

**T.C.**  
**GEBZE TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**LOMBER MR DİSK KONUMLARININ EN KISA YOL**  
**ALGORİTMALARININ YAPAY SİNİR AĞI SONUÇLARINA**  
**UYGULANARAK BULUNMASI**

**MERVE KAYA**  
**YÜKSEK LİSANS TEZİ**  
**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**GEBZE**  
**2019**

**T.C.  
GEBZE TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**LOMBER MR DİSK KONUMLARININ EN  
KISA YOL ALGORİTMALARININ YAPAY  
SİNİR AĞI SONUÇLARINA UYGULANARAK  
BULUNMASI**

**MERVE KAYA  
YÜKSEK LİSANS TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMANI  
PROF. DR. YUSUF SİNAN AKGÜL**

**GEBZE  
2019**

**T.R.**  
**GEBZE TECHNICAL UNIVERSITY**  
**GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES**

**ESTIMATION OF THE LUMBAR DISC  
POSITIONS BY SHORTEST PATH  
ALGORITHMS ON NEURAL NETWORK  
RESULTS**

**MERVE KAYA**  
**A THESIS SUBMITTED FOR THE DEGREE OF  
MASTER OF SCIENCE**  
**DEPARTMENT OF COMPUTER ENGINEERING**

THESIS SUPERVISOR  
PROF. DR. YUSUF SINAN AKGUL

**GEBZE**  
**2019**

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 10/07/2019 tarih ve 2019/31 sayılı kararıyla oluşturulan jüri tarafından 29/07/2019 tarihinde tez savunma sınavı yapılan Merve KAYA'nın tez çalışması Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

**JÜRİ**

ÜYE

(TEZ DANIŞMANI) : Prof. Dr. Yusuf Sinan AKGÜL

ÜYE

: Dr. Öğr. Üyesi Yakup GENÇ

ÜYE

: Dr. Öğr. Üyesi Ayşe Betül OKTAY

**ONAY**

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun  
...../...../..... tarih ve ...../..... sayılı kararı.

## ÖZET

İnsan omurgasının anatomik yapısının tespit edilmesi fitik, disk kayması, skalyoz gibi hastalıkların teşhisi için önemlidir. Omurganın otomatik olarak tespit edilebilmesi için son zamanlarda birçok derin öğrenme tabanlı yöntemler önerilmiştir. İnsan omurgasının görüntülenme yöntemlerinden biri Manyetik Rezonans (MR)'dir. Bu çalışmada bir bel MR görüntüsünde bulunan omurgadaki disklerin otomatik olarak bulunması için derin öğrenme tabanlı üç farklı yöntem denenmiştir.

Birinci yöntem olan İki Katmanlı Evrişimli Sinir Ağları (ESA), iki aşamadan oluşmaktadır. İlk aşamada her disk için, merkezlerinden belli uzaklıklarda görüntü parçaları alınıp farklı boyutlarda birleştirilmiş ve eğitilerek inanç haritaları çıkarılmıştır. İlk aşamada üretilen sonuçlar ikinci aşamada girdi olarak kullanılmaktadır. İkinci aşamada ise bu inanç haritaları ile beraber disklerin kendi öz nitelikleri birleştirilerek eğitim ve test süreci gerçekleşmiştir.

İkinci yöntem olan Tek Aşamalı ve Saklı Markov Modeli (SMM) tabanlı Faster RCNN'de, nesne bulmada son dönemlerde popüler olan Faster RCNN kullanılmıştır. Tekli aşamalı Faster RCNN'de sadece diskler eğitilirken, SMM tabanlı Faster RCNN'de sistem SMM'ye benzetilerek disklerin yanında komşu diskler de eğitilmiş ve test edilmiştir.

Üçüncü yöntem olan en kısa yol algoritması tabanlı Faster RCNN'de, sistem ağırlıklı çizge olarak düşünülmüş ve eğitim iki aşamadan oluşmaktadır. Eğitimin ilk aşamasında Faster RCNN yöntemi kullanılarak aday diskler bulunmuş ve her aday disk, çizgede bir düğüme karşılık gelmiştir. İkinci eğitim aşamasında ise, iki komşu diskin öğrenilebilmesi için ayrı bir Evrişimli Sinir Ağı (ESA) eğitilmiştir. Çizgedeki bağlantıların ağırlıkları, iki aşamadan çıkan puanlardan hareketle bir formül ile hesaplanmış ve çizgedeki en kısa yolu bulabilmek için Dijkstra'nın en kısa yol algoritması kullanılmıştır.

**Anahtar Kelimeler: Bel MR görüntüsü, Lumbar disk tespiti, Faster RCNN, Dijkstra'nın en kısa yol algoritması.**

## SUMMARY

Detection and identification of the anatomical structure of the human vertebrae is important for the diagnosis of diseases such as hernia, disc slippage, scoliosis. A lot of deep learning methods have recently been proposed for the automatic detection of the vertebrae. One of the scanning methods of human vertebrae is Magnetic Resonance (MR). In this work, we present three different methods based on the deep learning algorithms for the automatic detection and identification of the intervertebral discs on a MR image.

First method, two stage CNN, consists of two steps. In the first stage, image patches are cropped for each disc, from their centers with different distances and different scales. Image patches which has same center and distances are combined in a single image. These images are trained and according to distances, heatmaps are created. In the second stage network is trained and tested by combining of these heatmaps with feature vector of discs.

In second method, single stage and Hidden Markov Model (HMM) based Faster Region based Convolutional Neural Network (FRCNN) is used which is the recently popular object detection method. While in single stage FRCNN, each disc is trained, in HMM based FRCNN, system simulate to HMM and two sequential neighbor discs are also trained and tested.

In third method, shortes path algorithm based Faster RCNN, system is thought like a weighted graph. It consists of two stage. In first stage FRCNN find candidate discs. These candidate discs correspond a node in a graph. In second stage, to learn relation between two discs, Convolutional Neural Network (CNN) is trained. To calculate weight of edges, scores which is come from two stages are given to formula and finally Dijkstra's Algorithm is used to find shortest path in the graph.

**Key Words: Spine MRI, Lumbar disc detection, Faster RCNN, Dijkstra's Algorithm.**

## TEŐEKKÜR

BaŐta, lisans ve y¼ksek lisans eđitimimde desteđini ve yardımlarını hiçbir zaman esirgemeyip, bilgisi ile bu çalıŐmanın oluŐmasının yolunu ačan danıŐmanım Prof. Dr. Yusuf Sinan AKG¼L hocama, tezin uygulama aŐamasında laboratuvarın her t¼rl¼ imkanlarından yararlanmamı sađlayan T¼BİTAK BİLGEM B3Lab'a, her t¼rl¼ manevi destekleri ve bana olan inançları için aileme, her zorlukta yanımda olan ve bu tezin yazımında b¼y¼k miktarda yardımcı olan sevgili eŐim Mehmet ZEYBEL'e en içten teŐekk¼rlerimi sunarım.

# İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ	xi
1. GİRİŞ	1
1.1. İnsan Omurgası	1
1.2. Omurga Görüntüleme Yöntemleri	3
1.3. Tezin Amacı, Katkısı ve İçeriği	4
2. VERİ KÜMESİ	6
3. LİTARATÜR ÇALIŞMASI	7
3.1. Makine Öğrenmesi Tabanlı Yöntemler	7
3.2. Derin Öğrenme Tabanlı Yöntemler	8
4. CONVOLUTIONAL POSE MACHINES MAKALESİNİN DİSKLERE UYGULANMASI	11
4.1. Convolutional Pose Machines makalesi	11
4.2. Convolutional Pose Machines makalesi yöntemleri ile Disklerin Otomatik Bulunması	12
4.2.1 Veri Kümesi ve Sınıfların Oluşturulması	12
4.2.2 İki Aşamalı Eğitim ve Test Yöntemleri	14
4.2.3 Kullanılan Sistemin Özellikleri	22
5. TEK AŞAMALI VE SMM TABANLI FASTER RCNN	23
5.1. Tek Aşamalı Faster RCNN	23
5.2. Saklı Markov Modeli (SMM) Tabanlı Faster RCNN	27
6. EN KISA YOL ALGORİTMASI TABANLI FASTER RCNN	31
6.1. İlk Eğitim Aşaması: Önceden Eğitilmiş Faster RCNN	31
6.2. İkinci Eğitim Aşaması: Evrişimli Sinir Ağları	32
6.3. Test Aşaması	35

6.4. Deneyley	37
7. SONUÇLAR	43
KAYNAKLAR	45
ÖZGEÇMİŞ	50
EKLER	51

## SİMGELER ve KISALTMALAR DİZİNİ

<u>Simgeler ve</u>	<u>Açıklamalar</u>
<u>Kısaltmalar</u>	
Dak.	: Dakika
mm	: Milimetre
sn	: Saniye
2B	: 2 Boyutlu
3B	: 3 Boyutlu
BT	: Bilgisayarla Tomografi
ESA	: Evrişimli Sinir Ağları
DPM	: Deforme Parça Modeli
DVM	: Destekçi Vektör Makinesi
GTÜ	: Gebze Teknik Üniversitesi
MR	: Manyetik Rezonans Görüntüleme
ROA	: Rastgele Orman Algoritması
SGD	: Stochastic Gradient Descent
SMM	: Saklı Markov Modeli
TESA	: Tekli Evrişimli Sinir Ağları
TÜBİTAK	: Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
YGH	: Yönlü Gradyan Histogramı

# ŞEKİLLER DİZİNİ

<u>Şekil No:</u>		<u>Sayfa</u>
1.1:	Omurganın yapısı, omur çeşitleri, omur ve disk yapıları gösterimi.	2
1.2:	Sırasıyla T1 ve T2 ağırlıklı MR görüntüleri.	4
1.3:	Bel MR görüntüsü ve üzerinde bulunan bel diskleri.	5
4.1:	Convolutional Pose Machines makalesinden örnek sistem adımları.	11
4.2:	Veri kümesinde bulunan örnek bel MR görüntüleri ve disk merkezleri işaretlenmiş örnek bel MR görüntüsü.	12
4.3:	Farklı boyutlarda çıkarılmış görüntü parçacıkları.	13
4.4:	İki katmanlı ESA'nın birinci aşamasının eğitim kısmı.	15
4.5:	İki katmanlı ESA'nın birinci aşamasının test kısmı.	16
4.6:	Birinci aşama test sonuçları.	17
4.7:	İki katmanlı ESA'nın ikinci aşamasının eğitim kısmı.	18
4.8:	İki katmanlı ESA'nın ikinci aşamasının test kısmı.	19
4.9:	Örnek bir MR görüntüsünün, sistemdeki tüm aşamaları.	21
4.10:	Test kümesi üzerinde kötü sonuçlar veren görüntüler. Sırasıyla disk sınıflandırıcılarının sonuçlarının çevritlerinin çıkarımı.	21
4.11:	Sırasıyla disk sınıflandırıcılarının sonuçlarının çevritlerinin çıkarımı.	22
5.1:	Tek aşamalı ESA'nın eğitim ve test adımları.	26
5.2:	SMM tabanlı Faster RCNN'nin eğitim ve test adımları.	28
5.3:	8 çapraz katman doğrulama yöntemindeki katmanların doğruluk değerleri.	29
5.4:	SMM tabanlı Faster RCNN yönteminden örnek MR görüntüleri.	30
6.1:	Veri kümesinden örnek bir MR görüntüsü.	32
6.2:	İkili komşu diskin farklı boyutlarda, eğitim kümesi oluşturma adımları.	33
6.3:	En kısa yol tabanlı Faster RCNN'nin eğitim aşamaları.	34
6.4:	En kısa yol tabanlı Faster RCNN'nin test aşamaları.	36
6.5:	Dijkstra's Algoritmasının sistemdeki görsel hali.	37
6.6:	10 çapraz katman doğrulama yöntemi sonuç grafiği.	37
6.7:	En kısa yol tabanlı Faster RCNN sistem sonuçları.	40

## TABLolar DİZİNİ

<b><u>Tablo No:</u></b>		<b><u>Sayfa</u></b>
5.1	Tekli ve SMM tabanlı Faster RCNN sonuçlarının karşılaştırılması.	30
6.1	Tüm sistemin TP ve FP sonuçlarında, doğruluk değeri, dice puanı, merkezden hata miktarı ve standart sapma değerlerini göstermektedir.	39
6.2	Bu alanda daha önceden makalelerdeki, bir bel MR/BT görüntüsündeki disklerin/omurların bulunması için uygulanan yöntemlerin karşılaştırılması.	42

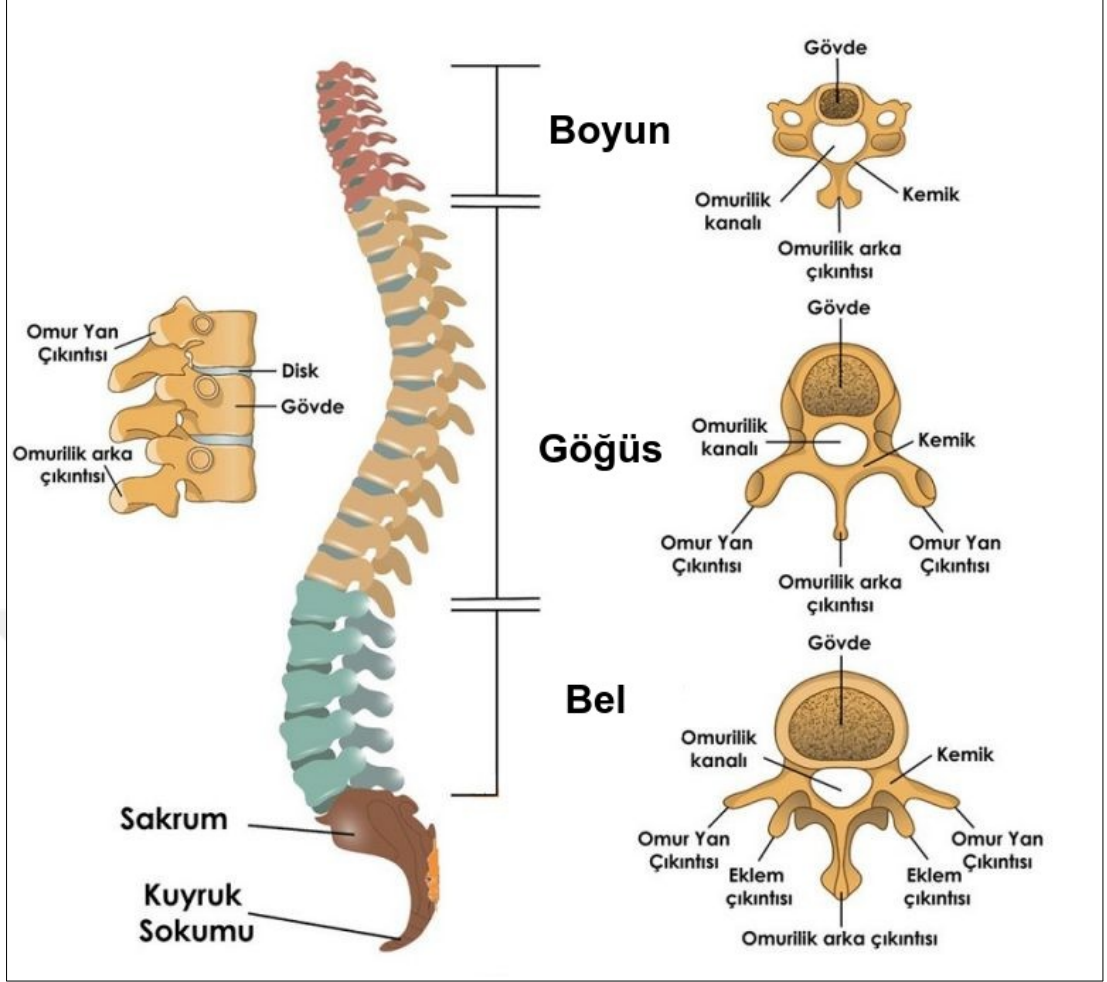
# 1. GİRİŞ

Sırt ağrısı dünyadaki en yaygın problemlerden biridir [1]. 2010 yılında Global Burden of Disease Study tarafından yapılan arařtırmalara gre sırt ağrısının, dnyada gzken en yksek ilk 10 hastalık arasında olduėu saptanmıřtır [2]. Artan sırt ağrılarının sebebinin ortaya ıkması iin radyologlar tarafından omurga grntlenmekte ve hastalıklı disk/omurun bulunabilmesi iin omurgada bulunan tm omur ve diskler elle iřaretlenmektedir. Bu iřlem uzun srmekte ve disk ve omurların birbirlerine olan ařırısı benzerliklerinden dolayı hataya aık olmaktadır. Yanlıř iřaretlenen herhangi bir disk veya omur, yanlıř tedavilere hatta yanlıř ameliyatlara sebep olmakta, bu da insan saėlıėını olumsuz etkilemektedir. Bu sebeple bu iřlemin otomatikleřtirilmesi uzun zamandır arařtırmacılar tarafından zerinde alıřılan bir konudur.

Yapay zeka teknolojilerinin hızla ilerlemesi ile makine ėrenmesi ve derin ėrenmede yeni yntemler ve algoritmalar geliřtirilmiřtir. zellikle son zamanlarda popler olan ve gncel olan en iyi deėerleri yakalayan derin ėrenme yntemleri, oėu alan gibi bu alanda da bařarılı sonular vermiřtir. Bir omurga grntsndeki disklerin ve omurların bilgisayar tarafından otomatik olarak bulunması iin birok makine ėrenme ve derin ėrenme tabanlı sistemler geliřtirilmiřtir.

## 1.1. İnsan Omurgası

Her insanda bulunan omurga, 33 adet omurdan oluřmaktadır ve bu omurlar birbirlerine disklerle baėlıdır. Omurlar, 7 adet boyun omuru (C1-C7), 12 adet gėė omuru (T1-T12), 5 adet bel omuru (L1-L5), 5 adet sakrum omuru (S1-S5) ve 4 adet kuyruk sokumu omuru olmak zere beř eřitir. Őekil 1.1'de insan omurgası ve zerinde bulunan omurlar gsterilmiřtir. Őekil [medalite/omurga](http://medalite.com/omurga) sitesinden alınmıř ve ufak deėiřiklikler yapılmıřtır.



Şekil 1.1: Omurganın yapısı, omur çeşitleri, omur ve disk yapıları gösterimi.


Omurga üzerinde toplam 23 adet disk bulunmakta [3] ve bu diskler omurgada esnekliği sağlamaktadır. Her iki omur arasında bulunan diskler, baş ve sonlarında bulunan omurlardan isimlerini almaktadırlar. Örneğin; L1 omuru ile L2 omuru arasında L1L2 diski bulunmaktadır.

## 1.2. Omurga Görüntüleme Yöntemleri

Omurganın sağlığı, hareket edebilmemiz ve omuriliğin korunabilmesi açısından çok önemlidir. Omurga üzerinde bulunan omur veya disklerde herhangi bir hasar meydana geldiği zaman, bu hasarın görüntülenebilmesi için farklı görüntüleme teknikleri bulunmaktadır. Bunlardan en sık kullanılanları, manyetik alan kullanarak görüntülemeyi sağlayan Manyetik Rezonans Görüntüleme (MR), X ışını yayarak görüntülemeyi sağlayan Bilgisayarla Tomografi (BT) ve X-ray'dir. Literatürde bulunan bir omurgadaki disk veya omurların bulunması çalışmaları özellikle 2 ana görüntüleme tekniğini esas almıştır. Bunlardan biri BT [4]-[7] iken, diğeri MR'dir [8], [9]. Aralarından X-Ray ile görüntüleme en ucuz ve en hızlı yöntem olmasına rağmen bu alanda yapılmış az çalışma vardır [10].

Bu çok yaygın olarak kullanılan üç görüntüleme tekniğinden MR görüntüleme [11]-[14], yumuşak dokuları daha iyi gösterir [15] ve hastayı radyasyona maruz bırakmaz. Bu da MR ile görüntülenmeyi son zamanlarda daha popüler hale getirmiştir [16]. Aynı zamanda, BT görüntülerinde radyasyona maruz kalındığı için kanser riski daha yüksek olmakla beraber bu görüntülerde tüm omur-disk hastalıkları görülememektedir. Bu sebepler de MR görüntülerinin incelenmesini daha cazip hale getirmiştir [17].

MR görüntülerinin oluşturulabilmesi için protonların miktar farkı, T1 süresi farkı ve T2 süresi farkı olmak üzere 3 farklı özelliğe bakılmaktadır [18]. T1 ve T2 değerleri sürecin hızını gösteren sabitlerdir. T1 süresi farkı T1 ağırlıklı, T2 süresi farkı T2 ağırlıklı, proton farkı ise proton ağırlıklı MR görüntüleri oluşturmaktadır. T1 ağırlıklı görüntülerde anatomi, T2 ağırlıklı görüntülerde ise hastalıklar daha iyi görünmektedir. T2 görüntülerinde su içeriği parlak gözükürken, T1 görüntülerinde aynı yer siyah gözükmektedir [19]. T1 ve T2 ağırlıklı MR görüntüleri Şekil 1.2'de gösterilmiştir.



Şekil 1.2: a) T1 ağırlıklı MR görüntüsü, b) T2 ağırlıklı MR görüntüsü

### 1.3. Tezin Amacı, Katkısı ve İçeriği

Bir bel MR görüntüsündeki omur ve diskleri otomatik olarak bulmak, disk ve omurların birbirine benzerliği, hastalıklı disk ve omurlarının olması, şekil bozuklukları, çekilen MR veya BT görüntülerinin çok karanlık olması, görüntü açılarının farklı olması, alandaki veri azlığından dolayı zor bir problemdir [20]-[23] ve skalyoz, fitik, disk kayması gibi hastalıkların teşhisinde çok önemlidir. Günümüzde bir bel MR görüntüsündeki disk ve omurların yerlerinin belirlenmesi radyologlar tarafından el ile yapılmaktadır. Bu işlem zaman açısından uzun sürmekte ve insan odaklı olduğu için hataya daha yatkın olmaktadır. Bir omurgadaki omur ve disklerin doğru bulunması büyük oranda yanlış yapılan bel ameliyatlarını azaltacaktır [22]. Bu sebeple, insan omurgasının anatomik yapısının otomatik olarak belirlenmesi önemlidir [24]. Bu alanda birçok yöntem önerilmiştir. Bu yöntemlere Bölüm 2’de değinilecektir.

Bu tez kapsamında T1 ve T2 ağırlıklı MR görüntüsündeki bel disklerinin (L1L2, L2L3, L3L4, L4L5, L5S1) otomatik olarak derin öğrenme algoritmalarıyla bulunmasına odaklanılmıştır. Şekil 1.3’te bir bel MR görüntüsü ve üzerinde bulunan bel diskleri gösterilmiştir. Bu çalışma ile iki katmalı Evrişimli Sinir Ağları (ESA) mimarileri oluşturulmuş, daha önce bu alanda denenmeyen Faster RCNN’ler, Dijkstra’nın en kısa yol algoritması ile birleştirilerek diskleri bulmak için

kullanılmıştır. Faster RCNN'lerin bu alanda yapılan çalışmalarda en iyi sonucu yakalayan sonuçlarla benzer hatta bazı kriterlerde daha yüksek sonuca vardığı gözlenmiştir.



Şekil 1.3: Bel MR görüntüsü ve üzerinde bulunan bel diskleri.

Bu tez çalışmasında bir bel MR görüntüsündeki diskleri bulabilmek için üç farklı yöntem denenmiştir. İlk yöntemde [25] makalesi esas alınarak iki katmanlı ESA eğitilmiş ve birinci aşamanın sonucu ikinci aşamada, ikinci ESA'ya girdi olarak verilmiştir. Bu yöntemin ayrıntıları Bölüm 4'de anlatılmıştır. Bölüm 5'de ikinci yöntem olan tek aşamalı ve SMM tabanlı Faster RCNN, Bölüm 6'te ise üçüncü yöntem olan, Faster RCNN ve ESA'nın Dijkstra'nın en kısa yol algoritması ile birleştirilmesi anlatılmıştır. Bölüm 7'de ise kullanılan yöntemler ve mevcutta olan yöntemler karşılaştırılmış, bu çalışmanın gelecek dönemlerinde yapılacaklar anlatılmıştır.

## 2. VERİ KÜMESİ

Bu tez kapsamında kullanılan veri kümesi 80 adet, T1 ve T2 ağırlıklı orta sagittal bel MR görüntülerinden oluşmaktadır. Görüntüler 2 boyutludur (2B). Her bir bel MR görüntüsündeki disklerin merkezi noktaları, radyologlar tarafından işaretlenmiş ve bu işaretlemelere göre disklerin merkezi koordinatları ayrı dosyalarda saklanmıştır. Görüntülerde bulunan her bir pikselin boyutu 0.625 x 0.625 mm'dir. [26] makalesindeki veri kümesiyle aynı veri kümesi kullanılmıştır.

Veri kümeleri, çalışmalarda kullanılan derin öğrenme algoritmalarındaki yöntemlere uygun olacak şekilde artırılmış ve çeşitlendirilmiştir.

Yapılan çalışmalar farklı veri kümeleri üzerinde de denenmek istenmiş fakat detaylı yapılan araştırmalara rağmen uygun bir veri kümesi bulunamamıştır.

### 3. LİTARATÜR ÇALIŞMASI

Bir bel MR görüntüsünde, omurganın anatomik yapısının otomatik olarak tespit edilmesi için birçok yöntem sunulmuştur. Bu yöntemler, makine öğrenmesi tabanlı yöntemler ve derin öğrenme tabanlı yöntemler olmak üzere iki temel başlık altında toplanmıştır.

#### 3.1. Makine Öğrenmesi Tabanlı Yöntemler

Okay ve Akgul [26], bir bel MR görüntüsündeki, bel disklerini bulabilmek için Markov Zinciri tabanlı grafiksel bir model önermişlerdir. Bu modelde disklerin özellikleri, Yönlü Gradyan Histogramı (YGH) ile çıkarılmış ve makine öğrenmesi yöntemlerinden biri olan Destekçi Vektör Makinesi (DVM)'e eğitilmesi için verilmiştir. Her bir disk ve omur için ayrı bir DVM eğitilmiştir. Eğitilmiş olan DVM ile aday diskler belli bir skor değeriyle bulunmuş ve en son grafiksel bir model ile dinamik programlama yapılarak disklerin kesin yerleri saptanmıştır. Makaledeki doğruluk oranı %97.2'dir. Bu makaledeki dezavantajlar, her bir disk ve omur için ayrı bir DVM eğitilmesi ve sadece MR görüntülerinin orta sagittal yüzeyindeki görüntülerde çalışmasıdır.

Lootus ve diğerleri [20], Felzenszwalb ve diğerleri [27] tarafından yayınlanan Deforme Parça Modeli'ni (DPM) YGH ile beraber kullanmış ve bunu grafiksel model ile birleştirmişlerdir. Modelin ilk aşamasında YGH ile omur ve sakrumun öz nitelik vektörleri çıkarılmış, vektörler eğitilmesi için DPM'e verilmiştir. Eğitim sonucunda aday omur ve sakrumlar tespit edilmiştir. Maksimum olmayan baskılama algoritması kullanılarak, yanlış tespit edilen aday omur ve sakrumlar elenmiştir. Kalan adaylar grafiksel modele verilerek doğru omurların yerleri saptanmıştır. Bu makalede [26]'teki makaleden farklı olarak, her bir omur için ayrı bir sınıflandırıcı eğitmek yerine tek bir genel omur bulucu eğitilmiş ve bu omur bulucu tüm omurları bulmak için yeterli olmuştur. Aynı zamanda MR görüntülerinde sadece orta sagittal kısma değil tüm iki boyutlu yüzeylere bakılmıştır. Doğruluk değerleri ise [26] makalesinden daha az olup, %86.9'dur.

Glocker ve diğerleri [28] de diğer makalelerdeki gibi iki aşamalı bir model önermiştir. İlk aşamada gözetimli öğrenme tekniklerinden biri olan Rastgele

Ormanlar ile eğitim aşamasında omurların pozisyonlarını, görüntü üzerindeki noktalarla ilişkilendiren bağlanım fonksiyonunu öğrenmişlerdir. Bu eğitim sonucunda oluşan aday omurlar ikinci aşamada SMM'ye verilerek dinamik programlama ile tüm omurların yerleri bulunmuştur. Bu makalenin, diğer makalelerden farkı regresyon ormanlarına ve olasılık tabanlı grafiksel modele dayanmasıdır. Bu fark, omurganın görünür kısmının kabaca tespit edilmesini sağlamıştır. Makalenin doğruluk oranı %81'dir.

Yukarıda bahsedilen makalelerde klasik yöntemler kullanılmıştır. Problem alt problemlere bölünmüş ve en son bu problemlerin sonuçları grafiksel yöntemle omurgada birleştirilmiştir. Bu alt problem safhalarında özellikler genellikle el ile çıkartılmış ve makine öğrenmesi yöntemine verilmiştir. Son dönemlerde popüler olan derin öğrenme yöntemleri ile özellikler ağlar ile çıkarılmakta ve eğitilmektedir. Derin öğrenme yöntemlerinin, insan omurgasının, omurların ve disklerin otomatik olarak tespitinde hız ve doğruluk değerleri açısından en iyi sonuçlara vardığı gözlemlenmiştir. Bu alanda çalışılan bazı yöntemler aşağıdaki gibidir.

### **3.2. Derin Öğrenme Tabanlı Yöntemler**

Forsberg ve diğerleri [29] makalelerinde, bel ve boyun için iki ayrı tespit etme ve etiketleme sistemi geliştirmişlerdir. Bu sistemde, omurlar ve S1/C2 diskleri için iki ayrı ESA eğitilmiştir. Yanlış bulunan doğruları elemek ve sıralı bir şekilde etiketleme yapabilmek için bu iki ESA'nın sonuçları en son grafiksel bir modelde birleştirilmiştir. Modelin doğruluk oranı %96-97 arasındadır. Bu makale ile derin öğrenme algoritmalarının, bel MR görüntüsündeki omurları-diskleri bulmada iyi sonuç verdiği gözlemlenmiştir.

Chen ve diğerleri [30], yaptıkları çalışmada sistemin daha verimli çalışması için Rastgele Orman Algoritmasını (ROA) kullanmışlardır. İlk aşamada eğitim safhasında ROA ile omurlar eğitilerek tekli sınıflandırma yapılmaktadır. Test safhasında ise kayan pencere yöntemi ile aday omurlar bulunmaktadır. İkinci aşamada bu aday omurlar, komşu bağımlılıkları da dikkate alınarak ESA'ya verilmekte ve omurların yeri tespit edilmektedir. Modelin omurları doğru tespit etme oranı %84 ile %91 arasındadır. Bu çalışma derin öğrenme algoritmalarıyla denenen ilk yöntemlerden biri olup, benzer algoritma kullananlardan daha iyi sonuç vermiştir.

Suzani ve diğeri [16] çalışmalarında öncelikle yoğunluk bazlı özellikleri çıkarmış ve bu özellikleri derin öğrenme yöntemlerinden biri olan ESA'ya vermişlerdir. ESA, üç saklı katmandan oluşmuş ve aktivasyon fonksiyonu olarak Stochastic Gradient Descent (SGD) kullanılmıştır. Test zamanında öncelikle tüm voksellerden özellikler çıkarılmış ve her bir vokselin uzaklığının tahmin edilmesi için eğitilen ESA modeline verilmiştir. Her göreceli mesafe, etiketin gerçek pozisyonuna dönüştürülmüş ve belli bir omurun konumu için o vokselin oyu olarak kabul edilmiştir. En son, tüm voksellerin oyları difüzyon bazlı çekirdek yoğunluğu hesaplaması [31] kullanılarak toplanmış ve böylece her omurun sınıflandırılması güçlü bir biçimde yapılmıştır. Modelin doğruluk değeri %100 olup, sadece bel omurları bulunmaktadır.

Wang ve diğeri [22], çalışmalarında ilk aşamada, el yapımı çıkarılan özellikler yerine, gözetimsiz bir şekilde derin yığılmış seyrek oto kodlayıcı kullanarak bağlamsal özellikleri öğrenmişlerdir. Bunu yaparken, omurların lokalizasyonu ve tanımlanmasına fayda sağlayan ve sağlamayan görüntü parçacıklarını esas almışlardır. Otsu [32] yöntemi ile omurlar ve omurganın anatomik yapıları arasındaki farkı bölmüş, ardından resmi morfolojik olarak ikili bağlı bloklara bölmüşlerdir. Bu blokları rastgele seçerek ayarladıktan sonra bağlamsal bilgileri daha geniş bir aralıkta yakalayabilmek için bağlamsal yama oluşturma algoritması geliştirilmiştir. Bu yamalar derin yığılmış seyrek oto kodlayıcılara verilmiş ve eğitilmiş bir model oluşturulmuştur. Regresyon Ormanları ile bu yapılandırılmış bilgiler kullanılarak omur lokalizasyonu ve tanımlanması için kullanılmıştır. Son yerleştirme aşamasında ise Otsu [32] yöntemi kullanılarak yanlış bulunan yerler elenmiş ve omurların bulunma yüzdeleri %76 ile %88 arasında çıkmıştır. Bu çalışmanın en büyük avantajı, özellikleri elle çıkarmak yerine bağlamları denetimsiz olarak öğrenen model geliştirmesidir.

Derin öğrenme alanında yapılan bu çalışmalar, bir BT/MR görüntüsündeki omur/disk bulmayı bir aşamaya kadar getirirse de, sistemde performans sıkıntısı, veri azlığı, doğruluk değerlerinin istenen seviyede olmaması veya olsa da performans açısından veya ortalama merkezden hata miktarı bakımından kötü olması gibi sorunlarından dolayı araştırılmaya devam edilmektedir. Ayrıca veri kümesinde yeteri kadar görüntü olduğu durumlarda baştan uca olan yöntemler (tek modelde girdi olarak bir MR görüntüsünü alıp sonucunda tüm disklerin pozisyonlarını ve etiketlerini döndüren yöntemler) sıra tabanlı yöntemlere göre daha başarılı sonuç

vermektedir. Yukarıda anlatılan tüm çalışmalarda, baştan uca yöntemler yerine sıra tabanlı sistemler kullanılmaktadır. Bunun sebebi bu alanda etiketli MR görüntüsünün az olmasından kaynaklanmaktadır.

Bu çalışmada da benzer bir şekilde sıra tabanlı derin öğrenme yöntemleri denenmiştir. Bu yöntemler sırasıyla iki katmanlı ESA, tek aşamalı ve SMM tabanlı Faster RCNN, en kısa yol algoritması tabanlı Faster RCNN olmak üzere üç adettir. Faster RCNN'lerin literatürde daha önce bu alanda hiç denenmediği gözlemlenmiştir. Bu çalışma ile Faster RCNN'lerin, bir bel MR görüntüsündeki diskleri bulmadaki performansının, doğru bulma oranının yüksek olduğu, ortalama merkezden hata miktarının ise olması gerektiği gibi az olduğu ortaya çıkmış ve bu alanda kullanılabileceği görülmüştür.

## 4. CONVOLUTIONAL POSE MACHINES MAKALESİNİN DİSKLERE UYGULANMASI

### 4.1. Convolutional Pose Machines makalesi

Bu çalışmada [25] makalesindeki yöntemler, bir bel MR görüntüsündeki diskleri bulmak için uygulanmıştır. Makalede amaç insan vücudunda bulunan eklem yerlerinin anlık olarak bulunmasıdır. Sistem her bir eklem yeri için 2B inanç haritaları üreten evrişimli ağ dizisinden, aşamasından oluşmaktadır. Her aşamada, görüntünün özellikleri ve bir önceki aşamada üretilen inanç haritaları bir sonraki aşamaya girdi olarak verilmektedir. İnanç haritaları, iki eklem arasındaki ilişkinin görüntü bağımlı mekansal modellerini öğrenmesini sağlar. Makaledeki en önemli kavramlardan biri olan alıcı alan boyutlarının büyümesiyle eklemler arasındaki ilişkilerin daha iyi öğrenildiği ve doğruluk değerinin arttığı gözlemlenmiştir. Sistemdeki örnek bir sınıflandırma adımı Şekil 4.1’de [25] gösterilmiştir.



**Girdi**

**Faz 1**

**Faz 2**

**Faz 3**

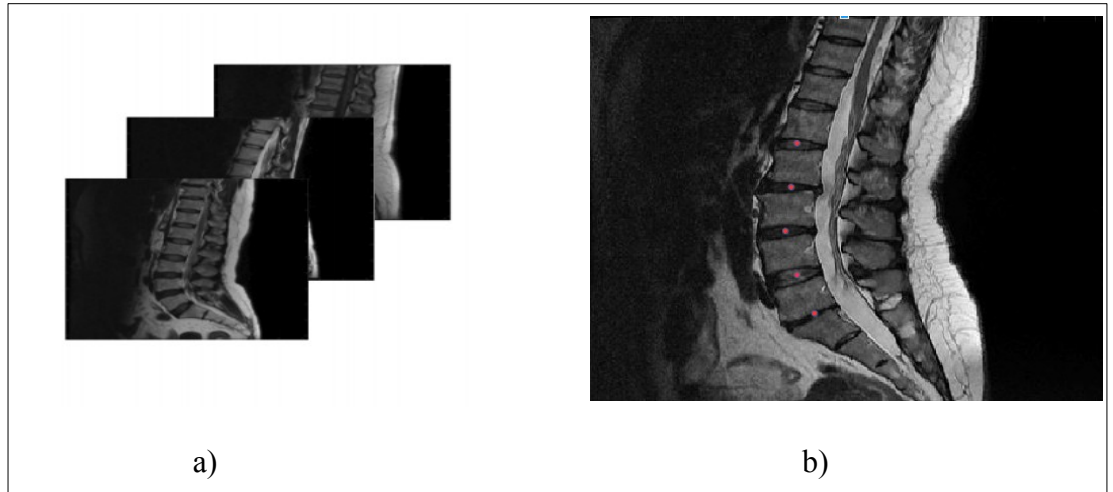
Şekil 4.1: Convolutional Pose Machines makalesinden örnek sistem adımları. Convolutional Pose Machines her görüntü lokasyonunda daha derin tahminlemeler yapabilmek için bir dizi sınıflandırıcılardan oluşur. Bu görüntüde sağ elin bulunabilmesi için her aşamada artarak düzelen sistem gösterilmiştir. Faz 1’de sadece yerel özelliklere bakılması birden fazla yerin bulunmasına sebebiyet vermiş, Faz 2’de çok parçalı içeriğin alınması belirsizliği giderilmiş, Faz 3’de ise sınıflandırıcılardaki ek tekrarlamalar belirli bir çözüme ulaşmaya yardımcı olmuştur.

## 4.2. Convolutional Pose Machines makalesi yöntemleri ile Disklerin Otomatik Bulunması

Convolutional Pose machines makalesindeki [25] yönteme benzer bir yaklaşım bel MR görüntüsündeki diskleri bulmak için izlenmiştir. Bir bel MR görüntüsündeki diskleri bulmak, anlık olarak bir insan vücudundaki eklem yerlerini bulma probleminde daha basit bir problem olduğu için üç aşamaya gerek duyulmadan iki aşamada sistem istenilen doğruluk değerine ulaşmıştır.

### 4.2.1 Veri Kümesi ve Sınıfların Oluşturulması

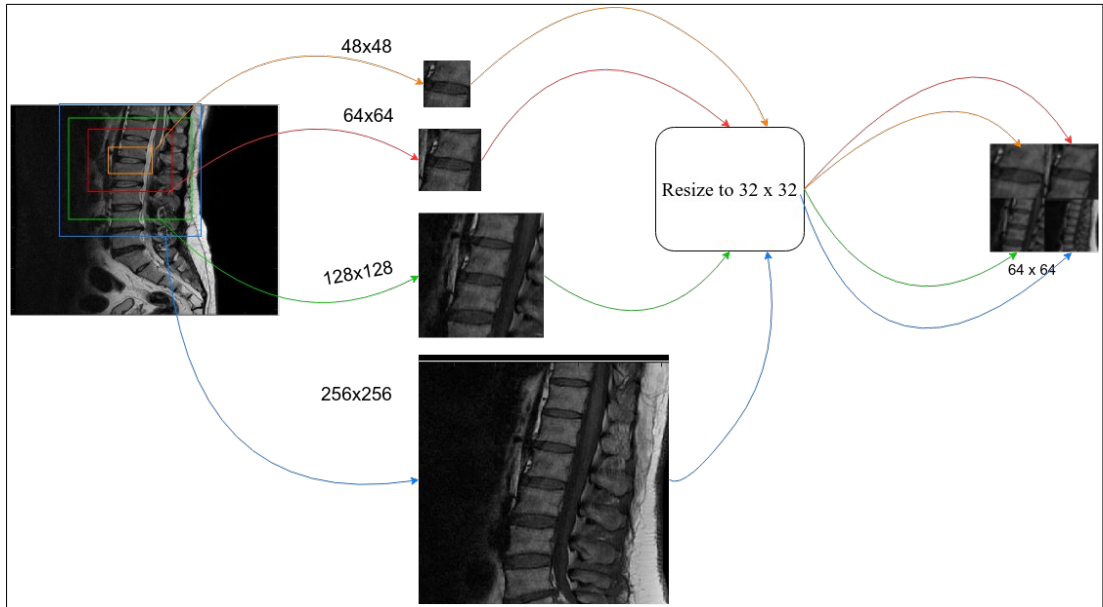
Veri kümesinde 80 T1, 80 T2 olmak üzere 160 adet bel MR görüntüsü bulunmaktadır. Sistemde ilk olarak bu 160 bel MR görüntüsünde bulunan L1L2, L2L3, L3L4, L4L5, L5S1 bel disklerinin merkezleri işaretlenmiş ve bu merkezlerin koordinatları her bir disk için ayrı bir dosyaya yazılmıştır. Şekil 4.2’de veri kümesinden örnek MR görüntüleri ve merkezleri işaretlenmiş bir bel MR görüntüsü bulunmaktadır.



Şekil 4.2: a.) Veri kümesinde bulunan örnek bel MR görüntüleri, b) Disk merkezleri işaretlenmiş örnek bel MR görüntüsü.

Sistem eğitim ve test olmak üzere iki kısımdan oluşmaktadır. Veri kümesindeki görüntülerin %80’i eğitim kümesinde, %20’si test kümesinde olacak şekilde

ayrılmıştır. Eğitim veri kümesini oluşturmak için 0-1-2-3, 4-5-6, 7-8-9, 10-11-12, 13-14-15, 16-17-18, 19-20-21, 22-23-24, 25-26-27, 35-36-37, 48-49-50, 60-61-62, 70-71-72, 80-81-82, 90-91-92, 100-101-102, 130-131-132, 161-162-163, 190-191-192, 218-219-220 sayıları gruplanmış ve her bir grup bir sınıfı temsil etmektedir. Bu aralıklar belirlenirken farklı kombinasyondaki aralıklar da denenmiş en son aşamada en uygun aralıklar olarak bunlar seçilmiştir. Bu aralık grupları 0'dan başlayıp 19'a kadar sınıflandırılmıştır. Böylece toplamda 20 uzaklık sınıfı belirlenmiştir. Her bir diskin merkezi yukarıdaki sınıfların uzaklıklarında kaydırılarak görüntü parçacıkları çıkarılmıştır. Her bir disk merkezini  $(x_i, y_i)$  ile gösterirsek, disklerin merkezi her sınıftaki  $r$  uzaklığı için  $(x_{i-r}, y_{i-r})$  olacak şekilde kaydırılmıştır. Bu merkezlerden 48x48, 64x64, 128x128, 256x256 boyutlarında dört ayrı görüntü parçacığı çıkarılmıştır. Dört farklı boyutta çıkarılmasının sebebi, disklerle beraber komşu diskleri de hesaba katarak daha fazla bilgi edinmeye çalışmaktır. Bu görüntü parçacıkları 32x32'ye yeniden boyutlandırılıp, dördü 64x64'lük bir görüntü içerisinde birleştirilmiştir. Bu aşamanın görsel hali Şekil 4.3'te verilmiştir.

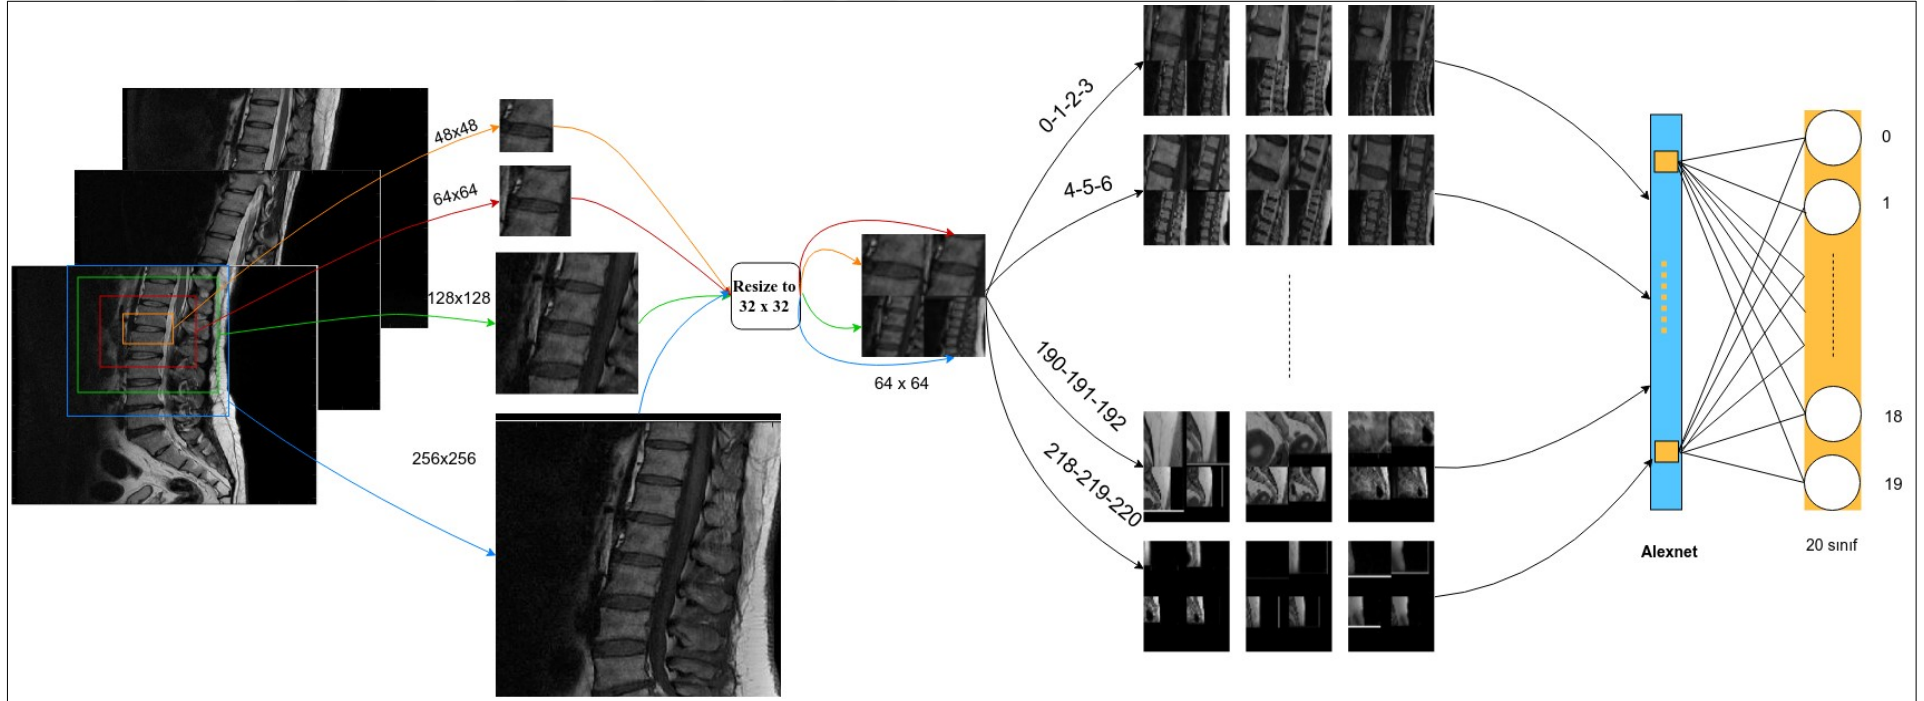


Şekil 4.3: Farklı boyutlarda çıkarılmış görüntü parçacıkları. Disklerin merkezlerine belli uzaklarda dört farklı boyutta görüntü parçacıkları çıkarılmış ve bu görüntü parçaları 32x32'ye indirgenerek, 64x64 boyutlu bir görüntüde birleştirilmiştir.


Her bir sınıf için 1000'er tane görüntü çıkarılmıştır. 20 tane sınıf olduğundan dolayı her bir disk için eğitim kümesinde toplamda 20.000 eğitim görüntüsü bulunmaktadır.

## 4.2.2 İki Aşamalı Eğitim ve Test Yöntemleri


Her bir disk için ayrı ayrı veri kümeleri oluşturulduktan sonra, veriler ESA modellerinden biri olan AlexNet'e [33] verilip eğitim süreci başlatılmıştır. Eğitim yaklaşık 20 dakika sürmüştür. Birinci aşamanın eğitim kısmının görsel hali Şekil 4.4'teki gibidir. Eğitimin ardından, test aşamasında kayan pencere yöntemi ile görüntü üzerinde görüntü parçacıkları, eğitimdekine benzer şekilde dört farklı boyutta çıkarılıp en son 32x32'ye yeniden boyutlandırılmış ve 64x64'lük bir görüntüde birleştirilmiştir. Bu görüntü parçacıkları çıkarılarak sınıflandırıcılara değerleri sorulmuştur. Sınıflandırmanın verdiği değerlere göre inanç haritası çıkarılmıştır. İnanç haritasında kırmızı renkli yerler disklerin olduğu yeri, sarı renkli yerler diskin yakın olduğu yeri, yeşil renkli yerler diske uzak yeri, mavi renkli olan yerler ise disk olmayan, diske çok uzak olan yerleri göstermektedir. Birinci aşama test kısmı adımları Şekil 4.5, test sonuçları Şekil 4.6'da gösterilmiştir.



Şekil 4.4: İki katmanlı ESA'nın birinci aşamasının eğitim kısmı. Öncelikle eğitimi kümesinde bulunan her bir diskin merkezleri çıkarıldıktan sonra bu merkezlere göre 0-1-2-3, 4-5-6 ... uzaklıklarında, 48x48, 64x64, 128x128, 256x256'lık görüntü parçacıkları çıkarılmış ve bu parçalar teker teker 32x32'ye indirgenerek, 64x64'lük bir görüntü içerisinde birleştirilmiştir. Belli uzaklık sınıflarına göre çıkarılan bu görüntü parçacıkları, uzaklıklarına göre sınıflandırılmış ve eğitim için Alexnet'e verilmiştir. Şekilde L1L2 diski sınıflandırıcısı için eğitim aşamaları gösterilmiştir. Diğer diskler için de aynı aşamalar tekrarlanmaktadır.

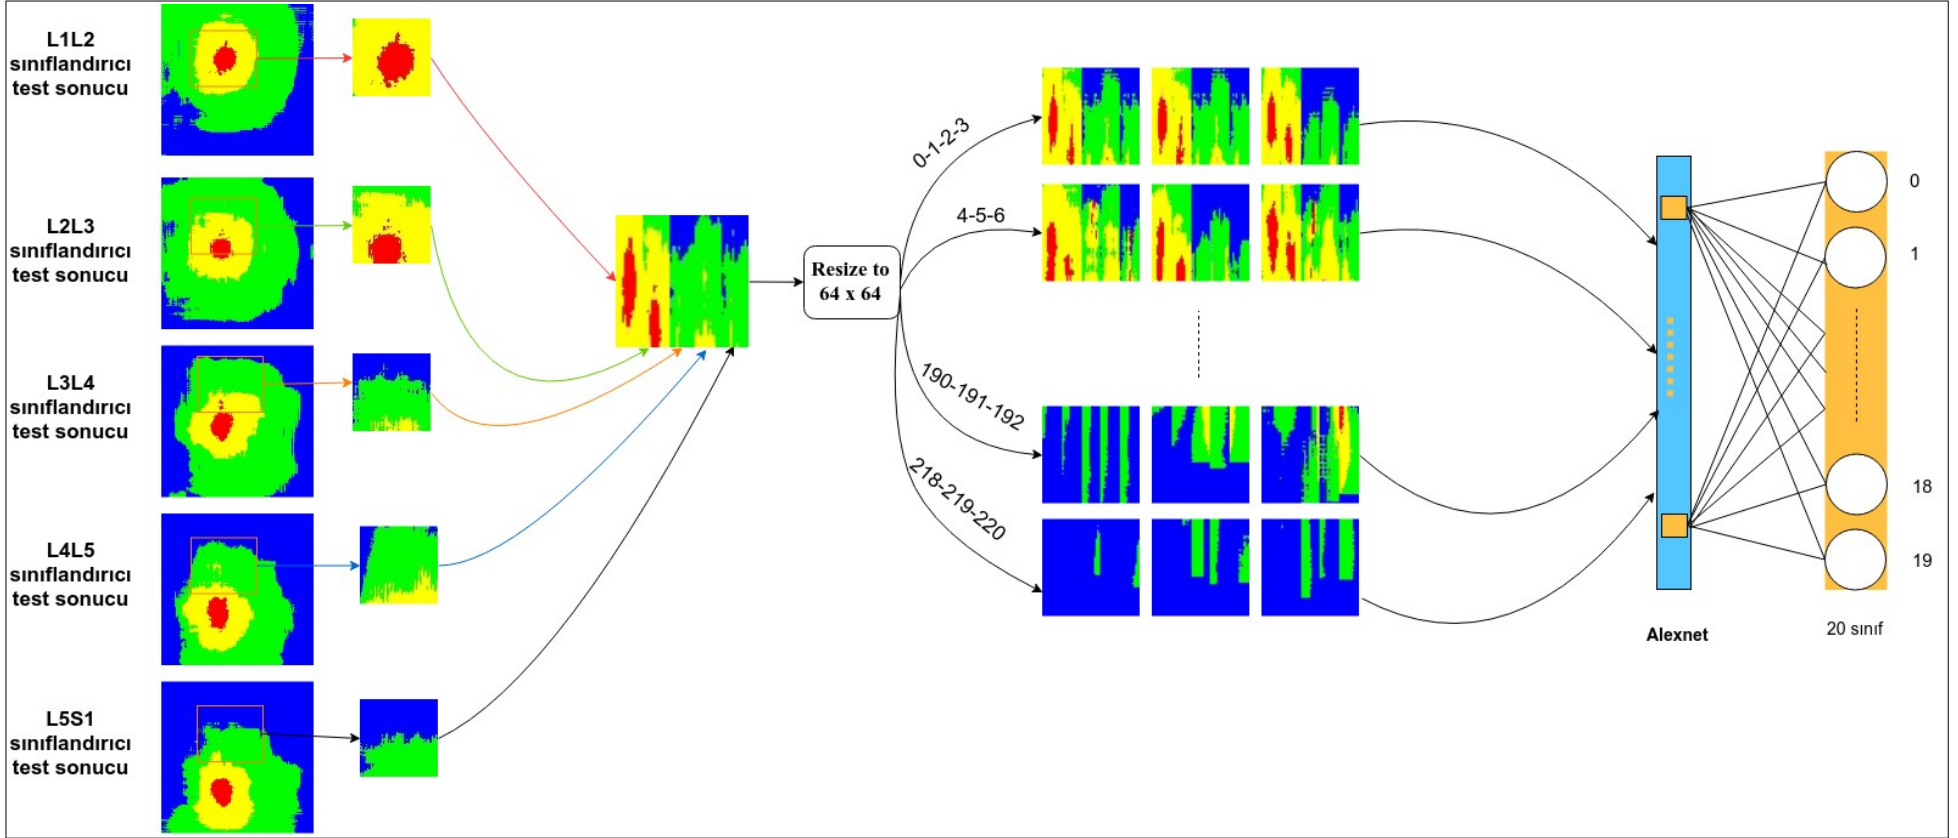


Şekil 4.5: İki katmanlı ESA'nın birinci aşamasının test kısmı. Kayan pencere yöntemi ile tüm resim baştan sonra piksel piksel taramakta ve her bir pikselde 48x48, 64x64, 128x128, 256x256'lık görüntü parçacıkları çıkarılıp, 32x32'ye indirgindikten sonra 64x64'lük bir görüntüde birleştirilmiş ve bu görüntü birinci aşamada eğitilen Alexnet modeline verilerek sınıfı öğrenilmiştir. Bu sınıfa göre, inanç haritaları çıkarılmıştır. Bu şekil L1L2 disk sınıflandırıcısı test aşamalarını göstermektedir. Diğer disk sınıflandırıcıları için aynı aşamalar tekrarlanmıştır.

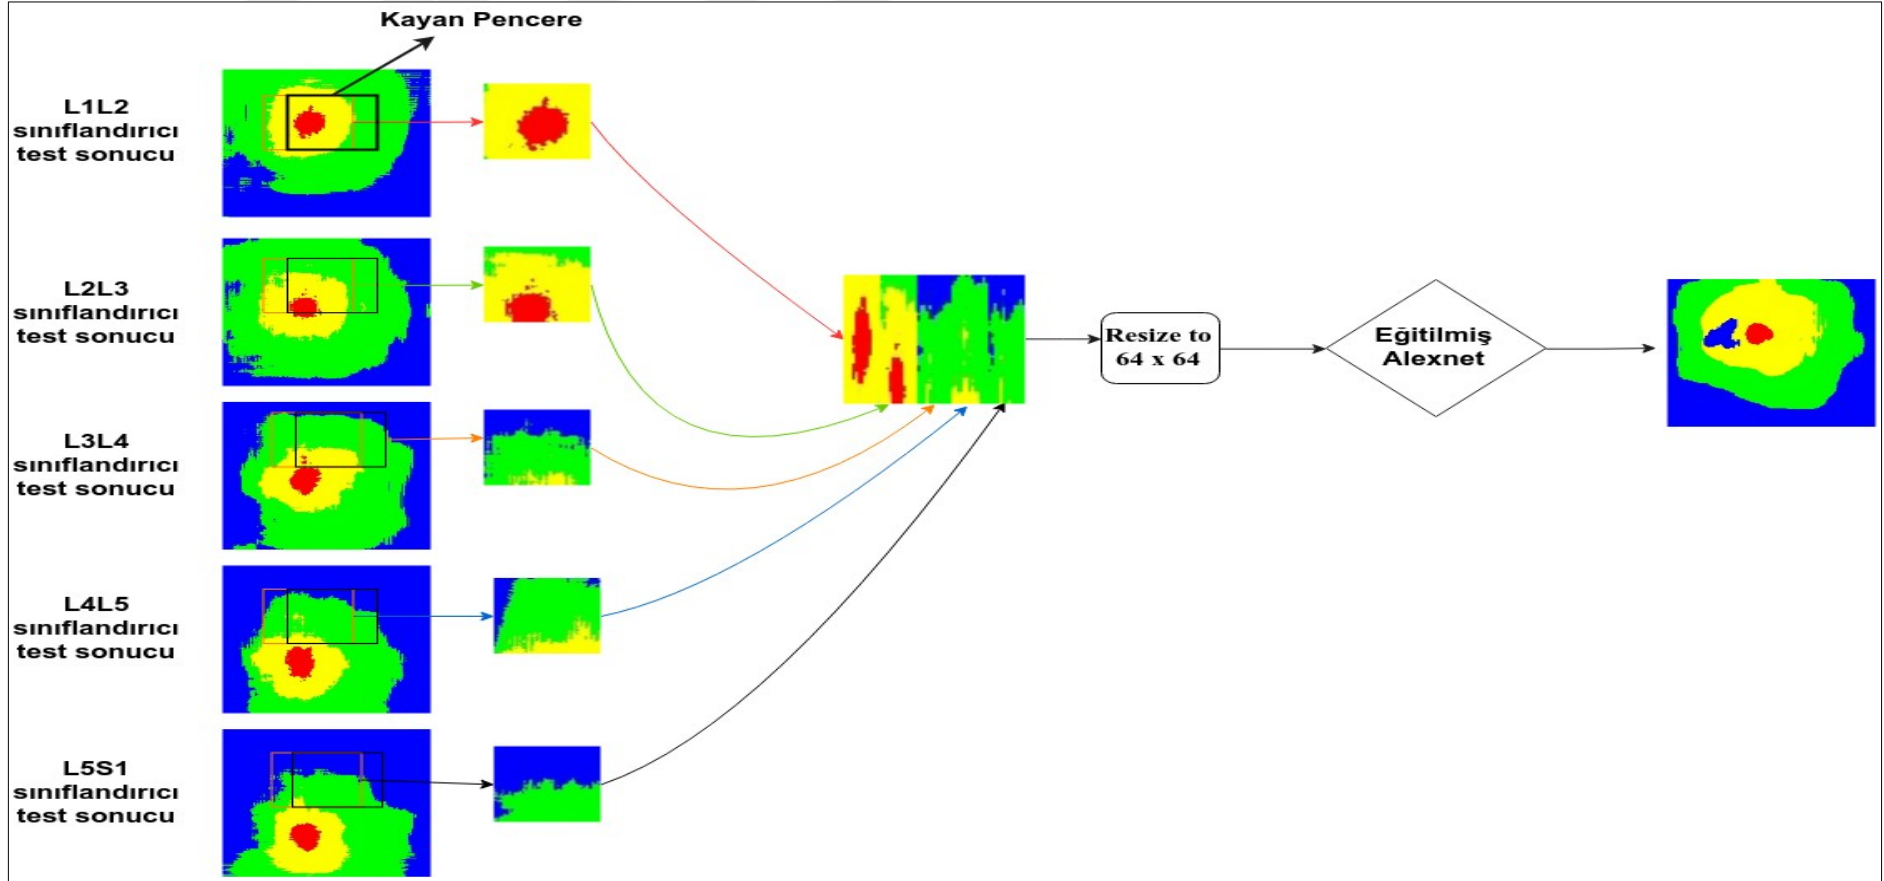


Şekil 4.6: Birinci aşama test sonuçları. a) L1L2 disk sınıflandırıcısının birinci aşama test sonucu, b) L3L4 disk sınıflandırıcısının birinci aşama test sonucu, c) L4L5 disk sınıflandırıcısının birinci aşama test sonucu.

Birinci aşama sonucu, Şekil 4.6’da görüldüğü gibi, disklerin bulunduğu yerleri ve çevresini iyi bulmakla beraber, tam olarak bulunmak istenen diski tek başına bulamamaktadır. Bu sebeple modele ikinci bir aşama daha eklenmiştir. İkinci aşamada ise [25] makalesi doğrultusunda birinci aşamada elde edilen inanç haritaları, bir sonraki aşamanın girdisi olarak kullanılmıştır. Bu inanç haritalarının yanında, her bir disk için, diğer disk sınıflandırıcıların kendi sınıfı hakkında ne düşündüğü bilgisi de eklenmiştir. Bunu gerçekleştirmek için test görüntüsü, beş disk sınıflandırıcısına tek tek verilmiş ve belirli bir disk için inanç haritalarına bakılmıştır. Bu beş sınıfın sonuçları 64x64’lük görüntü parçacıkları olarak çıkarılmış ve yan yana birleştirilmiştir. Birleştirilen bu görüntüler en son tekrardan 64x64 boyutuna indirgenmiştir. Bu inanç haritalarında, birinci aşamadaki gibi her bir disk için merkezden belirlenen 20 sınıftaki uzaklıklara göre her bir sınıftan 1000 tane olacak şekilde görüntü parçacıkları çıkarılmıştır. Oluşturulan bu görüntü parçacıkları birinci aşamadaki gibi ESA’ya verilmiş ve eğitime başlanmıştır. İkinci aşamanın eğitim kısmı Şekil 4.7’de gösterilmiştir. Eğitilen model, test verisi üzerinde test edilmiştir. Birinci aşama ile aynı şekilde kayan pencere ile inanç haritaları çıkarılmıştır. İkinci aşamanın test kısmı Şekil 4.8’de gösterilmiştir.

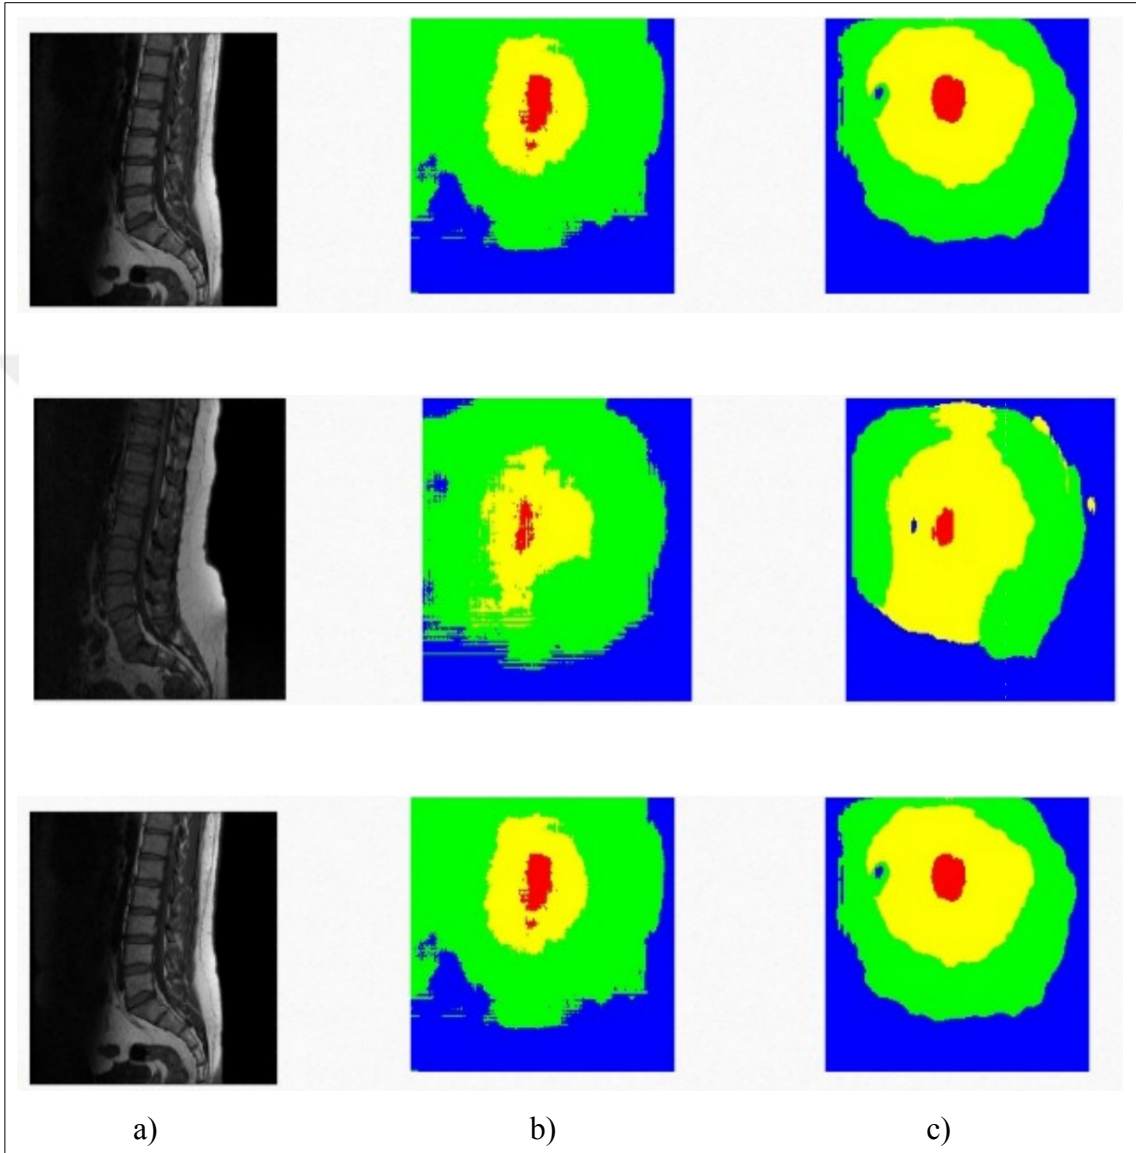


Şekil 4.7: İki katmanlı ESA'nın ikinci aşamasının eğitim kısmı. İkinci aşamanın eğitim kısmında, her bir sınıflandırıcının ürettiği inanç haritalarından, L1L2 diski merkezinden 0-1-2-3, 4-5-6, ... uzaklıkta, 64x64'lük görüntü parçacıkları çıkarılmış ve bir görüntüde yan yana birleştirilerek 64x64'e indirgenmiştir. Belli uzaklık sınıflarına göre çıkarılan bu görüntü parçacıkları, uzaklıklarına göre sınıflandırılmış ve eğitim için Alexnet'e verilmiştir. Şekilde L1L2 diski sınıflandırıcısı için eğitim aşamaları gösterilmiştir. Diğer diskler için de aynı aşamalar tekrarlanmaktadır.




Şekil 4.8: İki katmanlı ESA'nın ikinci aşamasının test kısmı. Kayan pencere yöntemi ile tüm resim baştan sonra piksel piksel taranmış ve her bir sınıflandırıcının ürettiği inanç haritalarından, görüntü parçacıkları çıkarılıp birleştirildikten sonra 64x64'e indirgenmiş ve bu görüntü ikinci aşamada eğitilen Alexnet modeline verilerek sınıfı öğrenilmiştir. Modelin verdiği sınıfa göre, inanç haritaları çıkarılmıştır. Bu şekil L1L2 disk sınıflandırıcısı test aşamalarını göstermektedir. Diğer disk sınıflandırıcıları için de aynı aşamalar tekrarlanmaktadır.

Yapılan testlerde, makalede [25] yazıldığı gibi ikinci aşama sonucunun birinci aşamadan daha iyi olduğu yani kırmızı ile beliren yerlerin gerçek disklerin olduğu yerlerde yoğunlaştığı görülmüştür. Şekil 4.9’da bazı MR görüntülerinin birinci ve ikinci aşama sonuçları gösterilmektedir.




Şekil 4.9: Örnek bir MR görüntüsünün, sistemdeki tüm aşamaları. a) Bel MR görüntüleri, b) Yukarıdan aşağı sırasıyla L1L2, L2L3, L3L4, L4L5, L5S1 sınıflandırıcılarının görüntü üzerindeki birinci aşama sonucu oluşan inanç haritaları, c) Yukarıdan aşağı sırasıyla L1L2, L2L3, L3L4, L4L5, L5S1 sınıflandırıcılarının görüntü üzerindeki ikinci aşama sonucu oluşan inanç haritaları.



Şekil 4.9: Devam.


Sonuçlarda iyi görüntüler olduğu gibi, ikinci aşamada daha kötü sonuç veren görüntüler de mevcuttur. Şekil 4.10 ikinci aşamada, birinci aşamadan daha kötü sonuç veren görüntüleri içermektedir.



Şekil 4.10: Test kümesi üzerinde kötü sonuçlar veren görüntüler. Yukarıdan aşağı sırasıyla a) Bel MR görüntüleri, b) 1. aşama sonucunda çıkan inanç haritaları, c) 2. aşama sonucunda oluşan inanç haritaları.

Şekil 4.10'da ikinci aşama sonuçlarında, kırmızı yerlerin ilk resimde tamamen yok olduğu, ikincisinde ise çok fazla yaygınlaşıp diskleri karıştırdığı görülmektedir. Kırmızı renkte olan bölgenin çoğalması, oralarda diskin olabileceği anlamını içerdiğinden, sonucun kötü olduğunu göstermektedir. Bu görüntülerde sistem doğru çalışmayıp yanlış sonuçlar üretmiştir.

Bu inanç haritalarındaki kırmızı yerlerin bel MR görüntülerinde nerelere denk geldiğini bulmak için, kırmızı olan bölgenin çevritleri çıkarılıp görüntü üzerine gömülmüştür. Sonuç Şekil 4.11'de gösterilmiştir.



Şekil 4.11: Sırasıyla disk sınıflandırıcılarının sonuçlarının çevritlerinin çıkarımı.

Şekil 4.11'de görüldüğü gibi inanç haritalarındaki kırmızı bölgeler, MR görüntülerinde disklerin var olduğu yerleri göstermektedir.

### 4.2.3 Kullanılan Sistemin Özellikleri

Bu yöntemde ESA olarak Alexnet, yardımcı araç olarak Digit kullanılmıştır. Alexnet'teki varsayılan parametrelere dokunulmamış ve olduğu gibi eğitilmiştir. Test etmek için Caffe [34], OpenCV [35] kütüphaneleri kullanılmış ve kod C++ programlama dilinde yazılmıştır. Modelin doğruluk değeri %95, çalışma zamanı 20 dakikadır. Çalışma zamanının yüksek olmasının sebebi, görüntünün kayan pencere yöntemi ile piksel piksel taranmasından kaynaklanmaktadır.

## 5. TEK AŞAMALI VE SMM TABANLI FASTER RCNN

Birinci yöntem olan iki aşamalı ESA'nın en büyük dezavantajı 20 dak. süren çalışma zamanıdır. Geçen zamanın bu kadar çok olması sistemin gerçek hayatta uygulanabilirliğini azaltmaktadır. Bu sebeple daha hızlı çalışan çözümlere gidilip probleme farklı bakış açısından bakılmıştır.

Bir bel MR görüntüsündeki disk ve omurların sınıflarının ve yerlerinin bulunması problemi aslında bir nevi nesne tanıma problemidir ve nesne tanıma problemleri sınıflandırma problemlerinden daha zordur. Yapılan araştırmalar, okunan makaleler ve denenilen yöntemler neticesinde, klasik ESA ağlarının bu problemi çözmede yeterli kalmadığı görülmüştür. Bu sebeple nesne tanıma problemi için birçok yöntem sunulmuştur. [36] makalesinde ESA'yı bölge ile birleştiren, Bölge Bazlı ESA (RCNN) önerilmiştir. RCNN, nesne tanımada doğruluk değeri açısından iyi sonuçlar verse de eğitim ve test zamanında yavaş olduğu gözlemlenmiştir. Ek olarak çok fazla belleğe ihtiyaç duymaktadır. Bu dezavantajlarından dolayı [37] ilgi bölgesi havuzunu kullanarak, RCNN'den 9 kat daha hızlı ve daha az bellek kaplayan Hızlı RCNN (Fast RCNN) adı altında bir yöntem geliştirmiştir. [38] makalesinde ise yeni bölgesel yöntemler denenerek Fast RCNN'den daha yüksek doğruluk değerine, daha az çalışma zamanına sahip Daha Hızlı RCNN (Faster RCNN) modeli önerilmiştir. Yüksek doğruluk değeri ve neredeyse gerçek zamanlı çalışma süresinden dolayı bir bel MR görüntüsündeki diskler bulunurken Faster RCNN kullanılmaya karar verilmiştir.

Bu kapsamda, Faster RCNN'in bir omurgadaki diskleri bulabilmesi için tek aşamalı Faster RCNN ve Saklı Markov Modeli (SMM) tabanlı Faster RCNN olmak üzere iki farklı yöntem denenmiştir.

### 5.1. Tek Aşamalı Faster RCNN

Bu yöntemde, bir bel MR görüntüsündeki L1L2, L2L3, L3L4, L4L5, L5S1 diskleri bulunmaya çalışılmıştır. Veri kümesinde 80 T1 ağırlıklı MR görüntüsü bulunmaktadır. Öncelikle eğitim kümesini oluşturabilmek için bu görüntülerdeki bel disklerinin hepsi sınırlayıcı kutu içerisine alınmıştır. Bu kutu ile beraber her diskin

{x\_min,x\_max,y\_min,y\_max,genişlik,yükseklik,sınıf ismi} bilgileri çıkarılmış ve her bir görüntü için ayrı xml dosyalarına kaydedilmiştir. 80 MR görüntüsü derin öğrenme algoritmaları için çok azdır. Bu sebeple veri artırma yöntemleri ile görüntüler çoğaltılmıştır. Veriyi artırabilmek için öncelikle MR görüntüleri için artırma uygun olan aralıklar belirlenmiştir. Bu aralıklar, yeniden boyutlandırma için (450, 600), döndürme için (-6, +6), ölçeklendirme için (-0.15, +0.15) ve kırpma için (-0.1, +0.1) olarak seçilmiştir. Rastgele seçilen bu artırma yöntemleri, rastgele sayıda ve rastgele aralıklarda birleştirilerek her bir MR görüntüsünden 100 tane yeni görüntü elde edecek şekilde artırma işlemi yapılmıştır. Algoritmanın sözde kodu Algoritma 5.1'deki gibidir.

Algoritma 5.1: Veri artırma algoritmasının sözde kodu.

---

**Algorithm 1** Veri Arttırma Algoritması

---

```

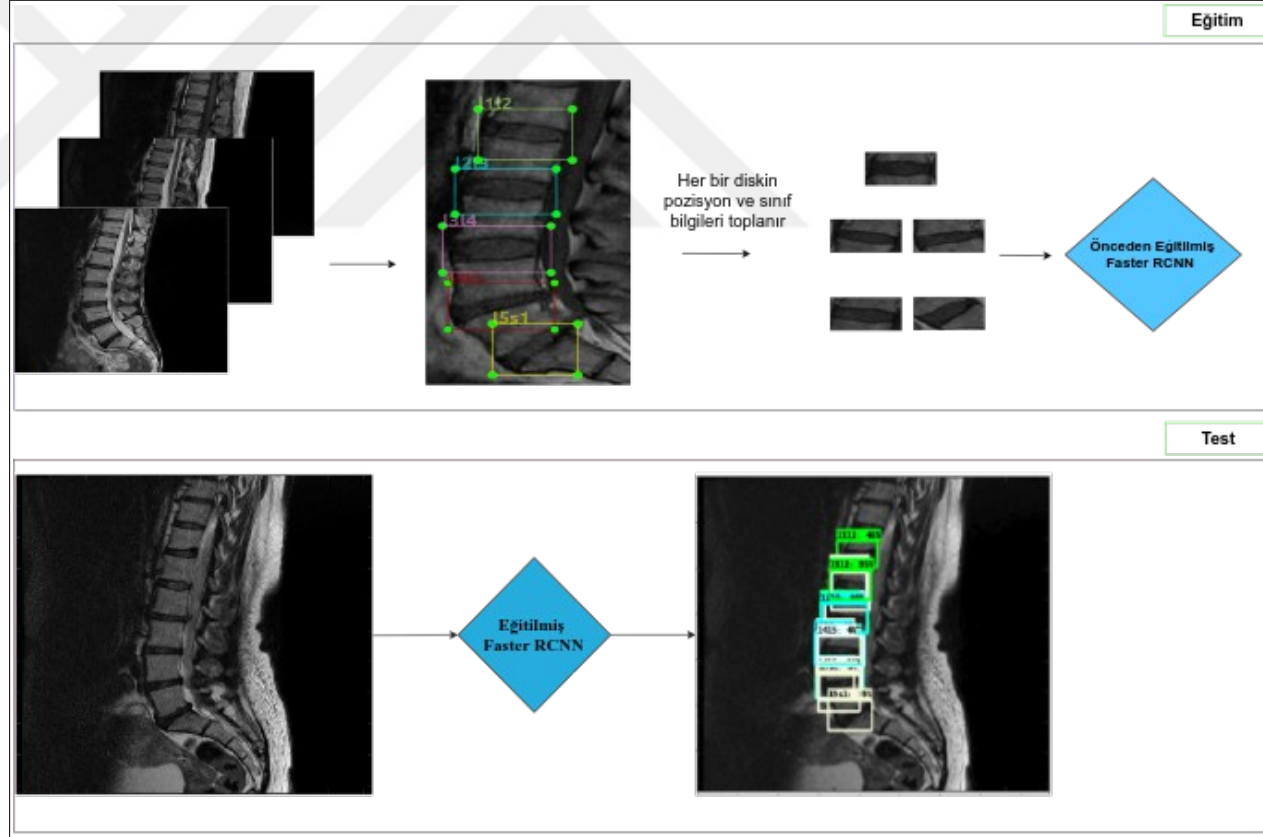
1: procedure DATA AUGMENTATION(Dataset, DatasetBBoxInfo)
2:   for  $i=1$  to  $M$  do
3:     Dataset[ $i$ ]
4:     DatasetBBoxInfo[ $i$ ]
5:     for  $j=1$  to 100 do
6:       resize = RandomNumber(450,600)
7:       rotate = RandomNumber(+6,-6)
8:       scale = RandomNumber(+0.15,-0.15)
9:       crop = RandomNumber(+0.1,-0.1)
10:      transformValues = [resize,rotate,scale,crop]
11:      transformsArray = []
12:      for  $k = 1$  to RandomNumber(1,4) do
13:        index=RandomNumber(1,4)
14:        insert transformValues[index] into transformsArray
15:        ApplyTransformation(Dataset[ $i$ ],DatasetBBoxInfo[ $i$ ],transformsArray)
16:

```

---

Böylece veri kümesinde toplam 8000 MR görüntüsü olmuştur. Veri kümesi eğitim ve test kümesi olmak üzere ikiye ayrılmıştır. Sistemin testi için 8 çapraz katman doğrulama yöntemi [39] kullanılmış, böylece her katmanda eğitim kümesinde 7000, test kümesinde 1000 adet MR görüntüsü yer almıştır. Sistemde eğitim kümesinin {x\_min,x\_max,y\_min,y\_max,genişlik,yükseklik,sınıf ismi} özelliklerini çıkarmak için yardımcı bir araç olan LabelImg [40] kullanılmıştır. Bu araç sayesinde, diskleri sınırlayıcı kutular içerisine alarak, veri kümesinde bulunan görüntülerdeki disklerin pozisyonel ve yapısal özellikleri xml tipinde dosyalara kaydedilmiştir. Veri artırımı olduktan sonra tüm görüntülerdeki diskleri tek tek el ile sınırlayıcı kutu içerisine almak uzun zaman alacağından veri artırımı yaparken aynı zamanda pozisyonel özellikleri de aynı şekilde değiştiren bir kütüphane kullanılmıştır [41]. Eğitim

aşamasında Faster RCNN'ye bu xml dosyaları ve görüntüler verilmiştir. Eğitim kümesinde bulunan görüntü sayısı tüm veriyi öğrenmek için yine de az olduğu için yeni bir modeli baştan oluşturup eğitmek yerine var olan bir model kullanılarak eğitim aktarması yapılmıştır. Bu model Tensorflow [42] tarafından sağlanan ve COCO [43] veri kümesi üzerinde eğitilmiş FRCNN Inception V2 [44] modelidir. Bu modelin son katmanında ince ayarlar yapılmış olup, tasarlanan sisteme uygun çalışacak şekilde parametreler ayarlanmıştır. Modelin öğrenme oranı 0.0002 ve etkilenim fonksiyonu softmax'tir. Sistem 57. 000 epoka kadar eğitilmiş ve yaklaşık 2 saat sürmüştür. Eğitim bittikten sonra sistem test kümesi üzerinde test edilmiştir. Test aşamasında, görüntüler eğitilmiş olan Faster RCNN modeline verilmiş ve model, her bir disk için belli bir puana ve sınıfa sahip sınırlayıcı kutu üretmektedir. Bu puanlar, o sınırlayıcı kutu için tahmin edilen sınıfın puanıdır. Sistemin eğitim ve test aşaması Şekil 5.1'de gösterilmiştir. Bu yöntemde, test kümesi için tahmin edilen sınıfların doğruluk değeri %85, ortalama merkezden hata miktarı 1.04 mm ve standart sapma 0.64 çıkmıştır. Sonuçlar ortalama 0.4 saniyede gelmektedir. Sistem bu aşamada sadece diskleri öğrendiği, diskler arasındaki ilişkiyi öğrenemediği ve çok fazla hatalı onaylanmış disk bulduğu için, doğruluk değerinin artması ve hatalı onaylanmış disklerin sayısının azalması için diskler arasındaki ilişkileri de öğrenen SMM bazlı Faster RCNN adlı farklı bir yöntem denenmiştir.



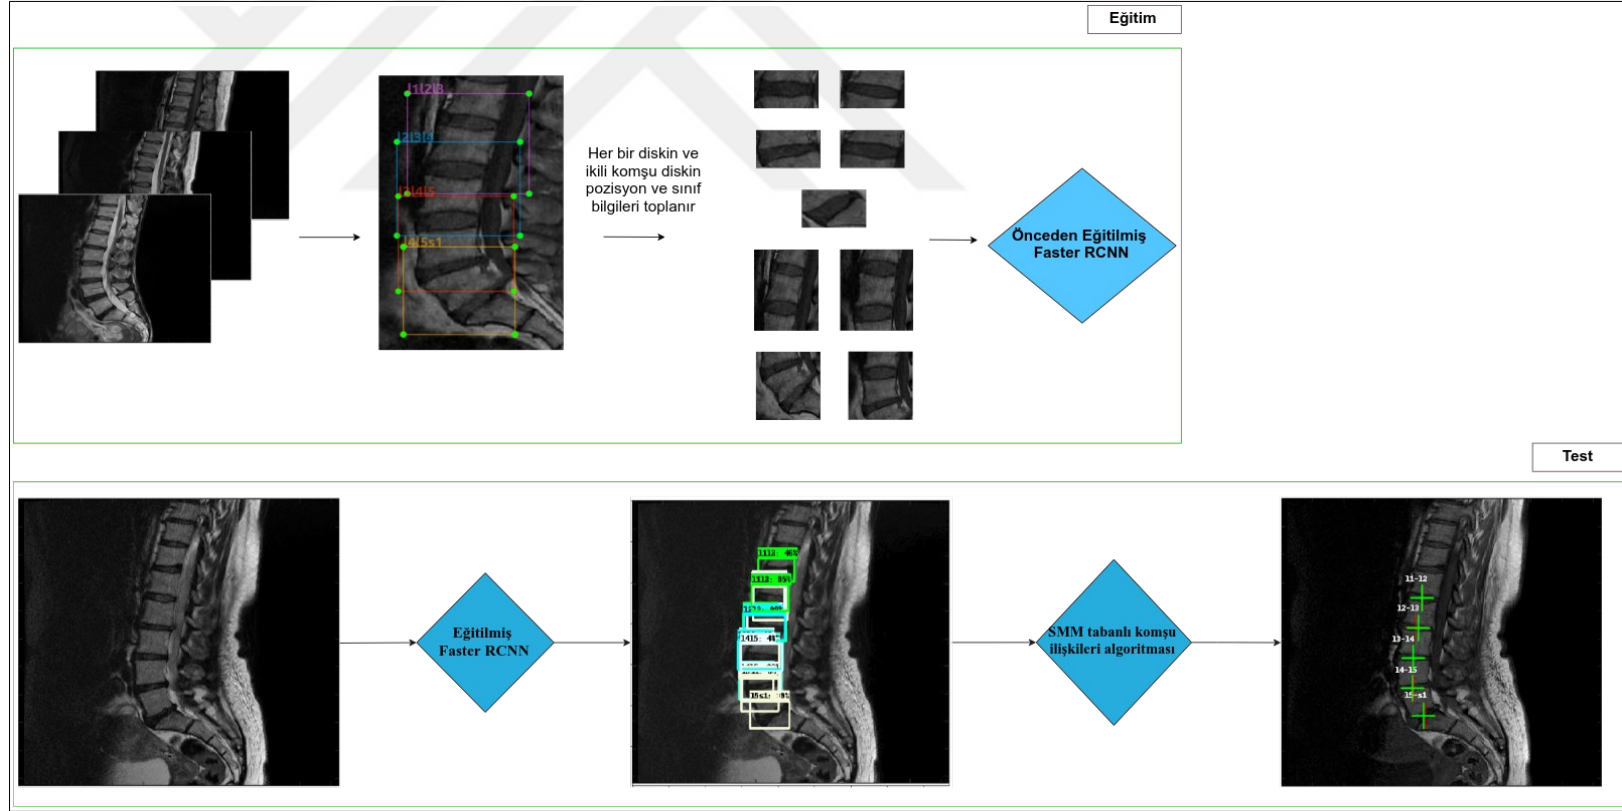
Şekil 5.1: Tek aşamalı ESA'nın eğitim ve test adımları. Tek aşamalı Faster RCNN'de ilk olarak veri kümesinde bulunan her bir MR görüntüsü için L1L2, L2L3, L3L4, L4L5, L5S1 diskleri LabelImg aracıyla sınırlayıcı kutular içerisine alınmış, etiketleri verilmiştir. Bu işlemin sonucunda her bir MR görüntüsü için, pozisyon ve sınıf bilgilerini tutan dosyalar üretilmiştir. Bu dosyalar önceden eğitilmiş Faster RCNN'e verilmiş ve eğitim tamamlanmıştır. Test aşamasında ise eğitilmiş Faster RCNN modeline test görüntüleri verilerek test edilmiştir. Test sonucunda Faster RCNN modeli, her bir disk için belli puana sahip sınırlayıcı kutular üreterek disklerin olabileceği yerler hakkında tahminlemelerde bulunmuştur.

## 5.2. Saklı Markov Modeli (SMM) Tabanlı Faster RCNN

İkinci yöntemde sistem SMM'e benzetilmiş ve disklerin yanında ikili komşu diskler de eğitilmiştir. Örneğin, L1L2 - L2L3 diskleri aynı sınırlayıcı kutu içerisine alınıp bu kutuların da  $\{x\_min, x\_max, y\_min, y\_max, genişlik, yükseklik, sınıf\ ismi\}$  bilgileri çıkarılmıştır. Böylece 5 adet disk sınıfı, 4 adet de komşu disk sınıfı olmak üzere toplam 9 sınıf oluşmuştur. Bu sınıflar ilk yöntemdeki gibi önceden eğitilmiş model olan FRCNN Inception V2 modeline verilmiş ve bu modelin son katmanında ince ayarlar yapılmıştır. Eğitim bittikten sonra test aşamasında farklı bir yöntem izlenmiştir. Test aşamasında her bir sınıf için Faster RCNN modelinin ürettiği maksimum 5 farklı sınırlayıcı kutu alınmıştır. Her bir diski bulmak için, disklerin kendi olasılıkları, ikili komşu disklerin olasılıklarıyla çarpılmış ve sonuç en üst düzeye çıkarılmaya çalışılmıştır.  $i = 0, 1, \dots$  için her bir disk adayını  $c_i$ ,  $j = 0, 1, 2, \dots$  için her bir disk sınıfı da  $s_j$  olarak kabul edelim. Bu durumda  $P_E(s_j | c_i)$ ,  $i$ . disk adayının  $j$  sınıfı olma olasılığını vermektedir.  $P_T(s_j | s_{j-1})$  ise  $j-1$  sınıfı mevcut iken,  $j$  sınıfının olma olasılığını vermektedir. Her bir diski bulabilmek için aşağıdaki 5.1 denklem sonucu en üst düzeye getirilmeye çalışılmıştır.

$$P(S, J) = P_T(s_j | s_{j-1}) \cdot P_E(s_i | c_i) \quad (5.1)$$

Her bir sınıf için üretilen maksimum beş adet sınırlayıcı kutu ve puanları için yukarıdaki denklemdeki gibi her bir disk sınıfının kendi olasılığı, bağlı olduğu komşu disk olasılıkları ile çarpılmış ve sonuç maksimuma çıkarılmaya çalışılmıştır. Bu esnada komşu olup da aynı sınırlayıcı kutu içerisinde bulunmayan diskler hesaplama alınmamış, böylece yanlış disk konumlamaları elenmiştir. Sonucu en yüksek yapan disk konumunun yer bilgileri kaydedilmiş ve diğer disklerde de aynı işlem uygulanmıştır. En son yukarıdaki denklemi maksimum eden disklerin yerleri sistem tarafından işaretlenmiştir. Test sonucunun doğruluk değerinin %89 olduğu, yani ilk yöntemden %4 daha iyi olduğu gözlemlenmiştir. Uygulanan yöntemin eğitim aşaması ve test aşaması Şekil 5.2'de gösterilmiştir.



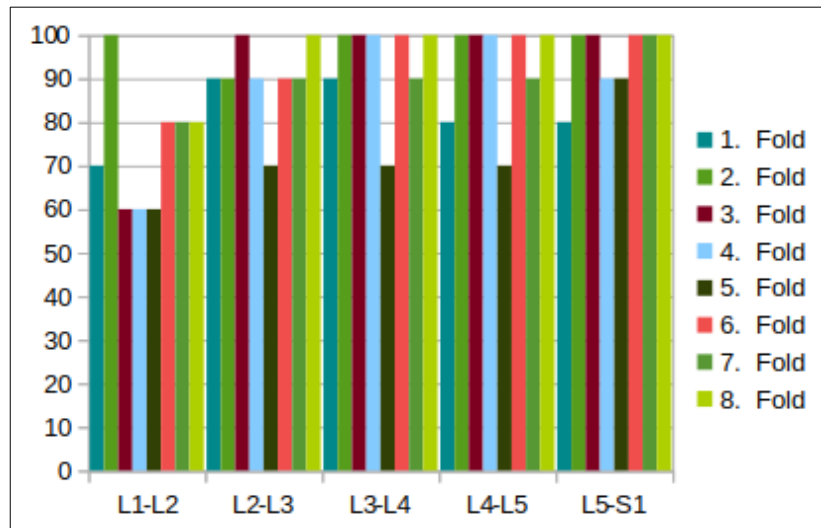
Şekil 5.2: SMM tabanlı Faster RCNN'nin eğitim ve test adımları. Veri kümesinden tek aşamalı Faster RCNN gibi L1L2, L2L3, L3L4, L4L5, L5S1 diskleri sınırlayıcı kutular içerisine alınmıştır. Bu diskler ile beraber ikili komşu diskler L1L2-L2L3, L2L3-L3L4, L3L4-L4-L5, L4L5-L5S1 diskleri de aynı sınırlayıcı kutu içerisine alınmıştır. Bu sınırlayıcı kutuların pozisyon, genişlik, yükseklik ve sınıf bilgileri bir dosyaya kaydedildikten sonra görüntülerle beraber önceden eğitilmiş Faster RCNN'e verilmiş ve eğitilmiştir. Eğitim sonucunda çıkan model test kümesindeki verilerle test edilmiş ve modelin ürettiği disk pozisyonları SMM tabanlı komşu ilişkileri algoritmasına verilerek, disklerin tam yerleri işaretlenmiştir.

Tek aşamalı Faster RCNN’de, sadece diskler eğitildiği durumda doğruluk değeri %85, ortalama merkezden hata miktarı 1.04 mm ve standart sapma 0.64 çıkmıştır. Sonuçlar ortalama 0.4 saniyede gelmektedir. Hata miktarı hesaplanırken, uzmanlar tarafından işaretlenen disk merkezleri ile sistem tarafından bulunan disk merkezleri arasındaki fark Euclidean uzaklığı

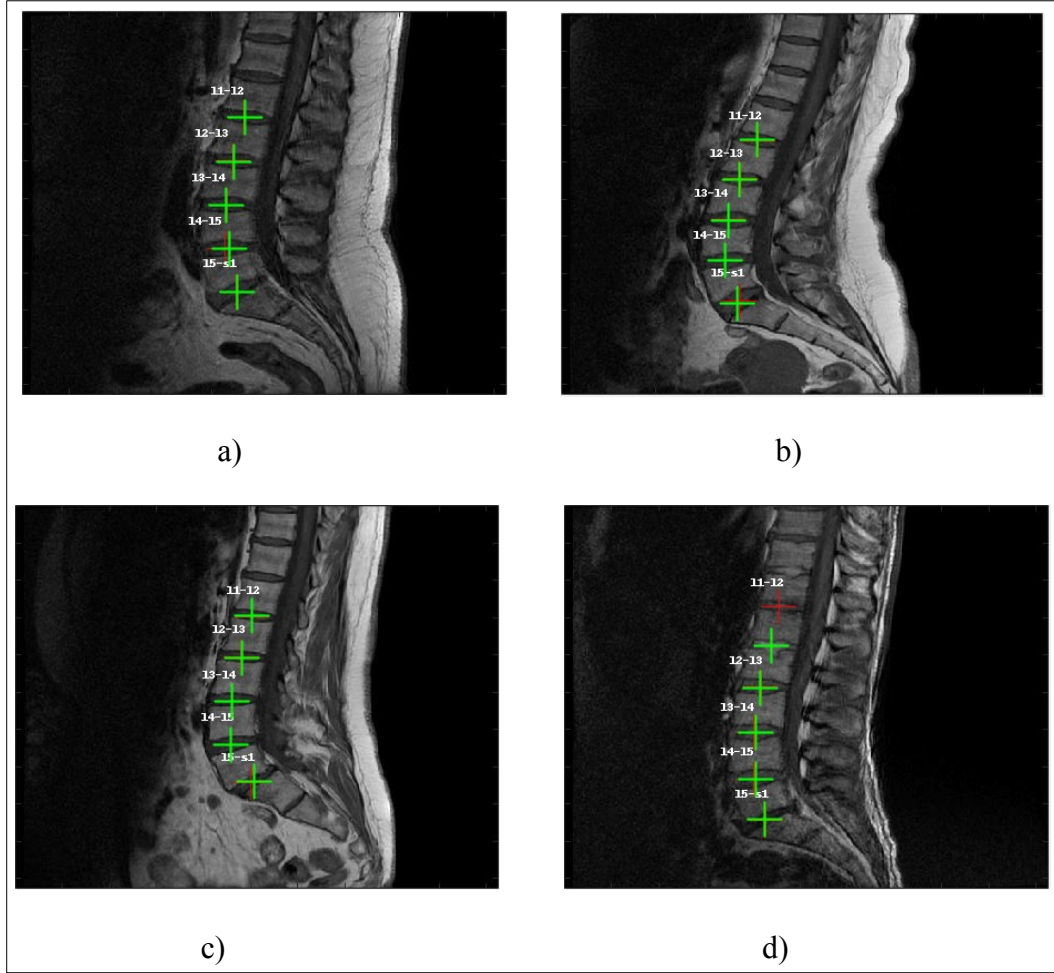
$$D_{xy} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \cdot 0.625 \quad (5.2)$$

denklemleri ile hesaplanmıştır. Her bir piksel 0.625 x 0.625 mm olduğu için, piksel farkı bulunduğundan sonra 0.625 ile çarpılmıştır.

İkinci yöntemde ikili disk ilişkileri de eklendikten sonra doğruluk değeri %89, ortalama merkezden hata miktarı 1.11 mm ve standart sapma da 0.67 olmuştur. Sonuçlar ortalama 0.6 saniyede gelmektedir. 8 çapraz katman doğrulama yönteminde her katmanda her disk için çıkan doğruluk değeri Şekil 5.3’te gösterilmiştir. Ortalama hata miktarı ve standart sapma miktarı çok az seviyede artmış olup sistemin doğru çalışması, bu miktardaki artıştan daha önemli derecede rol almaktadır. Sistemin test kümesinden modelin doğru ve yanlış sonuçlar ürettiği örnek MR görüntüleri Şekil 5.4’te gösterilmiştir. Tablo 5.1’de ise iki yöntemin karşılaştırmalı sonuçları bulunmaktadır.



Şekil 5.3: 8 çapraz katman doğrulama yöntemindeki katmanların doğruluk değerleri. Her bir renk, bir katmanı göstermektedir.



Şekil 5.4: SMM tabanlı Faster RCNN yönteminden örnek MR görüntüleri. a), b) c)'deki görüntüler sistemin doğru sonuç görüntüleri, d) görüntüsü sistemin doğru çalışmadığı örnek görüntü.

Tablo 5.1: Tekli ve SMM tabanlı Faster RCNN sonuçlarının karşılaştırılması.


Yöntem	Doğruluk Değeri	Merkezden Hata Miktarı (mm)	Standart Sapma	Çalışma Zamanı
Tek Aşamalı Faster RCNN	%85	1.04	0.64	0.4
SMM tabanlı Faster RCNN	%89	1.11	0.67	0.6

## 6. EN KISA YOL ALGORİTMASI TABANLI FASTER RCNN

Bu yöntemde de gerçek zamanlı çalışmasından, az bellek tüketmesinden, yüksek doğruluk değerinden dolayı, 2. yöntemdeki gibi Faster RCNN kullanılmıştır. Sistem iki aşamadan oluşmuş olup grafiksel bir yöntemdir. Sistem özet olarak, ilk aşamada Faster RCNN ile aday diskleri bulmaktadır. Bu aday diskler, çizgede düğümleri oluşturmaktadır. İkinci aşamada sistemin iki komşu disk arasındaki ilişkiyi öğrenebilmesi için ayrı bir tekli ESA (TESA) eğitilmiştir. Eğitilen TESA sonucu oluşan model, ağırlıklı çizgedeki bağlantıları oluşturmaktadır. Bağlantıların ağırlıkları, iki aşamadan çıkan puanlardan hareketle bir formül ile hesaplanmış ve çizgedeki en kısa yolu bulabilmek için Dijkstra'nın en kısa yol algoritması kullanılmıştır.

### 6.1. İlk Eğitim Aşaması: Önceden Eğitilmiş Faster RCNN

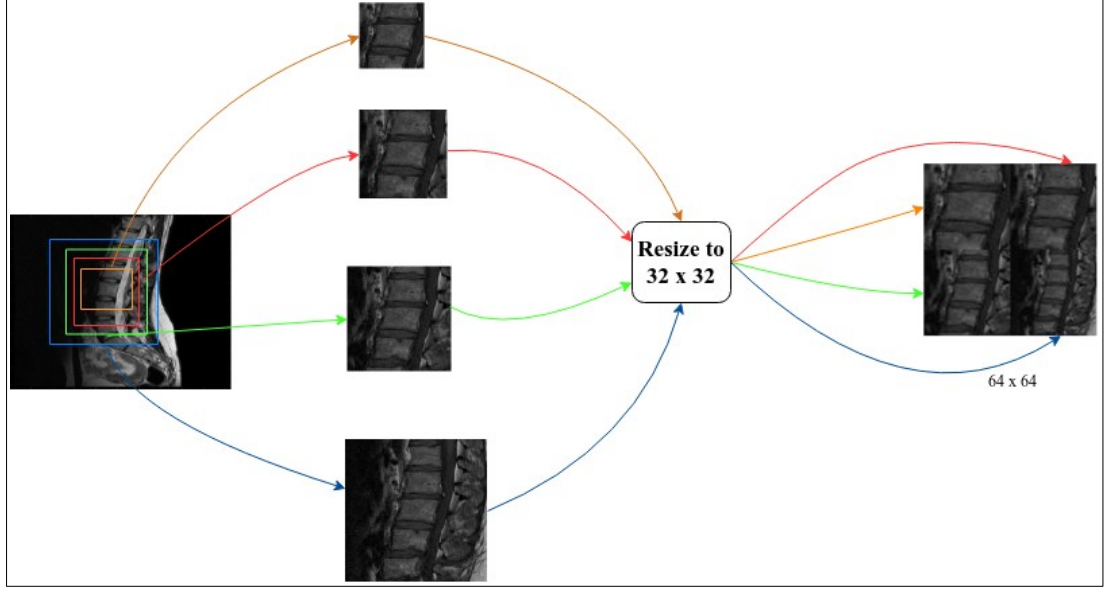
İlk aşamada eğitim ve test verisinin oluşturabilmesi için 2. yöntemdeki gibi (Algoritma 5.1.) veri artırma algoritması ile görüntüler artırılmış ve LabelImg ile görüntülerin pozisyonel özellikleri çıkarılıp bir xml dosyasına kaydedilmiştir. 2. yöntemden farklı olarak 10 çapraz katman doğrulama kullanılmıştır. Böylece 8000 verinin, 7200'ü eğitim, 800'ü test verisi olacak şekilde ayrılmıştır. Eğitim kümesinden örnek bir MR görüntüsü Şekil 6.1'deki gibidir. Görüntüler önceden eğitilmiş model olan FRCNN Inception V2 modelinde ince ayarlamalar yapılarak 10 katman eğitilmiştir. Model, 2. yöntemdeki gibi 57. 000 epoka kadar eğitilmiş ve her bir katman 2 saat sürmüştür. Test zamanında model her bir disk için pozisyonel ve koordinat bilgisi olan belli bir puana sahip sınırlayıcı kutu üretmektedir.  $i = 0,1,2 \dots$  için her disk adayını  $c_i$ ,  $j = 0,1,2 \dots$  için her bir disk etiketini  $d_j$  olarak farz edelim. Bu durumda bu aşamanın sonucu  $P_E(d_i | c_j)$ , aday bir diskin  $d_i$  etiketi olma olasılığını vermektedir. Tek aşamalı Faster RCNN'de denenip görüldüğü üzere, tek başına bu bilgi diskleri bulmak için yeterli değildir. Bunun sebebi, eğitim kümesinin yeterli olmaması, Faster RCNN'lerin diskleri bağımsız, tek başına öğrenmesi, birbirleri aralarındaki sıralamadan, ilişkiden bihaber olması ve disklerin görünüş açısından birbirlerine çok benzemesinden kaynaklanmaktadır. Bu sebeple, disklerin aralarındaki ilişkinin öğrenebilmesi için ayrı bir ESA modeli eğitilmiştir.



Şekil 6.1: Veri kümesinden örnek bir MR görüntüsü.

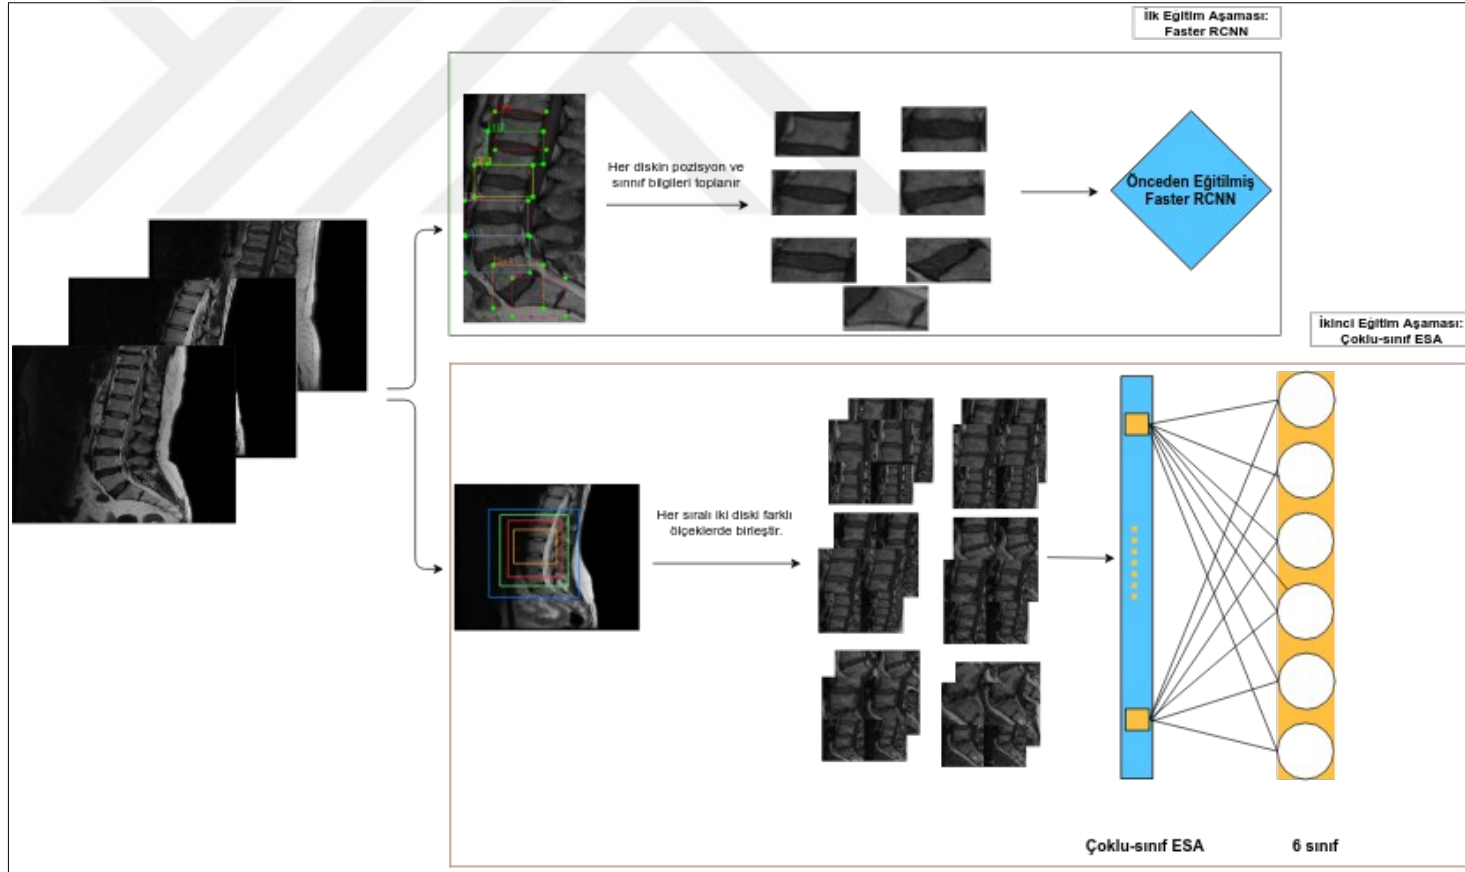
## 6.2. İkinci Eğitim Aşaması: Evrişimli Sinir Ağları

İkinci aşamada iki disk arasındaki ilişkinin öğrenilebilmesi için TESA eğitilmiştir. Öncelikle bu aşama için ayrı bir veri kümesi hazırlanmıştır. Disklerin merkezleri baz alınarak iki komşu disk, 64x64 boyutunda görüntü parçacığı olacak şekilde görüntüden kesilmiştir. Burada ikili komşu diskler tek başlarına alınmamıştır. Bunun sebebi tek başlarına alınınca sisteme daha az bilgi vermesi ve eğitimin iyi çıkmamasıdır. Bunun yerine aynı disk merkezinden, dört farklı boyutta görüntü parçacıkları çıkarılmış ve ardından 32x32'ye yeniden boyutlandırılıp 64x64 boyutlu bir görüntüde birleştirilmiştir. Böylece komşu disklerin çevre bilgisi de eğitime verilmiştir. Bu aşamaların görsel hali Şekil 6.2'de gösterilmiştir.



Şekil 6.2: İkili komşu diskin farklı boyutlarda, eğitim kümesi oluşturma adımları. Her komşu ikili diskin, iki katmanlı ESA'daki gibi, aynı merkezden farklı ölçeklerde görüntü parçacıkları çıkarılıp 32x32'ye indirgenmiş ve en son 64x64'lük bir görüntü içerisinde bu görüntü parçacıkları birleştirilmiştir.

Veri kümesinde birinci eğitim aşamasındaki gibi 8000 görüntü vardır. Bunlardan 7200'ü eğitim, 800'ü test verisi olarak kullanılmıştır. ESA modeli basit bir model olup sırasıyla 2B evrişim katmanı – 2B maksimum ortaklama katmanı – seyreltme katmanı – düzleştirme katmanı – yoğun katman – seyreltme katmanı – yoğun katmanından oluşmaktadır. Etkilenim fonksiyonu olarak softmax, iyileştirici olarak rastgele gradyan inişi [45], yitim fonksiyonu olarak ise kategorisel çapraz entropi [46] kullanılmıştır. 1. aşama ile aynı şekilde 10 çapraz katman doğrulama yöntemi kullanılarak eğitim tamamlanmıştır. Test aşamasında model bir önceki diskin sınıfını bilirken, diğer diskin etiketinin ne olduğu olasılığını vermektedir. Yani TESA her ikili disk için  $P_T(d_i | d_{i-1})$  olasılığını vermektedir. Eğitim aşamalarının görsel hali Şekil 6.3'teki gibidir.



Şekil 6.3: En kısa yol tabanlı Faster RCNN'nin eğitim aşamaları. Eğitim aşamasında her bir diskin LabelImg aracılığıyla pozisyonel, yükseklik, genişlik ve sınıf bilgileri bir soyaya kayıt edildikten sonra görüntülerle birlikte önceden eğitilmiş Faster RCNN'e verilmektedir. Bu aşamada eğitim devam ederken, diğer eğitim aşamasında iki diskin merkezlerinden farklı ölçeklerde alınan görüntü parçacıkları aynı boyuta indirgenip 64x64'lük bir görüntüde birleştirilmiş ve bu görüntüler çoklu sınıf ESA'ya verilerek eğitim süreci başlatılmıştır.

### 6.3. Test Aşaması

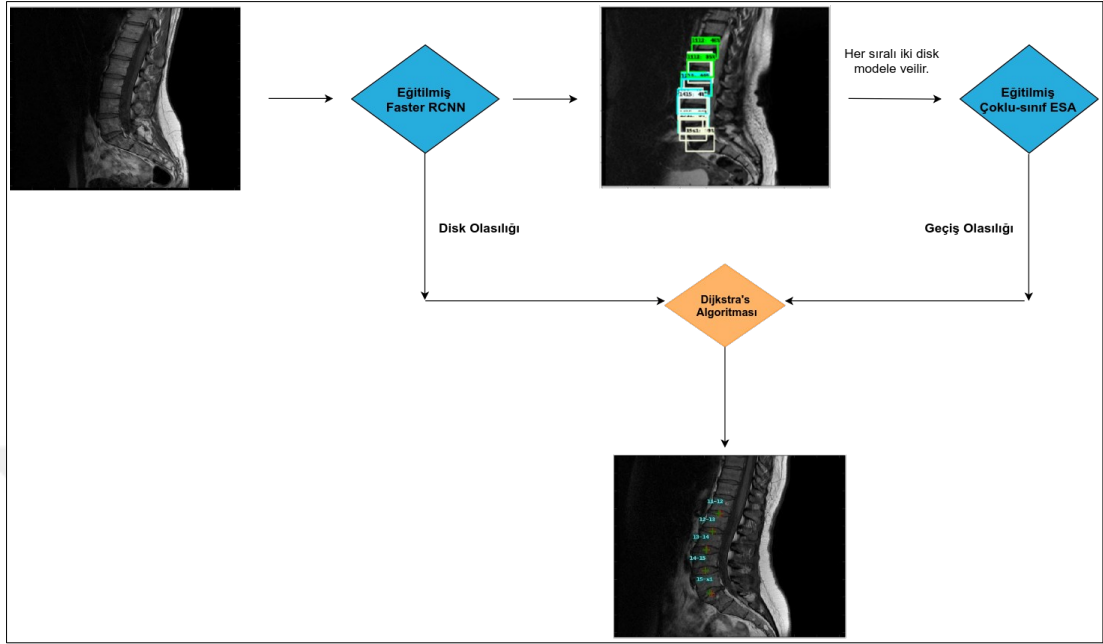
Test aşamasında bu iki eğitim aşaması sonucu oluşan modeller birbirlerine çizge ile bağlanmıştır. Öncelikle ilk eğitim aşamasında oluşan aday disklerden her bir disk için maksimum 5 aday alınmıştır. Bu disk adayları çizgedeki düğümlere karşılık gelmektedir. Her bir düğümün kendine ait bir puanı bulunmaktadır. İkinci aşamadaki model ise iki komşu diski birbiriyle bağıntı ile bağlanmasını sağlamaktadır. Bu bağıntı maliyetleri hesaplanırken

$$W = \begin{cases} 1 - P_E(d_i|c_j) & \text{if } i=0 \vee i=n \\ 1 - P_E(d_i|c_j) + 1 - P_T(d_i|d_{i-1}) & \text{otherwise} \end{cases} \quad (6.1)$$

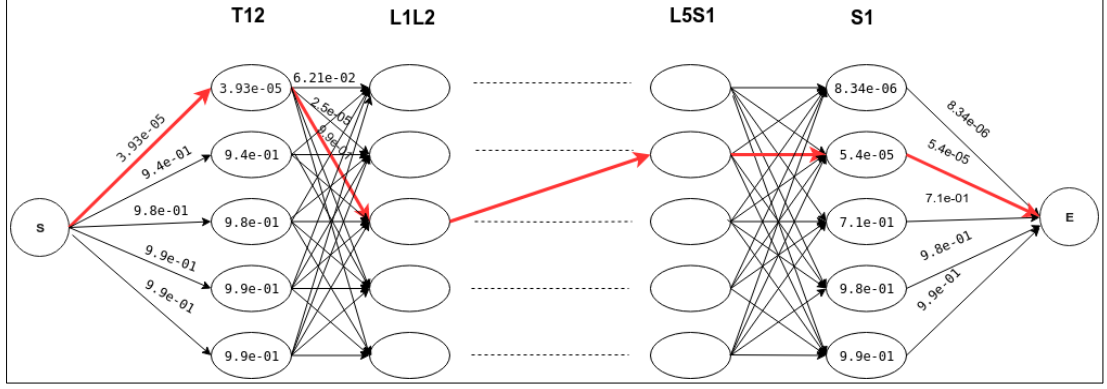
denklemini esas alınmıştır. Buradaki n disk ve omur sayısını vermektedir. Amaç maksimum olasılıklı disk sıralamasını bulmak için maliyeti en aza indirmektir. Bu sebeple en kısa yol algoritmalarından Dijkstra'nın algoritması kullanılmıştır. Böylece algoritma polinomal sürede en olası disk yolunu vermektedir.

Test aşamasında yapılanlar şu şekildedir: Öncelikle önceden öğrenilmiş olan Faster RCNN modeli test verisi üzerinde test edilmiş ve her bir disk için beş tane maksimum değer alınmıştır. Sistem çizge olarak düşünülmüş ve her bir aday çizgede düğümlere karşılık gelmiştir. İki düğümün komşu olma olasılığı, TESA eğitimi sonucu çıkan modelden öğrenilmiştir. Komşu olasılığı ve düğümün kendi puanı 6.1'deki denkleme verilmiş ve bağlantıların ağırlıkları bulunmuştur. Sistemde 5 adet disk bulunmakta ve her bir diskin 5 tane adayı bulunmaktadır. Tüm adaylar arasında en olası disk sıralamasını bulabilmek için tek tek tüm yollara bakılırsa, bu işlemin çalışma zamanı  $5^5$  olmaktadır. Disk sayısı arttıkça algoritmanın karmaşıklığı  $O(5^n)$  olmakta bu da sistemin çalışma zamanının polinomal bir zamanda sonuçlanamayacağını göstermektedir. Problemi polinomal bir zamanda çözebilmek için en kısa yol algoritmalarından biri olan Dijkstra's Algoritması kullanılmıştır. Bu algoritma ile başlangıç düğümünden başlanarak son düğüme kadar en kısa maliyete sahip bağlantılar seçilerek son düğümde en olası disk sıralaması polinomal zamanda bulunmuştur. Sistemin başlangıç ve bitiş disklerini karıştırmaması, daha doğru ve güçlü çalışması için başlangıç omuru olan t12 omuru ve bitiş omuru olan s1 omuru

da eğitime ve teste katılmıştır. Şekil 6.4'te sistemin test aşaması, Şekil 6.5'de ise Dijkstra's Algoritması'nın sistemdeki görsel hali bulunmaktadır.




Şekil 6.4: En kısa yol tabanlı Faster RCNN'nin test aşamaları. Test kümesinde bulunan MR görüntüsü eğitilmiş Faster RCNN modeline verildikten sonra her disk için çıkan olası sınırlayıcı kutular birleştirilerek, eğitilmiş çoklu sınıflandırıcı ESA'ya verilir. Eğitilmiş Faster RCNN'den alınan olasılık değeri ile, eğitilmiş çoklu sınıflandırıcı ESA'dan alınan olasılık değerlerinin bir denkleme (6.1) verilmesiyle oluşturulan maliyetler Dijkstra'nın Algoritması'na verilerek en az maliyetli yol belirlenir.



Şekil 6.5: Dijkstra's Algoritmasının sistemdeki görsel hali. Her bir diskin Eğitilmiş Faster RCNN modeli sonucu çıkan, olası maksimum 5 değeri alınmış ve bu değerler çizgede düğümlere denk gelmiştir. Bağıntı (geçiş) maliyetleri ise, çoklu-sınıf ESA'nın ve Faster RCNN modelinin verdiği olasılık değerinin (6.1) denklemine verilmesi ile oluşturulmuştur. Bu değerlere göre Dijkstra's Algoritması maliyeti en az olan yolu bulmuştur.

## 6.4. Deneyler

Sistemde belirtildiği gibi test olarak 10 çapraz katman doğrulama yöntemi kullanılmıştır. Bu çapraz doğrulama sonucu, sistemin elde ettiği doğruluk değeri %96.25'tir. Şekil 6.6'daki grafik 10 çapraz katman doğrulama yöntemindeki her katmanın doğruluk değerini göstermektedir.



Şekil 6.6: 10 çapraz katman doğrulama yöntemi sonuç grafiği - Her katmanın doğruluk değeri farklı bir renk ile gösterilmiştir.

Sistemin doğruluk değerinin yanında Dice puanı [47] da hesaplanmıştır. Bunun için

$$\frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (6.2)$$

- TP: Doğru bulunan yere doğru demek, doğru onaylanmış
- FP: Yanlış bulunan yere doğru demek, hatalı onaylanmış
- FN: Yanlış bulunan yere yanlış demek, hatalı reddedilmiş

denklemini esas alınmıştır. Bu denklemden hareketle sistemin dice puanı %98 çıkmaktadır.

Sistemin merkezden hata uzaklığını bulmak için 5.2'deki denklem kullanılmıştır. Standart sapmayı hesaplamak için ise

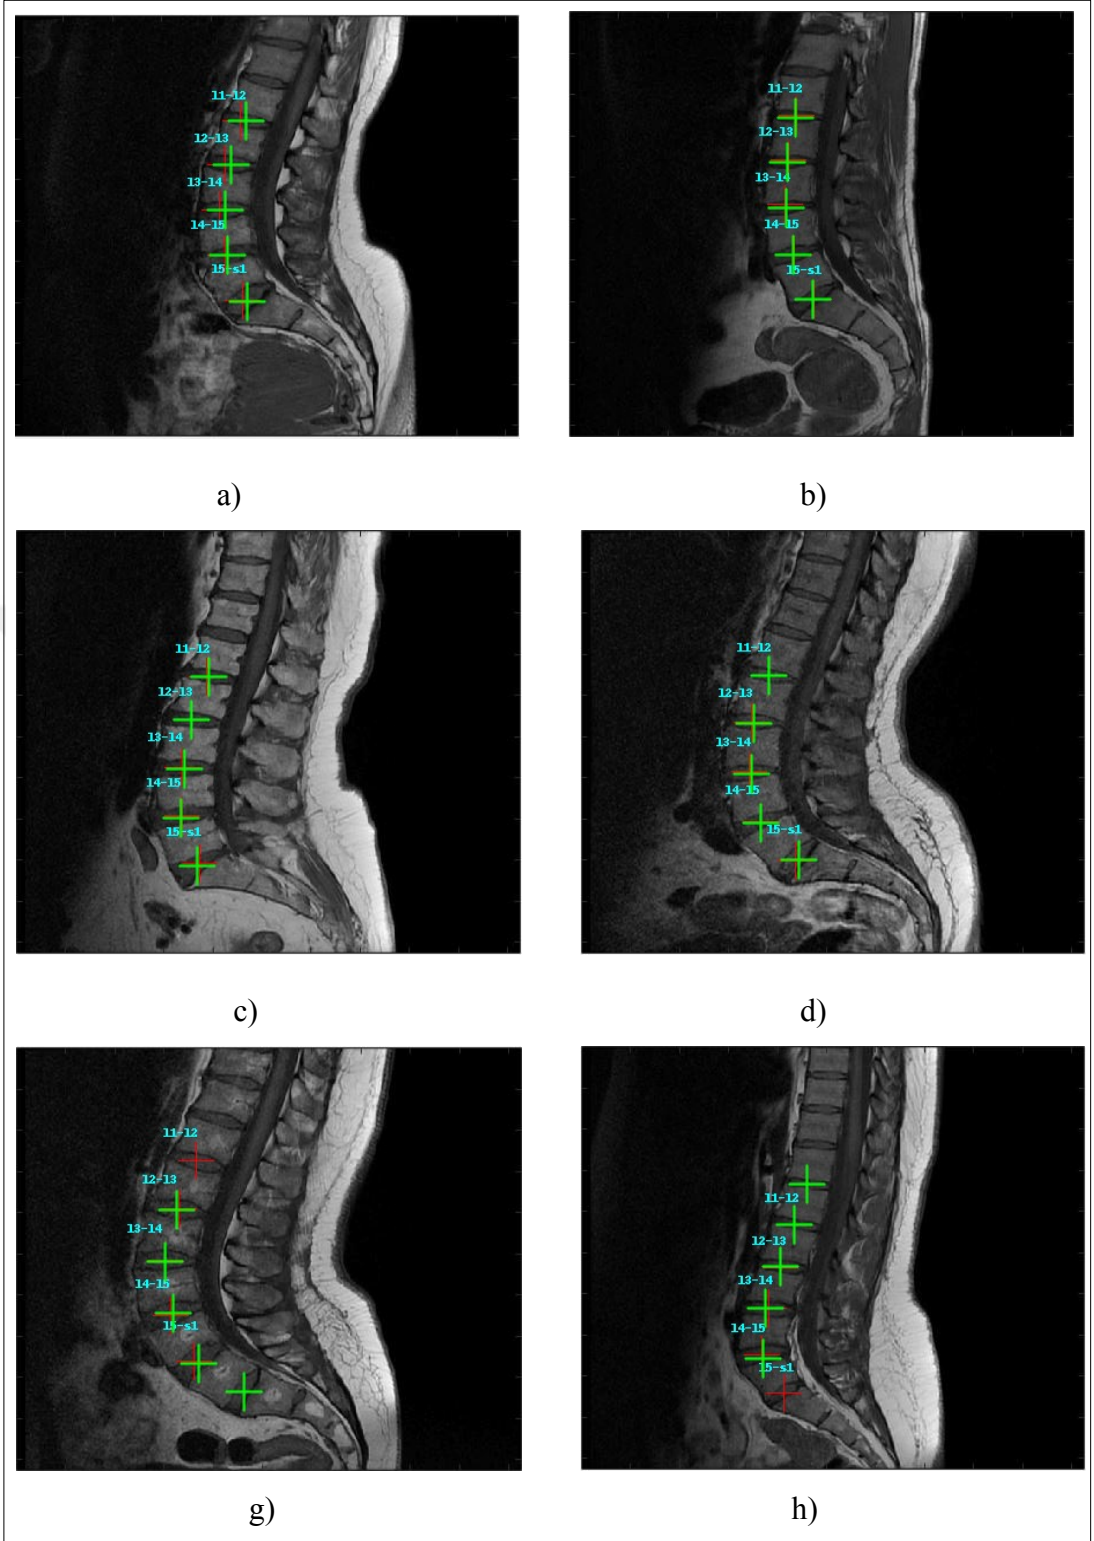
$$\sigma = \sqrt{\frac{\sum (x - \text{mean})^2}{2}} \quad (6.3)$$

formülü kullanılmıştır. Sistemin merkezden olan ortalama hatası ve standart sapması hesaplanırken sadece doğru onaylanmış sonuçlarda ve doğru onaylanmış (TP), hatalı reddedilmiş (FP) görüntülerin bütününde denenmiştir. Sonuçlar Tablo 6.1'deki gibidir.

Tablo 6.1: Tüm sistemin TP ve FP sonuçlarında, doğruluk değeri, dice puanı, merkezden hata miktarı ve standart sapma değerlerini göstermektedir.

Yöntem – Test Kümesi	Doğruluk Değeri	Dice Puanı	Merkezden Hata Miktarı (mm)	Standart Sapma
Faster RCNN (TP)	%85	%91	1.04	0.64
Faster RCNN (TP + FP)	%85	%91	2.47	5.6
Faster RCNN + TESA + Dijkstra's Alg. (TP)	%96.25	%98	1.08	0.68
Faster RCNN + TESA + Dijkstra's Alg. (TP + FP)	%96.25	%98	1.98	4.63

Sistemin test MR görüntülerindeki sonuçları Şekil 6.7'deki gibidir. Yeşil artı işaretleri radyolog tarafından işaretlenmiştir. Kırmızı artı işaretleri ise sistem tarafından otomatik işaretlenmektedir.



Şekil 6.7: En kısa yol tabanlı Faster RCNN sistem sonuçları. a)'dan d)'ye kadar olan görüntüler sistemin tüm diskleri doğru bulduğu görüntülerdir. e) ile f) görüntülerinde sistem yanlış çalışmış ve tüm diskleri kaydırmıştır.

Şekil 6.7'de görüldüğü gibi sistemin yanlış çalıştığı durumlarda tüm diskler kaymaktadır. Bunun sebebi, sistemin Dijkstra's algoritması ile en kısa yolları

bulmaya çalışması ve bütünsel karar vermesidir. SMM tabanlı Faster RCNN’de sadece komşu disklerle bakılmış ve yerel sonuçlar elde edilmiş bu durum da doğruluk değerinin çok yüksek olmamasına sebep olmuştur. Bu yöntemde ise hem yerel sonuçlara bakılmış hem de Dijkstra’s algoritması ile bütünsel sonuçlar çıkarılmıştır. Bu durum doğruluk değerini artırır da yanlış çıktığı durumda tüm disklerin kaymasına sebep olmuştur. Sistemin tek dezavantajı budur. Bu dezavantaj da verilerin artırılmasıyla giderilebilir.

Sistem 1.1 saniyede sonuçları getirmektedir. Bu da sistemin, bu alanda yapılmış en son çalışmalarla karşılaştırılabilir seviyede olduğunu göstermektedir. Sistemin bu kadar hızlı olmasının sebebi Faster RCNN ve en kısa yol algoritması olan ve polinomal zamanda çalışan Dijkstra’s algoritmasıdır.

Bu sistemde kullanılan veri kümesi ile [26] ‘teki makalede kullanılan veri kümesi aynıdır. Bu iki sistem arasında karşılaştırma yapılırsa, [26]’te doğruluk değeri %97, ortalama merkezden hata miktarı 3.25 mm’dir. Bu sistemin doğruluk değeri ise %96, merkezden hata miktarı ise 1.08 mm’dir. Bu sonuçlar bu sistemin çok kısa sürede benzer doğruluk değerinde, merkezi daha doğru bir şekilde bulunduğunu göstermektedir. Denenen yöntemlerde en iyi olan Dijkstra’s algoritması tabanlı Faster RCNN’nin, diğer makalelerde geçen sistemlerle karşılaştırılması Tablo 6.2’deki gibidir.

Tablo 6.2: Bu alanda daha önceden makalelerdeki, bir bel MR/BT görüntüsündeki disklerin/omurların bulunması için uygulanan yöntemlerin karşılaştırılması.

Yöntem	Doğruluk (%)	Dice Puanı	Merkezden Hata Miktarı (mm)	Standart Sapma	Çalışma Zamanı
Dijkstra's Alg. tabanlı Faster RCNN	96.25	98	1.08	0.68	1.1 sn.
Jamaludin [48]		84	1.1	0.6	-
Glocker [28]	81		6.1	5.5	2 dakikadan az
Oktay [26]	97		3.1		-
Suzani [16]	95		18.2	11.4	3 saniyeden az
Chen [30]	84		8.82	13.04	-
Lootus [20]	84		3.3	3.2	1 dakikadan az
Cai [49]	98.1		3.23	2.09	-
Yang [50]	90		6.4	5.9	3 sn.

Her ne kadar [26]'teki makale dışında, diğer tüm makalelerde kullanılan veri kümeleri ile bu çalışma kapsamında kullanılan veri kümesi farklı olsa da Tablo 6.2'de de görüldüğü gibi üçüncü yöntem olan Dijkstra's algoritması tabanlı Faster RCNN'nin standart sapma, ortalama merkezden hata miktarı, çalışma zamanı açısından diğer denenen yöntem ve makalelerden daha iyi sonuç vermesi, bu yöntemin bu alanda kullanılabileceğini göstermektedir.

## 7. SONUÇLAR

Bu tez kapsamında bir bel MR görüntüsündeki diskleri otomatik bulabilmek için toplamda üç farklı yöntem denenmiştir. İlk yöntem olan iki aşamalı ESA'da, [25] makalesi baz alınarak, ilk aşamada ESA ile her bir disk için ayrı inanç haritaları oluşturulmuş, ikinci aşamada ise birinci aşamada üretilen bu inanç haritaları görüntü özellikleri ile beraber farklı bir ESA ile eğitilmiş ve kayan pencere yöntemi ile test verisi üzerinde test edilmiştir. Sistemin doğruluk oranı %95 olup çalışma zamanı 20 dak.'dir. Bu yöntemin en büyük dezavantajı kayan pencere ile tüm görüntüyü piksel piksel dolaşması ve bu işlemin de çalışma zamanını artırmasıdır. Bu sebeple farklı sinir ağlarına yönelinmiş ve disk bulma problemi nesne bulma problemi olarak düşünülmüştür.

Nesne bulma problemlerinin çözümü için son dönemlerde doğruluk değeri, ortalama hata miktarı, çalışma zamanı açısından en güncel araştırmalarda en iyi sonuçlardan birini yakalayan Faster RCNN, farklı yöntemlerle bir araya getirilerek disk bulma problemi için kullanılmıştır. Tek aşamalı Faster RCNN hızlı olsa da, diskleri ayrı ayrı birbirinden bağımsız olarak öğrendiği için doğruluk açısından çok fazla yeterli olmamıştır. SMM tabanlı Faster RCNN ise yerel olarak ikili disk ilişkilerini öğrenip daha yüksek doğruluk oranına sahip olsa da, bütünsel olarak çıkarım yapamadığı için istenilen seviyeye gelememiştir.

En kısa yol algoritması tabanlı Faster RCNN'de, ilk aşamasında Faster RCNN'nin hızından, yüksek doğruluk değerinden yararlanılmış, ikinci aşamasında ise yerel olarak iki disk arasındaki disk ilişkisi öğrenilmiştir. Test aşamasında bütünsel bir çıkarım yapabilmek için bu iki sinir ağı, çizgede birleştirilmiş, en kısa yol algoritmalarından biri olan Dijkstra's algoritması ile bütünsel çıkarımlar yapılarak en olası disk yolu bulunmuştur. Bu sayede en yüksek doğruluk oranına varılmıştır. Son yöntem, bu çalışmada denenilen diğer yöntemlerden daha yüksek doğruluk değerine sahiptir.

Bu alanda yapılan çalışmalarla karşılaştırıldığında ise Tablo 6.2'de görüldüğü gibi hız, merkezden hata miktarı, standart sapma açısından tüm denenilen yöntemlerden daha iyi sonuç vermiştir. Her ne kadar [26] makalesindeki veri kümesi hariç diğer veri kümeleri farklı olduğu için denenilen yöntemin daha iyi olduğu iddia edilemese de sonuçlar umut vericidir. Aynı veri kümesini kullanan [26] makalesindeki sonuçlarla karşılaştırıldığında ise yöntemin makalede denenilen

yöntemden çalışma zamanı, merkezden hata miktarı açısından daha iyi sonuç verdiği gözlemlenmiştir.

Tez kapsamında yapılan bu çalışma ile Faster RCNN, disklerin otomatik bulunması probleminde ilk kez bu çalışma ile denenmiştir. Bu alanda veri sayısının az olmasından dolayı, modeli baştan eğitmek yerine önceden başka bir veri kümesi üzerinde eğitilmiş modelin kullanılmasının daha iyi sonuç verdiği gözlemlenmiştir. Büyük bir veri kümesi üzerinde eğitim sonucu oluşan model, buradaki problem için çok büyük ve karmaşıktır. Bu sebeple, sisteme çalışma zamanı ve hafızada tahsis ettiği yer bakımından bir dezavantaj katmıştır. Sağlık alanında toplanan MR, BT gibi görüntüler üzerinde eğitilmiş bir model olursa, sistemin daha iyi bir sonuç vereceği düşünülmektedir.

Bütünsel bilgilerin çıkarılması için kullanılan Dijkstra's algoritması da literatürde bu bağlamda ilk kez kullanılmış ve polinomal zamanda çalışması ile disklerin daha hızlı bulunmasını sağlamıştır.

Yapılan bu çalışma, bel MR görüntülerindeki disklerin yanlış bulunması, yanlış tedavilerin uygulanması gibi problemlerin önüne geçmesi açısından önem arz etmektedir.

Bu çalışma ile bir bel MR görüntüsündeki disklerin otomatik bulunmasına farklı bir bakış açısı ve yöntem geliştirilmiştir. Gelecek çalışmalarda sistemin doğruluk değeri artırılmaya çalışılacaktır. Şu an 2B ve MR görüntülerinde denenilen yöntemler, 3B BT görüntülerine de uygulanacaktır. Sadece bel disklerine değil omurgada tüm disk ve omurlar için aynı yöntemler denenecektir. İleriki aşamalarda otomatik olarak bulunan omur ve disklerden, hastalık teşhisinin de otomatik olarak yapılması için çalışılacaktır.

## KAYNAKLAR

- [1] Jamaludin M., (2017), "Automated analysis of spinal MRI using deep learning", Doctoral dissertation, University of Oxford.
- [2] Vos T., Flaxman A. D., Naghavi M., Lozano R., Michaud C., Ezzati M., Abraham J., (2012), "Years lived with disability (YLDs) for 1160 sequelae of 289 diseases and injuries 1990–2010: a systematic analysis for the Global Burden of Disease Study 2010", *The Lancet*, 380 (9859), 2163-2196.
- [3] Web1, (2018) ,<https://www.sciencedirect.com/topics/medicine-and-dentistry/intervertebral-disk>, (Erişim Tarihi: 24/09/2018).
- [4] Hanaoka S., Fritscher K., Schuler B., Masutani Y., Hayashi N., Ohtomo K., Schubert R., (2011), "Whole vertebral bone segmentation method with a statistical intensity-shape model based approach", *Medical Imaging 2011: Image Processing*, 7962, 796242.
- [5] Klinder T., Ostermann J., Ehm M., Franz A., Kneser R., Lorenz C., (2009), "Automated model-based vertebra detection, identification, and segmentation in CT images", *Medical image analysis*, 13 (3), 471-482.
- [6] Naegel B., (2007), "Using mathematical morphology for the anatomical labeling of vertebrae from 3D CT-scan images", *Computerized Medical Imaging and Graphics*, 31 (3), 141-156.
- [7] Rasoulia A., Rohling R. N., Abolmaesumi P., (2013), "A statistical multi-vertebrae shape pose model for segmentation of CT images", In *Medical Imaging 2013: Image-Guided Procedures, Robotic Interventions, and Modeling*, 8671, 86710.
- [8] Peng Z., Zhong J., Wee W., Lee J. H., (2006), "Automated vertebra detection and segmentation from the whole spine MR images", In *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, 2527-2530.
- [9] Raja'S, Alomari, Jason J. Corso, Vipin Chaudhary, (2010), "Labeling of lumbar discs using both pixel-and object-level features with a two-level probabilistic model", *IEEE transactions on medical imaging*, 30 (1), 1-10.
- [10] Lecron F., Benjelloun M., Mahmoudi S., (2012), "Fully automatic vertebra detection in x-ray images based on multi-class SVM", In *Medical Imaging 2012: Image Processing*, 8314, 83142.
- [11] Raja'S A., Corso J. J., Chaudhary V., Dhillon G., (2009), "Desiccation diagnosis in lumbar discs from clinical MRI with a probabilistic model", In *2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro* 546-549.

- [12] Raja'S A., Corso J. J., Chaudhary V., Dhillon G., (2010), "Computer-aided diagnosis of lumbar disc pathology from clinical lower spine MRI", *International journal of computer assisted radiology and surgery*, 5 (3), 287-293.
- [13] Fardon, David F., Pierre C. Milette, (2001), "Nomenclature and classification of lumbar disc pathology: recommendations of the combined task forces of the North American Spine Society, American Society of Spine Radiology and American Society of Neuroradiology", *Spine*, 26 (5), E93-E113.
- [14] Pfirrmann C. W., Metzdorf A., Zanetti M., Hodler J., Boos N., (2001), "Magnetic resonance classification of lumbar intervertebral disc degeneration", *Spine*, 26 (17), 1873-1878.
- [15] Remonda L., Lukes A., Schroth G., (1996), "Spinal stenosis: current aspects of imaging diagnosis and therapy", *Schweizerische medizinische Wochenschrift*, 126 (6), 220-229.
- [16] Suzani A., Rasoulia A., Seitel A., Fels S., Rohling R. N., Abolmaesumi P., (2015), "Deep learning for automatic localization, identification and segmentation of vertebral bodies in volumetric MR images", In *Medical Imaging 2015:Image-Guided Procedures, Robotic Interventions and Modeling*, 9415, 941514.
- [17] Zukic D., Vlasak A., Egger J., Horinek D., Nimsky C., Kolb A, (2014), "Robust detection and segmentation for diagnosis of vertebral diseases using routine MR images", In *Computer Graphics Forum*, 33, 6, 190-204.
- [18] Web2, (2018), <https://acikders.ankara.edu.tr/mod/resource/view.php?id=61243>, (Erişim Tarihi: 12/11/2018).
- [19] Athertya J. S., Kumar G. S., (2016), "Segmentation and labelling of human spine mr images using fuzzy clustering", *CS and IT-CSCP*, 2016, 99-108.
- [20] Lootus M., Kadir T., Zisserman A., (2014), "Vertebrae detection and labelling in lumbar MR images", In *Computational methods and clinical applications for spine imaging*, 219-230.
- [21] Chen H., Shen C., Qin J., Ni D., Shi L., Cheng J. C., Heng P. A., (2015), "Automatic localization and identification of vertebrae in spine CT via a joint learning model with deep neural networks", In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 515-522.
- [22] Wang X., Zhai S., Niu Y., (2019), "Automatic Vertebrae Localization and Identification by Combining Deep SSAE Contextual Features and Structured Regression Forest", *Journal of digital imaging*, 32 (2), 336-348.

- [23] Schmidt S., Kappes J., Bergtholdt M., Pekar V., Dries S., Bystrov D., Schnörr C., (2007), "Spine detection and labeling using a parts-based graphical model", In Biennial International Conference on Information Processing in Medical Imaging, 122-133, Berlin, Heidelberg.
- [24] Ghosh S., Malgireddy M. R., Chaudhary V., Dhillon G., (2012), "A new approach to automatic disc localization in clinical lumbar MRI: combining machine learning with heuristics", In 2012 9th IEEE, International Symposium on Biomedical Imaging (ISBI), 114-117.
- [25] Wei S. E., Ramakrishna V., Kanade T., Sheikh Y., (2016), "Convolutional pose machines", In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 4724-4732.
- [26] Oktay A. B., Akgul Y. S., (2013), "Simultaneous localization of lumbar vertebrae and intervertebral discs with SVM-based MRF", IEEE transactions on biomedical engineering, 60 (9), 2375-2383.
- [27] Felzenszwalb P. F., Girshick R. B., McAllester D., Ramanan D., (2009), "Object detection with discriminatively trained part-based models", IEEE transactions on pattern analysis and machine intelligence, 32 (9), 1627-1645.
- [28] Glocker B., Feulner J., Criminisi A., Haynor D. R., Konukoglu E., (2012), "Automatic localization and identification of vertebrae in arbitrary field-of-view CT scans", In International Conference on Medical Image Computing and Computer-Assisted Intervention, 590-598, Berlin, Heidelberg.
- [29] Forsberg D., Sjöblom E., Sunshine J. L., (2017), "Detection and labeling of vertebrae in MR images using deep learning with clinical annotations as training data", Journal of digital imaging, 30 (4), 406-412.
- [30] Chen H., Shen C., Qin J., Ni D., Shi L., Cheng J. C., Heng P. A., (2015), "Automatic localization and identification of vertebrae in spine CT via a joint learning model with deep neural networks", In International Conference on Medical Image Computing and Computer-Assisted Intervention, 515-522.
- [31] Botev Z. I., Grotowski J. F., Kroese D. P., (2010), "Kernel density estimation via diffusion", The annals of Statistics, 38 (5), 2916-2957.
- [32] Vala H. J., Baxi A., (2013), "A review on Otsu image segmentation algorithm", International Journal of Advanced Research in Computer Engineering and Technology (IJARCET), 2 (2), 387-389.
- [33] Krizhevsky A., Sutskever I., Hinton G. E., (2012), "Imagenet classification with deep convolutional neural networks", In Advances in neural information processing systems, 1097-1105.
- [34] Jia Y., Shelhamer E., Donahue J., Karayev S., Long J., Girshick R., Darrell T., (2014), "Caffe: Convolutional architecture for fast feature embedding",

In Proceedings of the 22nd ACM international conference on Multimedia, 675-678.

- [35] Bradski G., Kaehler A. (2008), “Learning OpenCV: Computer vision with the OpenCV library”, O'Reilly Media, Inc.
- [36] Girshick R., Donahue J., Darrell T., Malik J., (2014), “Rich feature hierarchies for accurate object detection and semantic segmentation”, In Proceedings of the IEEE conference on computer vision and pattern recognition, 580-587.
- [37] Girshick R., (2015), “Fast r-cnn”, In Proceedings of the IEEE international conference on computer vision, 1440-1448.
- [38] Ren S., He K., Girshick R., Sun J., (2015), “Faster r-cnn: Towards real-time object detection with region proposal networks”, In Advances in neural information processing systems, 91-99.
- [39] Kohavi R., (1995), “A study of cross-validation and bootstrap for accuracy estimation and model selection”, In Ijcai, 14, 2, 1137-1145.
- [40] Web3, (2019), <https://github.com/tzutalin/labelImg>, (Erişim Tarihi: 01/02/2019).
- [41] Web4, (2019), <https://github.com/Paperspace/DataAugmentationForObjectDetection>, (Erişim Tarihi: 15/04/2019).
- [42] Abadi M., Barham P., Chen J., Chen Z., Davis A., Dean J., Kudlur M., (2016), “Tensorflow: A system for large-scale machine learning”, In 12th {USENIX} Symposium on Operating Systems Design and Implementation ({OSDI} 16), 265-283.
- [43] Lin T. Y., Maire M., Belongie S., Hays J., Perona P., Ramanan D., Zitnick C. L., (2014), “Microsoft coco: Common objects in context”, In European conference on computer vision, 740-755.
- [44] Howard A. G., Zhu M., Chen B., Kalenichenko D., Wang W., Weyand T., Adam H., (2017), “Mobilenets: Efficient convolutional neural networks for mobile vision applications”, arXiv preprint arXiv:1704.04861.
- [45] Bottou L., (2010), “Large-scale machine learning with stochastic gradient descent”, In Proceedings of COMPSTAT'2010, 177-186.
- [46] Lin T. Y., Goyal P., Girshick R., He K., Dollar P., (2017), “Focal loss for dense object detection”, In Proceedings of the IEEE international conference on computer vision, 2980-2988.
- [47] Rychly P., (2008), “A lexicographer-friendly association score”, In RASLAN, 6-9.

- [48] Jamaludin A., Lootus M., Kadir T., Zisserman A., (2015), “Automatic intervertebral discs localization and segmentation: a vertebral approach”, In International Workshop and Challenge on Computational Methods and Clinical Applications for Spine Imaging, 97-103.
- [49] Cai Y., Landis M., Laidley D. T., Kornecki A., Lum A., Li S., (2016), “Multi-modal vertebrae recognition using transformed deep convolution network”, Computerized medical imaging and graphics, 51, 11-19.
- [50] Yang D., Xiong T., Xu D., Huang Q., Liu D., Zhou S. K., Chin S. P. (2017), “Automatic vertebra labeling in large-scale 3D CT using deep image-to-image network with message passing and sparsity regularization”, In International Conference on Information Processing in Medical Imaging, 633-644.

## ÖZGEÇMİŞ

Merve KAYA ZEYBEL 1993 yılında İstanbul'da doğdu. 2011 yılında başladığı Gebze Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünü 2016 yılında birincilikle bitirdi. Aynı yıl Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında yüksek lisansına başladı. 2017 yılından bu yana TÜBİTAK BİLGEM Bulut Bilişim ve Büyük Veri Laboratuvarında Yazılım Geliştirme Sorumlusu olarak çalışmaktadır.

# EKLER

## Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

M. K. Zeybel ve Y. S. Akgul, 2019, “Faster RCNN ile Bel MR görüntülerinden Lumbar Disklerin Otomatik Olarak Tanınması ve Yerlerinin Belirlenmesi”, Uluslararası Bilgisayar Bilimleri ve Mühendisliği Konferansı.

## Ek B: Tez Terimleri Sözlüğü: İngilizce – Türkçe

Tablo B1.1: Tezde kullanılan kelimelerin İngilizce – Türkçe sözlüğü.

A	
Accuracy	Doğruluk Değeri
Activation Function	Etkilenim Fonksiyonu
B	
Binary	İkili
Bounding Box	Sınırlayıcı Kutu
C	
Candidate Discs	Aday Diskler
Categorical Cross Entropy	Kategorisel Çapraz Entropi
Cervical Vertebrae	Boyun Omuru
Class	Sınıf
Classification	Etiketleme – Sınıflandırma
Clip	Kırpma
Coccyx	Kuyruk
Computed Tomography (CT)	Bilgisayarlı Tomografi (BT)
Contextual Feature	Bağlamsal Özellik
Contour	Çevrit
Convolution Layer	Evrişim Katmanı
Convolutional Neural Network (CNN)	Evrişimli Sinir Ağları (ESA)
D	

Tablo B1.1: Devam.

Data Augmentation	Veri Artırımı
Dataset	Veri Kümesi
Deep Learning	Derin Öğrenme
Deep Stacked Sparse Autoencoder	Derin Yığılmış Seyrek Kodlayıcı
Deformable Part Model (DPM)	Deforme Parça Modeli (DPM)
Dense Layer	Yoğun Katman
Dice Score	Dice Puanı
Dimension (D)	Boyut (B)
Disc	Disk
Dropout Layer	Seyreltme Katmanı
Dynamic Programming	Dinamik Programlama
E	
Edge	Bağlantı
Edge Cost	Bağıntı maliyetleri
Emission Probability	Emisyon Olasılığı
End-to-end Methods	Baştan-uca Yöntemler
Epoch	Epok
F	
False Negative (FN)	Hatalı Reddedilmiş
False Positive (FP)	Hatalı Onaylanmış
Feature Vector	Öznitelik Vektörü
Fine Tuning	İnce Ayar
Flatten Layer	Düzleştirme Katmanı
G	
Global	Bütünsel
Graph	Çizge
Graphical Model	Grafiksel Model
H	
HeatMap	İnanç Haritası
Hidden Markov Model (HMM)	Saklı Markov Modeli (SMM)
Histogram of Oriented Gradients (HOG)	Yönlü Gradyan Histogramı (YGH)
I	
Image Patch	Görüntü Parçacığı

Tablo B1.1: Devam.

	L
Label	Etiket
Layer	Katman
Learning Rate	Öğrenim Oranı
Library	Kütüphane
Local	Yerel
Localization	Yerini Belirleme
Localization Error	Ortalama Merkezden Hata Miktarı
Loss Function	Yitim Fonksiyonu
Lumbar Vertebrae	Bel Omuru
	M
Machine Learning	Makine Öğrenmesi
Magnetic Resonance (MR)	Manyetik Rezonans (MR)
Markov Chain	Markov Zinciri
Maximum Pooling Layer	Maksimum Ortaklama Katmanı
Mean	Ortalama
Multi-class CNN	Çoklu-sınıf ESA
	N
N - Fold Cross Validation	Çapraz Katman Doğrulama
Neural Network	Sinir Ağları
Node	Düğüm
Non-maxima suppression	Maksimum Olmayan Baskılama
	O
Object Detection	Nesne Tanıma
Optimizer	İyileştirici
	P
Pixel	Piksel
Polynomial	Polinomal
Positional	Pozisyonel
	R

Tablo B1.1: Devam.

Random	Rastgele
Random Forest	Rastgele Ormanlar
Random Forest Algorithm (RFA)	Rastgele Orman Algoritması (ROA)
Real-time	Gerçek Zamanlı
Receptive Field	Alıcı Alan
Region based CNN (RCNN)	Bölge Bazlı ESA (BBESA)
Regression Function	Bağlanım Fonksiyonu
Regression Trees	Regresyon Ağaçları
Resize	Yeniden Boyutlandırma
Roi	İlgi Bölgesi
Rotation	Döndürme
S	
Sacrum	Kuyruk Sokumu
Scale	Ölçeklendirme
Score	Puan
Sequential Phase Based Methods	Sıra bazlı Yöntemler
Shortest Path Algorithm	En Kısa Yol Algoritması
Sliding Window	Kayan Pencere
Soft tissue	Yumuşak Doku
Spine	Omurga
Standard Deviation	Standart Sapma
State of art	Güncel En İyi Sonuçlar
Stochastic Gradient Descent	Rastgele Gradyan İnişi
Structural	Yapısal
Supervised Learning	Gözetimli Öğrenme
Support Vector Machine (SVM)	Destekçi Vektör Makinesi (DVM)
T	
Thoracic Vertebrae	Göğüs Omuru
Tool	Araç
Train	Eğitim
Transfer Learning	Eğitim Aktarması
Transition Probability	Geçis Olasılığı
True Negative (FP)	Doğru Reddedilmiş
True Positive (TP)	Doğru Onaylanmış

Tablo B1.1: Devam.

	U
Unary	Tekli
	V
Vertebra	Omur
	W
Weigh	Ağırlık

### Ek C: Tez Terimleri Sözlüğü: Türkçe – İngilizce

Tablo C1.1: Tezde kullanılan kelimelerin Türkçe – İngilizce sözlüğü.

	A
Aday Diskler	Candidate Discs
Ağırlık	Weigh
Alıcı Alan	Receptive Field
Araç	Tool
	B
Bağıntı maliyetleri	Edge Cost
Bağlamsal Özellik	Contextual Feature
Bağlanım Fonksiyonu	Regression Function
Bağlantı	Edge
Baştan-Uca Yöntemler	End-to-End Methods
Bel Omuru	Lumbar Vertebrae
Bilgisayarlı Tomografi (BT)	Computed Tomography (CT)
Boyun Omuru	Cervical Vertebrae
Boyut (B)	Dimension (D)
Bölge Bazlı ESA (BBESA)	Region based CNN (RCNN)
Bütünsel	Global
	Ç
Çapraz Katman Doğrulama	N - Fold Cross Validation
Çevrit	Contour
Çizge	Graph
Çoklu-sınıf ESA	Multi-class CNN

Tablo C1.1: Devam.

D	
Daha Hızlı Bölge Bazlı ESA (DHBBESA)	Faster Region Based CNN (Faster RCNN)
Deforme Parça Modeli (DPM)	Deformable Part Model (DPM)
Derin Öğrenme	Deep Learning
Derin Yığılmış Seyrek Kodlayıcı	Deep Stacked Sparse Autoencoder
Destekçi Vektör Makinesi (DVM)	Support Vector Machine (SVM)
Dice Puanı	Dice Score
Dinamik Programlama	Dynamic Programming
Disk	Disc
Doğru Onaylanmış	True Positive (TP)
Doğru Reddedilmiş	True Negative (FP)
Doğruluk Değeri	Accuracy
Döndürme	Rotation
Düğüm	Node
Düzleştirme Katmanı	Flatten Layer
E	
Eğitim	Train
Eğitim Aktarması	Transfer Learning
Emisyon Olasılığı	Emission Probability
En Kısa Yol Algoritması	Shortest Path Algorithm
Epok	Epoch
Etiket	Label
Etiketleme – Sınıflandırma	Classification
Etkilenim Fonksiyonu	Activation Function
Evrişim Katmanı	Convolution Layer
Evrişimli Sinir Ağları (ESA)	Convolutional Neural Network (CNN)
G	
Geçiş Olasılığı	Transition Probability
Gerçek Zamanlı	Real-time
Göğüs Omuru	Thoracic Vertebrae
Görüntü Parçacığı	Image Patch
Gözetimli Öğrenme	Supervised Learning

Tablo C1.1: Devam.

Grafiksel Model	Graphical Model
Güncel En İyi Sonuçlar	State of art
H	
Hatalı Onaylanmış	False Positive (FP)
Hatalı Reddedilmiş	False Negative (FN)
Hızlı BBESA	Fast RCNN
İ	
İkili	Binary
İlgi Bölgesi	Roi
İnanç Haritası	HeatMap
İnce Ayar	Fine Tuning
İyileştirici	Optimizer
K	
Kategorisel Çapraz Entropi	Categorical Cross Entropy
Katman	Layer
Kayan Pencere	Sliding Window
Kırpma	Clip
Kuyruk	Coccyx
Kuyruk Sokumu	Sacrum
Kütüphane	Library
M	
Makine Öğrenmesi	Machine Learning
Maksimum Olmayan Baskılama	Non-maxima suppression
Maksimum Ortaklama Katmanı	Maximum Pooling Layer
Manyetik Rezonans (MR)	Magnetic Resonance (MR)
Markov Zinciri	Markov Chain
N	
Nesne Tanıma	Object Detection
O	
Omur	Vertebra
Omurga	Spine
Ortalama	Mean
Ortalama Merkezden Hata Miktarı	Localization Error

Tablo C1.1: Devam.

Ö	
Öğrenim Oranı	Learning Rate
Ölçeklendirme	Scale
Öznitelik Vektörü	Feature Vector
P	
Piksel	Pixel
Polinomal	Polynomial
Pozisyonel	Positional
Puan	Score
R	
Rastgele	Random
Rastgele Gradyan İnişi	Stochastic Gradient Descent
Rastgele Orman Algoritması (ROA)	Random Forest Algorithm (RFA)
Rastgele Ormanlar	Random Forest
Regresyon Ağaçları	Regression Trees
S	
Saklı Markov Modeli (SMM)	Hidden Markov Model (HMM)
Seyreltme Katmanı	Dropout Layer
Sınıf	Class
Sınırlayıcı Kutu	Bounding Box
Sıra bazlı Yöntemler	Sequential Phase Based Methods
Sinir Ağları	Neural Network
Standart Sapma	Standard Deviation
T	
Tekli	Unary
V	
Veri Artırımı	Data Augmentation
Veri Kümesi	Dataset
Y	
Yapısal	Structural
Yeniden Boyutlandırma	Resize
Yerel	Local

Tablo C1.1: Devam.

Yerini Belirleme	Localization
Yitim Fonksiyonu	Loss Function
Yoğun Katman	Dense Layer
Yönlü Gradyan Histogramı (YGH)	Histogram of Oriented Gradients (HOG)
Yumuşak Doku	Soft tissue