



**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**DERİN ÖĞRENME YÖNTEMLERİ**  
**KULLANILARAK CT GÖRÜNTÜLERİ**  
**ÜZERİNDEN DAMAR SEGMENTASYONU**

**Ömer Faruk BOZKIR**  
**YÜKSEK LİSANS**  
**Elektrik- Elektronik Mühendisliği Anabilim Dalı**

**HAZİRAN-2023**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Ömer Faruk BOZKIR tarafından hazırlanan “Derin Öğrenme Yöntemleri Kullanılarak CT Görüntüleri Üzerinden Damar Segmentasyonu” adlı tez çalışması 15/06/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Doç. Dr. Erdiñ KOÇER

#### Danışman

Doç Dr. Murat CEYLAN

#### Üye

Doç. Dr. Bayram AKDEMİR

### İmza

.....

.....

.....

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.

Ömer Faruk BOZKIR

Tarih: 15.06.2023

## ÖZET

### YÜKSEK LİSANS TEZİ

## DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK CT GÖRÜNTÜLERİ ÜZERİNDEN DAMAR SEGMENTASYONU

Ömer Faruk BOZKIR

Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. MURAT CEYLAN

2023, 50 Sayfa

Jüri

Doç. Dr. Murat CEYLAN

Aort, insan vücudundaki en önemli arter damardır ve kanın kalpten diğer tüm organlara taşınmasından sorumludur. Aortta görülen hastalıklardan damar kireçlenmesi, damar diseksiyon ve abdominal aort anevrizması hastalığı erken teşhis edilememesi halinde sonu ölümle sonuçlanabilmektedir. Günümüzde hekimler hastaların aort yapısını inceleyebilmesi için bilgisayarlı tomografi ve manyetik rezonans görüntüleme tekniklerini kullanmaktadır. Bu görüntüleme teknikleri aortun analizi, deforme olmuş bölgenin tespiti, ameliyat öncesi planlama ve ameliyat sonrası periyodik takibi için gereklidir. Tıbbi görüntüleme uygulamalarında bilgisayarlı tomografi görüntülerinde yer alan aort yapısının analizinde görüntü işleme teknikleri kullanılmaktadır. Bu teknikler ile üç boyutlu aort yapısının segmentasyonu bir hayli zordur. Son yıllarda derin öğrenme yöntemleri kullanılarak geleneksel yöntemlerle yapılan segmentasyon sorunlarının önüne geçilmektedir. Tez çalışmasında kontrastlı aort yapısının derin öğrenme yöntemleri kullanılarak segmentasyonu işlemi gerçekleştirilmiştir. Çalışmada ilk olarak iki boyutlu görüntü ve maskeler 256x256 olarak yeniden boyutlandırılmıştır. Ön işlemede görüntüler üzerinde pencere seviyesi ve normalizasyon işlemleri uygulanmıştır. Üç boyutlu bilgisayarlı tomografi görüntüleri ile U-Net, Attention U-Net, Inception U-Netv2 ve LinkNet modelleri eğitilmiştir. Eğitim sonucunda iki boyutlu maske çıktıları kesitlerin birleştirilmesi ile üç boyutlu hale getirilmiştir. Eğitim sonrasında elde edilen çıktılara küçük objelerin temizlemesi ve girdi görüntüsünün piksel aralığının ile merkez koordinat bilgilerinin maske taramasına aktararak üç boyutlu olarak görselleştirilmesi gerçekleştirilmiştir. Çalışma sonucunda DONGYANG veri setinde en yüksek başarı sonuçları Inception U-Netv2 modelinde % 93.5 dice benzerlik katsayısı, % 87.8 Jaccard, % 92.8 özgüllük, % 100 duyarlılık ve KİTS veri setinde ise en yüksek başarı Inception U-Netv2 modelinde % 86.58 dice benzerlik katsayısı, % 79.78 Jaccard, % 83.18 özgüllük ve % 100 duyarlılık değerleri elde edilmiştir.

**Anahtar Kelimeler:** Bilgisayarlı tomografi anjiyografisi, Aort Segmentasyon, Derin öğrenme

## **ABSTRACT**

### **MS THESIS**

## **VESSEL SEGMENTATION ON CT IMAGES USING DEEP LEARNING METHODS**

**Ömer Faruk BOZKIR**

**Konya Technical University  
Institute of Graduate Studies  
Department of Electrical and Electronics Engineering**

**Advisor: Assoc. Prof. Dr. Murat CEYLAN**

**2023, 50 Pages**

### **Jury**

**Assoc. Prof. Dr. Murat CEYLAN**

The aorta is the most important artery in the human body and is responsible for carrying blood from the heart to all other organs. Diseases affecting the aorta, such as atherosclerosis, aortic dissection, and abdominal aortic aneurysm, can be fatal if not diagnosed early. Today, physicians use computed tomography and magnetic resonance imaging techniques to examine the structure of patients' aortas. These imaging techniques are necessary for analyzing the aorta, identifying deformed regions, and planning and monitoring surgery. In medical imaging applications, image processing techniques are used to analyze the structure of the aorta in computed tomography images. Segmentation of the three-dimensional aorta structure is quite challenging with these techniques. In recent years, deep learning methods have been used to overcome segmentation problems encountered with traditional methods. In this thesis, the segmentation of the contrast-enhanced aorta structure was performed using deep learning methods. First, two-dimensional images and masks were resized to 256x256. Window level and normalization operations were applied to the images during preprocessing. U-Net, Attention U-Net, Inception U-Netv2, and LinkNet models were trained using three-dimensional computed tomography images. After training, the two-dimensional mask outputs were combined to obtain a three-dimensional output. The obtained outputs were further processed by removing small objects and transferring the pixel range and center coordinate information of the input image to the mask scanning process, allowing them to be visualized in three dimensions. The highest success rates in the DONGYANG dataset were obtained with the Inception U-Netv2 model, with a 93.5 % dice similarity coefficient, 87.8 % Jaccard, 92.8 % specificity, and 100% sensitivity. The highest success in the KiTS dataset was achieved with the Inception U-Netv2 model, with an 86.58 % dice similarity coefficient, 79.78 % Jaccard, 83.18 % specificity, and 100 % sensitivity.

**Keywords:** Computed tomography angiography, Aortic Segmentation, Deep learning

## ÖNSÖZ

Tez çalışmam boyunca değerli katkılarıyla beni yönlendiren danışmanım Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Öğretim Üyesi Sn. Doç. Dr. Murat Ceylan'a, bu süreçte maddi ve manevi desteklerinden dolayı kıymetli aileme, çalışmamın ilerleyişinde yapmış oldukları değerli önerilerinden dolayı AKGÜN Yazılım şirketinden Yapay Zekâ Birim yöneticim Sn. Abdulkadir Budak'a ve çalışma arkadaşım Sn. Çağlar Gürkan'a teşekkür ederim.

Ömer Faruk BOZKIR  
KONYA-2023



## İÇİNDEKİLER

|   |           |
|---|-----------|
| ÖZET .....  | iv        |
| ABSTRACT.....   | v         |
| ÖNSÖZ .....   | vi        |
| İÇİNDEKİLER .....   | vii       |
| SİMGELER VE KISALTMALAR .....   | ix        |
| <b>1. GİRİŞ.....</b>  | <b>1</b>  |
| <b>2. KAYNAK ARAŞTIRMASI .....</b>                                    | <b>5</b>  |
| <b>3. MATERYAL VE YÖNTEM.....</b>                                     | <b>10</b> |
| 3.1 Veri Seti .....   | 10        |
| 3.2 Aort Segmentasyonu.....   | 12        |
| 3.3 Ön İşlem.....   | 13        |
| 3.3.1 Yeniden boyutlandırma.....                                      | 13        |
| 3.3.2 Hounsfield birim değerinin belirlenmesi .....                   | 14        |
| 3.3.3 Normalizasyon .....   | 16        |
| 3.4 Derin Öğrenme .....   | 17        |
| 3.4.1 Evrişimsel sinir ağı .....                                      | 17        |
| 3.4.1.1 Evrişim.....  | 18        |
| 3.5 Segmentasyon .....  | 24        |
| 3.6 Segmentasyonda Kullanılan Derin Öğrenme Modelleri.....            | 24        |
| 3.6.1 U-Net Mimarisi .....  | 24        |
| 3.6.2 Attention U-Net Modeli .....                                    | 25        |
| 3.6.3 Inception U-Netv2 Modeli.....                                   | 26        |
| 3.6.4 LinkNet Modeli.....   | 28        |
| 3.7 Segmentasyon Sonrası İşlemler .....                               | 28        |
| 3.7.1 İki boyutlu çıktıların üç boyuta dönüştürülmesi .....           | 28        |
| 3.7.2 Üç boyutlu verinin iyileştirilmesi .....                        | 29        |
| 3.8 Performans Değerlendirme Metrikleri.....                          | 30        |
| 3.8.1 Özgüllük.....   | 31        |
| 3.8.2 Duyarlılık.....   | 31        |
| 3.8.3 Dice benzerlik katsayısı (DBK).....                             | 31        |
| 3.8.4 Jaccard oranı(JO) .....   | 31        |
| <b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>                        | <b>33</b> |
| 4.1 Aort Segmentasyon Sonuçları .....                                 | 34        |
| 4.1.1 Dongyang veri seti ile elde edilen segmentasyon sonuçları ..... | 34        |
| 4.1.2 KiTS veri seti ile elde edilen segmentasyon sonuçları .....     | 38        |
| <b>5. SONUÇLAR VE TARTIŞMA.....</b>                                   | <b>43</b> |
| 5.1 Sonuçlar .....  | 43        |

|                        |           |
|------------------------|-----------|
| 5.2 Tartışma .....     | 43        |
| <b>KAYNAKLAR .....</b> | <b>46</b> |





## SİMGELER VE KISALTMALAR

### Simgeler

|                 |                 |
|-----------------|-----------------|
| mm              | :Milimetre      |
| mm <sup>2</sup> | :Milimetre kare |
| *               | :Evrşim işlemi  |

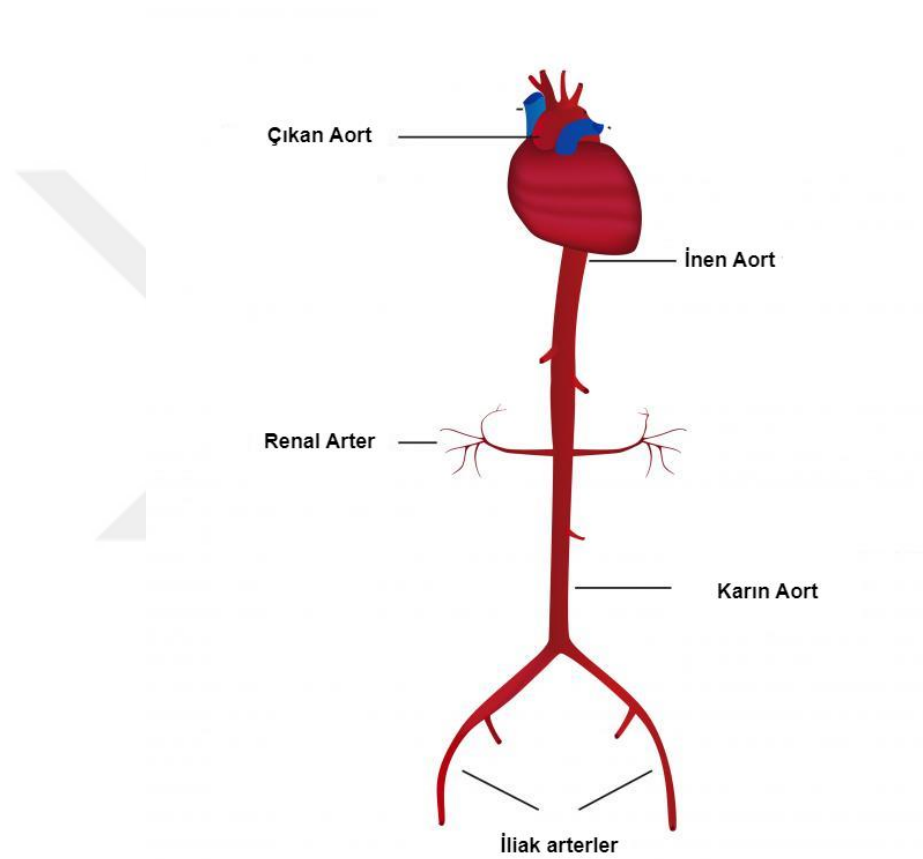


## Kısaltmalar

|         |   |
|---------|---|
| AAA     | : Abdominal Aort Anevrizma                        |
| ABD     | : Amerika Birleşik Devletleri                     |
| Adagrad | :Adaptif Eğim                                     |
| ADAM    | :Adaptif Moment Tahmin                            |
| BT      | :Bilgisayar Tomografisi                           |
| BTA     | :Bilgisayarlı Tomografi Anjiyografisi             |
| DN      | :Doğru Negatif                                    |
| DP      | :Doğru Pozitif                                    |
| ELU     | : Üstel Doğrusal Birim                            |
| ESA     | : Evrışimsel Sinir Ağı                            |
| HB      | : Hounsfield Birimi                               |
| ISBI    | : Uluslararası Biyomedikal Görüntüleme Sempozyumu |
| MITK    | :Tıbbi Görüntüleme Etkileşim Araç Seti            |
| MR      | : Manyetik Rezonans                               |
| PACS    | : Görüntü Arşivleme ve İletişim Sistemleri        |
| ReLU    | : Lineer Birim                                    |
| RMSprop | : Kare Ortalamalarının Karekökü Yayılımı          |
| SELU    | : Doğrusal Birim                                  |
| SGD     | : Stokastik Gradyan İnişi                         |
| YN      | : Yanlış Negatif                                  |
| YP      | : Yanlış Pozitif                                  |
| YSA     | : Yapay Sinir Ağları                              |

## 1. GİRİŞ


Aort, insan vücudundaki en büyük arterdir. Sol ventrikülden çıkarak karnın aşağısına doğru uzanır ve aşağıya doğru küçük damarlara dallanır (Mercan ve ark., 2017). Aort yapısı Şekil 1.1’de görüldüğü gibi çıkan-inen aort, abdominal aort, yanlara dallanan renal arterler ve iliak arterlere kadar uzanan üç kısımdan oluşmaktadır. Aort oksijenlenmiş kanı tüm vücut parçalarına sistemik dolaşım ile ulaştırır.



Şekil 1.1. Aort yapısı (Princeton, 2022)


Aortta, tümü üç boyutlu tıbbi görüntüleme ile tanımlanabilen anevrizma, diseksiyon, stenoz ve koarktasyonlar gibi hastalıklar meydana gelmektedir. ABD’de her yıl yaklaşık 200.000 kişiye aort hastalıklarından biri olan AAA (Abdominal Aort Anevrizma) teşhisi konmaktadır (Hu ve ark., 2022). AAA hastalığı genellikle sigara içen yaşlı erkeklerde, 70 yaş üstü kadınlarda görülmektedir (Hu ve ark., 2022). AAA, Şekil 1.2’de görüldüğü gibi vücuda kan sağlayan ana damar kısmında 3 cm’den fazla patolojik genişleme ve deformasyona neden olmaktadır (Aggarwal ve ark., 2011). ABD’de yılda 15.000 insanın aniden damar yırtılmasıyla ölümüne neden olmaktadır (Bahia ve ark., 2013). AAA herhangi bir bulgu vermeden önce büyümesinden dolayı rüptüre

anevrizmalarının çoğu erken tanı ve ilaç tedavisi ile önlenmektedir (Bahia ve ark., 2013). Patolojik genişlemeye uğramış bölgelerin doğru ölçümü, rüptür olasılığını tahmin etmek ve endovasküler onarımından sonra çapın aktivitesini izlemek için gereklidir. Son yıllarda cerrahlar, femur girişinden sokulan bir kateter kullanarak anevrizma kesesine bir veya daha fazla damarın çapına uygun boyutlarda stent greft yerleştirerek anevrizma kesesinin basıncını ve duvar yırtılması riskini azaltmaktadır (López-Linares ve ark., 2019). AAA'lar yüksek oranda morbidite ve mortalite ile ilişkili olduğundan, daha fazla hastanın sağlığına kavuşması için doğru tanı ve preoperatif değerlendirme çok önemlidir (Sparks ve ark., 2002).




Şekil 1.2. Abdominal aort anevrizması (Martinez, 2020)

Günümüzde uzmanlar vücut anatomisinin incelenmesinde Bilgisayar Tomografisi (BT) ve Manyetik Rezonans (MR) gibi radyolojik görüntüleme tekniklerini kullanmaktadır. BT görüntüleri, X-ışınları kullanarak iki boyutlu kesitler halinde görüntü taramaları üretmektedir. Elde edilen iki boyutlu görüntüler hekimin hasta hakkında tanı koymasına için Şekil 1.3'te görüldüğü gibi sagittal, aksiyal ve koronal olmak üzere üç düzlemde Tıbbi Görüntüleme Etkileşim Araç Seti (MITK) (Wolf ve ark., 2005) arayüzünde gösterilmektedir.



Şekil 1.3. Doktorların analiz yaptığı MITK arayüzü

Şekil 1.4 (a)'da kontrastsız aksiyal görüntü gösterilmektedir. Hekimler damarları daha kolay şekilde analiz etmek için hastaya iyotlu ilaç enjekte ederek damarların kontrast değerinin artırılarak belirginleştirilmesini sağlar. Bilgisayarlı Tomografi Anjiyografisi (BTA) adı verilen bu görüntüleme tekniği Şekil 1.4 (b)'de gösterilmektedir. BTA görüntüleme tekniği abdominal aort anevrizması hastalığında hekimlerin, preoperatif süreçte damarın lokasyonunun tam konumunu belirleyerek ameliyat anında deformasyona uğramış bölgeye en kolay yoldan müdahale edilmesine yardımcı olmaktadır.



Şekil 1.4. BTA (a) ilaçsız aksiyal görüntü (b) ilaçlı aksiyal görüntü

Görüntü analizinin ilk aşaması segmentasyondur. Görüntü segmentasyonu, tıp alanında ameliyat öncesi değerlendirme yaparak deformasyona uğramış bölgenin konumunu belirlemek, doku hacimlerini ölçmek, arttırılmış gerçekle ameliyatları simüle etmek, kanser hücrelerini tespit etmek ve tanımlamak için kullanılmaktadır (Vadapalli ve ark., 2021). BT görüntülerin iki boyutlu kesitler halinde incelenerek manüel segmente edilmesi hem zor hem de zaman alıcı bir süreçtir. Günümüzde Görüntü Arşivleme ve İletişim Sistemlerinde (PACS) anatomik yapının iki ve üç boyutlu segmentasyonunda seviye seti, bölge büyütme ve eşik değer görüntü işleme yöntemleri kullanılmaktadır. Fakat kontrastlı/kontrastsız BT görüntülerde damar ve diğer dokuların piksel değerlerinin birbirine yakın olmasından dolayı görüntü işleme yöntemleri ile birbirinden ayrılması oldukça zordur. Son yıllarda bu sorunlara çözüm olarak derin öğrenme yöntemleri yardımıyla dokuların segmentasyonunda başarılı sonuç üreterek hekime yardımcı otomatik sistemler oluşturulmaktadır.

Bu çalışma derin öğrenme yöntemleri kullanılarak kontrastlı BT görüntüleri üzerinden torasik aort, abdominal aort ve iliak arterlerin segmentasyon işlemi gerçekleştirerek üç boyutlu olarak damarın analizini sağlamaktır. Bu çalışmanın amacı, hekimlerin aort yapısının analizine yardımcı olan, doğru lokasyona müdahale edebilmeleri ve ameliyat öncesi değerlendirme yapabilmeleri için aort yapısını segmente eden bir sistem oluşturmaktır.

## 2. KAYNAK ARAŞTIRMASI

Derin öğrenme yöntemleri kullanılarak kontrastlı ve kontrastsız bilgisayarlı tomografi görüntülerinde aort segmentasyonu ile ilgili önemli çalışmalar yapılmıştır.

2017 yılında Dasgupta ve ark. yaptıkları çalışmada kontrastlı ve kontrastsız 120 BT toraks görüntülerinde aort segmentasyonu görüntü işleme yaklaşımı önermiştir. Bu çalışmada inen ve çıkan aortun lokalizasyonunun belirlenmesi için Dairesel Hough Dönüşümü, aort bölgesini segmentlere ayırabilmek için aktif kontur yöntemi uygulanmıştır. Çalışma sonucunda aort bölgesinin segmentasyonunda 0.88 dice benzerlik katsayısı elde edilmiştir.

Zheng ve ark. 2018 yılında, yaptıkları çalışmada az sayıda BT taraması ile derin öğrenme yöntemleri kullanarak abdominal aort anevrizmalı hastalarda aort segmentasyon işlemini önermişlerdir. Çalışmada modelin ezberlememesi için döndürme ve gri değer varyasyonu uygulayarak modeli daha gürbüz hale getirmişlerdir. Eğitim hazırlık sürecinde Stokastik Gradyan İnişi (SGİ) ve Adam optimizasyon algoritmalarını kullanmışlardır. U-net modeli ile 0.824 dice benzerlik katsayısı elde edilmiştir.

2018 yılında Noothout ve ark., kontrastsız BT taramalarında aort segmentasyonu üzerine bir derin öğrenme yaklaşımı önermiştir. Çalışmada 24 düşük doz BT görüntüsü kullanmışlardır. İki boyutlu Evrişimli Sinir Ağı (ESA) ile aortun lokasyonunu belirleyerek görüntüleri yeniden boyutlandırmışlardır. ESA yapısında kayıp fonksiyonunda çapraz entropi ile zar katsayısının birleşimini ve optimizasyon algoritması olarak ADAM'ı kullanmışlardır. İki boyutlu ESA kullanılarak aksiyal, koronal ve sagittal olmak üzere üç düzlem için de aort segmentasyonu gerçekleştirilmiştir. Ayrıca çıkan aort, aortik ark, inen aort ve torasik aort sınıflandırma işlemi için ESA'lar yardımıyla üç boyutlu olasılık haritası çıkarılarak en yüksek sınıflı olasılığa göre çoklu sınıflandırma gerçekleştirilmiştir. Test sonucunda aort segmentasyonunda 0.91 dice benzerlik katsayısı elde edilmiştir.

Lareyre ve ark. (2019) BT taramaları kullanarak vasküler sistem ve AAA hızlı tespiti için bir sistem mimarisi önermişlerdir. Bu çalışmada Nice Üniversite hastanesinden toplanan 40 BT taraması kullanılmıştır. Anevrizma tespiti işlemini ön işlem aort lümeninin segmentasyonu, aort trombusünün segmentasyonu ve aort kalsifikasyonu olmak üzere üç adımda gerçekleştirmişlerdir. Veriler üzerinde HB değeri 40-400 olarak ayarlayıp gürültü azaltma filtresi uygulamışlardır. Aort lümenini lokalize

etmek için sınır yayılımına dayalı yöntem kullanmışlardır. Son olarak lümenin segmentasyonu çıktısı üzerinden trombüs segmentasyonu ve kalsifikasyonların segmentasyonu gerçekleştirmişlerdir. Test sonuçlarında aort lümeni segmentasyonunda ortalama duyarlılık 0.90, ortalama özgüllük 0.9997, ortalama jaccard indeksi 0.87 ve ortalama dice benzerlik katsayısı 0.93 olarak hesaplamışlardır.

2019 yılında Morris ve ark. BT ve MR görüntüleri kullanarak üç boyutlu ESA yapıları ile kardiyopulmoner sistemin alt yapılarını otomatik olarak segmentlere ayırmak için bir yöntem önermişlerdir. Çalışmada 193 eğitim, 24 doğrulama ve 24 test BT tarama verileri kullanmışlardır. İlk olarak görüntüler akciğer etrafından kırılarak 512x512 olarak yeniden boyutlandırılmıştır ve normalizasyon yapılmıştır. Segmentasyon için kodlayıcı-kod çözücü yapıya sahip olan Deeplabv3+ modeli kullanılmıştır ve aort segmentasyonunda 0.92 dice benzerlik katsayısı elde edilmiştir.

Yu ve ark. (2020) yaptıkları çalışmada üç boyutlu ESA kullanılarak BTA taramalarında tüm aortun, gerçek ve yanlış lümenin segmentasyonu ve çap ölçümü için otomatik bir yöntem önermişlerdir. Kullanılan veri seti 139 aort diseksiyonlu hastadan oluşmaktadır. İlk olarak veriler gürültüden arındırılmış ve sonrasında aort lümenini hedeflemek için bir ilgi bölgesi algılama algoritması kullanılmıştır. Büyük veri çeşitliliği göz önünde bulundurularak BTA görüntülerinin boyutu 128 x 128 x 128 olacak şekilde yeniden örneklenmiştir. Veri arttırma için döndürme ve çevirme işlemi uygulanmıştır. Eğitim işleminde 125 katmanlı bir Evrişim sinir ağı yapısına sahip üç boyutlu U-Net-DenseNet modeli kullanılmıştır. Kodlayıcı kısmında, evrişim katmanları 3x3x32'lik filtre boyutu 2'şerli adım atlayacak şekilde ayarlanmıştır. Modelin son katmanda softmax aktivasyon fonksiyonu kullanmıştır. Eğitim işleminde 30 iterasyondan sonra validasyon verilerinde kayıp değeri düşmediği için eğitim durdurulmuş ve 25 adet aort diseksiyonlu hasta verisi ile test işlemi gerçekleştirdi. Test sonuçları incelendiğinde tüm aort, doğru aort ve yanlış aort için sırasıyla 0.958, 0.961 ve 0.932 ortalama dice benzerlik katsayısı elde edilmiştir.

D. Hahn ve ark. (2020), BTA taramaları kullanarak derin öğrenme yöntemleri ile aort diseksiyonunda segmentasyon yöntemi önermişlerdir. Çalışmada 153 adet abdominal BTA görüntüsü kullanılmıştır. Bu görüntülerin 103'ü eğitimde, 22'si doğrulamada ve 28'i test işleminde kullanılmıştır. Eğitimde kayıp fonksiyonu olarak ikili



çapraz entropi, optimizasyon algoritması olarak ise ADAM kullanılmıştır. Önerilen sistem 5 adımdan oluşmaktadır. İlk olarak derin öğrenme yöntemleri kullanarak kodlayıcı-kod çözücü mantığında çalışan TernaNet modelinde kodlayıcı kısmında VGG blok yapılarını kullanarak aksiyal düzlemde aort lokalizasyon işlemi gerçekleştirilmiştir. İkinci aşamada aort lokalizasyonundan elde edilen 3B maskeden merkez noktaları elde edilmiştir. Elde edilen merkez noktalar uzman tarafından elde edilen maske verileri ile karşılaştırılmış ve sonrasında TernaNet modeli kullanılarak gerçek ve yanlış lümen olarak aort segmentasyonu işlemi gerçekleştirilmiştir. Test sonuçlarında aort segmentasyonunda %95.2 dice benzerlik katsayısı elde edilmiştir.

Fantanzini ve ark.(2020) derin öğrenme yöntemleri kullanarak BTA taramalarında torasik aorttan ana iliak arterlere kadar olan tüm aort lümenini üç boyutlu olarak segmentasyonunu gerçekleştirmişlerdir. Çalışmada San Martino Üniversite Hastanesinden topladıkları 80 BTA taraması kullanmışlardır. Veri ön işlemede pencere seviyesi 800 ve pencere genişliği 200 Hounsfield Birimi (HB) olarak ayarlamışlardır ve piksel değerlerini 0-255 arasına normalize etmişlerdir. Veri sayısını arttırmak için görüntüler üzerinden döndürme, kaydırma ve yakınlaştırma işlemleri gerçekleştirmişlerdir. Çalışmanın sistem mimarisinde ilk olarak aort lümeninin lokalizasyonunu belirlemek için iki boyutlu U-Net modeli ile segmentasyon işlemi gerçekleştirilerek ilgili bölgede 144x144 boyutunda kırpma işlemi uygulanmıştır. Sonrasında aksiyal, koronal ve sagittal düzlemlerde iki boyutlu U-Net modeli ile ayrı ayrı eğitim işlemi gerçekleştirilmiştir. İşlem sonucunda üç düzlem için elde edilen maskeler birleştirilerek üç boyutlu olarak görselleştirilmiştir. Bu çalışmada üç boyutlu ESA yapılar çok fazla veri ve bellek gerektirdiğinden iki boyutlu ESA tercih edilmiştir. Test görüntülerinde,  $0,92 \pm 0,01$ 'lik bir dice benzerlik katsayısı elde edilmiştir.

Bonechi ve ark. (2021) üç boyutlu BT görüntüleri kullanarak iki boyutlu aort segmentasyon yaklaşımı önermişlerdir. Çalışmada veri seti olarak Siena Üniversitesinden topladıkları üç boyutlu 153 BT tarama görüntülerini kullanmışlardır. İlk olarak görüntüleri aksiyal, sagittal ve koronal olmak üzere üç düzleme ayırıp ön işlem olarak kırpma ve histogram eşitleme yöntemlerini uygulamışlardır. Daha sonra U-Net ve LinkNet modellerinin kodlayıcı bloklarına Resnet34 ve Inception ResnetV2 uygulayarak modelleri aksiyal, koronal ve sagittal düzlemleri için ayrı ayrı eğitmişler ve test etmişlerdir. Sonuç olarak aort segmentasyonunda en yüksek skoru LinkNet+ResNetV2

modelinde, aksiyal %83.45, koronal %77.11, sagittal %76.75 ortalama jaccard skoru elde etmişlerdir.

2021 yılında Adam ve ark., gerçekleştirdikleri çalışmada AAA hastalığının tespiti için maksimum aort çapını belirlemek ve hasta takibinin sağlanması için tam otomatik derin öğrenme tabanlı bir yöntem önermişlerdir. Çalışmada 345 hastaya ait 551 BTA taraması kullanılmıştır. Aort segmentasyonu için V-Net mimarisi kullanmıştır. Elde edilen segmentasyon görüntülerine bulanık bölge rekabet algoritması uygulanarak iyileştirme yapılmıştır. Çap ölçümü için üç boyutlu damar maskelerinin merkez noktaları belirlenerek bu noktalara dik olan noktaların en büyüğü çap olarak kabul edilmiştir. Aort segmentasyonu sonucunda sağlıklı, hasta ve endovasküler tedavisinden sonrası hasta aortlarda sırasıyla 0.85, 0.95 ve 0.93 dice benzerlik katsayısı skorlarına ulaşmışlardır.

Lartaud ve ark. (2021), BT görüntülerinde derin öğrenme yöntemleri kullanarak bölütlemesi zor olan kalbin doku yapısının sanal kontrastsız görüntüleme tekniği ile segmentasyonu için bir sistem önermişlerdir. Bu çalışmada 122 BT verisi kullanılmış ve 3B U-Net modelinde aort segmentasyonunda 0.92 dice benzerlik katsayısı elde edilmiştir.

2022 yılında Sieren ve ark., sağlıklı ve hastalıklı BT görüntülerinde bir derin öğrenme yaklaşımı kullanarak aort segmentasyonu ve damar analizi gerçekleştirmişlerdir. Çalışma 191 BT taraması ile gerçekleşmiş olup 3B U-Net modelinde eğitilerek aort segmentasyonu gerçekleştirilmiştir. Aort segmentasyonunda tüm çalışmalarda 0.95'lik dice benzerlik katsayısı, 0.76 ortalama yüzey mesafesi, 8 Hausdorff yüzey mesafesi, hasta bireylerde 0.94 dice benzerlik katsayısı, 1.02 ortalama yüzey mesafesi, 8.58 hausdorff yüzey mesafesi elde edilmiştir. Aort çapı ölçümü için bir merkez çizgisi tanımlanmış ve bu merkez çizgisine dik olarak düzlemler yerleştirilip damarın max çapı, etkin çapı ve alanı otomatik olarak çıkarılmıştır. Bland-Altman analizine göre aort damarındaki mutlak hata sonuçları, maksimum çap için  $(0.8 \pm 1.5)$  mm, alan için  $(-30.0 \pm 81.6)$  mm<sup>2</sup>, anevrizmaları damarlarda maksimum çap için  $(-0.5 \pm 2.3)$  mm, etkin çap için  $(0.3 \pm 1.6)$  mm, alan için  $(64.9 \pm 114.9)$  mm<sup>2</sup> hesaplanmıştır.

Yine 2022 yılında Wang H. ve ark, tarafından gerçekleştirilen çalışmada aort ve pulmoner arterlerin kontrastsız BT görüntülerinden segmentasyonundaki zorluğun üstesinden gelmek için kontrast geliştirme ve segmentasyon modelinden oluşan iki aşamalı derin öğrenme yöntemi önerilmiştir. Ulusal Taiwan Üniversitesi hastanesinden alınan akciğer kanserli hastaya ait 179 BT taraması kullanılmıştır.

Çalışmada ilk olarak HB değeri -160'a 240 olarak ayarlanmıştır. 3B U-Net modelinde kontrastlı BT görüntülerinde eğitim işlemi gerçekleştirilmiş ve bu eğitimde elde edilen ağırlıklar kullanılarak segmentasyon başarımı arttırılmıştır. Çalışma sonucunda beş kat çapraz doğrulama yapılarak aort ve pulmoner arterin segmentasyonu gerçekleştirilmiş ve sırasıyla  $0.97 \pm 0.66$  ve  $0.93 \pm 0.16$  dice benzerlik katsayıları elde edilmiştir.

2022 yılında gerçekleştirilen diğer bir çalışmada, 18 BTA taramasında aort segmentasyonun performansını geliştirmeye yönelik bir yaklaşım sunulmuştur (Bencevic ve ark., 2022). Bu çalışmada ön işlem olarak görüntü boyutları 256x256, BT taramalarının pencere aralığı 200-500 HB, veriler üzerinde [-0.5,0.5] aralığında normalizasyon işlemi gerçekleştirilmiştir. Eğitimde kayıp fonksiyonu olarak dice katsayısı ve optimizasyon algoritması olarak ADAM kullanılmıştır. Aksiyal veriler ilk olarak U-Net modelinde üçlü çapraz doğrulama uygulanarak segmente edilmiştir. Elde edilen bu segmentasyon verileri her bir obje için merkez noktaları belirlenerek ayrı ayrı polar transform ağlarından geçirilmiştir. Son olarak aort segmentasyon işlemi gerçekleştirilmiştir. Sonuç olarak aort segmentasyonunda  $0.932 \pm 0.027$  dice benzerlik katsayısı,  $0.895 \pm 0.033$  ortalama jaccard skoru elde edilmiştir.

### 3. MATERYAL VE YÖNTEM

Bu bölümde 3.1 kısmında veri setinden, Bölüm 3.2'de aort segmentasyonu için önerilen sistem mimarisinden, Bölüm 3.3'te eğitim öncesi verilere uygulanan ön işlemlerden, Bölüm 3.4'te derin öğrenmeden, Bölüm 3.5'te segmentasyondan, Bölüm 3.6'da segmentasyonda kullanılan derin öğrenme modellerinden, Bölüm 3.7'de segmentasyon sonrası işlemlerden, Bölüm 3.8'de ise performans değerlendirme metriklerinden bahsedilmiştir.

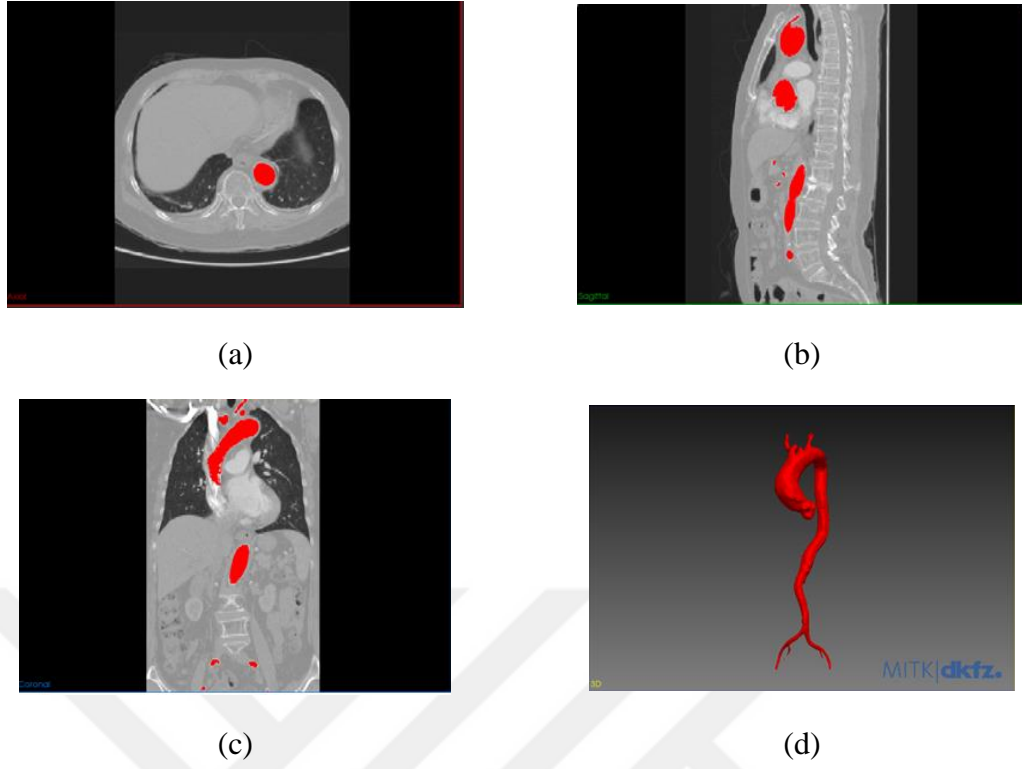
#### 3.1 Veri Seti

Tez çalışmasında, Radl ve arkadaşlarının 2022 yılında hazırladığı torasik aort, abdominal aort ve iliak arter, kontrastlı BT görüntülerini içeren veri seti kullanılmıştır. Bu veri seti iki farklı veri seti olan KiTS19 ve Dongyang veri setlerinden oluşmaktadır. Çizelge 3.1'de görüldüğü gibi KiTS BT tarama görüntülerinin boyutları 512x512, Dongyang BT tarama görüntülerinin boyutları 512x666'dır. Bu çalışmada iki farklı veri setinden toplamda 8099 (38 tarama) aksiyal kesit görüntüsü kullanılmıştır.

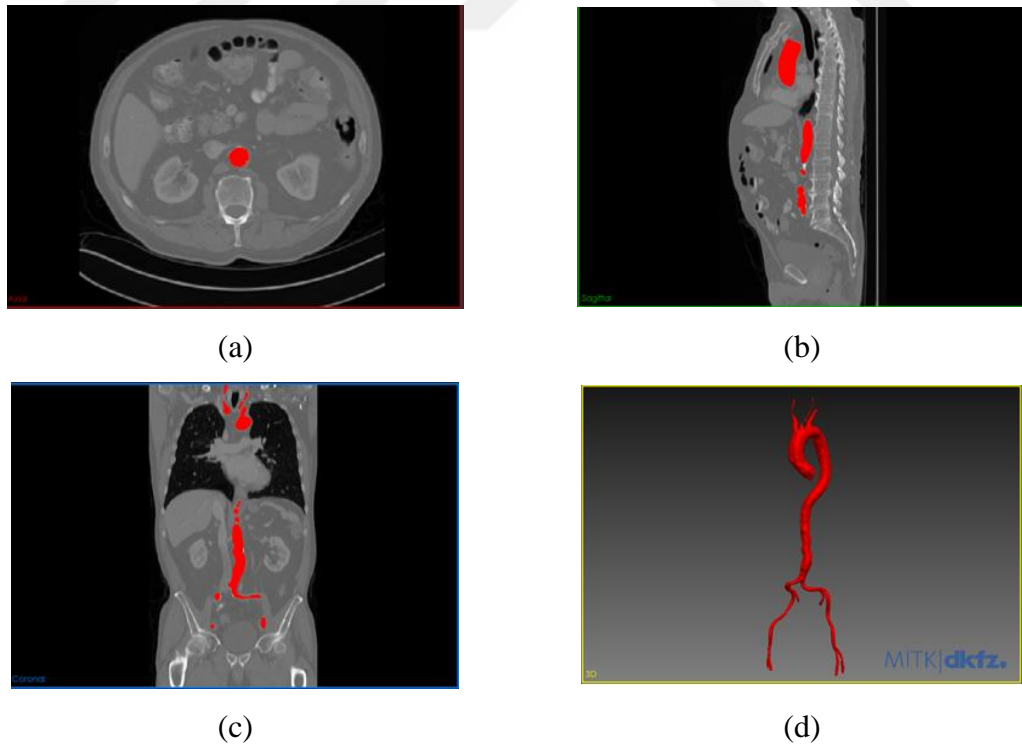
Çizelge 3.1. Veri Seti

|            |                      | Veri Seti |            |
|------------|----------------------|-----------|------------|
|            |                      | Dongyang  | KiTS       |
| Özellikler | Tarama sayısı        | 18        | 20         |
|            | Axial görüntü sayısı | 2840      | 5259       |
|            | Görüntü Boyutu       | 512x666   | 512x512    |
|            | Dilim kalınlığı      | 2/3/3 mm  | 0.5/5/5 mm |

Bu veri setinde her tarama için yarı otomatik olarak segmentasyon maskeleri mevcuttur. İki farklı BT veri setinden alınan orijinal ve gerçek maske görüntüleri iki boyutlu ve üç boyutlu olarak Şekil 3.1 ve 3.2'deki gibi MITK arayüzünde gösterilmiştir.



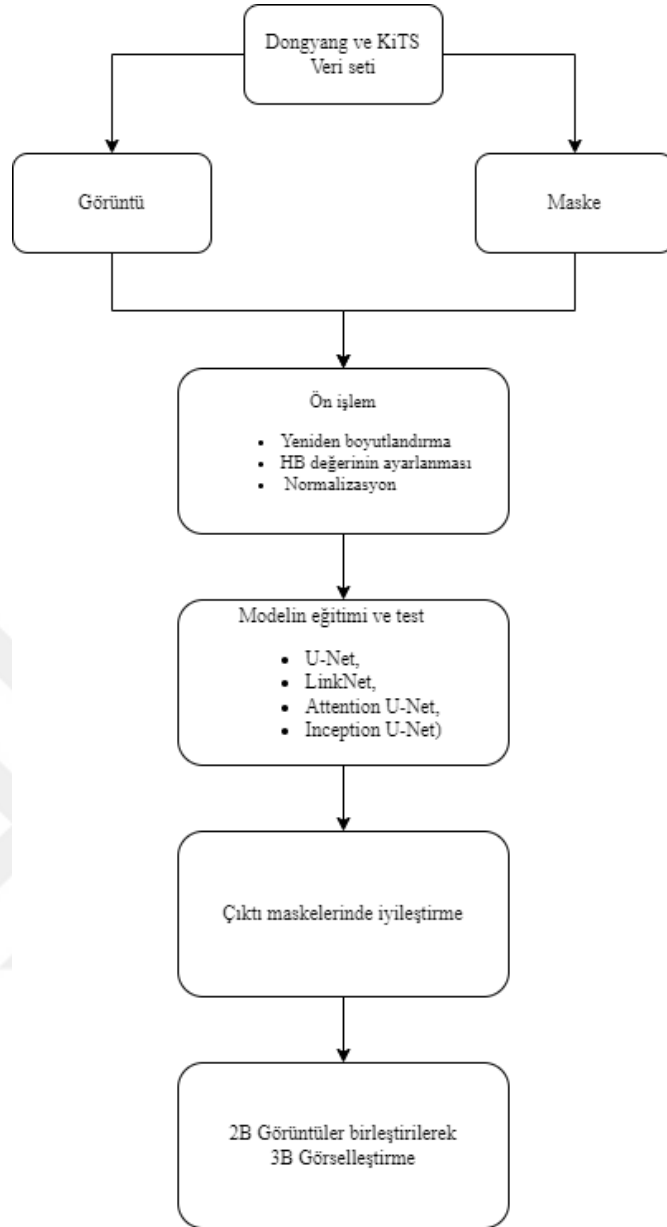
**Şekil 3.1.** Dongyang veri setinde 2B ve 3B orjinal görüntü ve gerçek maske (a) aksiyal görüntü ve kırmızı tonda gerçek maskesi, (b) sagittal görüntü ve kırmızı tonda gerçek maskesi, (c) koronal görüntü ve kırmızı tonda gerçek maskesi, (d) gerçek maskenin 3D gösterimi



**Şekil 3.2.** KiTS veri setinde 2B ve 3B orjinal görüntü ve gerçek maske (a) aksiyal görüntü ve kırmızı tonda gerçek maskesi, (b) sagittal görüntü ve kırmızı tonda gerçek maskesi, (c) koronal görüntü ve kırmızı tonda gerçek maskesi, (d) gerçek maskenin 3D gösterimi

### 3.2 Aort Segmentasyonu

İki boyutlu aksiyal BTA görüntüleri kullanılarak üç boyutlu torasik aort, abdominal aort ve iliak arterlerin segmentasyonu için önerilen sistemin blok gösterimi Şekil 3.3'te verilmiştir. Şekilden de görülebileceği gibi BT tarama verilerinden elde edilen aksiyal görüntü ve maske üzerinde ilk olarak ön işlem uygulanmıştır. Eğitime hazır olan iki boyutlu veriler U-Net (Ronneberger ve ark., 2015), Attention U-Net (Oktay ve ark., 2018), Inception-U-Net (Delibasoglu ve Cetin, 2020) ve LinkNet (Chaurasia ve ark., 2017) modellerinde ayrı ayrı eğitilmiştir. Eğitim sonrasında modeller test edilmiştir. Test sonucunda elde edilen iki boyutlu aksiyal maske görüntüleri kesit numarasına göre üst üste birleştirilmiş ve üç boyutlu maske taramaları elde edilmiştir. Daha sonra test edilen orijinal görüntü taramasının merkez koordinatları ile aksiyal, koronal ve sagittal düzlemlerinin iki piksel arası uzaklık değerleri maske taramasına aktararak üç boyutlu görüntüdeki bozulma düzeltilmiştir. Görüntü üzerinde farklı yerlerde bulunan yanlış negatif objelerin temizlenmesi için küçük alanlı objelerin çıkarılması metodu uygulanarak üç boyutlu görüntü taramaları üzerinde iyileştirme yapılmıştır. Son olarak elde edilen veriler MITK uygulamasında üç boyutlu olarak görselleştirilmiştir.



Şekil 3.3. Aort segmentasyonu için önerilen sistemin blok gösterimi

### 3.3 Ön İşlem

Derin öğrenme çalışmalarında eğitim işlemi gerçekleştirilmeden önce problem odaklı ön işlem uygulanarak veriler eğitim için hazır hale getirilir. Veri ön işleme, derin öğrenme ağlarını uygun şekilde eğitmek için çok önemlidir. Aşağıda, veri ön işleme ile ilgili tüm adımlar sırasıyla açıklanmıştır.

#### 3.3.1 Yeniden boyutlandırma

Büyük boyutlu veriler yüksek bellek ve RAM kapasitesine ihtiyaç duyar. Bu nedenle görüntülerde boyut küçültme verinin daha hızlı ve minimum donanımla eğitilmesini sağlamaktadır. Tez çalışmasında Dongyang ve KiTS veri setindeki aksiyal

görüntülerin sırasıyla 512x666 ve 512x512 olan boyutları 256x256 olarak yeniden boyutlandırılmıştır.


### 3.3.2 Hounsfield birim değerinin belirlenmesi

Hounsfield birimi (HB), BT görüntülerinde dokuların yoğunluğunu ölçmek için kullanılan bir ölçü birimidir (Bell ve ark., 2019). Hounsfield birimi, sahip olduğu radyasyon yoğunluğuna göre gri tonlamalı bir görüntüde, vücuttaki farklı dokuların yoğunluğunu ölçmek için kullanılır. Çizelge 3.2'de radyologların BT taramalarını dokuları analiz etmek ve yorumlamasına yardımcı olan HB ölçeğini göstermektedir. Bu çalışmada, aort yapısının çevresindeki gereksiz dokuların filtrelenmesi için literatüre uygun (Bencevic ve ark., 2022) olarak HB değeri kontrastlı Dongyang veri setinde 200-500, kontrastlı KiTS veri setinde 500-1200 olarak belirlenmiştir. Elde edilen çıktılara ait görüntüler Şekil 3.4 ve 3.5'te yer almaktadır.


**Çizelge 3.2.** Hounsfield ölçeği (Bell ve ark., 2019)

| <b>ORTAM</b>             | <b>HB DEĞERİ</b> |
|--------------------------|------------------|
| <b>Hava</b>              | -1000            |
| <b>Yağ</b>               | -100             |
| <b>Su</b>                | 0                |
| <b>Yağ doku</b>          | 30-45            |
| <b>Kan</b>               | 60-90            |
| <b>İodinize kontrast</b> | 100-500          |
| <b>Trabeküler kemik</b>  | 300-800          |
| <b>Kortikal kemik</b>    | >1000            |





**Şekil 3.4.** Dongyang veri setinde BT görüntülerinde HB değerinin ayarlanması (a), (b) ve (c) sırasıyla aksiyal, sagittal ve koronal düzlemde HB değeri değiştirilmemiş görüntü taraması (d), (e) ve (f) sırasıyla aksiyal, sagittal ve koronal düzlemde HB değeri 200-500 olarak ayarlanmış görüntü taraması



**Şekil 3.5.** KiTS veri setinde BT görüntülerinde HB değerinin ayarlanması (a), (b) ve (c) sırasıyla aksiyal, sagittal ve koronal düzlemde HB değeri değiştirilmemiş görüntü taraması (d), (e) ve (f) sırasıyla aksiyal, sagittal ve koronal düzlemde HB değeri 500-1200 olarak ayarlanmış görüntü taraması

### 3.3.3 Normalizasyon


Normalizasyon işlemi sayısal verileri, belirli bir aralığa getirmek için yukarı veya aşağı ölçeklenmesidir. Bu çalışmada 16 bit BT görüntülerine 0-255 normalizasyon işlemi yapılarak veriler 8 bit'e çevrilmiştir.

### 3.4 Derin Öğrenme

Derin öğrenme, daha karmaşık sorunların çözülmesinde önemli rol alan bir tür makine öğrenimidir (Lecun, 2015). Derin öğrenmeyle denetimli, denetimsiz ve pekiştirmeli öğrenme gerçekleştirilmiş olup başarılı sonuçlar vermiştir. Karmaşık sistemlerde mantıksal yapı ile verilerin analizi için yapay sinir ağları (YSA) kullanılmaktadır. YSA olarak bilinen nöron ağlar, yeni bilgi öğrenme, yeni bilgi üretme ve yeni bilgi türetme gibi insan beyni fonksiyonlarını otomatikleştirmek amacıyla geliştirilen bilgisayar sistemleridir. Derin öğrenmede YSA' dan farklı olarak özellik çıkarma işlemleri otomatik olarak gerçekleştirilmektedir. Derin öğrenme algoritmaları kullanılarak görüntüler üzerinde sınıflandırma ve segmentasyon işlemleri gerçekleştirilmektedir. Tıp alanında derin öğrenmenin kullanıldığı yerlere örnek olarak beyin segmentasyonu (Díaz-Pernas ve ark., 2021) ,meme kanseri tespiti (Nawaz ve ark., 2018), prostat kanseri (Arvidsson ve ark., 2018), cilt kanseri (Jinnai ve ark., 2020) sayılabilir.

#### 3.4.1 Evrişimsel sinir ağı

ESA derin öğrenmede görüntüleri analiz ederek görüntüyü bölütlemeye ve sınıflandırmaya yapması için kullanılan derin bir sinir ağıdır. ESA'lar giriş görüntü matrisinden özellik çıkarımı gerçekleştirerek belirli kategoriler altında sınıflandırma işlemi yapar (Sun ve ark., 2019). Derin öğrenmede bir veri setini eğitmek ve test etmek için Şekil 3.6'da görüldüğü gibi görüntüler matris haline getirilerek evrişim, aktivasyon fonksiyonları, havuzlama ve tam bağlı katmanlardan geçirilerek sınıflandırma fonksiyonu ile sınıflandırma işlemi gerçekleştirilir.



Şekil 3.6. Evrişimsel sinir ağı genel yapısı

### 3.4.1.1 Evrişim

Evrişim katmanı girdi görüntüsünden özelliklerin çıkarıldığı ilk katmandır. Arka arkaya evrişim katmanlarının uygulanması görüntülerden kenar, köşe bilgilerinin çıkarılarak özellik öğrenme katmanı ile dokunun özelliklerinin çıkarılmasını sağlar. Girdi görüntüsüne genel olarak Şekil 3.7’de verilen 3x3 ve 5x5 filtreler uygulanarak özellik haritaları çıkarılmaktadır.

|    |   |   |
|----|---|---|
| -1 | 0 | 1 |
| -2 | 0 | 2 |
| -1 | 0 | 1 |

(a)

|    |    |   |   |   |
|----|----|---|---|---|
| -1 | -2 | 0 | 2 | 1 |
| -2 | -3 | 0 | 3 | 2 |
| -3 | -5 | 0 | 5 | 3 |
| -2 | -3 | 0 | 3 | 2 |
| -1 | -2 | 0 | 2 | 1 |

(b)

Şekil 3.7. Farklı filtre kernelleri (a) 3x3 boyutlu (b) 5x5 boyutlu

Özellik haritaları, Şekil 3.8’de gösterildiği gibi girdi görüntüsüyle filtre matrisinin çarpılmasıyla elde edilir. Evrişim işleminde, girdinin sol üst köşesinden başlayarak tamamını tarayıp özellik haritası çıkarılmaktadır. Şekil 3.9’da görüldüğü gibi görüntü matrisinin sol üstüne yerleştirilen filtre matrisiyle üst üste çakışan değerler birbiriyle çarpılarak toplanır ve özellik matrisinin ilk değeri hesaplanmış olur. Aynı şekilde tüm görüntü taranarak Şekil 3.10’da görüldüğü iki boyutlu özellik haritası elde edilir.

|   |   |   |   |   |
|---|---|---|---|---|
| 1 | 1 | 1 | 0 | 0 |
| 0 | 1 | 1 | 1 | 0 |
| 0 | 0 | 1 | 1 | 1 |
| 0 | 0 | 1 | 1 | 0 |
| 0 | 1 | 1 | 0 | 0 |

(a)

X

|   |   |   |
|---|---|---|
| 1 | 0 | 1 |
| 0 | 1 | 0 |
| 1 | 0 | 1 |

(b)

Şekil 3.8. (a) Girdi görüntüsü (b) Girdi görüntüne uygulanan filtre

|                |                |                 |   |   |  |  |  |
|----------------|----------------|-----------------|---|---|--|--|--|
| 2 <sup>1</sup> | 4 <sup>0</sup> | 7 <sup>-1</sup> | 6 | 5 |  |  |  |
| 9 <sup>1</sup> | 7 <sup>0</sup> | 1 <sup>-1</sup> | 2 | 6 |  |  |  |
| 8 <sup>1</sup> | 3 <sup>0</sup> | 4 <sup>-1</sup> | 5 | 7 |  |  |  |
| 4              | 3              | 3               | 8 | 4 |  |  |  |
| 5              | 2              | 1               | 1 | 2 |  |  |  |

|   |  |  |
|---|--|--|
| 7 |  |  |
|   |  |  |
|   |  |  |

Şekil 3.9. İlk Evrişim işleminin uygulanması

|   |   |                |                |                 |  |  |  |
|---|---|----------------|----------------|-----------------|--|--|--|
| 2 | 4 | 7              | 6              | 5               |  |  |  |
| 9 | 7 | 1              | 2              | 6               |  |  |  |
| 8 | 3 | 4 <sup>1</sup> | 5 <sup>0</sup> | 7 <sup>-1</sup> |  |  |  |
| 4 | 3 | 3 <sup>1</sup> | 8 <sup>0</sup> | 4 <sup>-1</sup> |  |  |  |
| 5 | 2 | 1 <sup>1</sup> | 1 <sup>0</sup> | 2 <sup>-1</sup> |  |  |  |

|    |    |    |
|----|----|----|
| 7  | 1  | -6 |
| 13 | -2 | -9 |
| 9  | -6 | -5 |



Şekil 3.10. Son Evrişim işleminin uygulanması

### 3.4.1.2 Evrişimde adım sayısı ve sıfır ekleme

Evrişim katmanları görüntüye uygulanırken belirli adım sayısı belirlenerek görüntü veya özellik matrisleri üzerinde gezdirilmektedir. Adım sayısı Evrişim işlemlerinde çıkış özellik matrisinin boyutunu belirlemede önemli rol oynamaktadır. Çıkış görüntü matris boyutu Denklem 3.1’de görüldüğü gibi hesaplanmakta olup n girdi görüntü matris boyutunu, f filtre boyutunu, s adım sayısını ve p dolguyu ifade etmektedir. Şekil 3.11’de görüldüğü gibi 7x7 giriş matrisine 1 adımda ve 2 adımda Evrişim işlemleri uygulanmış olup çıktı özellik matrislerinin boyu sırasıyla 5x5 ve 3x3’tür (Örnek, 2019).

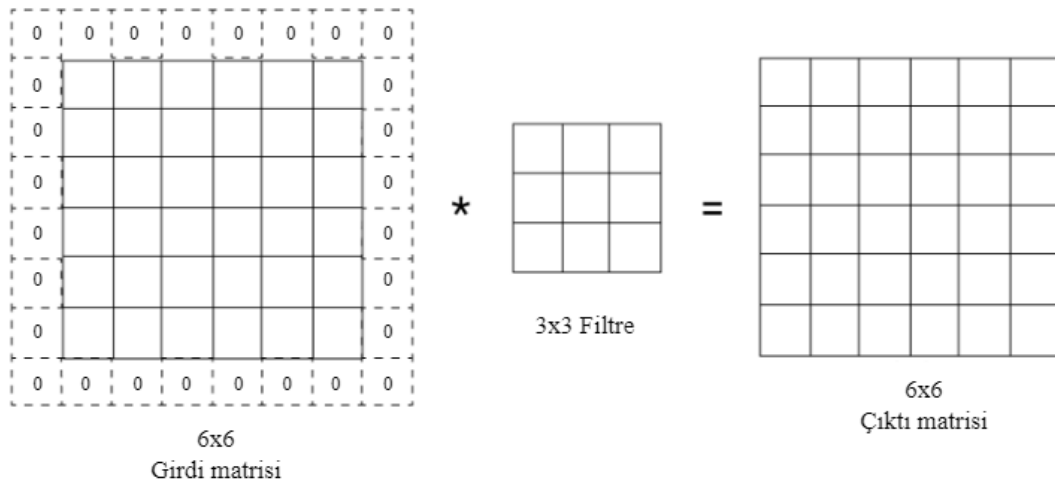
$$\left[ \frac{n+2p-f}{s} + 1 \right] \times \left[ \frac{n+2p-f}{s} + 1 \right] \quad (3.1)$$

n= Girdi görüntü matris boyutu  
f= Filtre boyutu  
s= Adım sayısı  
p= Dolgu



**Şekil 3.11.** (a) 1 adımlı Evrişim (b) 2 adımlı Evrişim

Evrişim işlem sonrasında Şekil 3.11’de girdi görüntüsü üzerinde çıkış özellik matris boyutlarının küçüldüğü görülmüştür. Bazen küçük seviyeli özellik haritaların çıkarılması için girdi matrisinin orijinal boyutu korunmalıdır. Çıktı matrisin girdi matrisiyle aynı boyutta olması için Şekil 3.12’de kesikli çizgilerle görüldüğü gibi girdi matrisinin çevresi komşu piksel değerleri ile veya sıfırlarla doldurulmaktadır.



Şekil 3.12. Görüntüler üzerinde sıfır ekleme

### 3.4.1.3 Havuzlama Katmanı

Havuzlama katmanı evrişim işleminden sonra özellik haritasının boyutunu azaltmak için kullanılmaktadır. Havuzlama katmanının yer alması aşırı öğrenmenin önüne geçer ve parametre sayısını azaltarak eğitim süresini kısaltır. Maksimum havuzlama ve ortalama havuzlama olmak üzere iki çeşit havuzlama yaklaşımı vardır. Havuzlama katmanlarında genel olarak 2x2 boyutunda ve 2 adımlık bir filtre kullanılır. Maksimum havuzlama katmanı Şekil 3.13 (a)'da görüldüğü gibi 2x2 filtre özellik matrisine yerleştirilerek maksimum piksel değeri alınır ve çıktı matrisine yazılır. Ortalama havuzlama katmanı Şekil 3.13 (b)'de görüldüğü özellik haritasına yerleştirildiği piksel değerleri toplanarak ortalama değeri çıktı matrisine yazılır. Havuzlama katmanından sonra elde edilen çıktı matrisinin boyutu Eşitlik 3.2'de görüldüğü gibi hesaplanmakta olup  $m$  özellik matrisi boyutunu,  $k$  filtre boyutunu,  $s$  adım sayısını ve  $n$  havuzlama katmanına uygulanmış matrisi ifade etmektedir.

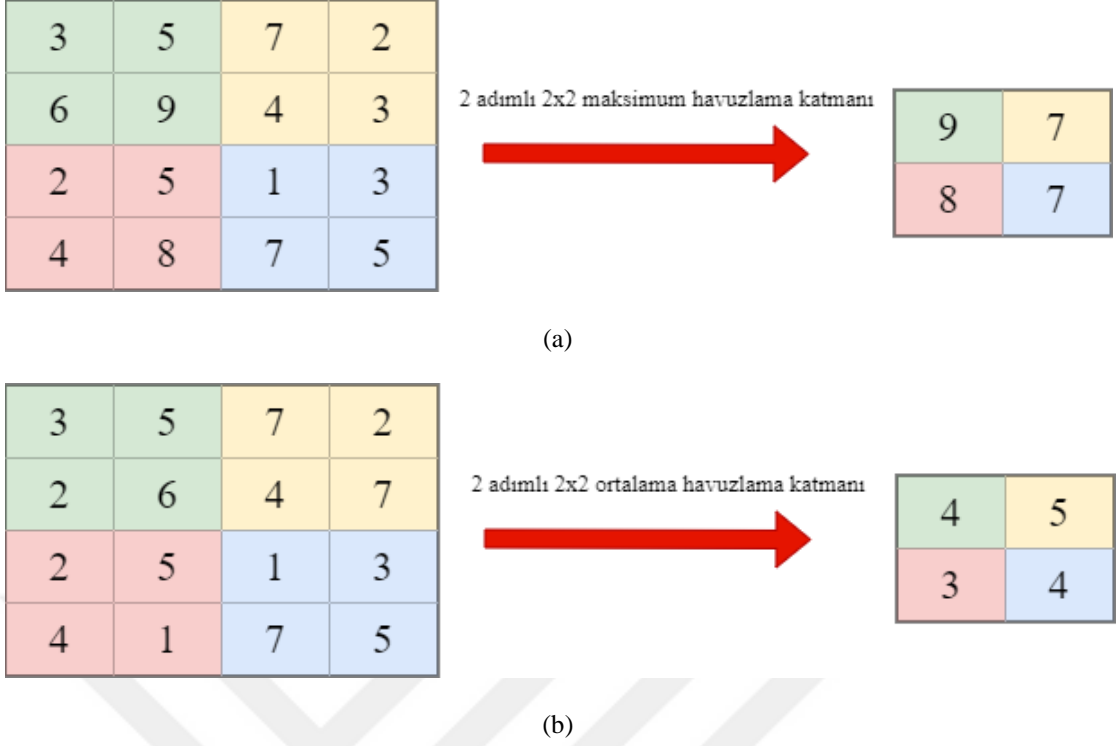
$$n = \left\lfloor \frac{m-k}{s} \right\rfloor + 1 \quad (3.2)$$

$n$ = Havuzlama katmanına uygulanmış matris

$m$ = Özellik matrisi boyutu

$k$ = Filtre boyutunu

$s$  = Adım sayısını



Şekil 3.13. Görüntü üzerinde havuzlama işlemi (a)maksimum havuzlama (b)ortalama havuzlama

#### 3.4.1.4 Düzleştirme ve Tam Bağlantı Katmanlar

Düzleştirme katmanı evrişim, havuzlama ve aktivasyon fonksiyonları sonucu elde edilen özellik haritalarındaki son katmanın özelliklerinin tek bir sütun halinde düzleştirildiği katmandır. Düzleştirme katmanında alınan çıktılar tam bağlantılı katmana girdi olarak verilir. Tam bağlantılı katmanların son katmanında sınıflandırma fonksiyonu ile sınıflandırma işlemi tamamlanır.

#### 3.4.1.5 Kayıp Fonksiyonları

Kayıp fonksiyonu, bir modelin tahmin ettiği değerlerle gerçek değerler arasındaki farkı ölçer ve bir hata (loss) değeri hesaplar. Amaç, bu hata değerini minimize etmek ve modelin performansını artırmaktır. Literatürde bir çok kayıp fonksiyonu bulunmaktadır. Tez çalışmasında segmentasyon için ikili çapraz entropi (Denklem 3.3) ve zar kaybı (Denklem 3.4) kullanılmıştır. Bu iki kayıp fonksiyonundan yararlanılarak Denklem 3.5'teki kayıp fonksiyonu hesaplanmıştır(Clarisse, 2021):

$$L_{bce} = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \quad (3.3)$$

$y_i$ = gerçek etiket

$p(y_i)$ = tahmin edilen etiket



$$L_{ZAR} = 1 - \frac{2 \times (y \cap p(y))}{y + p(y)} \quad (3.4)$$

$y$ = gerçek etiket

$p(y)$ = tahmin edilen etiket

$$L_{KYP} = L_{bce} + L_{ZAR} \quad (3.5)$$

### 3.4.1.6 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, sinir ağlarındaki bir gizli katmanın çıkış değerini belirlemek için kullanılır. ReLU, gizli katmanlar için en sık kullanılan etkinleştirme işlevidir. Sınıflandırma problemleri için softmax veya sigmoid fonksiyonunu kullanılmaktadır. Doğrultulmuş doğrusal birim (ReLU), Leaky ReLU, Sigmoid, Softmax, Tanh, ölçekli üstel doğrusal birim (SELU) ve üstel doğrusal birim (ELU) fonksiyonlarına ait matematiksel tanımlar Çizelge 3.3'te gösterilmiştir.

**Çizelge 3.3.** Aktivasyon fonksiyonları (Gürkan, 2021)

| Aktivasyon Fonksiyonunun Adı | Fonksiyonu   |
|------------------------------|--|
| ReLU                         | $f(x) = \max(0, x)$  |
| Leaky ReLU                   | $f(x) = \begin{cases} ax, & x < 0 \\ x, & x \geq 0 \end{cases}$                  |
| Sigmoid                      | $\sigma(x) = \frac{1}{1 + e^{-x}}$   |
| Softmax                      | $f(x) = \frac{e^{z_j}}{\sum_k e^{z_k}}$  |
| Tanh                         | $\tanh(x) = 2\sigma(2x) - 1$   |
| SELU                         | $selu(x) = \lambda \begin{cases} x, & x > 0 \\ ae^x - a, & x \leq 0 \end{cases}$ |
| ELU                          | $f(x) = \begin{cases} x, & x > 0 \\ a(e^x - 1), & x \leq 0 \end{cases}$          |


### 3.4.1.7 Optimizasyon Algoritmaları

Derin öğrenmede amaç, sınıflandırma probleminin başarılı bir şekilde gerçekleşmesi için iyi bir optimizasyon algoritması kullanan modelin oluşturulmasıdır. Kare ortalamalarının karekökü yayılımı (RMSprop) derin öğrenmede sıklıkla kullanılan optimizasyon algoritmalarındandır. RMS-Prop, öğrenme oranının, kare gradyanların kümülatif toplamı yerine gradyanların üstel bir ortalaması olduğu Adagrad'ın özel bir versiyonudur. RMSprop'ta öğrenme oranı otomatik olarak ayarlanır ve her parametre için

farklı bir öğrenme oranı seçmektedir. Popüler optimizasyon algoritmaları arasında Stochastic Gradient Descent (SGD), Adaptive Moment Estimation (Adam), Root Mean Squared Propagation (RMSProp) ve Momentum gibi metodlar bulunur. (Ruder ve ark., 2016)

### 3.5 Segmentasyon

Segmentasyon diğer adıyla bölütleme, bilgisayarla görmenin çok önemli bir bileşenidir. Bir görüntünün piksel özelliklerine göre anlamlı bölgelere ayrılması işleme segmentasyon denir. Görüntü bölütleme semantik segmentasyon ve örnek segmentasyon olmak üzere temel iki farklı teknik olarak incelenmektedir (Varatharasan ve ark., 2019). Semantik segmentasyon Şekil 3.14 (a)'da görüldüğü gibi, görüntüde aynı sınıfa ait tüm objelerin aynı pikselle ifade edilmesidir. Şekil 3.14 (b)'de ise örnek segmentasyon yer almaktadır ve burada aynı sınıfa ait nesnelere farklı piksel değerleri atanmıştır.



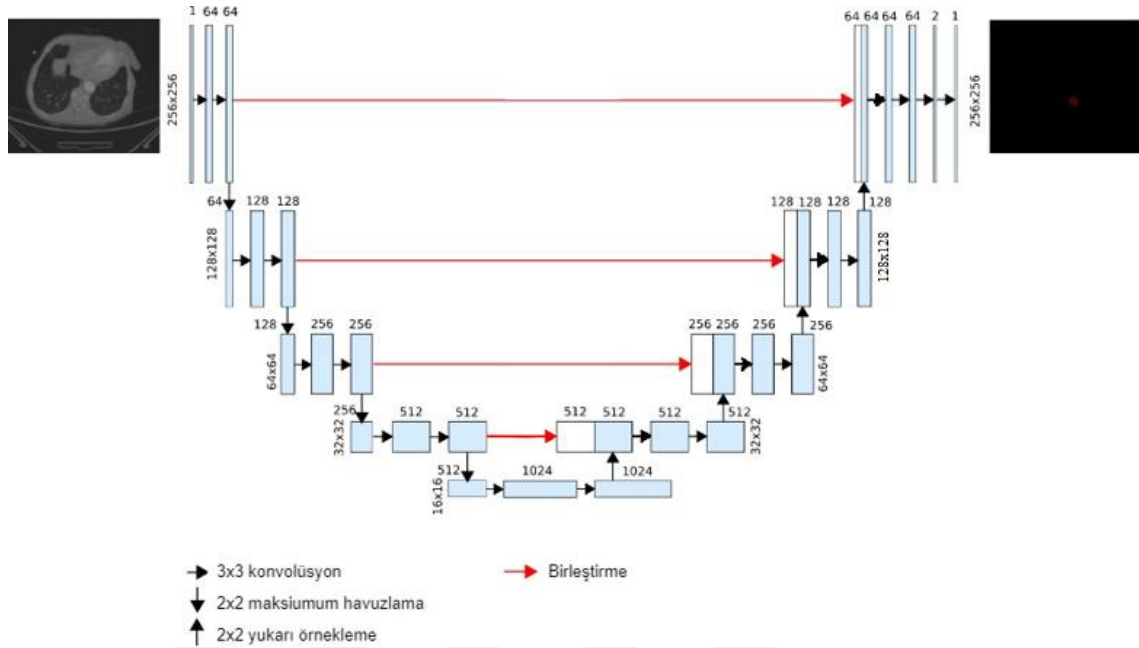
Şekil 3.14. (a) Semantik segmentasyon (b) Örnek segmentasyon (Varatharasan ve ark., 2019)

### 3.6 Segmentasyonda Kullanılan Derin Öğrenme Modelleri

#### 3.6.1 U-Net Mimarisi

İlk olarak 2015 yılında yayınlanan U-Net mimarisi (Ronneberger, 2015), yaklaşık olarak 31 milyon parametreye sahiptir. Şekil 3.15'te görüldüğü gibi U-Net mimarisinin sol kısmı kodlayıcı, ara kısmı dar boğaz ve sağ kısmın ise kod çözücü olarak tanımlanmaktadır. Girdi görüntü matrisine 3x3 filtreli iki boyutlu evrişim katmanları uygulanmaktadır. Ayrıca kodlayıcı bölümünde boyut küçültmek için her iki evrişim katmanından sonra maksimum havuzlama uygulanarak boyutlar yarıya düşürülür. Kod çözücü kısmında ise tam tersi olarak boyutlar iki katına çıkarılır. Kodlayıcı bölümünde evrişim katmanları sonrası elde edilen özellik haritaları kod çözücüde elde edilen özellik haritalarıyla birleştirilir. Son olarak çıkış katmanında

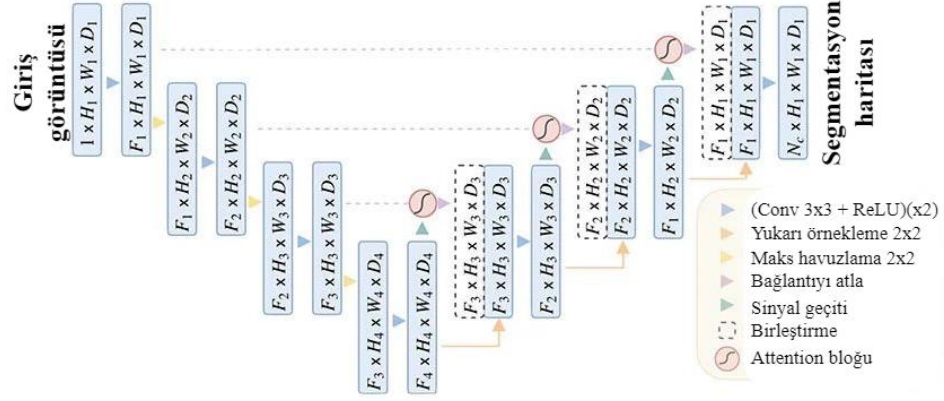
sigmoid fonksiyonu kullanılmış olup çıktı olarak tek sınıflı aort segmentasyon tahmini gerçekleştirilmektedir.



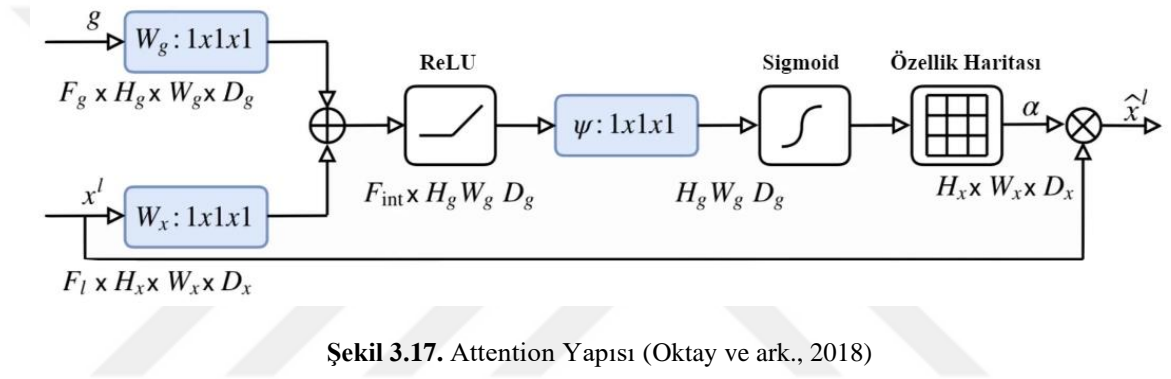
Şekil 3.15. U-Net Mimarisi (Ronneberger ve ark., 2015)

### 3.6.2 Attention U-Net Modeli

Attention U-Net, U-Net modeline Şekil 3.16’da görüldüğü gibi Attention kapı yapısı eklenerek elde edilmiştir. Bu model yaklaşık 34.87 milyon parametreye sahiptir. Bu modelde U-Net modeline ek olarak kodlayıcı kısmından düşük seviyeli özellik matrisleri ve kod çözücü kısmından gelen yüksek seviyeli özellik matrisleri aynı anda işlenerek segmentasyon performansı iyileştirilir. Şekil 3.17’de görüldüğü gibi bu özellik matrisleri ilgili bölgeye olan önemi artırır ve segmentasyon haritasını üretmektedir. Attention yapısında kodlayıcı ve kod çözücü bölümlerinden gelen vektörler 1x1 evrişim katmanından geçirilir. Sonrasında sırasıyla Relu aktivasyon fonksiyonundan, 1x1 evrişimden ve son olarak sigmoid katmanından geçer. Çıktı vektörü, kod çözücü kısmından gelen vektör ile çarpılarak kodlayıcı kısmındaki vektör ile birleştirilir.



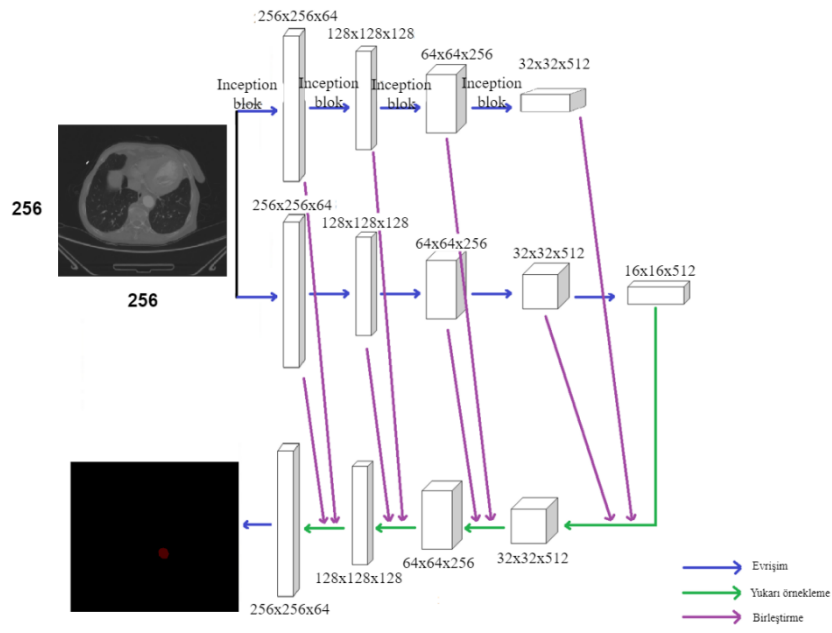
Şekil 3.16. Attention U-Net Mimarisi (Oktay ve ark., 2018)



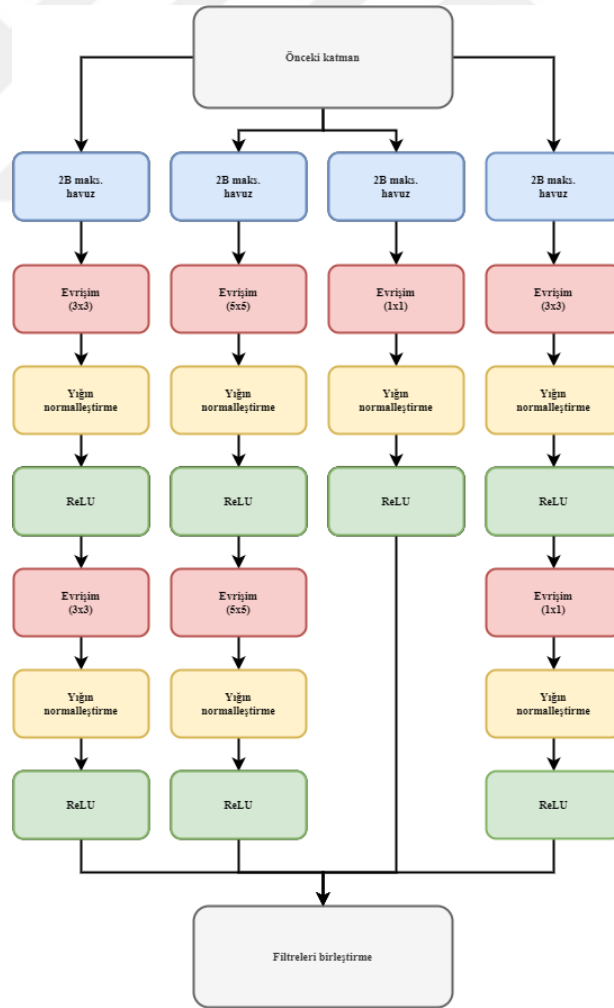
Şekil 3.17. Attention Yapısı (Oktay ve ark., 2018)

### 3.6.3 Inception U-Netv2 Modeli

Inception U-Netv2, Şekil 3.18'de görüldüğü gibi Unet modeline Inception bloklarının eklenmesiyle oluşturulmuştur ve toplamda 32.041.850 parametre içermektedir. Şekil 3.19'da görüldüğü gibi Inception block yapısında 4 farklı evrişim işleminden önce girdi matrisine maksimum havuzlama işlemi uygulanmıştır. Sonrasında ilk olarak iki defa 3x3 Evrişim, iki defa 5x5 Evrişim, 1 defa 1x1 Evrişim, son yapıda da 3x3 Evrişim ve 1x1 Evrişim işlemleri yapılmış olup her evrişim katmanından sonra ReLU aktivasyon fonksiyonu ve yığın normalizasyon uygulanmıştır.



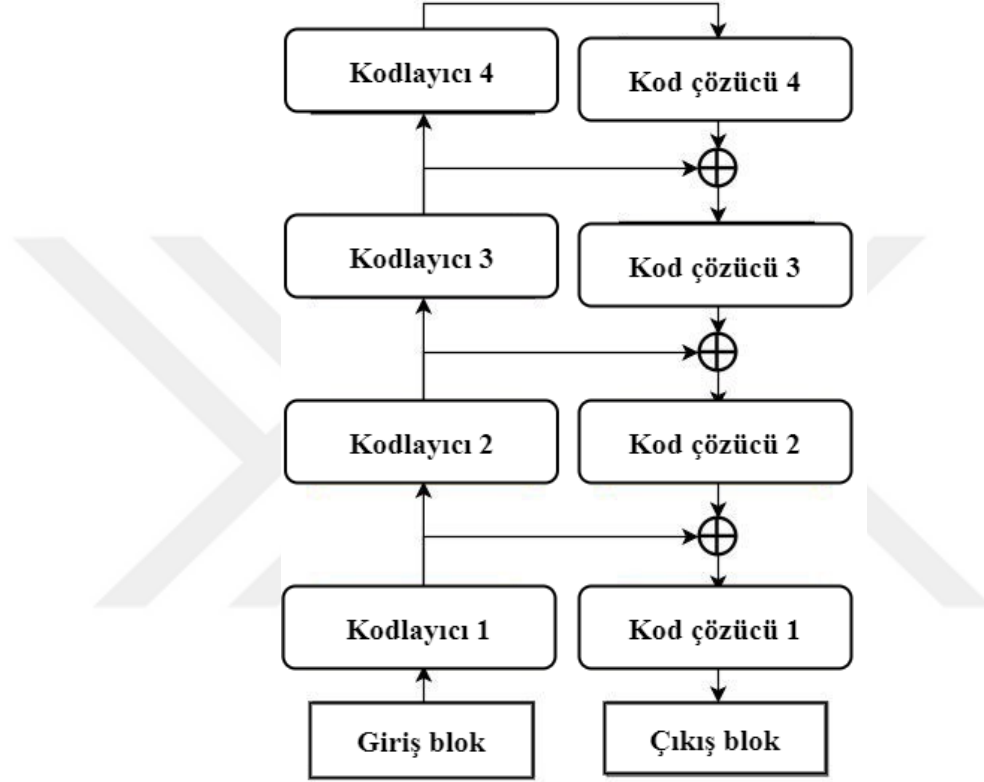
Şekil 3.18. Inception U-Netv2 Mimarisi (Delibasoglu ve Cetin, 2020)



Şekil 3.19. Inception blok

### 3.6.4 LinkNet Modeli

Yapı olarak U-Net mimarisine benzeyen LinkNet modeli, Şekil 3.20’de görüldüğü gibi kodlayıcı ve kod çözücü bölümlerinden oluşmaktadır. LinkNet modeli yaklaşık 11.5 milyon parametreye sahiptir. U-Net modeline göre parametre sayısının az olması sebebiyle daha hızlı eğitim ve test işlemi gerçekleştirebilmektedir. U-Net modelinden farkı kodlayıcı bloğundan gelen özellik haritalarının kod çözücü bloğa eklenmesidir.



Şekil 3.20. LinkNet Mimarisi (Chaurasia ve ark., 2017)

## 3.7 Segmentasyon Sonrası İşlemler


### 3.7.1 İki boyutlu çıktıların üç boyuta dönüştürülmesi

Bilgisayarlı tomografi taramalarında, merkez noktası ile aksiyal, sagittal ve koronal düzlemlerin piksel bazlı uzaklık değerleri her cihaza göre değişiklik göstermektedir. Tez çalışmasında iki boyutlu çıktı verilerini kesit numarasına göre üst üste bindirerek üç boyutlu formata getirildi. Fakat üç boyutlu görüntü taramasına merkez koordinat ve iki piksel arası mesafe değerleri verilmediği için Şekil 3.21 (a)'da görüldüğü gibi başarılı bir sonuca ulaşılamamış ve orijinal görüntü ile üst üste getirilememesine neden olmuştur. Bu sebeple dolayı nibabel kütüphanesi kullanılarak orijinal görüntüdeki

konum ve iki pikselin mesafe bilgileri üç boyutlu çıktı maske görüntüsüne aktarılarak Şekil 3.21 (b)'de görüldüğü gibi sorun düzeltilmiştir.



(a)




(b)


**Şekil 3.21.** (a) Koordinat ve pikseller arası mesafe bilgisi girilmeyen görüntü (b) Koordinat ve pikseller arası mesafe bilgisi girilen görüntü

### 3.7.2 Üç boyutlu verinin iyileştirilmesi

Derin öğrenme kullanılarak yapılan segmentasyon işleminde model, girdi görüntüleri üzerinde yanlış bölgeleri de segmente edebilmektedir. Tez çalışmasında gerçekleştirilen aort segmentasyonunda skimage kütüphanesi kullanılarak Şekil 3.22'de görüldüğü gibi aort çevresinde segmente edilen yanlış negatif objeler temizlenerek üç boyutlu görüntüler iyileştirilmiştir.



(a)



(b)



(c)

**Şekil 3.22.** Yanlış negatif olarak tespit edilen objelerin temizlenmesi (a) modelin 3B çıktısı (b) modelin iyileştirme yapılmış 3B çıktısı (c) model çıktısı ve iyileştirme yapılmış 3B çıktılarının üst üste bindirilmesi

### 3.8 Performans Değerlendirme Metrikleri

Derin öğrenme sonucu elde edilen tahmin maskelerini gerçek maske görüntüleriyle karşılaştırmak ve elde edilen sonucu değerlendirmek için karmaşıklık matrisi kullanılmaktadır. Modellerin başarısını ölçmek için birçok performans metriği vardır. Çizelge 3.4'te görüldüğü gibi tabloda sütunlar tahmin pozitif ve negatif, satırlar



dođru ve yanlıřı ifade etmektedir. Karmařıklık matrisindeki deđerler kullanarak özgülük, duyarlılık, dice benzerlik katsayısı, jaccard oranı metriklerinin hesaplamaları yapılmıřtır.

**Çizelge 3.4.** Karmařıklık matrisi

|        |             | Tahmin      |             |
|--------|-------------|-------------|-------------|
|        |             | Pozitif (1) | Negatif (0) |
| Gerçek | Pozitif (1) | DP          | YN          |
|        | Negatif (0) | YP          | DN          |

Çizelge 3.3'teki parametreler kullanılarak görüntü ve maske karşılaştırıldıđında

DP: Piksel deđeri gerçekte birken tahmin ettiđi bir olanların toplam sayısı

YN: Piksel deđeri gerçekte birken tahmin ettiđi sıfır olanların toplam sayısı

YP: Piksel deđeri gerçekte sıfırken tahmin ettiđi bir olanların toplam sayısı

DN: Piksel deđeri gerçekte sıfırken tahmin ettiđi sıfır olanların toplam sayısı

### 3.8.1 Özgülük

Eřitlik 3.6'da görüldüđü gibi, bir modelin veri kümesindeki pozitif olarak etiketlenen nesnelerin dođru bir řekilde tahmin edilme oranını ölçer. Aynı zamanda, pozitif olarak etiketlenen nesnelerin yanlıř olarak tahmin edilme oranını da göstermektedir.

### 3.8.2 Duyarlılık

Eřitlik 3.7'de görüldüđü gibi duyarlılık metriđi pozitif olarak etiketlenen nesnelerin dođru pozitif olarak tahmin edilme oranını ölçmektedir.

### 3.8.3 Dice benzerlik katsayısı (DBK)

Dice benzerlik katsayısı, piksel tabanlı bir performans ölçütüdür. Eřitlik 3.8'de görüldüđü gibi hesaplanmaktadır.

### 3.8.4 Jaccard oranı(JO)

Jaccard oranı, gerçekte maske ile model tahmini arasındaki benzerlik Jaccard oranı ile ölçülür. Jaccard oranı Eřitlik 3.9'da görüldüđü gibi hesaplanmaktadır.

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (3.6)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3.7)$$

$$\text{DBK} = \frac{2 \times DP}{2 \times DP + YP + YN} \quad (3.8)$$

$$\text{JO} = \frac{DP}{DP + YP + YN} \quad (3.9)$$

#### 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Tez çalışmasında, iliak, abdominal, torasik aort segmentasyonu için Dongyang veri setinde 18 BTA taramasından 2840 aksiyal görüntü, KiTS veri setinde ise 20 BTA taramasından 5259 aksiyal görüntü kullanılmıştır. Çalışmada model eğitimi ve test işlemlerinde Windows 10 işletim sistemi altında 2.90 GHz hızında çalışan bir Intel(R) Core (TM) i7-10700 CPU, 16.0 GB bellek ve NVIDIA® GeForce RTX 3060 12 GB ekran kartına sahip bilgisayar kullanılmıştır. Bu çalışmada eğitim ve test işlemleri spyder programında gerçekleştirilmiş olup modellerin pytorch kütüphanesi kullanılmıştır. Modelin gerçek performansını öğrenmek için veriler beş kat çapraz doğrulama ile test edilmiştir. Eğitim esnasında kullanılan hiperparametreler Çizelge 4.1 'de gösterilmiştir.

Çizelge 4.1. Dongyang ve KiTS verisetinin eğitim hiperparametreleri

|           |                  | Eğitim hiperparametreleri |              |               |                          |          |                             |
|-----------|------------------|---------------------------|--------------|---------------|--------------------------|----------|-----------------------------|
|           |                  | İterasyon                 | Parti Boyutu | Öğrenme oranı | Optimizasyon algoritması |          | Kayıp fonksiyonu            |
| Veri Seti | Dongyang ve KiTS | 50                        | 2            | 0.001         | RMSprop                  |          | Çapraz entropi + dice kaybı |
|           |                  |                           |              |               | Ağırlık azalması         | Momentum |                             |
|           |                  |                           |              |               | 1e-8                     | 0.9      |                             |

Önerilen sistem mimarisinde Dongyang ve KiTS veri setleri ilk olarak veriler 256x256 olarak yeniden boyutlandırılmıştır. Sonrasında kontrastlı Dongyang ve KiTS verilerinin HB değeri sırasıyla 200-500 ve 500-1200 olarak belirlenmiştir. Elde edilen görüntüler 0-255 arasına normalize edilmiştir. Bu işlemlerden sonra iki boyutlu aksiyal veriler U-Net, Attention U-Net, Inception U-Netv2 ve LinkNet modelleri ile eğitim ve test işlemleri gerçekleştirilmiştir. Test sonucunda tahmin edilen iki boyutlu aksiyal görüntüler orijinal görüntü taramasındaki kesit sırasına göre üst üste bindirilerek üç boyutlu görüntü haline getirilmiştir. Üç boyutlu görüntülere, nibabel kütüphanesi kullanılarak orjinal görüntü taramalarındaki koordinat bilgileri aktarılmıştır. Son olarak girdi görüntüleri üzerinde segmente edilen yanlış bölgeler skimage kütüphanesi kullanılarak küçük obje elemine etme fonksiyonu ile görüntüler üzerinde iyileştirme yapılmıştır ve 3B aort segmentasyon sonuçları MITK arayüzünde gösterilmiştir.

## 4.1 Aort Segmentasyon Sonuçları


### 4.1.1 Dongyang veri seti ile elde edilen segmentasyon sonuçları

Bu tez çalışmasında kontrastlı Dongyang veri seti kullanılarak U-Net, Attention U-Net, Inception U-Netv2 ve LinkNet modellerinde beş katlamalı çapraz doğrulama yapılarak sonuçlar karşılaştırılmıştır (Çizelge 4.2). Bu çalışmada kontrastlı Dongyang veri setinde aort segmentasyonunda dice, jaccard ve özgüllük parametrelerinde en yüksek başarı Inception U-Netv2 modelinde elde edilmiştir. LinkNet, U-Net, Attention U-Net ve Inception U-Netv2 modellerinden elde edilen iki boyutlu aksiyal görüntü sonuçları Şekil 4.1, 4.2, 4.3 ve 4.4'te görüldüğü gibidir. Son olarak Şekil 4.5 ve 4.6'da görüldüğü gibi modellerin üç boyutlu segmentasyon sonuçları gösterilmektedir.


Karşılaştırmalı analizde, en iyi performansı Inception U-Netv2 modeli elde ederken, en kötü performansı LinkNet modeli göstermiştir. Bunun nedeni LinkNet modelinin az sayıda parametre incelemesidir. Çizelge 4.4'te görüldüğü gibi LinkNet modeli en düşük eğitim ve test süresine sahiptir. Aksine, en yüksek eğitim ve test süresine sahip olan model ise Inception U-Netv2'dir. Bu bağlamda en yüksek parametre inceleyen modeldir. Inception U-Netv2 modeli Attention U-Net modeline göre daha az parametre incelerken U-Net modeline göre daha fazla parametre incelemiştir. Fakat, incelenen parametre sayılarının birbirine oldukça yakın olduğu gözlemlenmektedir. Buna karşın, en iyi performans Inception U-Netv2 modeli tarafından elde edilmiştir. Attention U-Net modeli, U-Net modeline göre Dice benzerlik katsayısı sonuçları dikkate alındığında yüksek oranda performans artırmamasına rağmen özgüllük değerini ciddi oranda artırmıştır. Özgüllük değeri sağlık veri setlerinde en çok dikkat edilmesi gereken performans değerlendirme metriklerinden bir tanesidir. Bu bağlamda, yine Inception U-Netv2 modeli en iyi duyarlılık sonucuna sahiptir.

**Çizelge 4.2.** Dongyang veri setinde model başarılarının karşılaştırılması


| Modeller          | DBK   | JO    | Özgüllük | Duyarlılık |
|-------------------|-------|-------|----------|------------|
| U-Net             | 0.925 | 0.860 | 0.909    | 1          |
| Attention U-Net   | 0.927 | 0.864 | 0.921    | 1          |
| Inception U-Netv2 | 0.935 | 0.878 | 0.928    | 1          |
| LinkNet           | 0.890 | 0.804 | 0.858    | 1          |




**Şekil 4.1.** U-Net modelinde iki boyutlu aksiyal sonuçların karşılaştırılması (a) ve (d) farklı dilimlere ait girdi görüntüsü, (b) ve (e) gerçek maske, (c) ve (f) tahmin edilen çıktı



**Şekil 4.2.** Attention U-Net modelinde iki boyutlu aksiyal sonuçların karşılaştırılması (a) ve (d) farklı dilimlere ait girdi görüntüsü, (b) ve (e) gerçek maske, (c) ve (f) tahmin edilen çıktı

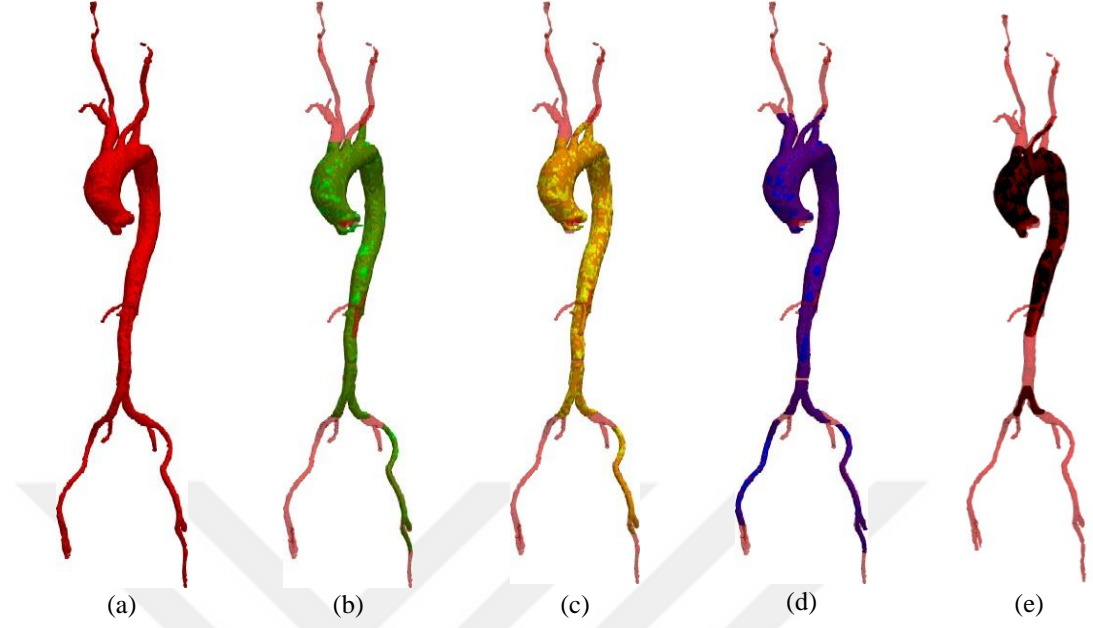


**Şekil 4.3.** Inception U-Netv2 modelinde iki boyutlu aksiyal sonuçların karşılaştırılması (a) ve (d) farklı dilimlere ait girdi görüntüsü, (b) ve (e) gerçek maske, (c) ve (f) tahmin edilen çıktı




**Şekil 4.4.** LinkNet modelinde iki boyutlu aksiyal sonuçların karşılaştırılması (a) ve (d) farklı dilimlere ait girdi görüntüsü, (b) ve (e) gerçek maske, (c) ve (f) tahmin edilen çıktı

Dongyang veri setindeki farklı test görüntülerine ait 3B model çıktıları Şekil 4.5 ve 4.6 'da gösterilmiştir.



**Şekil 4.5.** 3B Model çıktılarının 3B gerçek maskeyle karşılaştırılması (a) gerçek maske, (b) gerçek maske ve U-Net model çıktısının üst üste bindirilmesi, (c) gerçek maske ve Attention U-Net model çıktısının üst üste bindirilmesi, (d) gerçek maske ve Inception U-Netv2 model çıktısının üst üste bindirilmesi, (e) gerçek maske ve LinkNet model çıktısının üst üste bindirilmesi



**Şekil 4.6.** 3B Model çıktılarının 3B gerçek maskeyle karşılaştırılması (a) gerçek maske, (b) gerçek maske ve U-Net model çıktısının üst üste bindirilmesi, (c) gerçek maske ve Attention U-Net model çıktısının üst üste bindirilmesi, (d) gerçek maske ve Inception U-Netv2 model çıktısının üst üste bindirilmesi, (e) gerçek maske ve LinkNet model çıktısının üst üste bindirilmesi

#### 4.1.2 KiTS veri seti ile elde edilen segmentasyon sonuçları

Kontrastlı KiTS BT veri seti kullanılarak Unet, Attention U-Net, Inception U-Netv2 ve LinkNet modellerinde beş kat çapraz doğrulama yapılarak elde edilen sonuçlar Çizelge 4.3'te karşılaştırılmıştır. Bu çalışmada kontrastlı KiTS veri setinde aort segmentasyonunda dice, jaccard ve özgüllük parametrelerinde en yüksek başarı Inception U-Netv2 modelinde elde edilmiştir. LinkNet, U-Net, Attention U-Net ve Inception U-Netv2 modellerinden elde edilen iki boyutlu aksiyal görüntü sonuçları Şekil 4.7, 4.8, 4.9 ve 4.10'da görüldüğü gibidir. Modellerin iki boyutlu maske görüntülerinin birleştirilmesiyle elde edilen üç boyutlu segmentasyon sonuçları Şekil 4.11 ve 4.12'de gösterilmiştir.

Karşılaştırmalı analizde, en iyi performansı Inception U-Netv2 modeli elde etmiştir. LinkNet en kötü segmentasyon performansına sahiptir. Buna gerekçe olarak LinkNet modelinin daha az parametre incelemesi gösterilebilir. Çizelge 4.4'te görüldüğü gibi LinkNet modeli en düşük eğitim ve test süresine sahiptir. Aksine, en yüksek eğitim ve test süresine sahip olan model ise Inception U-Netv2'dir. Bu bağlamda en yüksek parametre inceleyen modeldir. Attention U-Net modeli, U-Net modeli ile aynı performansı göstermiştir. Attention mekanizması performansı bu veri seti üzerinde artırmamıştır. Dice benzerlik katsayısı yakın bir önem değerine sahip olan özgüllük sonucu dikkate alındığında, en iyi sonucu Inception U-Netv2 modeli elde etmiştir.


**Çizelge 4.3.** KiTS veri setinde model başarılarının karşılaştırılması

| Modeller          | DBK   | JO    | Özgüllük | Duyarlılık |
|-------------------|-------|-------|----------|------------|
| U-Net             | 0.863 | 0.763 | 0.830    | 1          |
| Attention U-Net   | 0.863 | 0.764 | 0.830    | 1          |
| Inception U-Netv2 | 0.866 | 0.767 | 0.832    | 1          |
| LinkNet           | 0.805 | 0.678 | 0.747    | 1          |




**Çizelge 4.4.** Dongyang ve KiTS veri setlerinde modellerin karşılaştırılması


| Modeller              | Eğitim Süresi<br>(Saat) |      | Tek Görüntü<br>Test<br>Süresi(Saniye) | Boyutu<br>(Mb) | Parametre<br>sayısı(Milyon) |
|-----------------------|-------------------------|------|---------------------------------------|----------------|-----------------------------|
|                       | Dongyang                | KiTS |                                       |                |                             |
| U-Net                 | 8                       | 17   | 0.04                                  | 121            | 31                          |
| Attention U-Net       | 10                      | 21   | 0.046                                 | 136            | 34                          |
| Inception U-<br>Netv2 | 13                      | 33   | 0.049                                 | 125            | 32                          |
| LinkNet               | 4                       | 13   | 0.034                                 | 45             | 11                          |




**Şekil 4.7.** KiTS veri setinin U-Net modelinde iki boyutlu aksiyal sonuçların karşılaştırılması (a) ve (d) farklı dilimlere ait girdi görüntüsü, (b) ve (e) gerçek maske, (c) ve (f) tahmin edilen çıktı



**Şekil 4.8.** KiTS veri setinin Attention U-Net modelinde iki boyutlu aksiyal sonuçların karşılaştırılması (a) ve (d) farklı dilimlere ait girdi görüntüsü, (b) ve (e) gerçek maske, (c) ve (f) tahmin edilen çıktı




**Şekil 4.9.** KiTS veri setinin Inception U-Netv2 modelinde iki boyutlu aksiyal sonuçların karşılaştırılması (a) ve (d) farklı dilimlere ait girdi görüntüsü, (b) ve (e) gerçek maske, (c) ve (f) tahmin edilen çıktı

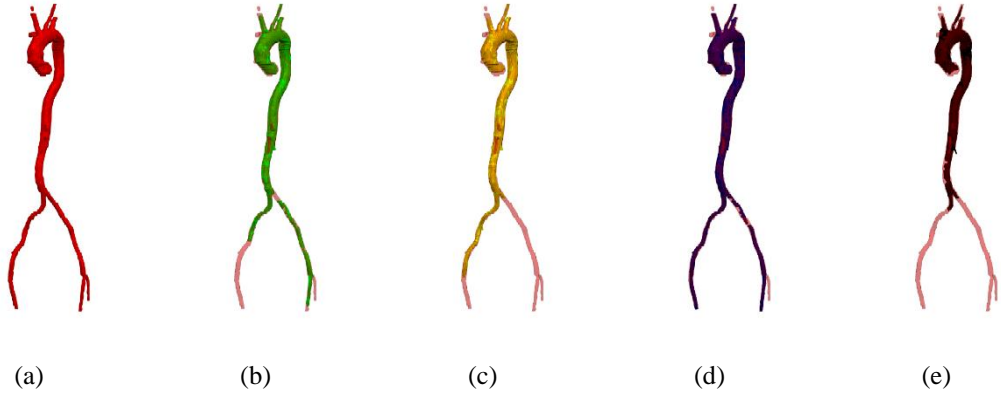


**Şekil 4.10.** KiTS veri setinin LinkNet modelinde iki boyutlu aksiyal sonuçların karşılaştırılması (a) ve (d) farklı dilimlere ait girdi görüntüsü, (b) ve (e) gerçek maske, (c) ve (f) tahmin edilen çıktı

KiTS veri setindeki farklı test görüntülerine ait 3B model çıktıları Şekil 4.11 ve 4.12 'de gösterilmiştir.



**Şekil 4.11.** 3B Model çıktılarının 3B gerçek maskeyle karşılaştırılması (a) gerçek maske, (b) gerçek maske ve U-Net çıktısının üst üste bindirilmesi, (c) gerçek maske ve Attention U-Net çıktısının üst üste bindirilmesi, (d) gerçek maske ve Inception U-Netv2 çıktısının üst üste bindirilmesi, (e) gerçek maske ve Linknet çıktısının üst üste bindirilmesi



**Şekil 4.12.** 3B Model çıktılarının 3B gerçek maskeyle karşılaştırılması (a) gerçek maske, (b) gerçek maske ve U-Net, (c) gerçek maske ve Attention U-Net, (d) gerçek maske ve Inception U-Netv2, (e) gerçek maske ve Linknet



## 5. SONUÇLAR VE TARTIŞMA

### 5.1 Sonuçlar

Tez çalışmasında, kontrastlı BT taramalarında torasik aort, abdominal aort ve iliak arterlerin segmentasyonu için bir yaklaşım önerilmiştir. Bu çalışmada kullanılan kontrastlı Dongyang ve KiTS veri setlerinin iki boyutlu aksiyal görüntülerinde yeniden boyutlandırma, HB değeri değiştirme ve normalizasyon işlemleri uygulanmıştır. Sonrasında iki farklı veri seti ayrı ayrı ve birleştirilerek iki boyutlu aksiyal görüntüler halinde LinkNet, U-Net, Attention U-Net ve Inception U-Netv2 modelleri ile eğitilmiş ve segmente edilmiştir. Elde edilen iki boyutlu aort maskeler üst üste bindirilerek üç boyutlu hale getirilmiştir. Üç boyutlu maske görüntülerinde küçük objelerin temizlenmesi ve orijinal görüntüden uzay koordinat bilgileri üç boyutlu maskeye aktararak görüntü üzerinde iyileştirme işlemleri yapılmıştır. Son olarak çıktı maskeleri MITK arayüzünde üç boyutlu olarak gösterilmiştir. Tez çalışmasında kontrastlı Dongyang veri setinde en başarılı model Inception U-Netv2 olup %93.5 Dice benzerlik katsayısı, %87.8 Jaccard, %92.8 Özgüllük, %100 Duyarlılık skoru elde edilmiştir. Kontrastlı KiTS veri setinde de en başarılı model Inception U-Netv2 olup %86.6 Dice benzerlik katsayısı, %76.7 Jaccard, %83.2 Özgüllük, %100 Duyarlılık skoru elde edilmiştir. Çalışma sonucunda kontrastlı BT görüntülerinde aort segmentasyonu gerçekleştirilmiştir. Bu bağlamda hekimlerin aort yapısının analizine yardımcı olan, doğru lokasyona müdahale edebilmeleri ve ameliyat öncesi değerlendirme yapabilmeleri için aort yapısını segmente eden bir sistem oluşturulmuştur.

### 5.2 Tartışma

Tez çalışmasında kullanılan veri seti olan Dongyangı sadece Bencevic ve ark. kullanmıştır. Bencevic ve ark. tarafından elde edilen 0.932 dice benzerlik katsayısı, bu çalışmada Inception U-Netv2 modeli kullanılarak elde edilen 0.935 dice benzerlik katsayısı sonucu ile geçilmiştir.

Dasgupta ve ark.(2017), J.-Q. Zheng ve ark.(2018), Noothout ve ark., F. Lareyre ve ark., Morris ve ark., A. Fantazzini ve ark., S. Bonechi ve ark., P.-J. Lartaud ve ark. tarafından yapılan çalışmalarda sırasıyla 0.880, 0.824, 0.910, 0.930, 0.850, 0.928 dice benzerlik katsayısı sonuçları elde edilirken, kullandıkları veri setlerinin boyutu sırasıyla 179, 24, 40, 25, 80, 153, 122 hastaya ait görüntüleri içermektedir. Buna karşın bu

çalışmada 18 hastaya ait görüntüyle eğitilen Inception U-Netv2 modeli 0.935 dice benzerlik katsayısı sonucu elde etmiştir.

Y. Yu ve ark.(2020) ve H.-J. Wang ve ark.(2022) sırasıyla 25 ve 179 hastaya ait görüntüleri kullanırken yaptıkları çalışmada sırasıyla 0.958 ve 0.970 dice benzerlik katsayısı sonuçlarına ulaşmışlardır. Bu bağlamda yapmış olduğumuz çalışmaya göre daha yüksek performans elde etmişlerdir. Bunun bir nedeni tez çalışmasında kullanılan veri sayısından daha fazla veri ile çalışmış olmalarıdır.

KiTS, başlıca böbrek ve böbrek tümörü segmentasyonuna yönelik olarak oluşturulmuş bir veri setidir. KiTS veri seti kullanılarak aort segmentasyonuna yönelik yürütülen bir çalışmaya literatürde tez çalışması sırasında rastlanmamıştır. Bu kapsamda, KiTS veri setinin kullanımı ile literatüre katkıda bulunulmuştur. KiTS veri seti henüz klinik olarak yeteri kadar doğrulanmadığı için elde edilen performans değerlendirme metrikleri sonuçları mevcut literatürdeki diğer veri setlerine göre daha düşüktür.

**Çizelge 5.1.** Dongyang ve KiTS veri seti sonuçlarının diğer çalışmalarla karşılaştırılması

| Çalışma   | Yayın yılı  | Görüntü sayısı | Dice         | Jaccard      | Özgüllük     | Duyarlılık |
|---|-------------|----------------|--------------|--------------|--------------|------------|
| Dasgupta ve ark.                                    | 2017        | 179            | 0.880        | X            | X            | X          |
| J.-Q. Zheng ve ark.                                 | 2018        | -              | 0.824        | X            | X            | X          |
| Noothout ve ark.                                    | 2018        | 24             | 0.910        | X            | X            | X          |
| F. Lareyre ve ark.                                  | 2019        | 40             | 0.930        | 0.870        | 0.900        | 0.999      |
| Morris ve ark.                                      | 2019        | 25             | 0.850        | X            | X            | X          |
| A. Fantazzini ve ark.                               | 2020        | 80             | 0.928        | 0.866        | X            | X          |
| Y. Yu ve ark.                                       | 2020        | 25             | 0.958        | X            | X            | X          |
| S. Bonechi ve ark.                                  | 2021        | 153            | X            | 0.835        | X            | X          |
| P.-J. Lartaud ve ark.                               | 2021        | 122            | 0.920        | X            | X            | X          |
| H.-J. Wang ve ark.                                  | 2022        | 179            | 0.970        | X            | X            | X          |
| Bencevic ve ark.                                    | 2022        | 18             | 0.932        | X            | X            | X          |
| <b>Tez çalışması (Dongyang) (Inception U-Netv2)</b> | <b>2023</b> | <b>18</b>      | <b>0.935</b> | <b>0.878</b> | <b>0.928</b> | <b>1</b>   |
| <b>Tez çalışması (KiTS) (Inception U-Netv2)</b>     | <b>2023</b> | <b>20</b>      | <b>0.866</b> | <b>0.767</b> | <b>0.832</b> | <b>1</b>   |

Gelecek arařtırmalara ynelik olarak yapılabilcek neriler ařađıda verilmiřtir;

1. U-Net mimari tasarımımda performansı artıran en nemli mimari yapı, atlama bađlantıları olarak karřımıza çıkmaktadır. Bu nedenle atlama bađlantıları evriřim katmanları ile desteklenebilir. Bu blme yođun veya artık bloklar eklenebilir.
2. U-Net mimarisinde yer alan evriřim katmanlarına ait filtre sayıları azaltılabilir. Bylelikle incelenen parametre sayısı dřrlebilir. Ayrıca bařka bir parametre sayısı azaltma yntemi olarak, derinlemesine, noktasal ve geniřletilmiř evriřimler kullanılabilir.
3. Aort yapısı eliptik olması nedeniyle, eliptik nesnelere ynelim sađlayacak yeni bir kayıp fonksiyonu geliřtirilebilir.
4. Kontrastlı BT grntlerde aort segmentasyonunda derin đrenme model çıktılarına merkez nokta belirlenerek grnt iřlemede blge bytme, eřik deđer belirleme vb. metodlar kullanılarak hibrit alıřabilecek bir sistem oluřturulup segmentasyon sonularında iyileřtirme yapılabilir.
5.  boyutlu aort yapısı sanal gereklik uygulamalarına entegre edilerek uzmanlara gerek zamanlı damar analizi sađlayacak sistem oluřturulabilir.

## KAYNAKLAR

Adam, C., Fabre, D., Mougin, J., Zins, M., Azarine, A., Ardon, R., D'Assignies, G., ve Haulon, S., 2021, Pre-surgical and Post-surgical Aortic Aneurysm Maximum Diameter Measurement: Full Automation by Artificial Intelligence, *European Journal of Vascular and Endovascular Surgery*, 62(6), 869–877.

Aggarwal, S., Qamar, A., Sharma, V., ve Sharma, A., 2011, Abdominal aortic aneurysm: A comprehensive review, *Experimental & Clinical Cardiology*, 16 (1), 11.

Arvidsson, I., Overgaard, N. C., Marginean, F. E., Krzyzanowska, A., Bjartell, A., Åström, K., Heyden, A., 2018, Generalization of prostate cancer classification for multiple sites using deep learning, *In 2018 IEEE 15th International Symposium on Biomedical Imaging*, 191-194.

Bahia, S. S., Karthikesalingam, A., ve Thompson, M. M., 2013, Abdominal aortic aneurysms: endovascular options and outcomes - proliferating therapy, but effective?, *Progress in Cardiovascular Diseases*, 56(1), 19–25.

Bell, D., ve Greenway, K., 2019, Hounsfield Unit, *Radiopaedia.Org*.

Benčević, M., Habijan, M., Galićgalić, I., ve Babin, D., 2022, Using the Polar Transform for Efficient Deep Learning-Based Aorta Segmentation in CTA Images, *2022 International Symposium ELMAR, IEEE*, 191-194.

Bonechi, S., Andreini, P., Mecocci, A., Giannelli, N., Scarselli, F., Neri, E., Bianchini, M., ve Dimitri, G. M., 2021, Segmentation of aorta 3D CT images based on 2D convolutional neural networks, *Electronics (Switzerland)*, 10 (20), 2559.

Chaurasia, A., ve Culurciello, E., 2017, Linknet: Exploiting encoder representations for efficient semantic segmentation, *2017 IEEE Visual Communications and Image Processing (VCIP)*, 1-4.

Clarisse, K. N. I., 2021, “Üretken çekişmeli ağ ve unet kullanılarak segmente edilmiş tomografi görüntülerinden covid-19 sınıflandırmasında farklı derin öğrenme mimarilerinin kullanımı”, Yüksek lisans tezi, *Konya Teknik Üniversitesi*.

Dasgupta, A., Mukhopadhyay, S., Mehre, S. A., & Bhattacharyya, P., 2017, Morphological geodesic active contour based automatic aorta segmentation in thoracic CT images, *Advances in Intelligent Systems and Computing*, 460, 187–195.

Delibasoglu, I., ve Cetin, M., 2020, Improved U-Nets with inception blocks for building detection, *Journal of Applied Remote Sensing*, 14(4), 044512.

Díaz-Pernas, F. J., Martínez-Zarzuela, M., Antón-Rodríguez, M., & González-Ortega, D., 2021, A deep learning approach for brain tumor classification and segmentation using a multiscale convolutional neural network, *In Healthcare*, 9(2), 153.



Fantazzini, A., Esposito, M., Finotello, A., Auricchio, F., Pane, B., Basso, C., Spinella, G., ve Conti, M., 2020, 3D Automatic Segmentation of Aortic Computed Tomography Angiography Combining Multi-View 2D Convolutional Neural Networks, *Cardiovascular Engineering and Technology*, 11 (5), 576–586.

Gürkan, Ç., 2021, Endüstri 4.0 ve Dijital Dönüşüm Teknolojileri ile Desteklenen Akıllı Fabrika Yönetim ve Bilişim Sisteminin Geliştirilmesi”, Yüksek lisans tezi, İzmir Katip Çelebi Üniversitesi.

Hahn, L. D., Mistelbauer, G., Higashigaito, K., Koci, M., Willeminck, M. J., Sailer, A. M., Fischbein, M., ve Fleischmann, D., 2020, CT-based True- and False-Lumen Segmentation in Type B Aortic Dissection Using Machine Learning, *Radiology. Cardiothoracic Imaging*, 2 (3).

Hu, G., Ding, N., Wang, Z., & Jin, Z., 2022, The association of body composition with abdominal aortic aneurysm growth after endovascular aneurysm repair, *Insights into Imaging*, 13(1), 1–11.

Jinnai, S., Yamazaki, N., Hirano, Y., Sugawara, Y., Ohe, Y., Hamamoto, R., 2020, The development of a skin cancer classification system for pigmented skin lesions using deep learning, *Biomolecules*, 10(8), 1123.

Lareyre, F., Adam, C., Carrier, M., Dommerc, C., Mialhe, C., ve Raffort, J., 2019, A fully automated pipeline for mining abdominal aortic aneurysm using image segmentation, *Scientific Reports 2019 9:1*, 9 (1), 1–14.

Lartaud, P. J., Hallé, D., Schleef, A., Dessouky, R., Vlachomitrou, A. S., Douek, P., Rouet, J. M., Nempont, O., ve Boussel, L., 2021, Spectral augmentation for heart chambers segmentation on conventional contrasted and unenhanced CT scans: an in-depth study, *International Journal of Computer Assisted Radiology and Surgery*, 16(10), 1699–1709.

Lecun, Y., Bengio, Y., & Hinton, G., 2015, Deep learning, *Nature* 2015, 7553, 436–444.

López-Linares, K., Stephens, M., García, I., Macía, I., González Ballester, M. Á., ve José Estepar, R. S., 2019, Abdominal Aortic Aneurysm Segmentation Using Convolutional Neural Networks Trained with Images Generated with a Synthetic Shape Model,” *Machine Learning and Medical Engineering for Cardiovascular Health and Intravascular Imaging and Computer Assisted Stenting : First International Workshop, MLMECH 2019, and 8th Joint International Workshop, CVII-STENT 2019, Held in Conj, 11794*, 167-174.

Martinez, K., 2020 , Everything you need to know about abdominal aortic aneurysms, *MedicalNewsToday*, <https://www.medicalnewstoday.com/articles/abdominal-aortic-aneurysm>: [ Ziyaret Tarihi: 15 Nisan 2022]

Mercan, K., Civalek, Ö., 2017, What is The Correct Mechanical Model of Aorta Artery, *International Journal of Engineering and Applied Sciences*, 9(2), 138–146.

Morris, E. D., Ghanem, A. I., Dong, M., Pantelic, M. V., Walker, E. M., ve Glide-Hurst, C. K., 2020, Cardiac substructure segmentation with deep learning for improved cardiac sparing. *Medical Physics*, 47(2), 576–586.

Nawaz, M., Sewissy, A. A., Soliman, T. H. A., 2018, Multi-class breast cancer classification using deep learning convolutional neural network, *Int. J. Adv. Comput. Sci. Appl*, 9(6), 316-332.

Noothout, J. M. H., de Vos, B. D., Wolterink, J. M., ve Isgum, I., 2018, Automatic Segmentation of Thoracic Aorta Segments in Low-Dose Chest CT, *Medical Imaging 2018: Image Processing*, 63, 446-451.

Oktay, O., Schlemper, J., Folgoc, L. Le, Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y., Kainz, B., Glocker, B., ve Rueckert, D., 2018, Attention u-net: Learning where to look for the pancreas, *arXiv preprint arXiv:1804.03999*.

Örnek, A. H., 2019, “Yeni doğan bebeklerin termal görüntülerinin derin öğrenme yöntemleri ile sınıflandırılması”, Doktora tezi, *Konya Teknik Üniversitesi*.

Princeton, C., 2022, The health board, In Anatomy, what is a Lumen?, <https://www.thehealthboard.com/in-anatomy-what-is-a-lumen.htm>: [Ziyaret Tarihi: 4 Ocak 2023]

Radl, L., Jin, Y., Pepe, A., Li, J., Gsaxner, C., Zhao, F. hua, ve Egger, J., 2022, AVT: Multicenter aortic vessel tree CTA dataset collection with ground truth segmentation masks, *Data in Brief*, 40, 107801.

Ronneberger, O., Fischer, P., ve Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, *International Conference on Medical image computing and computer-assisted intervention*, 234-241.

Ruder, S., 2016, An overview of gradient descent optimization algorithms, arXiv preprint arXiv:1609.04747.

Sieren, M. M., Widmann, C., Weiss, N., Moltz, J. H., Link, F., Wegner, F., Stahlberg, E., Horn, M., Oecherting, T. H., Goltz, J. P., Barkhausen, J., ve Frydrychowicz, A., 2022, Automated segmentation and quantification of the healthy and diseased aorta in CT angiographies using a dedicated deep learning approach, *European Radiology*, 32(1), 690–701.

Sparks, A. R., Johnson, P. L., ve Meyer, M. C., 2002, Imaging of Abdominal Aortic Aneurysms, *American Family Physician*, 65 (8), 1565–1570.

Sun, Y., Xue, B., Zhang, M., ve Yen, G. G., 2019, Evolving deep convolutional neural networks for image classification, *IEEE Transactions on Evolutionary Computation*, 24(2), 394-407.

Vadapalli, V., 2021, Image Segmentation Techniques [Step By Step Implementation] upGrad blog, <https://www.upgrad.com/blog/image-segmentation-techniques/>: [Ziyaret Tarihi: 19 Ekim 2022]

Varatharasan, V., Shin, H. S., Tsourdos, A., ve Colosimo, N., 2019, Improving Learning Effectiveness for Object Detection and Classification in Cluttered Backgrounds, *2019 International Workshop on Research, Education and Development on Unmanned Aerial Systems*, 78–85.

Wang, H. J., Chen, L. W., Lee, H. Y., Chung, Y. J., Lin, Y. T., Lee, Y. C., Chen, Y. C., Chen, C. M., ve Lin, M. W., 2022, Automated 3D Segmentation of the Aorta and Pulmonary Artery on Non-Contrast-Enhanced Chest Computed Tomography Images in Lung Cancer Patients, *Diagnostics*, 12(4), 967.

Wolf, I., Vetter, M., Wegner, I., Böttger, T., Nolden, M., Schöbinger, M., Hastenteufel, M., Kunert, T., ve Meinzer, H. P., 2005, The Medical Imaging Interaction Toolkit, *Medical Image Analysis*, 9(6), 594–604.

Yu, Y., Gao, Y., Wei, J., Liao, F., Xiao, Q., Zhang, J., Yin, W., ve Lu, B., 2021, A Three-Dimensional Deep Convolutional Neural Network for Automatic Segmentation and Diameter Measurement of Type B Aortic Dissection, *Korean Journal of Radiology*, 22 (2), 168–178.

Zheng, J.-Q., Zhou, X.-Y., Li, Q.-B., Riga, C., ve Yang, G.-Z., 2018, Abdominal aortic aneurysm segmentation with a small number of training subjects, *arXiv preprint arXiv:1804.02943*.