ait BT verilerini içerir. Taramalara beş hedef organ (karaciğer, pankreas, sol böbrek, sağ böbrek, dalak) dahil edilmiştir. Segmentasyon haritalarının sadece küçük bir kısmı beş hedef organın tümünü içerdiği için geri kalan segmentasyon işlemi manuel olarak gerçekleştirilmiştir. Adam optimizasyonu algoritması, çapraz entropi kaybı ve ReLU aktivasyon fonksiyonu kullanılarak her organ için bir U-Net mimarisi eğitilmiştir. Dice skoru en yüksek %71 ile karaciğer segmentasyon işleminde bulunmuştur.

Rister ve ark. (2020), tarafından yapılan çalışmada çoklu organ segmentasyon işleminde tüm etiketli organları aynı anda segmente edilmesi için bir derin sinir ağı eğitilmiştir. Karaciğer, akciğer, mesane, böbrek, kemik ve beyin olmak üzere 6 organ içeren 140 BT taraması içeren veri seti kullanılmıştır. İlk olarak, 3D Fourier dönüşümleri kullanılarak hızlandırılan, denetimsiz morfolojik algoritmalar ile akciğerler ve kemikler segmentlere ayrılmıştır. Diğer organları ayırmak için ise üç boyutlu U-Net mimarisi kullanılmıştır. Bu model bir atlama bağlantısına sahip, havuzlama veya yukarı örneklemeyle ayrılan parçalara bölünmüş bir FCN mimarisidir. Test setindeki Dice puanları organ başına %78-96 arasında değişir ve tüm organlarda ortalama %90'dır.

Liu Yingzi ve ark. (2020), tarafından yapılan çalışmada çoklu organ segmentasyonu için derin öğrenmeye dayalı bir yöntem geliştirilmiştir. BT görüntülerinde kalın bağırsak, ince bağırsak, onikiparmak bağırsağı, sol böbrek, sağ böbrek, karaciğer, omurilik ve mide olmak üzere sekiz organ hekimler tarafından etiketlenmiştir. Her hasta için yalnızca bir etiket seti belirlenmektedir. BT görüntüleri ve etiketleri önerilen derin öğrenme tabanlı yöntem için eğitim veri seti olarak kullanılmıştır. Segmentasyon işleminin gerçekleştirilebilmesi için 3D U-Net mimarisi

kullanılmıştır. Bu mimari bir eğitim ve bir segmentasyon aşaması içermektedir. Önerilen yöntemin performansı, Dice benzerlik katsayısı (DSC), duyarlılık, özgüllük, Hausdorff mesafesi %95 (HD95), ortalama yüzey mesafesi (MSD) ve kalan ortalama kare mesafe (RMSD) dahil olmak üzere altı ölçüm kullanılarak değerlendirilmiştir. DSC için kalın bağırsak, ince bağırsak, onikiparmak bağırsağı, sol böbrek, sağ böbrek, karaciğer, omurilik ve mide için sırasıyla 0.91, 0.89, 0.86, 0.95, 0.95, 0.96, 0.87 ve 0.93 değerlerine ulaşılmıştır.

Fang ve Yan (2020), çok ölçekli bir derin sinir ağının çoklu organ segmentasyonu için birden fazla kısmen etiketli veri kümesinde eğitilmesini sağlayan birleşik bir eğitim stratejisi önermektedir. Farklı ölçeklerde özellikleri birleştirmek için U-Net ağına piramit girdi alan sistem entegre edilmiştir. Son olarak iyileştirilmiş segmentasyon sonucu elde edebilmek için piramit çıktıları birleştirilir. Önerilen bu ağ PIPO-FAN olarak adlandırılır ve bu mimarinin gösterimi Şekil 2.5’de verilmiştir. Çoklu organ segmentaston modelini eğtmek için farklı veri seti kombinasyonları kullanılmıştır. PIPO-FAN ile ortalama %93.6 Dice puanı elde edilmiştir.



Şekil 2.5. PIPO-FAN mimarisi (Fang ve Yan, 2020)

3. MATERYAL VE YÖNTEM

Bu bölümde çoklu organ segmentasyon işleminin gerçekleştirilmesi için önerilen model detaylı olarak açıklanmıştır. Ayrıca önerilen modelin eğitiminde kullanılan veri seti ve veri ön işleme aşamaları verilmiştir. Ek olarak önerilen modelin temelini oluşturan yöntemler ve değerlendirilmesinde kullanılan değerlendirme ölçütü anlatılmıştır.

3.1. Veri Seti

Bu çalışmada Vanderbilt Üniversitesi Tıp Merkezinin (VUMC) çoklu organ segmentasyon yarışması (Multi-Atlas Labeling Beyond the Cranial Vault - Workshop and Challenge) için sağladığı karın BT görüntülerini içeren veri seti kullanılmıştır. Bu veri setinde 30 karın BT görüntüsü bulunmaktadır. BT görüntülerinin hacim boyutları $512 \times 512 \times 85$ - $512 \times 512 \times 198$ çözünürlük $0.54 \times 0.54 \text{ mm}^2$ - $0.98 \times 0.98 \text{ mm}^2$ ve dilim kalınlığı 2.5 mm- 5.0 mm. arasında değişmektedir. Her bir BT görüntüsü dalak, sağ böbrek, sol böbrek, safra kesesi, yemek, borusu, karaciğer, mide, aort, inferior vena kava, portal ven ve splenik ven, pankreas, sağ böbrek üstü bezi, sol böbrek üstü bezi olmak üzere toplam 13 organ eğitimi kişiler tarafından manuel olarak etiketlenmiştir ve bir radyolog tarafından onaylanmıştır. Bazı hastalarda sağ böbrek ve safra kesesi olmaması sebebiyle etiketleme işlemi gerçekleştirilememiştir. Kayıt verileri NIfTI dosya formatında oluşturulmuştur. Çizelge 3.1’de verilen numaralar isimleri verilen organlara karşılık gelmektedir. Şekil 3.1’de ise BT görüntülerinde organ isimlerine karşılık gelen organların her biri işaretlenerek gösterilmiştir (Xu, 2015).



Şekil 3.1. Organların BT görüntüleri

Çizelge 3.1. Organlara karşılık gelen numaralar

Organ Adı	Numaralar
Dalak	1
Sağ böbrek	2
Sol böbrek	3
Safra kesesi	4
Yemek borusu	5
Karaciğer	6
Mide	7
Aort	8
Inferior vena kava	9
Portal ven ve splenik ven	10
Pankreas	11
Sağ böbrek üstü bezi	12
Sol böbrek üstü bezi	13

3.2. Veri Ön İşleme ve Artırma

Veri setinde bulunan her BT taraması 512x512x85 ve 512x512x195 boyutunda değişmektedir. Her bir BT taramasının boyutunu eşitlemek için x ve y düzleminde görüntümüzün boyutu $\frac{1}{4}$ oranında küçültülmüştür. Z ekseninde ise dilim boyutlarını ayarlamak için etiketli görüntülerde organların bulunduğu başlangıç ve bitiş dilimleri tespit edilmiştir ve tahmin edilmesi istenen organların bulunmadığı kısımlar çıkarılmıştır. Bu işlemler sonucunda her bir BT görüntüsünün z ekseninde farklı boyutlar elde edilmektedir. Eğitim aşamasında her bir görüntünün boyutunu eşitlemek için rastgele bir başlangıç dilimi belirlenir ve bu başlangıç diliminden itibaren art arda gelen 48 tane dilim ile eğitim gerçekleştirilir. Sonuç olarak ağa alınacak görüntünün boyutu 128x128x48x1 olarak ayarlanmaktadır. Son kısımdaki 1 sayısı görüntünün tek kanallı olduğunu göstermektedir. Önerilen model iki aşamalıdır ve ilk aşamasında Simple ITK kütüphanesinde bulunan Colormap fonksiyonu ile veri setinde bulunan gri görüntüler HSV renk uzayına sahip görüntülere dönüştürülmüştür. Bu fonksiyon ile tek kanallı görüntüler 0 ile 1 arasında normalize edilir ve 1 değerine sahip piksellere renk haritasındaki ilk renk atanarak RGB renk uzayına sahip görüntüler elde edilir. RGB renk uzayına dönüştürülen görüntüler istenilen renk uzayına (HSV) dönüştürülür. Denklem 3.1’de RGB görüntülerin HSV renk uzayına sahip görüntülere dönüştürülebilmesi için maksimum ve minimum değerleri bulunur ve aralarındaki fark hesaplanır. Denklem 3.2,

3.3 ve 3.4’de denklem 3.1’de hesaplanan değerler kullanılarak sırasıyla görüntülerin Hue (renk özü), Saturation (doygunluk), Value (parlaklık) değerleri hesaplanır.

$$\begin{aligned} C_{max} &= \max(R, G, B) \\ C_{min} &= \min(R, G, B) \\ \Delta &= C_{max} - C_{min} \end{aligned} \quad (3.1)$$

$$\begin{aligned} H &= 0, \Delta = 0 \\ H &= \begin{cases} 60x \left(\frac{G-B}{\Delta} \text{Mod} 6 \right) & , C_{max} = R' \\ 60x \left(\frac{B-R}{\Delta} + 2 \right) & , C_{max} = G' \\ 60x \left(\frac{R-G}{\Delta} + 4 \right) & , C_{max} = B' \end{cases} \end{aligned} \quad (3.2)$$

$$S = \begin{cases} 0 & , C_{max} = 0 \\ \frac{\Delta}{C_{max}} & , C_{max} \neq 0 \end{cases} \quad (3.3)$$

$$V = C_{max} \quad (3.4)$$

Bu çalışmada kullanılan veri setinin az sayıda görüntü içermesi sebebiyle rastgele seçilen BT görüntülerine -5 ve 5 derece arasında rastgele döndürme işlemi uygulanmıştır. Aynı zamanda rastgele seçilen görüntüler üzerinde %25 ve %50 aralığında rastgele belirlenen bir oran ile görüntü yakınlaştırma işlemi gerçekleştirilir (Perez ve Wang, 2017). Ek olarak her bir BT görüntüsünün içerdiği tüm dilimler x ve y ekseninde iki parçaya ayrılmıştır ve görüntülerdeki dilim sayıları iki katına çıkmıştır. Bu parçalara ayrılmış görüntülerden rastgele 48 tane dilim seçilerek görüntü, giriş görüntüsü ile aynı boyutta 128x128x48 olarak ayarlanmıştır.

3.3.Derin Öğrenme

Gelişen teknoloji ile birlikte yapay zeka alanında kullanılmak üzere çok büyük boyutlu veri kümeleri elde edilmektedir. Elde edilen karmaşık veri kümelerinin analiz edilip önemli özelliklerin çıkarılması ve bu çıkarılan özelliklerin anlamlı bir forma dönüştürülerek sınıflandırma işleminin gerçekleştirilmesinde klasik veri işleme ve makine öğrenmesi yöntemleri yetersiz kalmaktadır. Bu problemlerin üstesinden gelmek

için son yıllarda derin öğrenme yöntemleri kullanılmaktadır (Wang Xizhao ve ark., 2020b).

Derin öğrenme, makine öğrenmesinin bir alt dalı olarak ortaya çıkarılmıştır. Makine öğrenmesi, verilerden çıkarılan kavramlar ve özellikler sayesinde otomatik olarak öğrenme gerçekleştirilmek üzere tasarlanmış yapay zekanın bir alanıdır. Makine öğrenmesi yöntemlerinin performansı verilerden çıkarılan özelliklerin tutarlılığına bağlıdır. Büyük boyutlu ve karmaşık verilerin işlenmesi çok zaman alıcı ve zor olması makine öğrenmesi yönteminin yetersiz kalmasına ve derin öğrenme modellerinin ortaya çıkmasına sebep olmuştur. Derin öğrenme mimarilerin temelinde yapay sinir ağları bulunmaktadır. Sinir ağlarının art arda eklenerek çok sayıda katmandan oluşması derin yapay sinir ağlarını oluşturmaktadır. Bu derin sinir ağlarının, ağa alınan verilerden doğrusal olmayan katmanlar sayesinde özellik çıkartılarak eğitilmesi sonucunda derin öğrenme gerçekleşmektedir. Eğitim aşaması her bir katmanın çıktısı kendisinden sonra gelen katmanın girdisi olarak alındığı hiyerarşik bir düzen ile büyük miktarda etiketlenmiş verilerin eşleşen özelliklerinin belirlenmesi sayesinde gerçekleştirilmektedir. Eğitim aşamasının tamamlanmasının ardından ise çıkarılan özellikler sayesinde etiketlenmemiş verilerin etiketlenmesi sağlanmaktadır (Dargan ve ark., 2020).


Derin öğrenme modelleri bilgisayarla görme, sınıflandırma, nesne tanıma, segmentasyon, doğal dil işleme ve ses tanıma gibi birçok alanda kullanılmaktadır. Otomatik kodlayıcılar (AE'ler), Derin İnanç Ağları (DBN'ler), Evrişimli Sinir Ağları (CNN'ler) Sınırlandırılmış Boltzmann Makineleri (RBM'ler), Tekrarlayan Sinir Ağları (RNN'ler) ve Uzun Kısa Süreli Bellek (LSTM) olmak üzere farklı derin öğrenme mimarileri bulunmaktadır (Dargan ve ark., 2020).

3.3.1. Otomatik Kodlayıcı (AE)

Otomatik kodlayıcı, kodlama ve kod çözme aşamalarından oluşan denetimsiz öğrenme tabanlı bir derin öğrenme yaklaşımıdır. Bu mimari ile giriş verilerinin öğrenilmesi ve temsili sonucunda, verilerin boyutlarının küçültülmesi, sıkıştırılması veya birleştirilmesi gibi birçok işlem gerçekleştirilir. Kodlama aşamasında, ağa alınan verilerin en az hata ile istenilen özellik boyutuna indirgenmesi sağlanır. Kod çözme aşamasında ise kodlama aşamasında elde edilen düşük boyutlu öznitelik haritasının ters

işlenmesi ile orijinal giriş verisine yakın bir temsil oluşturulması amaçlanmaktadır (Alom ve ark., 2019).

Otomatik kodlayıcı mimarisinde giriş katmanı, gizli katmanlar ve çıkış katmanı bulunmaktadır. Bu mimari ve yapay sinir ağları arasındaki fark, giriş ve çıkış katmanındaki nöron sayılarının eşit olması ve gizli katmanda bulunan nöron sayısının giriş katmanındaki nöron sayısından daha az olmasıdır. Birden fazla otomatik kodlayıcının art arda eklenmesi ile derin öğrenme mimarisi oluşturulmaktadır. Şekil 3.2’de basit bir otomatik kodlayıcı mimarisi gösterilmektedir (Kaynar ve ark., 2017).




Şekil 3.2. Otomatik kodlayıcı mimarisi (Alom ve ark., 2019)

3.3.2. Kısıtlı Boltzman Makinesi (RBM)

Kısıtlı Boltzman makinesi denetimsiz bir derin öğrenme yaklaşımıdır. Bu derin öğrenme yaklaşımı gizli ve görünür iki katmandan oluşan olasılıksal tabanlı bir modeldir. Boltzman makinesinde bulunan her bir nöron diğer tüm nöronlara bağlanarak tamamen bağlantılı ağ oluşturmaktadır. Kısıtlı Boltzman makinesinde görünür katmanların gizli katmanlara bağlandığı ve katman içi bağlantıların olmadığı Boltzman makinelerinin özel bir türüdür (Upadhy ve Sastry, 2019).

Bir RBM modelinde eğitim gerçekleştirebilmek için bir katmandaki tüm nöronlar rastgele ağırlıklarla başlatılır ve diğer katmanlardaki nöronlar denge dağılımı

sağlanana kadar güncellenmektedir (Liu Weibo ve ark., 2017). Şekil 3.3’de Kısıtlı Boltzman makinesi mimarisi verilmiştir.




Şekil 3.3. Kısıtlı Boltzman Makinesi Mimarisi (Liu Weibo ve ark., 2017)

3.3.3. Derin İnanç Ağları (DBN)

Kısıtlı Boltzman makinesi kullanılarak bir ağ eğitilebilir. RBM eğitiminde ağırlıkların rastgele başlatılması ile gittikçe derinleşen ağlarda gradyanların kaybolması sorunu ortaya çıkmaktadır. Bu nedenle önceden eğitilmiş ağlar için önceden eğitilmiş ağırlıklar kullanan daha sonra ince ayar yapan yeni bir yöntem Derin İnanç Ağları (DBN) önerilmiştir (Ghojogh ve ark., 2021).

DBN’ler Şekil 3.4’de gösterildiği gibi birden çok gizli ve görünür katmanlardan oluşmaktadır. Bu katmanlar arasında RBM’de de bahsedildiği gibi bağlantı bulunmaktadır. Art arda RBM ağlarının bağlanması ile DBN ağları oluşmaktadır. Her bir RBM’nin gizli katmanı bir sonraki RBM’nin görünür katmanına bağlanır ve bağlantı yukarıdan aşağıya olacak şekildedir. RBM’ler sıra ile eğitilmektedir. İlk olarak üst RBM’lerden çıkarılan öznetelikler alt RBM’lere iletilecektir. DBN’ler ön eğitim ve ince ayar aşamalarından oluşmaktadır. Ön eğitim aşamasında aşağıdan yukarıya doğru denetimli öğrenme ile öznetelik çıkarımı gerçekleştirilir. İnce ayar aşamasında ise ön


eğitim aşamasında çıkarılan ağırlıkların kullanılarak yeni ayarlamalar ile yukarıdan aşağıya yayılarak denetimli öğrenme gerçekleştirilir. Ön eğitim aşamasından çıkarılan ağırlıkların, rastgele ağırlıklara göre global optimumu daha yakın olduğu ve daha iyi performans gösterdiği ön görülmektedir. Ancak giriş verilerinin sabit olması istenilen performansın elde edilmesini engellemektedir. Bu sorunun üstesinden gelmek için DBN’lerde ağırlıkların ağın boyutuna ve yüksekliğine göre optimize eden aç gözlü bir algoritma ile katman katman öğrenme gerçekleştirilmektedir (Liu Weibo ve ark., 2017).



Şekil 3.4. Derin İnanç Ağı Mimarisi (Liu Weibo ve ark., 2017)

3.3.4. Yinelenen Sinir Ağları (RNN)


Yinelenen sinir ağları temel olarak sıralı veriler için kullanılan modellerden biridir. RNN, zaman serisi verilerinde yaygın olarak kullanılmaktadır (Pamina ve Raja, 2019). Örnek verilecek olursa bir metin içerisindeki cümlelerin anlaşılması kendinden önceki cümlelere ve kelimelere bağlıdır. Standart sinir ağları bu durum karşısında yetersiz kalmaktadır (Alom ve ark., 2019). Tekrarlayan sinir ağlarını diğer ağlardan ayıran en önemli özelliği kendinden önceki katmanlara geri beslemeli olarak bağlanmasıdır. Ek olarak, bu ağlar girdinin önceki hafızasını alır ve zaman içinde çıkan sorunlar için tekrar modelleyebilir (Dargan ve ark., 2020). Şekil 3.5’de yinelenen sinir ağının yapısı gösterilmektedir.



Şekil 3.5. Yinelenen Sinir Ağı (Olah, 2015)


3.3.5. Uzun Kısa Süreli Bellek (LSTM)

Bazı görevlerde tahmin etme işlemi için ağıdaki son bilgiye bakmak yeterli olmaktadır. Fakat tahmin edilmesi istenen bilginin daha fazla bağıllık bilgisine ihtiyaç duyduğu görevler söz konusu olabilmektedir. Bu durumlarda RNN'ler yetersiz kalmaktadır ve uzun vadeli bağımlılık sorununun üstesinden gelmek için LSTM'ler tasarlanmıştır (Olah, 2015). Tekrarlayan sinir ağları Şekil 3.6'da gösterildiği gibi tek bir tanh katmanından oluşan zincir şeklinde bir yapıya sahiptir.



Şekil 3.6. Tek katman içeren RNN modülü (Olah, 2015)


LSTM'ler de ise birbirini takip eden farklı yapıya sahip katmanlar bulunmaktadır. Şekil 3.7'da öğrenme, ekleme, birleştirme ve taşıma gibi farklı işlemleri içeren bir LSTM modülü gösterilmektedir (Olah, 2015).



Şekil 3.7. Farklı katmanlar içeren LSTM modülü (Olah, 2015)

3.3.6. Evrişimli Sinir Ağı (CNN)

1989 yılında Yann LeCun tarafından ilk CNN mimarisi tasarlanmıştır (Le Cun ve ark., 1989). 1998 yılına kadar iyileştirilen bu mimari LeNet olarak adlandırılmıştır (Lecun ve ark., 1998). Sonraki yıllarda daha gelişmiş yapıda olan VGG-Net (Simonyan ve Zisserman, 2014), Google-Net (Szegedy ve ark., 2015), Res-Net (He ve ark., 2016) gibi CNN mimarileri önerilmiştir. Evrişimli sinir ağlar (CNN), evrişim katmanları, genellikle doğrusal olmayan katmanlar, toplu normalleştirme ve havuzlama katmanlarından oluşan çok katmanlı mimarilerdir. Bir katmanın çıktısı diğer katmanın girdisi olarak kullanılmaktadır. İlk katmanlar, kenar, ışık ve renk gibi alt düzey kavramları öğrenirken, sonraki düzey katmanlar, nesnelerin ayırt edici özelliklerini tespit eden üst düzey kavramları öğrenir (Dargan ve ark., 2020). CNN'ler seyrek bağlantılara sahiptir bu yüzden aynı derinliğe sahip tam bağlantılı bir sinir ağından daha az parametreye sahiptir. CNN'lerde eğitim gradyan tabanlı öğrenme algoritması ile gerçekleştirilir. Bu algoritmalar sayesinde kayıp en aza indirilerek üretilen ağırlıklar optimize edilmektedir (Alom ve ark., 2019). Evrişimli sinir ağlar tıbbi görüntü analizinde yaygın olarak kullanılmaktadır. Tıbbi görüntüler üzerinde nesne algılama, tanıma, görüntü sınıflandırma ve segmentasyon işlemlerinde yüksek başarı elde eden modellere sahiptir (Karayeğen, 2021). Şekil 3.8'de basit bir evrişimli sinir ağı modeli verilmiştir.



Şekil 3.8. Klasik bir evrişimli sinir ağı modeli (Firildak ve Talu, 2019)


3.3.7. Evrişimli Sinir Ağında Kullanılan Katmanlar

Klasik bir evrişimli sinir ağında evrişim katmanı, havuzlama katmanı, aktivasyon işlemlerinin gerçekleştirildiği katman, toplu normalleştirme katmanları, tam bağlı katman ve sınıflandırma katmanı bulunmaktadır (Firildak ve Talu, 2019). Tam evrişimli bir sinir ağında ise tam bağlı katmanlar hariç klasik bir evrişim sinir ağında bulunan tüm katmanlar bulunur ve bunlara ek olarak yukarı örnekleme katmanı bulunmaktadır (Ronneberger ve ark., 2015). Bu bölümde bu katmanlar incelenmektedir.

3.3.7.1. Evrişim (Convolution) Katmanı

Evrişim katmanı, evrişimli sinir ağlarının temel katmanıdır. Bu katman ağa verilen girdilerin öznitelik haritalarının çıkarılmasından sorumludur ve birden fazla evrişim katmanı bulunmaktadır. Giriş görüntüsünden yeni öznitelikler önceden çıkarılmış öznitelik haritalarına farklı evrişim işlemleri uygulanarak çıkarılır ve elde edilen sonuçlar doğrusal olmayan bir aktivasyon fonksiyonundan geçirilir. (Guo ve ark., 2017)


Bir veya daha fazla kanallı giriş görüntüsüne uygulanan evrişim işleminin sonucunda birden fazla matris oluşmaktadır ve giriş matrisi ile çıkış matrisi boyutları birbirinden farklı olabilmektedir. Her girdi matrisi kendisine karşılık gelen çekirdek matrisinin değerleri ile çapılır ve son olarak çıkan sonuçlar toplanmaktadır. Bu işlemlerin yapılmasındaki amaç görüntü sınıflandırmada kullanılacak ayırt edici özellik haritalarının çıkarılmasıdır (Alom ve ark., 2019). Şekil 3.9’da evrişim işlemi örneği gösterilmektedir.



Şekil 3.9. Evrişim işlemi (Türkoğlu ve ark., 2021)

3.3.7.2. Havuzlama (Pooling) Katmanı

Havuzlama katmanı verilen girdilerin çıkarılan öznitelik haritasının boyutlarını kademeli olarak azaltmaktadır. Bu boyut azaltma işlemi, modelin hesaplayacağı parametre sayısını azaltarak hesaplama maliyetinin düşürülmesini ve karmaşıklığın giderilmesi sağlamaktadır. Çekirdek boyutunun büyümesi ağı verilen girdilerin önemli özelliklerinin kaybedilmesine ve modelin performansının düşmesine neden olabilir. Maksimum ve ortalama olmak üzere yaygın olarak kullanılan iki havuzlama yöntemi bulunmaktadır (O'shea ve Nash, 2015). Şekil 3.10'da maksimum ve ortalama havuzlama işlemlerinin gerçekleştirimi verilmiştir.



Şekil 3.10. Maksimum ve ortalama havuzlama işlemi (Ali ve Hanbay, 2018)

3.3.7.3. Aktivasyon (Activation) Fonksiyonları

Aktivasyon fonksiyonu karmaşık verilerin öğrenilmesine yardımcı olmaktadır. Uygun bir aktivasyon fonksiyonu seçimi modelin daha hızlı öğrenmesini ve daha iyi performans göstermesini sağlar. Bu katman bir girdiyi doğrusal olmayan bir çıktıya dönüştürür. Elde edilen bu çıktı sonraki katmanlara girdi olarak verilmektedir. Farklı aktivasyon fonksiyonları bulunmaktadır. Bunlar Sigmoid, Tanh, SWISH, ReLU ve

varyantlarıdır. Son zamanlarda ReLU ve varyantları daha iyi performans göstermesi sebebiyle tercih edilmektedir (Khan ve ark., 2020).

ReLU en yaygın kullanılan aktivasyon fonksiyonlarından biridir. ReLU hesaplama yaparken pozitif kısmı tutan ve negatif kısmı sıfıra eşitleyen doğrusal bir fonksiyondur. Bu işlemler Tanh ve Sigmoid fonksiyonlarına göre çok daha hızlı bir şekilde hesaplama yapılmasını sağlamaktadır. ReLU'da sıfırın süreksizliliği geri yayılımı olumsuz etkilemesine rağmen ve ön eğitim gerçekleştirilmeyen derin ağlarda bile daha iyi performans göstermektedir (Gu ve ark., 2018). Denklem 3.5'de ReLU aktivasyon fonksiyonu işlevi verilmektedir.


$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (3.5)$$

ReLU aktivasyon fonksiyonu ağa verilen girişin negatif olması durumunda nöronların ölmesine sebep olur. Bu yüzden Leaky ReLU (LReLU) aktivasyon fonksiyonunda negatif değerleri sıfıra eşitlemek yerine girdi değeri (0,1) aralığında sabit bir değer ile sıkıştırılır ve küçük bir eğim elde edilir (Gu ve ark., 2018).

Parametric ReLU'da (PReLU) ağa verilen negatif girişler Leaky ReLU'da olduğu gibi bir değer ile sıkıştırılır. Bu değer sabit bir sayı olarak alınırsa model negatif girdiler için doğru tahminlerde bulunamayabilir. Bu yüzden negatif kısmındaki bu değer hatanın geri yayılımı sırasında optimize edilerek güncellenmektedir (Alkhatib, 2021).

$$f(x) = \begin{cases} ax & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (3.6)$$

Denklem 3.6 ile hem LReLU hem de PReLU gösterilmektedir. 'a' değeri LReLU'da sabit bir değerdir. PReLU'da ise bu değer güncellenmektedir. Şekil 3.11'de ReLU, LReLU ve PReLU aktivasyon fonksiyonların grafikleri verilmiştir.



Şekil 3.11. ReLU, LReLU/ PReLU aktivasyon fonksiyonu grafikleri (Khanday ve Sofi, 2021)

3.3.7.4. Toplu Normalleştirme (Batch Normalization) Katmanı


Toplu normalleştirme, genellikle derin sinir ağlarında ara katmanlarındaki aktivasyon fonksiyonlarından sonra gelerek girdileri sıfır ortalama ve sabit standart sapmaya normalleştirmektedir. Bu teknik eğitimi hızlandırması, yüksek öğrenme oranları sağlaması ve doğruluğu geliştirmesi sebebiyle yaygın olarak kullanılmaktadır. Bu katman sayesinde gradyan adımları daha büyük alınarak hızlı bir yakınsama sağlanır ve yerel minimuma takılma sorunu engellenmektedir (Bjorck ve ark., 2018). Toplu normalleştirme işlemi denklem 3.7’de verilmiştir. N_l^k normalleştirilmiş özellik haritasını, F_l^k girdi özellik haritasını, μ_B ve σ_B^2 sırasıyla özellik haritası ortalamasını ve varyansını temsil etmektedir, ε ise sıfıra bölünmeyi engellemek için kullanılan küçük bir sayıdır.

$$N_l^k = \frac{F_l^k - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \quad (3.7)$$


3.3.7.5. Yukarı Örneklem (Upsampling)

Yukarı örneklem işlemi görüntünün boyutunu arttırmak için kullanılmaktadır. Ters havuzlama ve ters evrişim olmak üzere bu işlemi gerçekleştiren iki yöntem vardır.

Evrişimli bir sinir ağında havuzlama işlemin gerçekleştirimi sonucunda görüntüdeki uzamsal bilgiler kaybolmaktadır. Bu sorunun çözmek için havuzlama işlemi gerçekleştirilirken maksimum değerlerin konumları kaydedilir. Bu konumlar kullanılarak ters havuzlama işlemi gerçekleştirilir ve orijinal görüntüye yakın bir görüntü elde edilir. Ters havuzlama işlemi sonucunda görüntünün boyutu artırılır. Fakat seyrek bir özellik haritası elde edilmektedir. Evrişim benzeri işlemlerle ters evrişim katmanında elde edilen seyrek özellik haritaları yoğunlaştırılmaktadır. Havuzlama katmanlarında girdiler üzerine uygulanan filtrelerin çıkışları tek bir çıktıya bağlanırken ters evrişim katmanında filtre birden fazla çıktı ile ilişkilendirilmektedir (Noh ve ark., 2015). Şekil 3.12’de maksimum ters havuzlama ve Şekil 3.13’de ters evrişim işlemi verilmiştir.



Şekil 3.12. Ters havuzlama yöntemi ile yukarı örnekleme (Mishra, 2020)




Şekil 3.13. Ters evrişim yöntemi ile yukarı örnekleme (Mishra, 2020)

3.3.7.6. Tam Bağlı (Fully Connected) Katman

Tam bağlı katmanlar klasik bir yapay sinir ağına benzemektedir. Tam bağlı katmanlar evrişim ve havuzlama katmanından çıkarılan özellik vektörünü alır, global olarak analiz eder ve sınıflandırma için doğrusal olmayan bir kombinasyonunu yapar. Global bir analiz için bu katmandaki tüm nöronlar kendinden önceki ve sonraki tüm

nöronlara bağlanmaktadır. Bu katmandaki en büyük dezavantaj büyük boyutlu ve karmaşık veriler için hesaplanması gereken çok fazla parametre olmasıdır. Hesaplama maliyetini azaltmak için bırakma tekniği kullanılarak rastgele düğüm ve bağlantılar kaldırılmaktadır (Albawi ve ark., 2017, Khan ve ark., 2020). Şekil 3.14’de tam bağlı katman mimarisi verilmiştir.



Şekil 3.14. Tam bağlı katman (Amidi ve Amidi, 2018)

3.3.7.7.Geri Yayılım (Backpropagation) Algoritması

Geri yayılım algoritması, ileri besleme ve geri besleme aşamalarından oluşmaktadır. İleri besleme aşamasında ağın çıktısı elde edilir. Geri besleme aşamasında ise ağın çıktısı sonucu oluşan hatanın geriye yayılması ile her bir katmandaki ağırlıklar güncellenir ve bu sayede hata oranı azaltılmaktadır. Denklem 3.8’de her bir nöronun çıkış değeri ve denklem 3.9’da çıktı katmanındaki toplam hata değeri hesaplanır. Denklem 3.10’da katmanlardaki ağırlıkların değişim miktarı bulunur. Bu değişim miktarına göre ağırlıkların güncellenmesi denklem 3.11’de verilmiştir (Ayşe ve Berberler, 2017, Keleşoğlu, 2006).

$$y_i = f(\sum_{i=1}^n w_i x_i + b) \quad (3.8)$$

$$E = \frac{1}{2} \sum (d_i - y_i)^2 \quad (3.9)$$

$$\Delta w_i = \eta \cdot \delta_i \cdot y_i \quad (3.10)$$

$$w_i^{yeni} = w_i^{eski} + \Delta w_i \quad (3.11)$$

- w_i : Girdinin ağırlığı
- x_i : Girdi değeri
- b : Bias değeri
- f : Aktivasyon fonksiyonu
- n : Girdi sayısı
- y_i : Çıkış değeri
- d_i : Beklenen değer
- E : Toplam hata değeri
- η : Öğrenme oranı
- δ_i : Yerel gradyan
- Δw_i : Ağırlık değişim miktarı

3.3.7.8.Sınıflandırma (Classification) Katmanı

Bu katman tam bağlantı katmanından sonra gelen sınıflandırma yapabilmek için kullanılan ağın son katmanıdır. Kaç farklı nesne sınıflandırılmak isteniliyorsa bu katmanın çıkışı nesne sayısına eşitlenir. Bu katmanda farklı sınıflandırıcılar olmasına rağmen yüksek başarısından dolayı en çok tercih edilen softmax sınıflandırıcıdır (Özkan ve Ülker, 2017).

Softmax sınıflandırıcı çoklu sınıflandırma yapan modellerde kullanılmaktadır. Denklem 3.12’de softmax fonksiyonunun formülü verilmiştir, $x_1, x_2 \dots x_N$ softmax katmanını giriş değerlerini ve $f(x_i)$ çıktı değerini temsil eder (Wang Meiqi ve ark., 2018). Softmax fonksiyonunun çıktı değerleri $[0,1]$ aralığında ve toplamaları 1’e eşit olacak şekilde tasarlanmıştır. 1’e en yakın çıktı üreten sınıf hedef sınıf olarak işaretlenmektedir (Aldhahab ve ark., 2020, Özkan ve Ülker, 2017).

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}} \quad (i = 1, 2, \dots, N) \quad (3.12)$$


3.4.Semantik (Semantic) Segmentasyon

Son yıllarda otonom sürüş, insan-makine etkileşimi, hesaplamalı fotoğrafçılık görüntü arama motorları ve artırılmış gerçeklik gibi geliştirilen akıllı uygulamaların artmasıyla beraber sahnelerin doğru bir şekilde anlaşılması bilgisayarlı görme alanında

önemli bir sorun haline gelmiştir. Bu problemin çözülmesinde klasik bilgisayarlı görme ve makine öğrenmesi yöntemlerin popüler olmasına rağmen derin öğrenme yöntemi olan evrişimli sinir ağlarının bu alandaki başarısı diğer yöntemleri geride bırakmaktadır (Garcia-Garcia ve ark., 2017).

Semantik segmentasyon, görüntüdeki her pikselin bir sınıf etiketi ile ilişkilendirilmesi işlemidir. CNN ile semantik segmentasyon gerçekleştirebilmek için ağız eğitiminde hem görüntüler hem de bu görüntülerin piksellerine karşılık gelen sınıf etiketli görüntüler gereklidir. Evrişim katmanları sayesinde CNN, girdi ve çıktı arasında önemli miktarda doğrusal olmayan eşleşme sağlar (Karayeğen, 2021).

Semantik segmentasyon işleminin gerçekleştirilmesinde kullanılan mimari genel olarak bir kodlayıcı (encoder) ve kod çözücü (decoder) mimarisinden oluşmaktadır. Şekil 3.15’de kodlayıcı ve kod çözücü mimarisi verilmiştir. Bu mimarinin kodlayıcı ağı, evrişim ve havuzlama katmanları içermektedir. Bu katmanlar sayesinde girdi görüntüsü alt örneklenerek özellik vektörü çıkarılmaktadır. Kod çözücü ağına ise yukarı örnekleme için ters evrişim ve evrişim katmanları bulunmaktadır. Kod çözücü ağ kendisine gelen özellik vektörünü alır ve giriş görüntüsü boyutunda semantik segmentasyon haritaları üretir (Elmacı, 2018). Kodlayıcı ve kod çözücü yapılarını içeren farklı mimariler mevcuttur.




Şekil 3.15. Kodlayıcı- Kod Çözücü mimarisi (Elmacı, 2018)

3.4.1. Tam Evrişimli Sinir Ağı (Fully Convolutional Network)

Klasik evrişimli sinir ağlarında çıkarılan özneteliklerin tam bağlantılı katmanlara girdi olarak verilmesi sonucunda girdi görüntülerin uzamsal bilgileri kaybolmaktadır. Görüntü segmentasyonu için uzamsal bilgilerin önemli olmasından dolayı klasik evrişimli ağlar yetersiz kalmaktadır. Bu sorunun üstesinden gelmek için tam evrişimli sinir ağları önerilmiştir (Long ve ark., 2015). FCN, klasik bir evrişimli sinir ağından (CNN) üretilmiş bir mimaridir. Klasik CNN ağlarında sabit boyutlu girdiler kullanılarak tahmin işlemi gerçekleştirilir. Bu kısıtlama ağların tam bağlantılı katmanlara sahip olmasından kaynaklanmaktadır. FCN mimarileri yalnızca evrişim ve havuzlama katmanlarından oluşmaktadır. Klasik CNN ağların aksine FCN, tam bağlantılı katmanların kaldırılmasıyla rastgele boyutlu görüntüyü alır ve aynı boyutta bölümlere ayrılmış bir görüntü üretir. Üretilen çıktının boyutu ağa verilen girdilerin boyutuna bağlıdır (Le, 2021).

Tamamen evrişimli ağlar görüntünün özelliklerini çıkarmak için önce evrişimli sinir ağlarını kullanır ve ardından evrişimli sinir ağlarının tam bağlantılı katmanı 1x1 evrişim katmanları ile yer değiştirilir. Bu sayede çıktı istenilen sınıf sayısına eşitlenir. Fakat havuzlama işlemi gerçekleştirildiği için çıktı görüntünün boyutu girdi görüntünün boyutundan daha küçük çıkmaktadır. Girdi ve çıktı boyutunu eşitlemek için çıktı görüntüsü üzerinde yukarı örnekleme gerçekleştirilir. Bu işlem ters evrişim, yukarı evrişim ve yer değiştirmiş evrişim olarak da adlandırılır. FCN mimarisinde üst örnekleme için ters evrişim kullanılır. FCN8, FCN16 ve FCN32 olmak üzere 3 FCN sürümü vardır. FCN mimarisinde girdinin evrişim ve havuzlama katmanlarından geçirilerek aşağı örneklenmesi sonucunda düşük çözünürlüklü öznetelik haritaları üretilmektedir. Bu problemin üstesinden gelmek için FCN8 ve FCN16 mimarilerinde atlama bağlantıları kullanılmaktadır. Atlama bağlantıları sayesinde yüksek katman bilgileri ile düşük katman bilgileri birleştirilerek piksel tahmin sonucunun iyileştirilmesi sağlanmaktadır (Long ve ark., 2015, Sorg, 2018, Tsang, 2018). Şekil 3.16'da tam evrişimli sinir ağı mimarisi verilmiştir.





Şekil 3.16. FCN mimarisi (Long ve ark., 2015)

3.4.2. U-Net

Ronneberger ve ark. (2015) tarafından yapılan çalışmada FCN mimarisinin popüler bir varyasyonu olan U-Net mimarisi geliştirilmiştir. Bu mimari biyomedikal görüntüler için tasarlanmıştır ve az sayıda görüntü ile yüksek doğruluklar elde etmektedir (Sorg, 2018).

FCN mimarisinde olduğu gibi tamamen evrişimli katmanlardan oluşur ve tam bağlantı katmanı içermemektedir. U-Net mimarisi kodlayıcı ve kod çözücü yapısına sahiptir. Kodlayıcı kısmı tipik bir evrişimli sinir ağı modelinden oluşmaktadır. Art arda iki tane 3x3 boyutuna sahip evrişim katmanından oluşur ve her bir evrişim katmanından sonra ReLU aktivasyon fonksiyonu uygulanmaktadır. Daha sonra adım sayısı 2 alınarak 2x2 boyutlu maksimum havuzlama işlemi ile alt örnekleme yapılır. Her aşağı örnekleme adımı ile görüntünün boyutu azalır ve özellik kanal sayısı iki katına çıkmaktadır. Kod çözücü kısmında ise 2x2 boyutuna sahip yukarı evrişim işlemi ile özellik kanal sayısı yarıya inmektedir. Ağın kodlayıcı kısmında çıkarılan özellik haritaları kod çözücü kısmına karşılık gelen özellik haritaları ile birleştirilir. Birleştirilen bu özellik haritalarına 3x3 boyutunda art arda iki adet evrişim işlemi uygulanmaktadır. Her bir evrişim işleminden sonra ReLU aktivasyon fonksiyonu uygulanmaktadır. Son katmanda ise görüntüler 1x1 evrişim işlemi yapılarak istenilen sınıf sayısına eşitlenir ve segmentasyon vektörü çıkarılır. Toplamda U-Net mimarisi 23 evrişimli katmana sahiptir (Ronneberger ve ark., 2015). Şekil 3.17’de U-Net mimarisinin genel yapısı verilmiştir.





Şekil 3.18: Füzyon yöntemleri (Zhang ve ark., 2021)

3.6.Önerilen Model

Bu çalışmada çoklu organ segmentasyonu için farklı renk uzayına sahip BT görüntüleri ile erken füzyon yöntemini içeren iki aşamadan oluşan 3D U-Net tabanlı bir model önerilmiştir.

Roth ve ark. (2018c) tarafından yapılan çalışmada segmentasyon gerçekleştirebilmek için çok ölçekli 3D FCN yaklaşımı önerilmiştir. Çözünürlüğü düşürülmüş girdilerinden elde edilen 3D FCN tahminleri ile yüksek çözünürlüklü bir 3D FCN'nin girdileriyle birleştirilir. Bu yaklaşım ile segmentasyon başarısı artırılmıştır. Bu çalışmadan yola çıkılarak bu tez çalışmasında önerilen modelin genel yapısında Şekil 3.19'da görüldüğü gibi ilk aşamada HSV formatına dönüştürülmüş görüntüler önerilen 3D U-Net modeli kullanılarak eğitilir ve son aşamada 1x1x1 evrişim işleminden geçirilerek 13 tane organ ve 1 tane organ olmadığını belirten 14 kanallı bir çıktı elde edilir. Renk uzayı seçiminde ise Ghosh ve ark. (2018) tarafından yapılan çalışma etkili olmuştur. Bu çalışmada endoskopi görüntüleri üzerinde kanama bölgesini tespiti için önerilen mimari, farklı renk uzaylarında test edilmektedir ve en iyi performansın HSV renk uzayında elde edildiği görülmektedir. Ghosh ve ark. (2018)'nın renk uzayı çalışması sonuçları Çizelge 3.2'de verilmiştir. Bu bilgiler ışığında veri setinde kullanılan gri BT görüntüler HSV formatına dönüştürülmektedir. İkinci aşamada ise ilk aşamada elde edilen çıktı görüntüsü, orijinal görüntü ile birleştirilir ve toplamda 15 kanallı bir görüntü elde edilir. Bu birleştirme işlemi erken füzyon olarak adlandırılmaktadır. Bu sayede segmentasyonu yapılacak organların özelliklerinin daha

belirgin hale getirilmesi amaçlanmıştır. Birleştirilen bu görüntüler önerilen 3D U-Net mimarisi ile eğitilir ve tahmin segmentasyon sonuçları elde edilir.


Bu çalışmada kullanılan 3D U-Net modeli segmentasyon sonucunu iyileştirmek için geliştirilmiştir. Önerilen 3D U-Net modeli Şekil 3.20’de verilmiştir. Bu model kodlayıcı ve kod çözü kısımlarından oluşur. İlk aşamada özelliği çıkarılacak olan görüntü kodlayıcı kısmında ağa verilir. Kodlayıcı kısmında ağa alınan görüntüler üzerinde tüm seviyelerde $3 \times 3 \times 3$ boyutunda iki tane evrişim işlemi uygulanmaktadır. Her evrişim işlemini Batch Normalization ve ReLU aktivasyon fonksiyonu takip eder. Görüntülerdeki organların boyutlarının ve şeklinin farklı olması otomatik segmentasyon işlemini karmaşık bir görev haline getirmektedir. Özellikle küçük boyutlu organların tahmininde yüksek başarılar elde edilmesi oldukça zordur ve daha iyi sonuçlar elde edebilmek için modelin farklı bileşenleri öğrenmesi gerekmektedir. 3D U-Net mimarisinde evrişim katmanlarında görüntülerdeki özelliklerin öğrenme işlemi gerçekleşmektedir. Fakat havuzlama katmanı sabit bir işlemdir ve bu katmanda öğrenme işlemi gerçekleştirilmez. Modeldeki tüm havuzlama katmanlarının evrişim katmanları ile değiştirilmesi eğitim sırasında küçük boyutlu nesnelerin özelliklerinin kaybolmasını engelleyebilir fakat havuzlama katmanlarının kaldırılması modelin görüntülerdeki özellikleri ezberlemesine neden olabilir (Springenberg ve ark., 2014). Bu çalışmada çoklu organ segmentasyonunda küçük organların segmentasyonunu iyileştirmek için hem havuzlama katmanının hem de evrişim katmanının avantajlarından yararlanarak her ikisinin kullanıldığı hibrit bir yapı tasarlanmıştır. Bir seviyeden diğer bir seviyeye geçiş yaparken elde edilen özellik haritasına ayrı ayrı maksimum havuzlama ve adım sayısı 2 olan $2 \times 2 \times 2$ ’lik bir evrişim işlemi uygulanmıştır. Bu işlemler sonucunda boyutu yarıya düşen iki çıktı elde edilmiştir. Maksimum havuzlama katmanının kullanılması ile modelin görüntülerdeki özellikleri ezberlemesini ve evrişim işleminin uygulanması ile de görüntülerdeki önemli bilgilerin kaybının engellenmesi amaçlanmıştır. Bu iki katmanın çıktıları birleştirilerek bir sonraki katmana girdi olarak verilmektedir. Kod çözme kısmında ise kodlayıcı kısmından alınan çıktı giriş görüntüsünün boyutuna ulaşılan kadar 2 adımlık $2 \times 2 \times 2$ boyutunda ters evrişim ile yukarı örneklenir. Her bir ters evrişiminden sonra ReLU aktivasyon fonksiyonu uygulanmaktadır. Her seviyede bulunan öznetelik haritası kendisine karşılık gelen kodlayıcı kısmından elde edilen öznetelik haritası ile birleştirilir. Daha sonra bu birleştirilen öz niteliklere $3 \times 3 \times 3$ ’lük iki tane evrişim uygulanır. Son katmanda $1 \times 1 \times 1$ evrişim işlemi sonucu $128 \times 128 \times 48$

boyutunda 14 kanallı bir öznitelik haritası elde edilir ve softmax aktivasyon fonksiyonundan geçirilerek üç boyutlu çoklu organ segmentasyonu gerçekleştirilir.


Önerilen modelde kayıp fonksiyonu olarak ortalama Dice kayıp fonksiyonu kullanılmıştır (Wang Lu ve ark., 2020a). Her iki aşamada elde edilen çıktıların Dice kaybı hesaplanır ve ortalaması alınır.

Çizelge 3.2. Farklı renk uzaylarının performanslarının karşılaştırılması (Ghosh ve ark., 2018)

	Ortalama IoU	Ağırlıklı IoU
RGB	0.725	0.892
HSV	0.756	0.906
LAB	0.632	0.90
YIQ	0.714	0.881



Şekil 3.19. Önerilen modelin genel gösterimi




Şekil 3.20. Önerilen 3D U-Net model gösterimi

3.7. Değerlendirme Ölçütü

Bu çalışmada segmentasyon performansını değerlendirmek için Dice benzerlik katsayısı (DSC) kullanılmaktadır. Bu değerlendirme metriği iki görüntü arasında eşleşen piksellerin sayısını ölçmektedir. Şekil 3.21’de Dice benzerlik katsayısının grafiksel gösterimi verilmiştir. Bu katsayının değeri sıfırdan bire kadar değişir ve Dice kayıp oranı $1 - DC$ olarak ifade edilir. İkili sınıflandırması için Dice benzerlik katsayısı formülü denklem 3.13’de verilmiştir. Burada Y örneğin gerçek etiketini ve $\hat{Y}$ tahmin

değerlerini göstermektedir. $\hat{Y}$ ve Y 'deki öğeleri sırasıyla $\hat{y}_{ij}$ ve y_{ij} temsil eder. Satır ve sütun sayıları n ve m değişkenleri ile ifade edilir (Wang Lu ve ark., 2020a).



Şekil 3.21. Dice benzerlik katsayısının grafiksel gösterimi (Al-Rahamneh ve Ryalat, 2021)

$$DC = \frac{2|\hat{Y} \cap Y|}{|\hat{Y}| + |Y|} \quad (3.13)$$

$$\frac{2 \sum_{i=1}^n \sum_{j=1}^m \hat{y}_{ij} \cdot y_{ij}}{\sum_{i=1}^n \sum_{j=1}^m \hat{y}_{ij} + \sum_{i=1}^n \sum_{j=1}^m y_{ij}}$$

Bu çalışmada çok sınıflı segmentasyon gerçekleştirilmektedir. Bu yüzden her bir organ için Dice benzerlik katsayısı hesaplanmaktadır. Tüm organlar için hesaplanan Dice benzerlik katsayıların toplamının ortalaması alınarak ortalama Dice benzerlik skoru elde edilir. Denklem 3.14'de Ortalama Dice benzerlik katsayısı (ADC) formülü verilmektedir. K sembolü organ sayısını temsil etmektedir.

$$ADC = \frac{1}{K} \sum_{j=1}^K \frac{2 \sum_{i=1}^n \sum_{k=1}^m \hat{y}_{ij,k} \cdot y_{ij,k}}{\sum_{i=1}^n \sum_{k=1}^m \hat{y}_{ij,k} + \sum_{i=1}^n \sum_{k=1}^m y_{ij,k}} \quad (3.14)$$

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışmada otomatik çoklu organ segmentasyonunun gerçekleştiriminde Python (3.6) programlama dili kullanılmıştır. 3D BT görüntülerini okumak ve üzerinde işlem yapmak için Simple ITK kütüphanesi, sayısal işlemler için Numpy kütüphanesi ve derin öğrenme modellerini çalıştırmak için Pytorch kütüphanesi kullanılmıştır. Son olarak modellerin sonuçlarını görselleştirmek için Matplotlib kütüphanesi kullanılmıştır. Derin öğrenme modeli ise 16 GB'lık belleğe sahip NVidia GeForce RTX 2070 üzerinde çalıştırılmıştır. Değerlendirme ölçütü olarak Dice skoru kullanılmıştır. Tüm örnekler eğitim ve test için %70-%30 olarak ayrılmıştır.

4.1.Araştırma Sonuçları

Bu çalışmada gerçekleştirilen çoklu organ segmentasyon işleminde doğru tahmin oranını arttırmak için önerilen modelin eğitimi aşamasında kullanılan parametrelerin optimizasyonu gerçekleştirilmiştir. Her bir parametre ile önerilen model 300 adım çalıştırılmıştır ve optimum sonucu veren parametreler bulunmuştur.

Önerilen modelde ilk olarak öğrenme oranı $1e-3$, batch size 2 ve aktivasyon fonksiyonu ReLU olarak rastgele belirlenmiştir. Önerilen model belirlenen bu parametreler ve Adagrad, Adamax ve Adam optimizasyon algoritmaları ile ayrı ayrı çalıştırılmıştır. Bu sayede önerilen modelde optimum sonuç veren optimizasyon algoritması belirlenmiştir. Adagrad, Adamax ve Adam optimizasyon algoritmasının Dice sokuruna etkisi Çizelge 4.1' de verilmiştir.

Çizelge 4.1. Optimizasyon algoritmalarının önerilen model üzerindeki etkisi

Organ Adı	Adagrad	Adamax	Adam
Dalak	0.835	0.896	0.929
Sağ böbrek	0.876	0.908	0.918
Sol böbrek	0.814	0.90	0.920
Safra kesesi	0.338	0.430	0.704
Yemek borusu	0.648	0.681	0.645
Karaciğer	0.917	0.949	0.947
Mide	0.688	0.704	0.766
Aort	0.773	0.817	0.887
Inferior vena kava	0.709	0.748	0.798
Portal ven ve splenik ven	0.564	0.619	0.638
Pankreas	0.582	0.649	0.663
Sağ böbrek üstü bezi	0.453	0.49	0.546
Sol böbrek üstü bezi	0.00	0.492	0.517
Ortalama	0.63	0.714	0.76

Çizelge 4.1’de verilen sonuçlar karşılaştırıldığında Adam optimizasyon algoritması ile 11 organda en yüksek segmentasyon sonucu elde edilmiştir. Ayrıca tüm organların segmentasyon ortalamasında da en yüksek sonucu verdiği görülmüştür. Optimum sonucu elde edebilmek için önerilen modelin eğitiminde Adam optimizasyon algoritması kullanılmıştır. İkinci aşamada farklı aktivasyon fonksiyonlarının önerilen model üzerindeki etkisini görmek için öğrenme oranı $1e-3$, batch size 2 ve optimizasyon algoritması olarak Adam seçilmiştir. Bu parametreler ile beraber PReLU ve ReLU aktivasyon fonksiyonları ayrı ayrı çalıştırılmıştır ve bu iki aktivasyon fonksiyonunun çoklu organ segmentasyonunda Dice skoru üzerindeki etkisi Çizelge 4.2’de verilmiştir.

Çizelge 4.2. Aktivasyon fonksiyonlarının önerilen model üzerindeki etkisi

Organ Adı	PReLU	ReLU
Dalak	0.915	0.929
Sağ böbrek	0.928	0.918
Sol böbrek	0.927	0.920
Safra kesesi	0.340	0.704
Yemek borusu	0.662	0.645
Karaciğer	0.949	0.947
Mide	0.718	0.766
Aort	0.824	0.887
Inferior vena kava	0.779	0.798
Portal ven ve splenik ven	0.621	0.638
Pankreas	0.641	0.663
Sağ böbrek üstü bezi	0.5307	0.546
Sol böbrek üstü bezi	0.479	0.517
Ortalama	0.716	0.76

Çizelge 4.2’de verilen sonuçlar karşılaştırıldığında her iki aktivasyon fonksiyonunda sonuçların birbirine yakın olduğu gözlenmektedir. PReLU aktivasyon fonksiyonunda sağ böbrek, sol böbrek, karaciğer, mide, inferior vena kava ve böbrek üstü bezlerinde çok az bir farkla ReLU aktivasyon fonksiyonuna göre daha iyi sonuç elde edilmiştir. Diğer organlarda ve tüm organların segmentasyon ortalamasında ReLU aktivasyon fonksiyonunun daha yüksek sonuç verdiği görülmektedir. Ortalama segmentasyonda daha yüksek başarı elde etmesi ve PReLU aktivasyon fonksiyonuna göre hesaplama maliyetinin daha düşük olması sebebiyle önerilen modelin eğitiminde kullanılması için aktivasyon fonksiyonu olarak ReLU seçilmiştir. Öğrenme oranının önerilen model üzerindeki etkisini tespit edebilmek için batch size 2, Adam optimizasyon algoritması ve ReLU aktivasyon fonksiyonu kullanılmıştır. Önerilen modelde öğrenme oranları $1e-3$, $1e-4$ ve $1e-5$ olarak sırayla çalıştırılmıştır ve Çizelge 4.3’de Dice skor sonuçları verilmiştir.

Çizelge 4.3. Öğrenme oranlarının önerilen model üzerindeki etkisi

Organ Adı	1e-3	1e-4	1e-5
Dalak	0.929	0.897	0.78
Sağ böbrek	0.918	0.91	0.758
Sol böbrek	0.920	0.89	0.737
Safra kesesi	0.704	0.413	0.222
Yemek borusu	0.645	0.00	0.455
Karaciğer	0.947	0.935	0.845
Mide	0.766	0.712	0.554
Aort	0.887	0.813	0.71
Inferior vena kava	0.798	0.727	0.525
Portal ven ve splenik ven	0.638	0.574	0.244
Pankreas	0.663	0.601	0.353
Sağ böbrek üstü bezi	0.546	0.480	0.00
Sol böbrek üstü bezi	0.517	0.477	0.00
Ortalama	0.76	0.48	0.476

Çizelge 4.3’de verilen sonuçlar karşılaştırıldığında 1e-4 ve 1e-5 öğrenme oranlarının hızının düşük olması nedeniyle önerilen modelin 300 adım sayısında çalıştırılması eğitim için yeterli gelmemiştir ve modelin performansı düşmüştür. Bu sebepten dolayı 1e-3 öğrenme oranı seçiminde önerilen modelin sol böbrek üstü bezi haricinde diğer tüm organlarda ve tüm organların segmentasyon ortalamasında en yüksek sonucu verdiği gözlemlenmiştir. Önerilen modelde parametre optimizasyonu sonucunda öğrenme oranı 1e-3, aktivasyon fonksiyonu ReLU, optimizasyon algoritması Adam ve batch size 2 olarak belirlenmiştir. Belirlenen optimum parametreler ile önerilen model farklı adım sayılarında çalıştırılmıştır ve sonuçları Çizelge 4.4’de verilmiştir. Verilen sonuçlar incelendiğinde 100, 200 ve 300 adım sayısında segmentasyon doğruluk oranının arttığı görülmektedir. 300 adım sayısından sonra doğruluk oranı düşüşe geçmektedir.

Çizelge 4.4. Adım sayısının önerilen model üzerindeki etkisi

Organ Adı	Adım Sayısı				
	100	200	300	400	500
Dalak	0.928	0.926	0.929	0.919	0.927
Sağ böbrek	0.911	0.919	0.918	0.921	0.913
Sol böbrek	0.906	0.908	0.920	0.906	0.907
Safra kesesi	0.652	0.621	0.704	0.715	0.652
Yemek borusu	0.605	0.663	0.645	0.664	0.667
Karaciğer	0.935	0.942	0.947	0.95	0.949
Mide	0.712	0.776	0.766	0.756	0.804
Aort	0.842	0.856	0.887	0.884	0.874
Inferior vena kava	0.744	0.779	0.798	0.793	0.796
Portal ven ve splenik ven	0.639	0.636	0.638	0.643	0.627
Pankreas	0.644	0.665	0.663	0.641	0.646
Sağ böbrek üstü bezi	0.455	0.558	0.546	0.535	0.545
Sol böbrek üstü bezi	0.526	0.505	0.517	0.538	0.541
Ortalama	0.731	0.75	0.76	0.759	0.757

Son olarak veri arttırma işlemi gerçekleştirilmiştir ve optimum sonuç veren parametreler kullanılarak önerilen model 300 adım sayısında eğitilmiştir. Çizelge 4.5’ de veri artırma işlemi gerçekleştirilmeden önce ve gerçekleştirildikten sonra Dice skor sonuçları ve elde edilen bu sonuçlarda her bir organın piksel değerlerinin ne kadarını doğru tahmin ettiği bilgisini veren karmaşıklık matrisi Şekil 4.1’de verilmiştir. Çizelge 4.6’da ise artırılmış verilerin eğitim ve test sonuçları verilmiştir. Şekil 4.2’de BT görüntüleri ve bu görüntülerden elde edilen gerçek ve tahmin maske görüntüleri, ayrıca bu görüntüler üzerinde farklı renkte işaretlenen her bir organın hangi renge karşılık geldiği bilgisi verilmiştir. Şekil 4.3 ve 4.4’de sırasıyla BT görüntüsündeki çoklu organların gerçek ve tahmin segmentasyon maskelerinin 3D gösterimi verilmiştir.

Çizelge 4.5. Veri artırma gerçekleştirilmeden önceki ve sonraki sonuçlar

Organ Adı	Veri Artırma	
	Yok	Var
Dalak	0.929	0.94
Sağ böbrek	0.918	0.934
Sol böbrek	0.92	0.937
Safra kesesi	0.704	0.698
Yemek borusu	0.645	0.703
Karaciğer	0.947	0.951
Mide	0.766	0.847
Aort	0.887	0.873
Inferior vena kava	0.798	0.816
Portal ven ve splenik ven	0.638	0.698
Pankreas	0.663	0.774
Sağ böbrek üstü bezi	0.546	0.611
Sol böbrek üstü bezi	0.517	0.558
Ortalama	0.76	0.796

Çizelge 4.6. Artırılmış verilerin eğitim ve test sonuçları


Organ Adı	Artırılmış Veri	
	Eğitim	Test
Dalak	0.951	0.94
Sağ böbrek	0.937	0.934
Sol böbrek	0.939	0.937
Safra kesesi	0.887	0.698
Yemek borusu	0.836	0.703
Karaciğer	0.956	0.951
Mide	0.917	0.847
Aort	0.906	0.873
Inferior vena kava	0.879	0.816
Portal ven ve splenik ven	0.811	0.698
Pankreas	0.841	0.774
Sağ böbrek üstü bezi	0.851	0.611
Sol böbrek üstü bezi	0.834	0.558
Ortalama	0.888	0.796

Karmaşıklık Matrisi


0	9100532.0	1962.0	2640.0	1807.0	429.0	985.0	15745.0	15289.0	1873.0	3220.0	1631.0	3770.0	220.0	493.0
1	3491.0	53875.0	0.0	7.0	0.0	0.0	17.0	129.0	0.0	5.0	5.0	29.0	0.0	0.0
2	1927.0	0.0	35388.0	0.0	0.0	0.0	20.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3	2647.0	0.0	0.0	35941.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4	488.0	0.0	0.0	0.0	2591.0	0.0	425.0	22.0	0.0	0.0	0.0	0.0	0.0	0.0
5	998.0	0.0	0.0	0.0	0.0	2921.0	37.0	142.0	16.0	9.0	0.0	0.0	0.0	0.0
6	10650.0	0.0	15.0	0.0	63.0	5.0	344297.0	2429.0	0.0	1590.0	313.0	2.0	62.0	0.0
7	8605.0	573.0	7.0	0.0	0.0	228.0	259.0	84703.0	0.0	0.0	0.0	135.0	0.0	15.0
8	3561.0	0.0	0.0	0.0	0.0	18.0	0.0	0.0	17712.0	0.0	0.0	0.0	0.0	0.0
9	1533.0	3.0	2.0	0.0	0.0	0.0	803.0	0.0	1.0	17469.0	0.0	0.0	12.0	0.0
10	572.0	18.0	0.0	0.0	1.0	0.0	1204.0	11.0	0.0	0.0	5201.0	331.0	0.0	1.0
11	2996.0	11.0	0.0	0.0	4.0	0.0	80.0	349.0	0.0	49.0	283.0	14345.0	0.0	0.0
12	255.0	0.0	0.0	0.0	0.0	0.0	37.0	1.0	0.0	15.0	0.0	0.0	506.0	0.0
13	365.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	2.0	0.0	586.0
	0	1	2	3	4	5	6	7	8	9	10	11	12	13

Tahmin Piksel Etiketleri


Şekil 4.1. Çoklu organ segmentasyonu için karmaşıklık matrisi



Şekil 4.2. BT görüntülerinden çıkarılan gerçek ve tahmin edilen maske görüntüleri



Şekil 4.3. Gerçek segmentasyon maskesi 3D BT görüntüsü



Şekil 4.4. Tahmin segmentasyon maskesi 3D BT görüntüsü

Çizelge 4.7’de Model 1’in performansı ile önerilen modelin performansı karşılaştırılmıştır. Model 1 farklı renk uzaylarının kullanıldığı füzyon bir yaklaşım içermemektedir. Bu model gri görüntüleri girdi olarak alan tek aşamalı bir 3D U-Net yapısına sahiptir. Bu 3D U-Net yapısının önerilen modelden farkı kodlayıcı ağında seviyeler arası geçiş yapılırken sadece maksimum havuzlama yöntemi kullanılmasıdır. Her iki model de bu çalışmada kullanılan veri seti üzerinde eğitilmiştir ve aynı şartlar altında veri artırma işlemi gerçekleştirilerek 300 adım çalıştırılmıştır.

Çizelge 4.7. Model 1 ve önerilen modelin sonuçlarının karşılaştırılması

Organ Adı	Model 1	Önerilen Model
Dalak	0.90	0.94
Sağ böbrek	0.90	0.934
Sol böbrek	0.891	0.937
Safra kesesi	0.66	0.698
Yemek borusu	0.661	0.703
Karaciğer	0.926	0.951
Mide	0.765	0.847
Aort	0.832	0.873
Inferior vena kava	0.785	0.816
Portal ven ve splenik ven	0.632	0.698
Pankreas	0.626	0.774
Sağ böbrek üstü bezi	0.60	0.611
Sol böbrek üstü bezi	0.493	0.558
Ortalama	0.745	0.796

Çizelge 4.8’de önerilen model Larsson ve ark. (2018) tarafından yapılan çalışmada verilen sonuçlarla karşılaştırılmıştır. Bu çalışmada verilen CNN ve FCN mimarisi Larsson ve ark. (2018) tarafından önerilen mimarilerdir. IMI ve CLS modelleri MICCAI 2015 yarışmasında “Multi-Atlas Abdomen Labeling Challenge” yarışmasında en iyi sonucu veren iki modeldir. Önerilen model 9 organda ve tüm organların ortalamasında diğer modellere göre daha yüksek sonuç vermiştir. Tüm organların ortalamasında en düşük sonuç veren CLS modelidir.

Çizelge 4.8. Önerilen modelimizin sonuçlarının diğer modellerin sonuçları ile karşılaştırılması

Organ Adı	Önerilen Model	MICCAI 2015		(Larsson ve ark., 2018)	
		IMI	CLS	CNN	FCN
Dalak	0.94	0.919	0.911	0.930	0.936
Sağ böbrek	0.934	0.901	0.893	0.866	0.897
Sol böbrek	0.937	0.914	0.901	0.911	0.911
Safra kesesi	0.698	0.604	0.375	0.624	0.613
Yemek borusu	0.703	0.692	0.607	0.662	0.588
Karaciğer	0.951	0.948	0.940	0.946	0.949
Mide	0.847	0.805	0.704	0.775	0.764
Aort	0.873	0.857	0.811	0.860	0.870
Inferior vena kava	0.816	0.828	0.760	0.776	0.758
Portal ven ve splenik ven	0.698	0.754	0.649	0.567	0.715
Pankreas	0.774	0.740	0.643	0.602	0.646
Sağ böbrek üstü bezi	0.611	0.615	0.557	0.631	0.630
Sol böbrek üstü bezi	0.558	0.623	0.582	0.583	0.631
Ortalama	0.796	0.790	0.723	0.75	0.767

Son olarak önerilen modelin doğruluğunun tespit edilebilmesi için rastgele örnekler üzerinde üst üste 5 kez çalıştırılmış ve ortalaması alınmıştır. Önerilen modelin farklı veri kümelerindeki test sonuçları Çizelge 4.9’da verilmiştir.

Çizelge 4.9. Önerilen modelin farklı alt kümeler üzerinde değerlendirilmesi

Organ Adı	Alt küme 1	Alt küme 2	Alt Küme 3	Alt Küme 4	Alt Küme 5	Ortalama
Dalak	0.94	0.941	0.937	0.943	0.891	0.9304
Sağ böbrek	0.934	0.908	0.92	0.932	0.938	0.9264
Sol böbrek	0.937	0.919	0.849	0.93	0.911	0.9092
Safra kesesi	0.698	0.566	0.85	0.736	0.648	0.6996
Yemek borusu	0.703	0.724	0.72	0.713	0.744	0.7208
Karaciğer	0.951	0.942	0.945	0.952	0.943	0.9466
Mide	0.847	0.843	0.81	0.852	0.785	0.8274
Aort	0.873	0.903	0.889	0.878	0.90	0.8886
Inferior vena kava	0.816	0.85	0.712	0.824	0.829	0.8062
Portal ven ve splenik ven	0.698	0.674	0.604	0.704	0.702	0.6764
Pankreas	0.774	0.638	0.669	0.729	0.692	0.7004
Sağ böbrek üstü bezi	0.611	0.511	0.565	0.54	0.621	0.5696
Sol böbrek üstü bezi	0.558	0.64	0.662	0.654	0.59	0.6208
Ortalama	0.796	0.774	0.78	0.799	0.784	0.7866

4.2.Tartışma

Bu çalışmada önerilen modelin en iyi performans gösterdiği parametreler belirlenmiştir. Modelin hatasının minimum seviyeye düşürülmesinde etkili olan optimizasyon algoritması seçiminde Adam, Adagrad ve Adamax algoritmaları ve en iyi sonuç veren öğrenme oranı parametresinin belirlenmesi için $1e-3$, $1e-4$, $1e-5$ öğrenme oranları aynı şartlar sağlanarak çalıştırılmış ve en yüksek performansın Adam optimizasyon algoritması ile $1e-3$ öğrenme oranında elde edildiği görülmüştür. Modelin eğitimi için önemli olan bir diğer parametre olan aktivasyon fonksiyonu seçiminde ReLU ve onun varyantı olan PReLU fonksiyonları karşılaştırılmış ve test sonuçlarında çok büyük bir fark olmaması sebebiyle hesaplama maliyetinin daha düşük olması ReLU aktivasyon fonksiyonunun seçilmesinde etkili olmuştur. Veri setinde bulunan görüntülerin az miktarda olması sebebiyle adım sayısı artırıldığında önerilen modelin aşırı öğrenmesi test segmentasyon sonuçlarında doğruluğun azalmasına sebep olmuştur. Nihai olarak önerilen modelde kullanılacak olan parametreler öğrenme oranı $1e-3$, optimizasyon algoritması Adam, aktivasyon fonksiyonu ReLU ve batch size 2 olarak belirlenmiştir. Önerilen modelin aşırı öğrenmesinin engellemek için optimum parametreler kullanılarak veri artırma işlemi gerçekleştirilmiştir. Tüm organların ortalama segmentasyon eğitim sonucu %88.8 ve test sonucu %79.6 olarak bulunmuştur.

Şekil 4.1’de verilen karmaşıklık matrisi incelendiğinde birbirine sınırı olan organların segmentasyon tahmini olumsuz olarak etkilediği görülmüştür. Ayrıca az sayıda piksel içeren organlarda da hata yapılma oranının yüksek olduğu görülmüştür.

Çizelge 4.7’de önerilen modelin füzyon bir yapıda olmayan tek bir 3D U-Net modeline göre daha iyi sonuçlar verdiği görülmektedir. Çizelge 4.8’de ise önerilen model Larsson ve ark. (2018) tarafından yapılan çalışmada verilen sonuçlar ile karşılaştırılmıştır. Önerilen model bu modeller arasında dalak, sağ böbrek, sol böbrek, safra kesesi, yemek borusu, karaciğer, mide, aort ve pankreas organlarında en yüksek segmentasyon doğruluk sonucunu vermektedir. Inferior vena kava organında ise önerilen model 2. sırada, Portal ven ve splenik ven organı 3. sırada, sağ böbrek üstü bezi 4. sırada ve sol böbrek üstü bezi son sırada yer almaktadır. Önerilen model toplamda 9 organda ve tüm organların ortalamasında en yüksek segmentasyon sonucunu vermektedir.

5. SONUÇLAR VE ÖNERİLER

Bu çalışmada BT görüntüleri üzerinde çoklu organ segmentasyon işlemini otomatik olarak gerçekleştirebilmek için erken füzyon yaklaşımına sahip bir model önerilmiştir. Önerilen modelde segmentasyonu gerçekleştirilen dalak, sağ böbrek, sol böbrek ve karaciğerin doğruluk oranı %90'ın, mide, aort ve inferior vena kavanın doğruluk oranı %80'in, pankreas ve yemek borusunun doğruluk oranı %70'in üzerindedir. Safra kesesi, portal ven ve splenik ven ise yaklaşık %70, sağ böbrek üstü bezi %61.1 ve sol böbrek üstü bezi %55.8 segmentasyon doğruluk oranına sahiptir. Sağ böbrek üstü ve sol böbrek üstü haricindeki diğer organlar yaklaşık %70 ve %70'in üzerinde segmentasyon doğruluk oranına sahiptir. Önerilen modelin büyük hacimli organlarda yüksek segmentasyon başarısı elde ettiği sağ böbrek üstü bezi ve sol böbrek üstü bezi gibi çok küçük boyutlu organlarda segmentasyon başarısının düşük olduğu gözlemlenmiştir. Tüm organların ortalama segmentasyon eğitim ve test sonucu sırasıyla %88.8 ve %79.6'dır. Bu çalışma genel olarak değerlendirildiğinde, insan vücudunun iç yapısı hakkında bilgi edinilmesi için organların segmentasyon işleminin gerçekleştirilmesi ilk aşamadır ve segmentasyon sonucunda çeşitli hastalıkların teşhisi yapılabilir. Fakat radyologlar tarafından organların segmentasyonu ve sınıflandırılması organların şekillerinin değişiklik göstermesi sebebiyle zor ve zaman alıcıdır. Ayrıca bilgi ve deneyim gerektirmesi sebebiyle hata yapılma oranı yüksektir. Sonuç olarak, bu zorlukları ortadan kaldırmak için BT görüntüleri üzerinde otomatik olarak çoklu organ segmentasyon işlemi gerçekleştiren bu çalışmada başarılı ve umut verici sonuçlar elde edilmiştir.

Önerilen model BT görüntülerinde organların doğru bir şekilde tahmin etmede büyük hacimli organlarda yüksek başarılar elde etse de küçük hacimli organlarda beklenen başarı elde edilememiştir. Tüm organlar hakkında istenilen bilgileri elde etmek için daha fazla BT görüntüsü ve bu görüntülere ait etiket tanımlaması dahil edilerek eğitim ve test verilerinin sayısının artırılması segmentasyon başarısını yükseltebilir. Önerilen model daha önceden yapılmış CNN ve FCN mimarilerine çoğunluk olarak neredeyse eşit veya daha yüksek başarılar elde etmektedir.

KAYNAKLAR

- Al-Rahamneh Z , Ryalat M. 2021. Evaluation of Applying Surface Simplification Techniques in Medical Volume Data. *International Journal of Computer Applications* 975;8887.
- Albawi S, Mohammed TA , Al-Zawi S. 2017. Understanding of a convolutional neural network. 2017 International Conference on Engineering and Technology (ICET). Ieee, 1-6.
- Aldhahab A, Ibrahim S , Mikhael WB. 2020. Stacked sparse autoencoder and softmax classifier framework to classify mri of brain tumor images. *International Journal of Intelligent Engineering and Systems* 13;12-.
- Ali A , Hanbay D. 2018. Bölgesel evrişimsel sinir ağları tabanlı MR görüntülerinde tümör tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* 34;1395-408.
- Alkhatib R. 2021. Artificial Neural Network Activation Functions in Exact Analytical Form (Heaviside, ReLU, PReLU, ELU, SELU, ELISH).
- Alom MZ, Taha TM, Yakopcic C, et al. 2019. A state-of-the-art survey on deep learning theory and architectures. *Electronics* 8;292.
- Amidi A , Amidi S 2018. VIP Cheatsheet: Convolutional Neural Networks. Stanford University.
- Atlan F , Pençe İ. 2021. Yapay Zekâ ve Tıbbi Görüntüleme Teknolojilerine Genel Bakış. *Acta Infologica* 5;207-30.
- Ayşe A , Berberler ME. 2017. Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica* 1;55-73.
- Bjorck J, Gomes C, Selman B , Weinberger KQ. 2018. Understanding batch normalization. arXiv preprint arXiv:1806.02375.
- Conze P-H, Kavur AE, Cornec-Le Gall E, et al. 2021. Abdominal multi-organ segmentation with cascaded convolutional and adversarial deep networks. *Artificial Intelligence in Medicine* 117;102109.
- Dandil E , Gülteker E. 2019. Daha Hızlı Bölgesel-Evrişimsel Sinir Ağları ile Biyomedikal Görüntüler Üzerinde Organ Tanıma.
- Dargan S, Kumar M, Ayyagari MR , Kumar G. 2020. A survey of deep learning and its applications: a new paradigm to machine learning. *Archives of Computational Methods in Engineering* 27;1071-92.
- Elmacı M. 2018. Derin Öğrenme Yöntemiyle Çok Bantlı Görüntülerde Anlamsal Bölütleme. Yüksek Lisans, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği*, YÖK Tez, 20.
- Fang X , Yan P. 2020. Multi-organ segmentation over partially labeled datasets with multi-scale feature abstraction. *IEEE Transactions on Medical Imaging* 39;3619-29.
- Feng M, Huang W, Wang Y , Xie Y. 2019. Multi-organ Segmentation using Simplified Dense V-net with Post-processing. *SegTHOR@ ISBI*.
- Firildak K , Talu MF. 2019. Evrişimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi. *Computer Science* 4;88-95.
- Garcia-Garcia A, Orts-Escolano S, Oprea S, Villena-Martinez V , Garcia-Rodriguez J. 2017. A review on deep learning techniques applied to semantic segmentation. arXiv preprint arXiv:1704.06857.
- Ghojogh B, Ghodsi A, Karray F , Crowley M. 2021. Restricted Boltzmann Machine and Deep Belief Network: Tutorial and Survey. arXiv preprint arXiv:2107.12521.

- Ghosh T, Li L , Chakareski J. 2018. Effective deep learning for semantic segmentation based bleeding zone detection in capsule endoscopy images. 2018 25th IEEE International Conference on Image Processing (ICIP). IEEE, 3034-8.
- Gibson E, Giganti F, Hu Y, et al. 2018. Automatic multi-organ segmentation on abdominal CT with dense V-networks. IEEE transactions on medical imaging 37;1822-34.
- Gu J, Wang Z, Kuen J, et al. 2018. Recent advances in convolutional neural networks. Pattern Recognition 77;354-77.
- Guo T, Dong J, Li H , Gao Y. 2017. Simple convolutional neural network on image classification. 2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA). IEEE, 721-4.
- Hafiz AM , Bhat GM. 2020. A survey on instance segmentation: state of the art. International journal of multimedia information retrieval;1-19.
- He K, Zhang X, Ren S , Sun J. 2016. Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition. 770-8.
- Takeya H, Okada T , Oshiro Y. 2018. 3D U-JAPA-Net: mixture of convolutional networks for abdominal multi-organ CT segmentation. International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, 426-33.
- Karayegen G. 2021. Segmentation On Brain MR Images By Using Deep Learning Network And 3d Modelling Doktora, *Başkent University Institute of Science Engineering*, YÖK Tez, 1-31.
- Kaynar O, Yüksek AG, Görmez Y , Işık YE. 2017. Intrusion detection with autoencoder based deep learning machine. 2017 25th Signal Processing and Communications Applications Conference (SIU). IEEE, 1-4.
- Keleşoğlu Ö. 2006. YAPAY SİNİR AĞLARI İLE BETONARME KIRIŞ KESİTLERİN ANALİZİ. Teknik Dergi 17.
- Khan A, Sohail A, Zahoor U , Qureshi AS. 2020. A survey of the recent architectures of deep convolutional neural networks. Artificial Intelligence Review 53;5455-516.
- Khanday NY , Sofi SA. 2021. Deep Insight: Convolutional Neural Network and its Applications for COVID-19 Prognosis. Biomedical Signal Processing and Control;102814.
- Kingma DP , Ba J. 2014. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
- Larsson M, Zhang Y , Kahl F. 2018. Robust abdominal organ segmentation using regional convolutional neural networks. Applied Soft Computing 70;465-71.
- Le Cun Y, Jackel LD, Boser B, et al. 1989. Handwritten digit recognition: Applications of neural network chips and automatic learning. IEEE Communications Magazine 27;41-6.
- Le J. 2021. How to do Semantic Segmentation using Deep learning [Online]. Available: <https://nanonets.com/blog/how-to-do-semantic-segmentation-using-deep-learning/> [Accessed 20.03.2021].
- Lecun Y, Bengio Y , Hinton G. 2015. Deep learning. nature 521;436-44.
- Lecun Y, Bottou L, Bengio Y , Haffner P. 1998. Gradient-based learning applied to document recognition. Proceedings of the IEEE 86;2278-324.
- Liu W, Wang Z, Liu X, Zeng N, Liu Y , Alsaadi FE. 2017. A survey of deep neural network architectures and their applications. Neurocomputing 234;11-26.

- Liu Y, Lei Y, Fu Y, et al. 2020. CT-based multi-organ segmentation using a 3D self-attention U-net network for pancreatic radiotherapy. *Medical Physics* 47;4316-24.
- Long J, Shelhamer E, Darrell T. 2015. Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 3431-40.
- Lu S, Wang B, Wang H, Chen L, Linjian M, Zhang X. 2019. A real-time object detection algorithm for video. *Computers & Electrical Engineering* 77;398-408.
- Mietzner O, Mastmeyer A. 2020. Automatic multi-object organ detection and segmentation in abdominal CT-data. *medRxiv*.
- Mishra D. 2020. Transposed Convolution Demystified [Online]. Available: <https://towardsdatascience.com/transposed-convolution-demystified-84ca81b4baba> [Accessed 15.1.2022 2022].
- Noh H, Hong S, Han B. 2015. Learning deconvolution network for semantic segmentation. *Proceedings of the IEEE international conference on computer vision*. 1520-8.
- O'shea K, Nash R. 2015. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- Ogrean V, Dorobantiu A, Brad R. 2021. Deep Learning Architectures and Techniques for Multi-organ Segmentation.
- Olah C. 2015. Understanding lstm networks.
- Özekes S. 2006. Tıbbi görüntülemeye bilgisayar destekli tespit. *Marmara Üniversitesi (Turkey)*
- Özkan İ, Ülker E. 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi* 6;85-104.
- Pamina J, Raja B. 2019. Survey on deep learning algorithms. *International Journal of Emerging Technology and Innovative Engineering* 5.
- Pathak AR, Pandey M, Rautaray S. 2018. Application of deep learning for object detection. *Procedia computer science* 132;1706-17.
- Perez L, Wang J. 2017. The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*.
- Pinheiro PO, Lin T-Y, Collobert R, Dollár P. 2016. Learning to refine object segments. *European conference on computer vision*. Springer, 75-91.
- Ragland K, Tharcis P. 2014. A survey on object detection, classification and tracking methods. *Int. J. Eng. Res. Technol* 3;622-8.
- Ren S, Laub P, Lu Y, Naganawa M, Carson RE. 2019. Atlas-based multiorgan segmentation for dynamic abdominal PET. *IEEE Transactions on Radiation and Plasma Medical Sciences* 4;50-62.
- Rister B, Yi D, Shivakumar K, Nobashi T, Rubin DL. 2020. CT-ORG, a new dataset for multiple organ segmentation in computed tomography. *Scientific Data* 7;1-9.
- Ronneberger O, Fischer P, Brox T. 2015. U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*. Springer, 234-41.
- Roth HR, Oda H, Zhou X, et al. 2018a. An application of cascaded 3D fully convolutional networks for medical image segmentation. *Computerized Medical Imaging and Graphics* 66;90-9.
- Roth HR, Shen C, Oda H, et al. 2018b. Deep learning and its application to medical image segmentation. *Medical Imaging Technology* 36;63-71.

- Roth HR, Shen C, Oda H, et al. 2018c. A multi-scale pyramid of 3D fully convolutional networks for abdominal multi-organ segmentation. International conference on medical image computing and computer-assisted intervention. Springer, 417-25.
- Shen C, Roth HR, Oda H, et al. 2018. On the influence of Dice loss function in multi-class organ segmentation of abdominal CT using 3D fully convolutional networks. arXiv preprint arXiv:1801.05912.
- Simonyan K , Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Sorg BR. 2018. Multi-Task Learning SegNet Architecture for Semantic Segmentation. University of Dayton
- Soyhan İ, Gurel S , Tekin SA. 2021. Yapay Zeka Tabanlı Görüntü İşleme Tekniklerinin İnsansız Hava Araçları Üzerinde Uygulamaları. Avrupa Bilim ve Teknoloji Dergisi;469-73.
- Springenberg JT, Dosovitskiy A, Brox T , Riedmiller M. 2014. Striving for simplicity: The all convolutional net. arXiv preprint arXiv:1412.6806.
- Szegedy C, Liu W, Jia Y, et al. 2015. Going deeper with convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition. 1-9.
- Şeker A, Diri B , Balık HH. 2017. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. Gazi Mühendislik Bilimleri Dergisi (GMBD) 3;47-64.
- Toğaçar M , Ergen B. 2019. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi 31;109-21.
- Trullo R, Petitjean C, Nie D, Shen D , Ruan S. 2017. Joint segmentation of multiple thoracic organs in CT images with two collaborative deep architectures. Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: Springer; p. 21-9.
- Tsang S-H. 2018. FCN — Fully Convolutional Network (Semantic Segmentation) [Online].TowardsDataScience.Available:<https://towardsdatascience.com/review-fcn-semantic-segmentation-eb8c9b50d2d1>. [Accessed 20.3.2021 2021].
- Türkçetin AÖ. 2019. AKCİĞER KANSERİNİN TESPİT EDİLMESİNDE DERİN ÖĞRENME ALGORİTMALARININ KULLANILMASI.
- Türkoğlu M, Hanbay K, Sivrikaya IS , Hanbay D. 2021. Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi 9;334-45.
- Upadhy V , Sastry P. 2019. An overview of restricted boltzmann machines. Journal of the Indian Institute of Science 99;225-36.
- Vesal S, Ravikumar N , Maier A. 2019. A 2D dilated residual U-Net for multi-organ segmentation in thoracic CT. arXiv preprint arXiv:1905.07710.
- Wang L, Wang C, Sun Z , Chen S. 2020a. An improved dice loss for pneumothorax segmentation by mining the information of negative areas. IEEE Access 8;167939-49.
- Wang M, Lu S, Zhu D, Lin J , Wang Z. 2018. A high-speed and low-complexity architecture for softmax function in deep learning. 2018 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS). IEEE, 223-6.
- Wang X, Zhao Y , Pourpanah F 2020b. Recent advances in deep learning. Springer.
- Wiley V , Lucas T. 2018. Computer vision and image processing: a paper review. International Journal of Artificial Intelligence Research 2;29-36.
- Xiao Z, Huang R, Ding Y, et al. 2016. A deep learning-based segmentation method for brain tumor in MR images. 2016 IEEE 6th International Conference on computational advances in BIO and medical sciences (ICCABS). IEEE, 1-6.

- Xu Z. 2015. Multi-atlas labeling beyond the cranial vault - workshop and challenge [Online]. Available: <https://www.synapse.org/#!/Synapse:syn3193805/wiki/217760> [Accessed 6.3.2021 2021].
- Zhang Y, Sidibé D, Morel O , Mériaudeau F. 2021. Deep multimodal fusion for semantic image segmentation: A survey. Image and Vision Computing 105;104042.

