

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

RÖNTGEN GÖRÜNTÜLERİNDEN DERİN ÖĞRENME İLE
OMURGA DEFORMİTESİNİN TESPİTİ

YÜKSEK LİSANS TEZİ

Tuğba ÖZMEN

Biyomedikal Mühendisliği Anabilim Dalı

EYLÜL 2024

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

RÖNTGEN GÖRÜNTÜLERİNDEN DERİN ÖĞRENME İLE
OMURGA DEFORMİTESİNİN TESPİTİ

YÜKSEK LİSANS TEZİ

Tuğba ÖZMEN

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Hüseyin ESKİ

EYLÜL 2024

Tuğba ÖZMEN tarafından hazırlanan “RÖNTGEN GÖRÜNTÜLERİNDEN DERİN ÖĞRENME İLE OMURGA DEFORMİTESİNİN TESPİTİ” adlı tez çalışması 12/09/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı’nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı: **Dr. Öğr. Üyesi Hüseyin ESKİ (Danışman)**
Sakarya Üniversitesi

Jüri Üyesi: **Dr. Öğr. Üyesi Ulaş YURTSEVER**
Sakarya Üniversitesi

Jüri Üyesi: **Dr. Öğr. Üyesi Selman HIZAL**
Sakarya Uygulamalı Bilimler Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “RÖNTGEN GÖRÜNTÜLERİNDEN DERİN ÖĞRENME İLE OMURGA DEFORMİTESİNİN TESPİTİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete ’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(12/09/2024)

(imza)

Tuğba ÖZMEN





Anneme ve Babama



TEŞEKKÜR

Yüksek Lisans eğitimim ve tez yazım sürecimde bana her zaman destek olan, bilgi birikim ve deneyimiyle bana yön veren, düşünce ve fikirlerimde her daim bana destek olan kıymetli danışman hocam Dr. Öğr. Üyesi Hüseyin Eski'ye bana kattıkları için teşekkür ederim.

Hayatım boyunca bana her zaman inanan ve maddi manevi desteklerini hiçbir zaman esirgemeyen aileme, her koşulda yanımda oldukları ve bana mücadele etmeyi öğrettikleri için teşekkür ederim. İyi ki varsınız.

Tuğba Özmen



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET.....	xix
SUMMARY	xxi
1. GİRİŞ	1
1.2. Omurga Deformiteleri	3
1.2.1. Skolyoz	3
1.2.2. Bel kayması (Spondilolistezis)	5
2. LİTERATÜR ARAŞTIRMASI.....	7
3. MATERYAL VE METOT	13
3.1. X Işını Görüntüleme.....	13
3.2. Derin Öğrenme.....	14
3.3. Evrişimli Sinir Ağları (ESA).....	17
3.4. Veri Seti	21
3.5. Transfer Öğrenme	21
3.6. Sınıflandırma Metrikleri.....	22
3.7. Modelin Eğitimi ve Test Aşaması.....	23
4. BULGULAR	27
5. SONUÇLAR	33
KAYNAKLAR	35
ÖZGEÇMİŞ.....	39



KISALTMALAR

CLAHE	: Contrast Limited Adaptive Histogram Equalization
CNN-LTSM	: Convolutional Neural Network- Long Short-Term Memory
DensNet	: Densely Connected Convolutional Networks
ESA	: Evriřimli Sinir Aęları
FN	: False Negative
FP	: False Positive
GB	: Gigabyte
GPU	: Graphics Processing Unit
İmageNet	: ImageNet Large Scale Visual Recognition Challenge
LumbarNet	: Lumbar Networks
MR	: Manyetik Rezonans
NASNet-Mobile	: Neural Architecture Search Network-Mobile
RAM	: Random Access Memory
RCNN	: Region Based Convolutional Neural Networks
ReLu	: Rectified Linear Unit
ResNet	: Residual Network
RetinaNet	: Retina Networks
TN	: True Negative
TP	: True Positive
VGG-Net	: Visual Geometry Group Network
ZFNet	: Zeiler and Fergus Network



TABLO LİSTESİ

Sayfa

Tablo 3.1. Veri setinin gruplara göre dağılımı.	21
Tablo 3.2. Derin öğrenme modellerinin hiperparametre ve değerleri.	25
Tablo 4.1. Derin öğrenme mimarilerinin başarı oranları.	31





ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Omurganın Bölümleri (Dave Harrison, 2023).....	1
Şekil 1.2. Normal Omurga Anatomisi (Janis Savlovskis, 2019)	2
Şekil 1.3. Skolyoz (Important Facts About Scoliosis You Should Know, t.y.).....	4
Şekil 1.4. Bel Kaymasının Meyerding Sınıflandırması (a) Sağlıklı Omurga (b) 1. Derece: <%25 (c) 2. Derece: %25-50 (d) 3. Derece: %50-75 (e) 4. Derece: >%75 (Abbas Din, 2024)	6
Şekil 3.1. X Işını Tüpü (David Bernard, 2020)	13
Şekil 3.2. Wilhelm Röntgen'in Eşine Ait İlk Röntgen Görüntüsü (Baumrind, 2011)14	
Şekil 3.3. Derin Öğrenme, Makine Öğrenmesi ve Yapay Zeka İlişkisi	15
Şekil 3.4. Derin Öğrenme Mimarisi (Hossein Ashtari, 2022)	16
Şekil 3.5. ESA mimarisi (Pranshu Sharma, 2023).....	18
Şekil 3.6. Inception Modülü	19
Şekil 3.7. Residual Blok	20
Şekil 3.8. Veri setine ait X ışını görüntüleri (a) skolyoz (b) spondilolistezis (c) sağlıklı	21
Şekil 4.1. GoogleNet ve ResNet mimarilerine ait doğruluk grafikleri	27
Şekil 4.2. GoogleNet ve ResNet mimarilerine ait hassasiyet grafikleri	28
Şekil 4.3. GoogleNet ve ResNet mimarilerine ait özgüllük grafikleri.....	28
Şekil 4.4. GoogleNet ve ResNet mimarilerine ait F1 skoru grafikleri.....	29
Şekil 4.5. GoogleNet ve ResNet mimarilerine ait kesinlik grafikleri	29
Şekil 4.6. GoogleNet ve ResNet mimarilerine ait eğitim sürelerinin grafikleri	29
Şekil 4.7. GoogleNet ve ResNet mimarilerine ait test sürelerinin grafikleri	30
Şekil 4.8. Devir sayısına bağlı doğruluk grafiği	30
Şekil 4.9. ResNet mimarisine ait karışıklık matrisi	31
Şekil 4.10. GoogleNet mimarisine ait karışıklık matrisi	32



RÖNTGEN GÖRÜNTÜLERİNDEN DERİN ÖĞRENME İLE OMURGA DEFORMİTESİNİN TESPİTİ

ÖZET

Omurga, günlük hareketler ve duruş sırasında baş ve gövdeyi destekleyen, yerçekiminin stresine uyum sağlamak için mekanik olarak dengede kalma görevini yürüten, omuriliği, sinirleri ve vertebral arterleri çevreleyen kaslar tarafından kontrol edilen çok eklemlili bir sistemdir. Sağlıklı bir bireyin omurgası sagittal düzlemde bakıldığında S formunda, koronal düzlemde bakıldığında ise düz bir formda olmalıdır. Omurganın tanımlanmış hizalamasının normal sınırları dışında olduğu durumlar ve omurganın olması gereken anatomik duruşunun bozulması sonucunda meydana gelen anormal değişimler omurga deformiteleri olarak adlandırılmaktadır. Sagittal planda meydana gelen anormal değişimler spondilolistezis, kifoz ve lordoz olarak ayrılırken koronal plandaki anormal eğrilikler skolyoz olarak adlandırılmaktadır. Skolyoz, koronal düzlemde omurganın sola, sağa ya da hem sola hem sağa en az 10° Cobb açısı yapması olarak, spondilolistezis ise omurgayı oluşturan omurların komşu omur üzerinden sagittal planda kayması olarak tanımlanır.

Deformiteler sonucunda omurgada meydana gelen denge kaybı kişinin, biyomekanik açıdan dezavantajlı bir duruma düşmesine neden olur. Ayakta dik dururken, yürürken, günlük yaşam faaliyetleri sırasında hastanın fazladan enerji harcaması, sırt kaslarının aşırı gerilmesi, solunum fonksiyonlarında azalma ve yaşam kalitesinin düşmesi deformitelerin neden olduğu biyomekanik dengesizliğin sonuçlarındandır. Omurga deformitelerinin erken teşhisi, hastalığın kontrol altına alınması, doğru tedaviye zamanında başlanması ve hastanın yaşam kalitesi açısından önemlidir.

Omurga deformiteleri, günümüzde uzman doktorların tıbbi görüntüler üzerinden yaptığı manuel ölçümlerle tespit edilmektedir. Manuel ölçümler subjektif olmakla birlikte hatalara açık ve zaman alıcıdır. Bu çalışmada, omurga deformitelerinin daha hızlı ve doğru tespit edilmesi için derin öğrenme tabanlı otomatik bir teşhis yöntemi sunulmaktadır.

Gelişen teknoloji ile hayatımıza giren yapay zeka, ilk olarak 1950 yılında tanıtılmış olmasına rağmen tıp dünyasında, 2000'li yılların başlarında derin öğrenme tekniklerinin geliştirilmesiyle yer edinmiştir. Yapay zeka, tıpta hastalıkların teşhisi, tıbbi görüntülerin analizi, tedavi süreçlerinin planlanması ve sonuçların tahmini, hasta verilerinin analizi alanlarında kullanılmakta ve her geçen gün kapsamını genişletmektedir. X-ışını görüntü işleme, özellik çıkarımı ve deformite tespiti gibi işlemler için derin öğrenmeye dayalı evrişimli sinir ağları mimarileri yaygın olarak kullanılmakta ve olumlu sonuçlar vermektedir. Bu çalışmada, transfer öğrenimi yaklaşımıyla GoogleNet ve ResNet mimarilerinin X-ışını röntgen görüntülerini sınıflandırma performansları doğruluk, kesinlik, F1 skoru, özgüllük ve hassasiyet açısından karşılaştırılmıştır.

Eğitim için gerekli kütüphane ve modüller içe aktarıldıktan sonra veri setindeki görüntüler kendi sınıf etiketleriyle yüklenmiştir ve yeniden boyutlandırılmıştır. Veri

setindeki görüntüler %80 eğitim ve %20 test olmak üzere iki gruba ayrılmış ve GoogleNet modeli InceptionV3, ResNet modeli de ResNet50 mimarisi kullanılarak oluşturulmuştur. ImageNet veri kümesindeki önceden eğitilmiş ağırlıklarla başlayan model, eğitim ve doğrulama için gerekli katmanlar eklenerek derlenmiş ve eğitilmiştir. Eğitim sırasında doğruluk ve kayıp değerleri takip edilerek model kaydedilmiş ve eğitim sürecinin grafiği çizilerek ve sınıflandırma raporu oluşturularak modellerin performansı değerlendirilmiştir.

Yapılan çalışmalar sonucunda ResNet mimarisi doğruluk, duyarlılık, özgüllük, F1 skoru ve kesinlik metrikleri açısından GoogleNet'e karşı üstünlük kurmuş olup yüksek başarı göstermiştir. GoogleNet ise eğitim ve test süreleriyle ResNet'ten daha hızlı işlem yaptığını ve işlem hızı açısından ResNet'e göre daha üstün performansa sahip olduğunu gösterdiği görülmüştür.



DETECTION OF SPINE DEFORMITY DEEP FROM X-RAY IMAGES WITH DEEP LEARNING

SUMMARY

The spine is a multi-joint system controlled by muscles surrounding the spinal cord, nerves, and vertebral arteries, supporting the head and torso during daily movements and posture, mechanically maintaining balance to adapt to the stress of gravity. In the sagittal plane, the spine of a healthy individual should have an S-shaped curve, while in the coronal plane, it should be straight. The normal position of the spine is characterized by lumbar lordosis and thoracic kyphosis curves in the sagittal plane. The lumbar lordosis angle is defined as 30-40 degrees, and the thoracic kyphosis angle is defined as 20-45 degrees for adults, but differences may occur depending on age and gender.

Conditions where the spine's defined alignment is outside the normal limits and abnormalities resulting from the disruption of the spine's anatomical posture are referred to as spinal deformities. Abnormal changes occurring in the sagittal plane are categorized as spondylolisthesis, kyphosis, and lordosis, while abnormal curvatures in the coronal plane are referred to as scoliosis.

Loss of balance in the spine due to deformities leads the individual to a biomechanically disadvantaged state. Increased energy expenditure, excessive tension in the back muscles, decreased respiratory function, and decreased quality of life during standing, walking, and daily activities are consequences of biomechanical imbalance caused by deformities.

Deformities resulting from the spine's deviation from a straight line in the coronal plane by at least 10° Cobb angle to the right, left, or both sides are referred to as scoliosis. Although scoliosis generally progresses idiopathically, it can also occur due to genetic factors, differences in limb lengths in the lower extremities, or trauma. Individuals with scoliosis may experience noticeable abnormalities such as prominent shoulder blades or ribs, or significant asymmetry in the shoulders or pelvis.

Deformity resulting from the sliding of adjacent vertebrae in the sagittal plane, known colloquially as spondylolisthesis or slipped disc, is described. Spondylolisthesis can occur in any part of the spine but is most commonly seen in the lumbar spine (L4-L5, L5-S1).

Early diagnosis of spinal deformities is important for controlling the disease, starting the correct treatment in a timely manner, and for the patient's quality of life. Spinal deformities are currently diagnosed by specialist doctors through manual measurements on medical images. Manual measurements are subjective, prone to errors, and time-consuming. This study presents an automatic diagnostic method based on deep learning to detect spinal deformities more quickly and accurately. The aim is to create a low error rate, high-speed process, and objective standard for detecting deformities in clinical applications, shorten diagnosis and treatment processes, alleviate the workload of doctors, and reduce hospital costs.

Image processing and segmentation processes, object recognition, and anomaly detection can be performed quickly and reliably with artificial intelligence-based techniques. Convolutional neural network architectures based on deep learning are commonly used for processes such as X-ray image processing, feature extraction, and deformity detection, yielding positive results. Popular convolutional neural network architectures reported to work with high accuracy and efficiency include ResNet and GoogleNet. In this study, these two architectures will be compared for their classification performance on X-ray images using the transfer learning approach.

Deep learning is a representation-learning method with multiple levels of representation, transforming simple but nonlinear layers that increase the representation at each level to a higher, more abstract level. Each layer takes the output of the previous layer as input, and by creating sufficiently deep layers, complex functions can be learned. Deep learning emphasizes learning from representation rather than from data. For example, when an image is input as a sequence of pixel values, the first layer represents the presence or absence of edges at certain orientations and positions, while the second layer detects various patterns along with edge arrangements. When it comes to the third layer, it can combine patterns into recognizable parts of familiar objects, and subsequent layers can perceive objects as combinations of these parts.

With the development of deep learning, artificial intelligence studies have gained momentum and have been used in many areas of life. They are used in systems such as facial and voice recognition, autonomous driving, image enhancement, image processing, feature extraction from images, and object detection. Various deep learning architectures have been developed depending on application areas, specific tasks, and different types of data. In the field of image processing, convolutional neural networks, recurrent neural networks for processing sequential data, and autoencoders for restructuring data are some of these architectures.

Convolutional neural networks, the most widely used deep learning technique in image processing, are designed based on the animal visual system. These multilayer feedforward networks work based on filtering. By using filters, they highlight the distinctive features of an image, yielding successful results in classification tasks. The most widely used deep learning structure, CNN, has been reported to be useful for image processing and classification tasks due to its ability to reflect, rotate, scale, or detect features in an image. The ImageNet competition, organized worldwide in object detection, classification, and image processing areas, has also increased the popularity of CNN, and the software that won the competition is considered the cornerstone of deep learning architectures. Among the ESA architectures introduced to the deep learning world with the ImageNet competition are AlexNet, ZFNet, GoogleNet, ResNet, and VGGNet.

GoogleNet, created by Szegedy et al., was the winner of the 2014 ImageNet competition with 22 layers. What sets this architecture apart from others is its ability to increase the depth and width of the network while keeping costs low, thanks to the Inception module. GoogleNet uses multiple parallel filters of different sizes (1x1, 3x3, 5x5) to effectively capture the features of the image. Despite containing numerous layers and filters, GoogleNet has surpassed the system's memorization and excessive memory costs through its parallel modules.

ResNet achieved superior performance with a 3.57% error rate and became the winner of the 2015 ImageNet competition. This architecture consists of 152 layers, and the

main problem is that the efficiency of the network saturates as it deepens but then rapidly decreases. To address this degradation issue, Zhang et al. added shortcuts to this multilayer architecture, creating residual blocks. A residual block consists of multiple convolutional layers followed by a shortcut connection that skips these layers. The output of the block is the sum of the input and the residual mapping learned by the block. This prevented degradation in the network and created an ESA architecture with high accuracy.

Transfer learning, a technique actively used by machine learning and artificial intelligence developers in recent years, can be described as the reconfiguration of a pretrained model for a second task. Instead of training a model from scratch, transfer learning aims to create models from target data sets using information from the source data set. Since transfer learning enables the reuse of networks trained on large amounts of data for tasks with new and limited amounts of data, it is essential.

During the training and testing of transfer learning-based ESA models, a computer with 8 GB RAM, NVIDIA® GEFORCE 940MX, Intel® Core™ i5-7200U CPU specifications was used, and the Python programming language was selected.


After importing the necessary libraries and modules for training, the images in the data set are loaded with their class labels and resized. The images in the data set are divided into two groups, 80% for training and 20% for testing, and GoogleNet model with InceptionV3 and ResNet model with ResNet50 architecture are created. Starting with pre-trained weights in the ImageNet data set, the model is compiled by adding the necessary layers for training and validation and then trained. During training, accuracy and loss values are monitored, the model is saved, and its performance is evaluated by drawing the graph of the training process and generating a classification report.

As a result of the studies, ResNet architecture has demonstrated high success over GoogleNet in terms of accuracy, sensitivity, specificity, F1 score and precision metrics. GoogleNet, on the other hand, has shown that it processes faster than ResNet with training and testing times and has superior performance than ResNet in terms of processing speed.



1. GİRİŞ

Omurların, bağ dokusu, eklemler ve disklerle bağlanmasıyla oluşan omurga, insan başını ve pelvisi bağlayan kemikli bir köprü gibidir. Merkezi sinir sistemine ait en önemli bileşenlerden omurilik, omurganın içerisinde yer alır ve omurganın birincil görevi omuriliği korumaktır. Aynı zamanda omurga, vücut kütleini desteklemek, postüral kontrolü sağlamak, hareketlilik ve esnekliğe izin vermek ve dış kuvvetlere karşı koymak gibi diğer işlevlere de sahiptir (Frost vd., 2019).



Şekil 1.1. Omurganın Bölümleri (Dave Harrison, 2023)

Omurga; yukarıdan aşağıya servikal omurga, torasik omurga, lomber omurga, sakrum ve kuyruk sokumu olarak beş farklı bölüme ayrılır. (Şekil 1.1.). Servikal omurga, altı disk ve yedi omurdan (C1-C7) oluşan kafatası tabanından başlayarak göğüs kafesinin başladığı torasik omurgaya kadar uzanan kısımdır. Servikal omurga, başın hareketliliğini sağlarken başın ağırlığını ve boyna uygulanan yükleri taşır (Frost vd., 2019). Servikal omurganın bittiği noktada başlayan torasik omurga, on iki disk ve on iki omurdan (T1-T12) oluşur. Kalp ve akciğerleri koruyan göğüs kafesiyle bağlantılı olan torasik omurga, vücut stabilitesini desteklerken ağır yükleri taşımada ve omuriliğin korunmasında rol oynar (Frost vd., 2019).

Lomber omurga, torasik omurganın bitiminde başlar ve omurganın pelvise bağlandığı noktada son bulur. Gövdenin hareketi, bükülme, burulma durumlarında omuriliğin korunması, ağır yüklerin taşınması, gövdenin pelvis etrafındaki hareketliliği devam ederken stabilitenin korunması lomber omurganın ana fonksiyonlarındandır. Beş adet omurdan (L1-L5) ve beş adet intervertebral diskten oluşan bu bölümdeki omurlar, diğer omurlardan daha fazla yük taşıma sorumluluğuna sahip olduğundan daha büyük boyutlara da sahiptir ve bu nedenle daha dayanıklı ve güçlü olmak zorundadır (Frost vd., 2019). Sakrum, beş adet kaynaşmış omurdan (S1-S5) oluşmakta ve lomber omurga ile pelvis arasında bir köprü görevi görmektedir. Sakrumun devamında yer alan ve omurganın en alt bölümü olan kuyruk sokumu genellikle 4 adet kaynaşmış omurdan oluşur. Pelvik kaslar, bağlar ve tendonlar için bir bağlanma alanı olarak iş yapan kuyruk sokumunda herhangi bir sinir ya da omurlar arası disk bulunmadığından disk hasarı açısından önemsizdir (Frost vd., 2019).



Şekil 1.2. Normal Omurga Anatomisi (Janis Savlovskis, 2019)

Omurga, günlük hareketler ve duruş sırasında baş ve gövdeyi destekleyen, yerçekiminin stresine uyum sağlamak için mekanik olarak dengede kalma görevini yürüten, omuriliği, sinirleri ve vertebral arterleri çevreleyen kaslar tarafından kontrol edilen çok eklemlili bir sistemdir (Izzo vd., 2013). Sağlıklı bir bireyin omurgası sagittal düzlemden bakıldığında S formunda, koronal düzlemden bakıldığında ise düz formda

olmalıdır. Normal omurga pozisyonu sagittal planda lomber lordoz ve torasik kifoz eğrileri ile karakterize edilmektedir (Şekil 1.2.). Yetişkinler için lomber lordoz açısı 30-40 derece, torasik kifoz açısı ise 20-45 derece olarak tanımlanmaktadır ancak bu derecelerde yaşa ve cinsiyete bağlı gelişen farklılıklar olmaktadır (Iorio vd., 2018).

1.2. Omurga Deformiteleri

Omurganın tanımlanmış hizalamasının normal sınırları dışında olduğu durumlar ve omurganın olması gereken anatomik duruşunun bozulması sonucunda meydana gelen anormal değişimler omurga deformiteleri olarak adlandırılmaktadır. Sagittal planda meydana gelen anormal değişimler spondilolistezis, kifoz ve lordoz olarak ayrılırken koronal plandaki anormal eğrilikler skolyoz olarak adlandırılmaktadır (Good vd., 2011).

Deformiteler sonucunda omurgada meydana gelen denge kaybı kişinin, biyomekanik açıdan dezavantajlı bir duruma düşmesine neden olur. Ayakta dik dururken, yürürken, günlük yaşam faaliyetleri sırasında hastanın fazladan enerji harcaması, sırt kaslarının aşırı gerilmesi, solunum fonksiyonlarında azalma ve yaşam kalitesinin düşmesi deformitelerin neden olduğu biyomekanik dengesizliğin sonuçlarındandır (Good vd., 2011).


Omurga deformiteleri daha anne karnında başlayabileceği gibi insan yaşının ilerlemesi sonucunda ya da çeşitli travmalara bağlı da gerçekleşebilmektedir. Deformitelerin ilerlemesi insan yaşamını olumsuz etkileyecek sonuçlara sebebiyet vereceğinden erkenden tespit ve tedavi edilmesi yaşam kalitesinin olumlu seyri açısından çok önemlidir. Erken tanı sonucunda deformitelerin ilerleyişi durdurulabilir ya da tedavisi gerçekleştirilebilir (Iorio vd., 2018).

1.2.1. Skolyoz

Koronal düzlemde düz bir doğrultuda olması gereken omurganın sola, sağa ya da hem sola hem sağa (Şekil 1.3.) en az 10° Cobb açısı yapması sonucunda meydana gelen deformiteler skolyoz olarak adlandırılmaktadır (Haleem & Nnadi, 2018; Janicki & Alman, 2007).

Skolyoz genellikle idiyopatik olarak seyretse de genetik faktörlere, alt ekstremitedeki uzuv uzunluklarında meydana gelebilecek farklılıklara ya da travmalara bağlı gerçekleşebilmektedir (Janicki & Alman, 2007). Skolyoza sahip kişilerde kürek

kemiği veya kaburganın belirgin şekilde bir çıkıntı oluşturması, omuzlarda ya da pelviste fark edilir derecede asimetrik durumun meydana gelmesi gibi gözle görülür anormallikler yaşanmaktadır (Haleem & Nnadi, 2018).



Şekil 1.3. Skolyoz (Important Facts About Scoliosis You Should Know, t.y.)

Skolyoz genelde hastanın ya da çevresinin bu anormallikleri fark etmesi sonucu uzmana başvurusuyla ortaya çıkmaktadır. Hastalarda genelde bir ağrı durumu yaşanmamakla birlikte sırt ve kaburga ağrısı ile karşılaşılan durumlar da yaşanmaktadır. Kas koordinasyon bozukluğu, oturma güçlüğü, kalp ve solunum sorunları skolyozun diğer sonuçlarındandır. Skolyoz, her yaş grubundan insanın karşı karşıya kalabileceği bir durum olmakla birlikte en sık yetişkin kadınlarda görülmektedir (Haleem & Nnadi, 2018).

Skolyoz teşhisi için ilk aşamada klinik muayene ve X-ışını röntgenleri yeterli olmaktadır. X-ışını röntgenleri kolay, hızlı ve daha ucuz olması sebebiyle Cobb açısı ölçümlerini ve eğrilerin takibini gerçekleştirmek için tercih edilmektedir. İlerlemiş ve büyük eğriler için Manyetik Rezonans Görüntüleme, daha karmaşık vakalarda ve ameliyat planlaması için Bilgisayarlı Tomografi ile görüntülerin alınması tavsiye edilmektedir (Haleem & Nnadi, 2018).

Skolyoz teşhisi konulan kişi için postural stabilitenin sağlanması, anormal eğriliğin artmasının önlenmesi ve kozmetik görünümün iyileştirilmesi amaçlarıyla tedavi süreçleri planlanmaktadır. Tedavi planlaması yaşa, eğriliğin derecesine ve ilerleme riskine bağlı olarak gerçekleştirilir ve gözlem, ortez tedavisi ve cerrahi müdahaleyi içerir.


Büyüme çağında omurga olgunluğuna ulaşmamış çocuklar için 25°'den küçük eğriliklerde gözetim ve uzman takibi önerilirken 25°-50° aralığında ortez ve

desteklemeler ile eğriliğin kontrol altına alınması amaçlanmaktadır. Ancak bu desteklemelerle olumlu sonuç alınmazsa, çocuk omurga olgunluğuna ulaştıktan sonra cerrahi müdahaleye başvurulur. Skolyoz tedavisine hastanın yaşı büyüdükçe cerrahi müdahaleye olan zorunluluk artar çünkü skolyozun ilerlemesi büyüme ile bağlantılıdır. Ergenler ve yetişkinler için eğriliğin 60° derecenin üstüne çıkması halinde ameliyattan başka tedavi seçeneği sunulmamaktadır (Haleem & Nnadi, 2018; Janicki & Alman, 2007).

1.2.2. Bel kayması (Spondilolistezis)

Omurgayı oluşturan omurların komşu omur üzerinden sagittal planda kayması sonucu meydana gelen deformite, spondilolistezis ya da halk arasında yaygın bilinen ismiyle bel kayması olarak tanımlanır.

Spondilolistezis, omurganın herhangi bir bölümünde meydana gelebilmektedir ancak genellikle lomber omurgada (L4-L5, L5-S1) görülür (Guigui & Ferrero, 2017; Moustafa & Tur, 2018; Zhang vd., 2023). Spondilolistezisin etiyolojisi tam olarak bilinmese de bu durumun meydana gelmesinde birçok neden etkili olmaktadır. Bunlar arasında genetik faktörler, ani kayma ve kırıklarla sonuçlanan travmatik olaylar, yaşa bağlı eklem aşınması ve kemik erimesi, pars interartikularis, doğuştan beri var olan omurga şekil bozuklukları, kemik tümörleri ve patolojik durumlar sayılmaktadır (Guigui & Ferrero, 2017; Moustafa & Tur, 2018). Hastalığın ilk evrelerinde çoğu zaman semptomatik bir durum yaşanmasa da ilerleyen durumlarda şiddetli ağrı, yanma, günlük aktiviteler sırasında zorlanma, uyuşukluk ve bağırsak fonksiyonlarında problemler yaşanmaktadır (Moustafa & Tur, 2018; Zhang vd., 2023). Spondilolistezisin görülme sıklığı kadınlarda erkeklere oranla iki kat daha fazladır. Ayrıca etnik köken de spondilolistezisi etkileyen bir faktördür. Afrikalı insanlarda %1,8-2,4 iken beyaz ırkta spondilolistezis görülme sıklığı 5,6'dır. Eskimolar için ise en yüksek spondilolistezis oranları, adölesanlarda %13 ve yetişkinlerde %54 olarak bildirilmiştir (Moustafa & Tur, 2018). Bel kayması teşhisi için ilk aşamada klinik muayene ve X-ışını röntgenleri yeterli olmaktadır. İlerlemiş kayma dereceleri ve ameliyat planlaması için Kemik Sintigrafisi, Bilgisayarlı Tomografi, Manyetik Rezonans Görüntüleme ve Bilgisayarlı Tek Foton Emisyon Tomografisi ile detaylı incelemelerin yapılması gerekmektedir (Moustafa & Tur, 2018).



Şekil 1.4. Bel Kaymasının Meyerding Sınıflandırması **(a)** Sağlıklı Omurga **(b)** 1. Derece: <%25 **(c)** 2. Derece: %25-50 **(d)** 3. Derece: %50-75 **(e)** 4. Derece: >%75 (Abbas Din, 2024)

Spondilolistezis tedavisi planlanırken kayma dereceleri göz önünde bulundurulur. 1. ve 2. derece kaymalarda ağrıları azaltmak için ağrı kesici ilaçlar ve iğneler kullanılırken kaymayı yavaşlatmak ya da durdurmak için ortezler ve korseler kullanılmaktadır (Şekil 1.4.). Ayrıca hastalar için çeşitli fizik tedavi planları uygulanmakta ve aşırı hareketlerden kaçınmaları tavsiye edilmektedir. 3. ve 4. derece kayma seviyelerine gelen hastalar için cerrahi müdahale kaçınılmaz hale gelmektedir (Moustafa & Tur, 2018; Zhang vd., 2023).

Omurga deformitelerinin erken teşhisi, hastalığın kontrol altına alınması, doğru tedaviye zamanında başlanması ve hastanın yaşam kalitesi açısından önemlidir. Omurga deformiteleri, günümüzde uzman doktorların tıbbi görüntüler üzerinden yaptığı manuel ölçümlerle tespit edilmektedir. Manuel ölçümler subjektif olmakla birlikte hatalara açık ve zaman alıcıdır. Bu durum da teşhis ve tedavi süreçlerini aksatmakta hasta ve hastane masraflarını artırmaktadır. Bu çalışmada, omurga deformitelerinin daha doğru ve hızlı tespit edilmesi için transfer derin öğrenme yaklaşımına dayalı otomatik bir teşhis yöntemi sunulmaktadır. Otomatik teşhis yöntemleri ile klinik uygulamalarda deformite tespiti için hata oranı düşük, işlem hızı yüksek ve objektif bir standart oluşturmak, teşhis ve tedavi süreçlerini kısaltmak, doktorların iş yükünü hafifletmek, hastane maliyetlerini azaltmak amaçlanmaktadır.

2. LİTERATÜR ARAŞTIRMASI

Teknolojinin gelişmesiyle ile hayatımızda yer edinen yapay zeka, ilk olarak 1950 yılında tanıtılmış olmasına rağmen tıp dünyasında, 2000’li yılların başlarında derin öğrenme tekniklerinin geliştirilmesiyle yer edinmiştir (Kaul vd., 2020). Yapay zeka, tıpta hastalıkların teşhisi, tıbbi görüntülerin analizi, tedavi süreçlerinin planlanması ve sonuçların tahmini, hasta verilerinin analizi alanlarında kullanılmakta olup günbegün kapsamını genişletmektedir (Sayar, 2023).

Zhang J. ve arkadaşları lomber spondilolistezisin derin öğrenme tabanlı otomatik tespiti için X ışını radyografileri kullanarak araştırmalar yapmışlardır. Yaptıkları çalışmada lomber bölgedeki omur sınırlarını ve her bir omurun komşu omurla ilişkisini hızlı RCNN ve RetinaNet algoritmaları ile tespit ederek sonuçları hassasiyet, kesinlik ve F1 skoru açısından karşılaştırmışlardır. Görüntüler için ayrıca uzman doktorların görüşlerine de başvurmuşlardır. Karşılaştırmalar sonucunda hızlı RCNN’nin RetinaNet’e göre uzmanların teşhisine daha yakın olduğunu ve spondilolistezis teşhisi için daha uygun olduğunu bildirmişlerdir (Zhang vd., 2023).

Tan Z. ve arkadaşları, yaptıkları çalışmada ölçüm doğruluğunu artırmak ve doktorlara tanı koymada yardımcı olmak amacıyla derin öğrenme yaklaşımını temel alan otomatik skolyoz ölçüm ve tanı sistemi tasarlamışlardır. Veri serindeki omurga radyografilerini veri genişletme yöntemleriyle çoğaltmak ve segmentlere ayırmak için U-net segmentasyon ağını kullanmışlardır. Bölümlere ayrılmış görüntülere dayanarak, üst ve alt uç omurlarının spesifik konumlarını ve uç plakalarının eğimlerini, minimum dış zarf dikdörtgeni ve en küçük kare yöntemiyle belirlemişlerdir. Omurlara ait sınırlar belirlendikten sonra Cobb açıları, üst uç plakaları ile alt uç plakaları arasındaki açıları ölçmüşlerdir. Ölçümler sonucunda elde ettikleri Cobb açılarıyla uzman doktorlar tarafından manuel olarak hesaplanan Cobb açılarını karşılaştırarak sistemin doğruluğunu test etmişlerdir. Bu çalışmalar sonucunda derin öğrenme tabanlı sistemin yaptığı ölçümlerle manuel ölçümlerin benzer olduğunu ve tasarlanan sistemin skolyoz tanısı koymada doktorlara yardımcı olabileceğini bildirmişlerdir (Tan vd., 2018).

Masood ve arkadaşları, spondilolistezis ve lomber lordozun objektif olarak teşhis edilebilmesi için derin öğrenmeye dayalı çalışmalar yapmışlardır. Lomber omurga MR görüntülerinden oluşan veri setini kullanarak yaptıkları çalışmada lomber bölgedeki her bir omurun ağırlık merkezini bularak deformiteleri tespit etmek için farklı bir çerçeve sunmuşlardır. Çalışmalar sonucunda spondilolistezis sınıflandırmasında açısal sapma metriğini kullanarak %89'luk bir doğruluk değeri elde ederken, kapalı lomber eğri bölgesi içindeki alanın hesaplanmasıyla lomber lordoz belirlenmesinde %93 doğruluk elde ettiklerini bildirmişlerdir (Masood vd., 2022).

Veena A. ve arkadaşları, omurga deformitelerini tespit etmek için hibrit bir CNN-LSTM derin öğrenme yaklaşımını önermişlerdir. Omurga görüntüsündeki tahmin düzeyini arttırmak için X-ışını veri kümelerini ön işleme, segmentasyon işlemlerinden geçirdikten sonra sınıflandırma işlemlerini gerçekleştirmişlerdir. Analiz sonucunda, sunulan modelin, %97,46 doğruluk, %93,627 hatırlama, %99,721 kesinlik, %93,289 özgüllük, %97, 102,50 saniye eğitim süresi ile mevcut omurga deformitesi tahmin temsillerinden üstün olduğunu bildirmişlerdir (Veena & Gowrishankar, 2023).

Chen ve arkadaşları, değişen derecelerde skolyoz belirtilerine sahip 581 omurga ön-arka röntgen görüntüsünden oluşan veri setiyle yaptıkları çalışmada Cobb açısı ölçümünü otomatik olarak değerlendirmek için Uyarlanabilir Hata Düzeltme Ağı mimarisini kullanan yeni bir omurga Cobb açısı tahmin çerçevesi önermişlerdir. Önerilen Uyarlamalı Hata Düzeltme Ağı, görüntü özellikleri ile niceliksel değerlendirme parametreleri arasındaki oldukça doğrusal olmayan ilişkiyi ele alabilen ve dairesel çıktı düzeltmelerini açıkça öğrenebilen, doğrusal olmayan haritalama ve açık yapı modellemesinden oluşur. Yapılan çalışma sonucunda tasarladıkları sistemin son derece hassas Cobb açıları ölçümü yaptığını ve yalnızca klinisyenler tarafından kapsamlı skolyoz değerlendirmesi için değil, aynı zamanda diğer klinik uygulamalara da genişletilebileceğini bildirmişlerdir (Chen vd., 2019)

Trinh G. M. ve arkadaşları, bilgisayar destekli bir teşhis algoritması olan LumbarNet'i geliştirmek ve bu modelin lomber röntgen görüntülerinden spondilolistezisin otomatik olarak tespit edilmesindeki etkinliğini değerlendirmek amacıyla yaptıkları çalışmalarında, modelin vertebral kayma tespitinde %88,83'lük bir doğruluğa ulaştığını bildirmişlerdir. X-ışını röntgen görüntüleri kullanarak eğittikleri evrişimli sinir ağı ile lomber bölgedeki omurların sınırlarını belirleyerek omurlar arasındaki açıların ölçümlerini gerçekleştirmişlerdir. Sonuç olarak LumbarNet'in, tıbbi görüntü

segmentasyonunda yaygın olarak kullanılan bir derin öğrenme mimarisi olan U-Net'ten daha iyi performans gösterdiği ve spondilolistezi belirlemede güvenilir bir yöntem olarak hizmet edebileceği belirtmişlerdir (Trinh vd., 2022).

Fraiwani M. ve arkadaşları yaptıkları deneylerde, herhangi bir ölçüme gerek kalmadan röntgen görüntülerinden spondilolistezis ve skolyoz tanısı koymak için derin transfer öğrenmedeki gelişmelerden yararlanmışlardır. 188 skolyoz, 79 spondilolistezis ve 71 sağlıklı kişinin gerçek röntgen görüntülerinden topladıkları ham verileri derin transfer öğrenme modelleri ile sınıflandırmalar gerçekleştirmek için geliştirmişlerdir. Evrişimli sinir ağları modellerini kesinlik, hatırlama, özgüllük, F1 puanı ve doğruluk açılarından karşılaştırmışlardır. DensNet-201'in, ortalama %96,34, maksimum %99,01 ve minimum %94,06 ile üç istatistiksel ölçüm üzerinden de en yüksek doğruluk değerine ulaştığını EfficientNet modelinin de %87,92'lik ortalama doğrulukla en kötü performansı gösterdiğini bununla birlikte NASNet-Mobile'ın da %78,22 ile en düşük minimum doğruluk değerini elde ettiğini bildirmişlerdir. Bu sonuçlara göre konvolüsyonel sinir ağları modellerinin vertebral omurga bozukluklarını standart X-ışını görüntülerinden teşhis etme konusunda güçlü olduğunu ve hekimlerin daha az çaba ve hatayla, doğru ve erken tanı koyarak cerrahi müdahale ihtiyacını azaltmasına makul ölçüde yardımcı olabilecek destekleyici bir araç olduğunu belirtmişlerdir (Fraiwani vd., 2022)

Alharbi R. ve arkadaşları, otomatik skolyoz açısı ölçümü için derin öğrenme tabanlı bir algoritma üzerine çalışmalar yapmışlardır. Veri setindeki X ışını röntgen görüntülerine öncelikle CLAHE yöntemiyle kontrast uyumlulaştırma işlemi yapmışlardır. Ön işlemeden geçen görüntüler evrişimli sinir ağları modeli kullanılarak transfer öğrenme ile ResNet mimarisinden geçirilmiştir. Omurga üzerindeki her bir omur için sınır tespiti yapılarak nesne tanıma işlemi tamamlanmıştır. Omurlar işaretlendikten trigonometrik ölçümler algoritma ile yapılarak Cobb açısı ölçümü gerçekleştirilmiştir. Otomatik ölçüm sisteminin yaptığı ölçümlerle uzman doktor tarafından yapılan ölçümler karşılaştırıldığında 5-10 derecelik küçük farklar olduğunu yapılan çalışmanın derin öğrenme tabanlı Cobb açısı ölçümlerine ışık tutacağını bildirmişlerdir (Roa H. Alharbi vd., 2020).

Tu Y. ve arkadaşları, otomatik Cobb açısı ölçümü için ön işlemeden geçirdikleri radyografileri DU-Net derin öğrenme algoritması ile segmentasyon işlemine tabi tutmuşlardır. Omurganın merkez noktasını bulduktan sonra konturunu oluşturarak

omurga eğrisini tespit etmişlerdir. Tespit ettikleri Cobb açıları ile uzman doktor tarafından manuel ölçülen Cobb açılarını karşılaştırdıklarında ortalama 2,9 derecelik fark olduğunu ve önerdikleri yöntemin Cobb açısı ölçümlerinin güvenilirliğini ve hızını artırdığını bildirmişlerdir (Tu vd., 2019).

Sun Y. ve arkadaşları otomatik Cobb açısı ölçümü için yaptıkları çalışmada X ışını görüntülerini üç farklı aşamadan geçirmişlerdir. Evrişimli sinir ağları modelini kullandıkları modelde ilk aşamada omurları lokalize etmek için CenterNet tabanlı CenterNet1 mimarisini kullanmışlardır. İkinci aşamada omur köşelerini belirlemek için CenterNet2 ve DLA-34 mimarilerini kullanmışlardır. Üçüncü aşamaya gelindiğinde üst uçtaki omurun üst kenarıyla alt uçtaki omurun alt kenarı arasındaki açı olan Cobb açısını ölçmüşlerdir. Yaptıkları otomatik ölçümle uzman doktorun manuel ölçümlerini karşılaştırdıklarında benzer sonuçlar elde ettiklerini ve çalışmanın aynı anda birden fazla skolyoz eğrisini tespit edebildiğini bildirmişlerdir (Sun vd., 2022).

Nguyen T. P. ve arkadaşları spondilolistezis tespiti için derin öğrenme tabanlı ESA mimarilerini kullanmışlardır. Yaptıkları çalışmada X ışını röntgen görüntülerini VGG-net mimarisi ile işleyerek omurlara ait köşe noktaların tespitini yapmışlardır. Omurlara ait anahtar noktaların tespitinden sonra komşu omurlara ait noktalar arasındaki yer değiştirme ölçülerek spondilolistezis derecesi tespit edilmiştir. Önerilen sistemin, tespit hızı ve teşhis doğruluğu açısından önemli avantajları olduğunu bildirmişlerdir (Nguyen vd., 2021).

Varçın F. ve arkadaşları, spondilolistezis tespiti için derin transfer öğrenme yöntemi kullanarak AlexNet ve GoogleNet mimarilerinin performanslarını karşılaştırmışlardır. X ışını görüntüleri ile yaptıkları çalışmalar sonucunda GoogleLeNet'in %93,87 doğruluk oranına sahip olduğunu ve %91,67 doğruluk oranıyla AlexNet'ten daha iyi performans gösterdiğini bildirmişlerdir (Varçın vd., 2019).

Maaliw R. R. ve arkadaşları otomatik Cobb açısı tespiti için yaptıkları çalışmalarda evrişimli sinir ağlarını kullanmışlardır. X ışını röntgen görüntülerini U-Net mimarisi ile segmentasyon işlemlerinden geçirdikten sonra omurlara ait sınırları tespit etmişlerdir. Eğimin başladığı omurun en üst noktası ile eğimin sonlandığı omurun son noktası arasındaki Cobb açısını ölçmüşlerdir. Çalışmalar sonucunda otomatik Cobb açısı ölçüm sisteminin %91,81'lik hassasiyete sahip olduğunu ve uzman ölçümleriyle

karşılaştırıldığında 1,57 derecelik ortalama sapma ile yüksek doğruluk ve tutarlılık gösterdiğini bildirmişlerdir (Maaliw vd., 2022).


Yapay zeka tabanlı teknikler ile görüntü işleme ve segmentasyon işlemleri, nesne tanımlama, görüntü sınıflandırma gibi işlemler hızlı ve güvenilir bir şekilde yapılabilmektedir. Literatür araştırmaları da göstermiştir ki X-ışını görüntü işleme, özellik çıkarımı ve anomali tespiti gibi işlemler için derin öğrenmeye dayalı evrişimli sinir ağları mimarileri yaygın olarak tercih edilmekte ve pozitif sonuçlar vermektedir. Yapılan araştırmalar sonucunda yüksek doğrulukta ve verimde çalıştığı bildirilen popüler evrişimli sinir ağı mimarilerinden olan ResNet ve GoogleNet, bu çalışmanın da konusu olacak olup yapılacak çalışmada, bu iki mimari transfer öğrenme yaklaşımıyla eğitildikten sonra X-ışını röntgen görüntülerini sınıflandırma performansları karşılaştırılacaktır.



3. MATERYAL VE METOT

3.1. X Işını Görüntüleme

X ışınları ilk olarak, Alman fizik profesörü Wilhelm Röntgen'in Lenard tüpleri ve Crookes tüpleriyle yaptığı bir çalışma sırasında bulunmuştur (Elliott, 2005). İçi boş bir cam tüpün içine yerleştirilen biri anot biri katot iki elektrottan oluşan bir deney düzeneği ile (Şekil 3.1.) çalışan W. C. Röntgen, bu deneyde katottan çıkış yapan elektronların anot elektroda varamadan cama çarparak, floresan ışınlarını meydana getirdiğini görmekteydi. Takvimler 8 Kasım 1895'i gösterdiğinde deneyde değişikliğe giderek tüpü siyah bir karton ile kapladı ve ışık geçirgenliğini test edebilmek için odayı karartarak deneyi yineledi. Deney tüpünden 2 metre uzaklıkta baryum platinosiyanür sarılı olan kâğıtta bir parlama fark ettiğinde geleceğe yön verecek bir buluşa imza attığını anlayamamıştı (Röntgen, 1896). Deneyi her tekrarlayışında aynı durumu gözlemledi ve bu ışınları mat yüzeyden geçebilen yeni bir ışın olarak tanımladı. Daha sonra "Röntgen Işınları" adını alaca olan bu ışınları matematikte bilinmeyen simgeleyen X harfini kullanarak "X ışını" ismini verdi.



Şekil 3.1. X Işını Tüpü (David Bernard, 2020)

X ışını tabanlı görüntüleme sistemlerinde görüntü, nesnenin x ışınını soğurma derecesine göre siyah, beyaz, gri tonlarda oluşmaktadır (Şekil 3.2.). İnsan dokuları

atom yoğunluğu, kalınlık, ağırlık özelliklerinden dolayı farklılıklar gösterdiğinden x ışını soğurma dereceleri de farklıdır. Kemik ve tümör gibi yüksek yoğunluktaki dokular, kas ve yağ dokusu gibi düşük yoğunluktaki dokulara göre daha fazla x ışını soğurdukları için radyografilerde beyaz ve parlak görünürken ışın geçişine müsaade eden dokular siyah görünmektedir (Aydoğdu vd., 2017).




Şekil 3.2. Wilhelm Röntgen'in Eşine Ait İlk Röntgen Görüntüsü (Baumrind, 2011)

X ışınları keşfinden kısa bir süre sonra tıp dünyasında yerini almış ve vücut dokularını görüntülemeye vazgeçilmez bir yöntem olmuştur. Gelişen teknolojiyle birlikte de birçok tıbbi görüntüleme sistemi için temel oluşturmuştur. Radyografik görüntülemeye başlangıçta hastayı geçen X ışınları film üzerine düşürülerek görüntüleme işlemi gerçekleştirilmekteydi. Ancak son 20 yılda dijital teknikler geliştirilmiş x ışını tüpü- dedektör sistemleri kurulmuştur. Hastayı geçen x ışınları dedektör üzerinde toplandıktan sonra bilgisayara aktarılır ve görüntü işleme süreçlerinden sonra dijital görüntü elde edilir. Bu sayede görüntülerin saklanması ve depolanması da sağlanmıştır (Spahn, 2013).

3.2. Derin Öğrenme

Bilgisayarların icadı ile ortaya çıkan insan zekası gerektiren işleri makinelere yaptırma fikri sonucunda yapay zeka kavramını ortaya çıkarmıştır. Başlangıçta matematiksel


işlemleri yapmak, oyun oynamak gibi basit görevleri yerine getiren yapay zeka, teknolojinin gelişmesiyle makine öğrenmesi kavramını hayatımıza sokmuş ve makinelere çıkarımlar yapma ve karar verme özelliklerini kazandırmıştır (Grzybowski vd., 2024). Ancak donanımsal yetersizlikler nedeniyle sekteye uğrayan bu çalışmalar 2000’li yılların başında GPU’ların gelişmesiyle yeniden hareket kazanmıştır (Şeker vd., 2017). Artan çalışmalarla birlikte büyüyen veri kümelerini işlemek için daha katmanlı sistemlere ihtiyaç duyulmasıyla birlikte de ortaya derin öğrenme kavramı çıkmıştır (Lecun vd., 2015). Böylelikle yapay zeka makine öğrenmesinin makine öğrenmesi ise derin öğrenmenin ortaya çıkmasına zemin hazırlamıştır (Şekil 3.3.).



Şekil 3.3. Derin Öğrenme, Makine Öğrenmesi ve Yapay Zeka İlişkisi

Derin öğrenme, özellik çıkarma ve sınıflandırma gibi işlemler için her biri bir düzeydeki temsili daha soyut, daha yüksek bir mertebedeki temsile dönüştüren basit ancak doğrusal olamayan katmanların oluşturulmasıyla elde edilen, birden fazla temsil düzeyine sahip temsil-öğrenme yöntemidir. Her katman bir önceki katmanın çıktısını girdi olarak alır ve yeterince derin katmanlar oluşturularak karmaşık işlevler öğrenilebilir (Lecun vd., 2015; Şeker vd., 2017). Derin öğrenme, verilerin birden fazla özelliklerinin öğrenilmesine dayanan bir yapıya sahip olduğundan daha yüksek temsil katmanları, girdinin ayırt edici özelliklerini öne çıkarırken önemsiz kısımları bastırır. Üst katmandaki özellikler alt katmandan gelen girdilerden türetilerek hiyerarşik bir temsil oluşturulur (Lecun vd., 2015; Şeker vd., 2017). Derin öğrenmede, verinin

temsilinden öğrenme esastır. Örneğin bir görüntü piksel değerleri dizesi biçiminde girdi olarak geldiğinde birinci katmanda, görüntüdeki belirli konumlardaki ve yönlerdeki kenarların varlığı ya da yokluğu temsil edilirken ikinci katmanda kenar düzenlemeleri ile birlikte çeşitli desenler tespit edilir (Şekil 3.4.). Üçüncü katmana geldiğinde ise desenleri tanıdık nesnelere ait parçalara benzeterek daha büyük kombinasyonlar halinde bir araya getirebilir ve sonraki katmanlar da nesneleri bu parçaların kombinasyonları olarak algılayabilir. Derin öğrenmenin temel özelliği, bu katmanların mühendisler tarafından tasarlanmamış olmasıdır. Özellik çıkarımı için gerekli algoritmayı genel amaçlı bir öğrenme prosedürü kullanarak verilerden öğrenirler (Lecun vd., 2015; Şeker vd., 2017).



Şekil 3.4. Derin Öğrenme Mimarisi (Hossein Ashtari, 2022)

Derin öğrenmenin gelişimiyle yapay zeka çalışmaları da büyük bir ivme kazanmış olup hayatın birçok alanında kullanılmaya başlanmıştır. Yüz ve ses tanıma sistemlerinde, sürücüsüz araç kullanma ve otopilot özelliklerinde, görüntü iyileştirme, görüntü işleme, görüntülerden özellik çıkarımı ve nesne tespiti uygulamalarında kullanılmaktadır. Derin öğrenme sayesinde alarm sistemlerinde kullanılan bir özellik ile de kamera kayıtlarının sürekli takip edilmesine gerek kalmadan yalnızca olağan dışı durumlarda alarm sisteminin devreye girdiği prosedürler de mümkündür. Konuşmayı metne dönüştürmek, konuşma tahmini yapmak ve kullanıcıların önceki aramalarına göre tavsiye içerik önerileri sunmak ve siber güvenlik alanlarında tehdit analizleri yapmak da derin öğrenmenin kullanıldığı diğer uygulamalardır. Bunlarla birlikte sağlık sektöründe de önem kazanmaya başlayan derin öğrenme, kanser araştırmalarında, tıbbi görüntü analizleri ve sınıflandırmalarında, teşhis ve tedavi


süreçlerine yönelik öneriler ve analizler yapmada, hastalığın seyrine ilişkin tahminler yapmada kullanılmaktadır (Lecun vd., 2015; Şeker vd., 2017). Hepsine ek olarak borsa, sinema, kimya, meteoroloji, biyoloji, farmakoloji gibi birçok bir kullanım alanı olan derin öğrenme, teknolojinin gelişmesiyle her geçen gün uygulama alanlarını genişletmeye ve hayatı kolaylaştırmaya devam etmektedir.

Uygulama alanlarına, belirli görevlere ve farklı veri türlerine göre farklı katman özelliklerine sahip birçok derin öğrenme mimarisi geliştirilmiştir. Görüntü işleme alanında evrişimli sinir ağları, sıralı verileri işlemede tekrarlayan sinir ağları, verileri yeniden yapılandırmak için otomatik kodlayıcılar bu mimarilerden birkaçıdır (Doğan & Türkoğlu, 2019).

3.3. Evrişimli Sinir Ağları (ESA)

Görüntü işleme alanında en çok kullanılan derin öğrenme tekniği olan evrişimli sinir ağları hayvan görü sisteminden ilham alınarak tasarlanmıştır. Çok katmanlı ileri beslemeli bu ağlar filtreleme esasına dayalı çalışmaktadır. Kullanılan filtre ile görüntünün ayırt edici özelliğini öne çıkararak sınıflandırma işlemlerinde başarılı sonuçlar vermektedir (Doğan & Türkoğlu, 2019). En çok kullanılan derin öğrenme yapısı olan ESA, görüntü ve ses işleme alanları başta olmak üzere yüz tanıma, biyomedikal, doğal dil işleme gibi birçok alanda kullanılmakta olup en doğru sonuçları görüntü işleme alanında elde etmiştir (Doğan & Türkoğlu, 2019; Şeker vd., 2017). Çok katmanlı ESA'lar içerisinde birden fazla konvolüsyon katmanı, tam bağlı katman, aktivasyon katmanı, sınıflandırma katmanı, havuzlama katmanı ve ek katmaları barındırır (Şekil 3.5.).

Giriş Katmanı, ESA'nın birinci katmanıdır ve veriler ham olarak alınmaktadır. Giriş verilerinin boyutu işlem süresi, bellek durumu ve ağın performansını etkilediğinden veriler için boyut seçimi oldukça önemlidir. Verinin büyük boyutlu olması işlem süresini uzatırken yüksek bellek ihtiyacı doğurur ancak ağın başarısını da artırabilir. Küçük boyuttaki verilerde işlem süresi kısılırken ekstra belleğe duyulan ihtiyaç da azalır fakat bu sefer de ağın performansı düşebilir. En doğru sonuçlar en iyi ağ başarısı için en uygun veri boyutu seçilmelidir (İnik vd., 2017).



Şekil 3.5. ESA mimarisi (Pranshu Sharma, 2023)


Evrişimsel (konvolüsyonel) katmanlar, ESA'nın temelini oluşturan bu katmanda filtreler ile giriş görüntülerine evrişim işlemi uygulanır. Evrişim işleminde bir filtre tüm görüntü üzerinde dolaştırılarak ağı farklı konumlardaki kenarlar, dokular ve desenler gibi özellikleri algılamasını sağlar. Farklı boyutlara sahip filtreler bir önceki katmandan gelen görüntülere evrişim işlemi uyguladıktan sonra her bir filtreye özgü özelliklerin keşfedildiği bölgeleri ifade eden aktivasyon haritaları oluşur. ESA'ların eğitimi sırasında filtre katsayıları, eğitim kümesindeki her öğrenme tekrarlanmasıyla değişerek verideki önemli bölgeleri belirler (İnik vd., 2017; Lecun vd., 2015).

Düzleştirilmiş doğrusal birim katmanı (ReLU), konvolüsyon katmanını takiben yer alan bu katman doğrultucu birim olarak bilinir. Giriş verisindeki negatif değerleri sıfıra çeken bu katman sayesinde ağı öğrenmesi hızlanır. Aktifleşme katmanı olarak da adlandırılan bu katmanda konvolüsyonda doğrusal hale gelen ağ tekrardan doğrusal olmayan bir şekilde yapılandırılır (İnik vd., 2017).

Havuzlama katmanları, bir sonraki konvolüsyon katmanına aktarılabilecek giriş verisinin boyutunu küçültür ve bu sayede hesaplama karmaşıklığı azalırken öğrenilen özellikler küçük dönüşümlere karşı değişmez hale gelir. Havuzlama katmanı ESA'lar için opsiyonel olmakla birlikte burada da konvolüsyondaki gibi belirli filtreler uygulanabilmektedir. Filtreler görüntü üzerinde gezdirilir ve görüntüdeki piksellerin maksimum değerini ya da değerlerin ortalamasını alarak işlem yapılır. Maksimum havuzlama daha iyi performans gösterdiğinden genellikle tercih sebebidir (İnik vd., 2017; Lecun vd., 2015).

Tam bağlantılı katmalar, kendinden önceki katmanın tüm alanlarıyla bağlantılı olan katmandır. Bu katman, evrişim katmanları tarafından öğrenilen özellikleri entegre eder ve sınıflandırma veya regresyon görevlerini gerçekleştirir (İnik vd., 2017).


Çıkış katmanı, sınıflandırma işleminin yapıldığı bu katman tam bağlantılı katmandan sonra yer almaktadır. Çıkış katmanından elde edilecek çıkış değeri, sınıflandırması yapılacak nesne adedine bağlıdır. Örneğin 7 farklı nesnenin sınıflandırılması bekleniyorsa çıkış katmanı değeri 7 olmalıdır. Sınıflandırma esnasında her bir nesne 0-1 aralığında değerler üretirler ve 1'e yakın sonucu veren nesnenin beklenen sonuç olduğu anlaşılır (İnik vd., 2017).



Şekil 3.6. Inception Modülü

ESA mimarileri, yansıtma, döndürme, ölçeklendirme veya görüntüdeki özellikleri tespit edebilme yeteneklerine sahip olduklarından dolayı sınıflandırma ve görüntü işleme işlemleri için faydalı oldukları bildirilmiştir (Fraïwan vd., 2022). Nesne tespiti, sınıflandırma ve görüntü işleme alanlarında dünya çapında düzenlenen ImageNet yarışması da ESA'nın popülerliğini artırmış ve bu yarışmada birinci olan yazılımlar derin öğrenme mimarilerinin temel taşları olarak kabul edilmiştir (İnik vd., 2017). ImageNet yarışmasıyla birlikte derin öğrenme dünyasına kazandırılan ESA mimarileri arasında AlexNet, ZFNet, GoogleNet, ResNet ve VGGNet sayılabilir.

GoogleNet, Szegedy ve arkadaşları tarafından oluşturulmuş olup ImageNet yarışmasının 2014 kazananıdır. 22 katmandan oluşan bu mimariyi diğerlerinden ayıran özelliği Inception modülü (Şekil 3.6.) sayesinde ağın derinliğini ve genişliğini artırırken maliyetini düşük tutmasıdır. Ağı özellikleri etkili bir şekilde yakalaması için farklı boyutlarda (1x1, 3x3, 5x5) birden fazla paralel filtre kullanan GoogleNet, çok sayıda katman ve filtre içermesine rağmen kullandığı paralel modüller sayesinde sistemin ezberlemesinin ve aşırı bellek maliyetlerinin önüne geçmiştir (Szegedy vd., 2014).



Şekil 3.7. Residual Blok

ResNet, %3,57 hata oranıyla üstün performans sergilemiş ve 2015 yılında ImageNet yarışmasının galibi olmuştur. 152 katmandan oluşan bu mimaride ana sorun ağı derinleştikçe verimliliği doygunluğa ulaşır ancak sonrasında hızlı bir şekilde düşüşe geçer. Bu bozulmanın önüne geçebilmek için Zhang ve arkadaşları bu çok katmanlı mimariye kısayollar ekleyerek residual blokları oluşturmuşlardır (Şekil 3.7.). Residual blok, birden fazla evrişimli katmandan ve bu katmanları atlayarak geçen bir artık bağlantıdan oluşur. Bloğun çıktısı, girdinin ve blok tarafından öğrenilen artık haritalamanın toplamıdır (He vd., 2016). Bu sayede ağıdaki bozulmanın önüne geçilmiş ve yüksek doğruluğa sahip bir ESA mimarisi oluşturulmuştur.

3.4. Veri Seti

Bu çalışmada, Ürdün'deki Kral Abdullah Üniversitesi Hastanesi'nde toplanan (Fraïwan vd., 2022) 240'ı kadın 98'i erkek olmak üzere 338 kişiye ait X ışını röntgen görüntüleri kullanılmıştır. Mendeley Data aracılığıyla açık kaynaklardan temin edilen bu veri seti 79 spondilolistezis, 188 skolyoz ve 71'i sağlıklı olmak üzere üç gruba ayrılmıştır (Şekil 3.8.).



Şekil 3.8. Veri setine ait X ışını görüntüleri (a) skolyoz (b) spondilolistezis (c) sağlıklı

Tablo 3.1. Veri setinin gruplara göre dağılımı.

	Normal	Skolyoz	Spondilolistezis
Kadın	40	151	49
Erkek	31	37	30

3.5. Transfer Öğrenme

Son yıllarda derin öğrenme ve yapay zeka geliştiricilerinin aktif olarak kullandığı bir teknik olan transfer öğrenme, farklı bir görev için önceden eğitilmiş bir modelin ikinci bir görev için tekrardan yapılandırılması olarak ifade edilebilir. Transfer öğrenmede sıfırdan bir model eğitmek yerine kaynak veri kümesindeki bilgileri kullanarak hedef veri kümesinden modeller oluşturulması amaçlanır (Zhao vd., 2014). Transfer öğrenme büyük miktarlardaki veriler kullanılarak eğitilen ağların yeni ve sınırlı miktarlardaki verilere sahip görevler için yeniden kullanımına olanak tanıdığından önemlidir.

3.6. Sınıflandırma Metrikleri

Sınıflandırma metrikleri, sınıflandırma modellerinin işlem performansını değerlendirmek için kullanılır. Performans değerlendirme hesaplamaları karışıklık matrisi kullanılarak yapılır. Karışıklık matrisi, gerçek veriler ve model tarafından tahmin edilen veri noktaları arasındaki oluşumların sayısını kaydeden bir tablodur. Karışıklık matrisinin satırları, 'gerçek sınıfları' ifade ederken sütunları, uygun model tarafından 'tahmin edilen sınıfları' temsil eder (Manna, 2022).

Gerçek Pozitif (TP): Hem gerçekten pozitif olan hem de eğitilmiş model tarafından pozitif olduğu tahmin edilen verileri ifade etmektedir.

Gerçek Negatif (TN): Hem gerçekten negatif olan hem de eğitilmiş model tarafından negatif olduğu tahmin edilen verileri ifade etmektedir.

Yanlış Negatif (FN): Model tarafından negatif olduğu tahmin edilirken gerçekte pozitif olan verilerin sayısını ifade etmektedir.

Yanlış Pozitif (FP): Model tarafından pozitif olduğu tahmin edilirken gerçekte negatif olan verilerin sayısını ifade etmektedir.

Buradan anlaşılacağı gibi TP ve TN modele göre doğru sınıflandırmayı temsil ederken FN ve FP hataları temsil eder. Bir modelin performansını değerlendirmek için karışıklık matrisi tek başına yeterli değildir. Modelin başarı performansını değerlendirmek için doğruluk (accuracy), hassasiyet (precision), geri çağırma (recall), özgüllük (specificity) ve F1 puanı gibi farklı değerlendirme parametreleri de kullanılmaktadır (Manna, 2022).

Doğruluk (accuracy), doğru olduğu tahmin edilen verilerin toplam verilere oranıdır. Veri kümesindeki sınıfların dağılımı dengeliyse doğruluk ölçümleri kullanılabilir ancak dengeli bir dağılım mevcut değilse yanıltıcı sonuçlar alınabilir (DeVries vd., 2021; Manna, 2022).

$$\text{Doğruluk} = \frac{TN + TP}{TN + TP + FP + FN} \quad (3.1)$$

Geri çağırma (recall), modelin veri setindeki pozitif örnekleri bulma yeteneğini ölçer. Doğası gereği dengesiz olan bu ölçüm, pozitif sınıfın doğru tahmin edilmesinin önemli olduğu araştırmalarda kullanılır (DeVries vd., 2021; Manna, 2022).

$$Geri \text{ çağırma} = \frac{TP}{TP + FN} \quad (3.2)$$

Hassasiyet (precision), doğru olduğu tahmin edilen pozitif verilerin, toplam tahmin edilen pozitif verilere oranıdır. Bu ölçüm araştırmacıların pozitif sınıfla daha çok ilgilendiği durumlarda kullanılır (DeVries vd., 2021; Manna, 2022)

$$Hassasiyet = \frac{TP}{TP + FP} \quad (3.3)$$

Özgüllük (specificity), modelin veri kümesindeki negatif verileri bulma performansını ölçer. Bu ölçüm, veri setinde negatif sınıfların miktarı pozitif sınıflardan az olduğunda tarafsız bir model belirlemek için kullanılır (DeVries vd., 2021; Manna, 2022).

$$Özgüllük = \frac{TN}{TN + FP} \quad (3.4)$$

F1 Puanı, geri çağırma ve hassasiyetin harmonik ortalaması alınarak hesaplanır. Geri çağırma ve hassasiyet arasında bir denge kurulması istendiğinde kullanılabilecek iyi bir ölçümdür. Eşit dağılıma sahip olmayan veri kümelerinde hatalı model seçimi yapılmasının önüne geçmek için kullanılmaktadır (DeVries vd., 2021).

$$F1 \text{ Skoru} = 2 * \frac{Hassasiyet * Geri \text{ Çağırma}}{Hassasiyet + Geri \text{ Çağırma}} \quad (3.5)$$

3.7. Modelin Eğitimi ve Test Aşaması

Derin öğrenme tabanlı otomatik bir omurga deformitesi teşhis sistemi geliştirmek için yapılan bu tez çalışmasında GoogleNet ve ResNet mimarilerinin omurga röntgen görüntülerini sınıflandırma performansları karşılaştırılmıştır. InceptionV3 ve ResNet50 mimarileri transfer öğrenme teknikleriyle ImageNet veri kümesinden eğitilmiş ve eğitim basamakları bu bölümde anlatılmıştır. Derin öğrenme modellerine ait hiperparametre değerleri Tablo 3.2.'de gösterilmiştir.

Transfer öğrenme tabanlı ESA modellerinin eğitim ve test işlemleri gerçekleştirilirken 8 GB RAM, NVIDIA ® GEFORCE 940MX, Intel ® Core ™ i5-7200U CPU özelliklere sahip bir bilgisayar kullanılmış olup Python programlama dili seçilmiştir.

Eğitimin ilk aşamasında veri işleme, model oluşturma, eğitim değerlendirme ve sonuçları görselleştirme işleri için Python kütüphane ve modülleri (os, NumPy, sklearn, keras, matplotlib.pyplot) içe aktarılmıştır. Veri setindeki her bir görüntü kendi sınıf etiketiyle (scol, spond, normal) yüklendikten sonra yeniden boyutlandırılıp ve Keras için uygun dizi formatına dönüştürülmüştür. Veri seti, eğitimde ve performans değerlendirmesinde kullanılmak amacıyla %20 test, %80 eğitim olarak iki kümeye ayrıldıktan sonra modellerin eğitimi aşamasına gelinmiş ve önce GoogleNet modeli InceptionV3 mimarisi kullanılarak oluşturulmuştur. ImageNet veri kümesindeki önceden eğitilmiş ağırlıklarla başlayan model, eğitim ve doğrulama için gerekli katmanlar eklenerek derlenmiş ve eğitilmiştir. Eğitim sırasında doğruluk ve kayıp değerleri takip edilerek model kaydedilmiş olup eğitim sürecinin grafiği çizdirilmiş ve sınıflandırma raporu oluşturularak modelin performansı değerlendirilmiştir. Diğer bir model olan ResNet50 Residual Network mimarisi kullanılarak oluşturulmuş ve GoogleNet’de olduğu gibi bu model de ImageNet veri kümesinde önceden eğitilmiş ağırlıklarla başlatılmıştır. Eğitim ve doğrulama için gerekli katmanlar eklenerek derlendikten sonra mimari eğitilmiştir. Eğitim sırasında doğruluk ve kayıp değerleri takip edilerek modelin performansı değerlendirilmiştir.

Eğitim aşamasından sonra modelin test aşamasına gelindiğinde ilk olarak resimleri işlemek ve eğitilmiş modelleri yüklemek için gerekli Python kütüphaneleri (numpy, keras, keras.models, processing.image) içe aktarılmıştır. Tahmin edilecek giriş resminin ve eğitilmiş modellerin dosya yolları tanımlandıktan sonra modelin giriş resimlerini işleyebilmesi için giriş resminin boyutları belirlenmiştir. Modelin çıktılarını yorumlamak için sınıf etiketleri (normal, spond, scol) belirlenerek giriş görüntüsünü uygun formata getirebilmek için preprocess_image() fonksiyonu tanımlanmıştır. Görüntü yeniden boyutlandırılıp piksel değerleri [0,1] aralığına ölçeklenmiştir. Tahmin aşamasına gelindiğinde ise GoogleNet modelini yüklemek için predict_with_googleNet fonksiyonu kullanılarak görüntü bir ön işleme tabi tutulduktan sonra tahminler ve sonuçlar ekrana yazdırılmıştır. ResNet modeli ile tahminde aşamasında da predict_with_resNet fonksiyonu ile ResNet modeli yüklenmiş ve süreç GoogleNet’de olduğu gibi devam ettirilmiştir. İlgili fonksiyonlar kullanılarak tahminler yapılmış ve sonuçlar ekrana yazdırılmıştır.

Tablo 3.2. Derin öğrenme modellerine ait hiperparametreler ve değerleri.


Hiperparametreler	Değerler
Yığın Boyutu	32
Öğrenme Hızı	0.001
Devir Sayısı	10
Aktivasyon Fonksiyonu	Softmax
Optimizasyon Algoritması	Adam

Veri hazırlığından model eğitime ve sonuçların değerlendirilmesinden tahminlerin yapılmasına kadar devam eden bu süreçlerin adım adım işletilmesi modelin başarılı bir şekilde eğitilmesi ve sınıflandırma performansının değerlendirilmesi için önemlidir.



4. BULGULAR

Omurga deformitelerinin derin öğrenme tabanlı bir yaklaşımla otomatik olarak tespit edilmesi için yapılan bu tez çalışmasında GoogleNet ve ResNet mimarileri transfer öğrenme yöntemiyle kullanılmış olup eğitim ve test aşamalarına ilişkin sonuçlar ve grafikler bu bölümde değerlendirilecektir. Mimarilere ait doğruluk, duyarlılık, hassasiyet, özgüllük, F1 skoru ve işlem sürelerine ait grafikler karşılaştırmalı olarak çizilmiştir. Devir sayısına bağlı doğruluk çizelgesi oluşturulmuş olup mimarilere ait karışıklık matrislerine yer verilmiştir.




Şekil 4.1. GoogleNet ve ResNet mimarilerine ait doğruluk grafikleri

Mimarilere ait doğruluk grafikleri çizdirildiğinde ResNet'in 0,92, GoogleNet'in 0,85 doğruluğa sahip olduğu görülmüştür (Şekil 4.1.). Bu grafikler ışığında mimariler doğruluk açısından kıyaslandığında ResNet'in GoogleNet'den bir adım önde olduğunu söylemek mümkündür.


Mimarilerin performansları duyarlılık açısından karşılaştırıldığında GoogleNet'in 0,82, ResNet'in ise 0,91 duyarlılığa sahip olduğu ve duyarlılık açısından da GoogleNet'in ResNet'e kıyasla bir adım geride kaldığı görülmüştür (Şekil 4.2.).

GoogleNet ve ResNet özgüllük açısından karşılaştırıldığında ise Şekil 4.3'e göre ResNet'in 0,93, GoogleNet'in 0,88 özgüllük değerine sahip olduğu görülmektedir. Bu

durumda özgüllük açısından ResNet'in GoogleNet'e göre daha üstün performans gösterdiği söylenebilir.




Şekil 4.2. GoogleNet ve ResNet mimarilerine ait hassasiyet grafikleri




Şekil 4.3. GoogleNet ve ResNet mimarilerine ait özgüllük grafikleri

Mimarilerin F1 skoru performansları karşılaştırıldığında ise Şekil 4.4'e göre 0,92 ile ResNet 0,84 ile GoogleNet'in önüne geçmiş ve daha iyi performans göstermiştir. Hassasiyet ve duyarlılık arasındaki dengeyi ifade eden F1 skoru açısından GoogleNet'in ResNet'e göre bir adım geride kaldığı görülmektedir.


GoogleNet ve ResNet mimarilerine ait kesinlik değerleri grafik üzerinde incelendiğinde ResNet'in 0,94'le bir kez daha GoogleNet' karşı üstünlük sağladığı görülmektedir (Şekil 4.5.). GoogleNet 0,87 ile kesinlik performansı açısından ResNet'in gerisinde kalmıştır.



Şekil 4.4. GoogleNet ve ResNet mimarilerine ait F1 skoru grafikleri




Şekil 4.5. GoogleNet ve ResNet mimarilerine ait kesinlik grafikleri




Şekil 4.6. GoogleNet ve ResNet mimarilerine ait eğitim sürelerinin grafikleri

Mimariler eğitim süresi açısından karşılaştırıldıklarında 30 saniye ile GoogleNet'in ResNet'ten daha hızlı işlem yaptığı görülmüştür. ResNet, 45 saniye ile GoogleNet'e göre daha yavaş kalmış ve GoogleNet eğitim hızı açısından ResNet'e üstünlük kurmuştur (Şekil 4.6.).



Şekil 4.7. GoogleNet ve ResNet mimarilerine ait test sürelerinin grafikleri

Test süreleri açısından mimariler karşılaştırıldığında GoogleNet 0,5 saniye ile küçük bir farkla da olsa ResNet'ten daha üstün performans göstermiştir (Şekil 4.7). 0,6 saniye ile GoogleNet'in gerisinde kalan ResNet test süresi açısından daha düşük performans göstermiştir.



Şekil 4.8. Devir sayısına bağlı doğruluk grafiği

Mimarilerin devir sayısına bağılı doğruluk grafiğı incelendiğinde devir sayısı arttıkça doğruluğun da arttığı görölmektedir (Şekil 4.8.). Birinci devirden son devire kadar ResNet’in GoogleNet’e doruluk açısından üstünlüğü bu grafikte de net bir şekilde görölmektedir.

Tablo 4.1. Derin öğrenme mimarilerinin başarı oranları.

	GoogleNet	ResNet
Doğruluk	0,85	0,92
Duyarlılık	0,82	0,91
Özgüllük	0,88	0,93
F1 Skoru	0,84	0,92
Kesinlik	0,87	0,94
Eğitim Süresi (saniye)	30	45
Test Süresi (saniye)	0,5	0,6

Derin öğrenme mimarilerinin başarı oranlarına yer verilen Tablo 4.1’de de görüldüğü üzere ResNet, 0,92 doğruluk, 0,91 duyarlılık, 0,93 özgüllük, 0,92 F1 skoru ve 0,94 kesinlik oranlarıyla GoogleNet’e karşı üstünlük kurmuş olup yüksek başarı göstermiştir. GoogleNet ise 30 saniyelik eğitim ve 0,5 saniyelik test süreleriyle ResNet’ten daha hızlı işlem yaptığını ve işlem hızı açısından ResNet’e göre daha üstün performansa sahip olduğunu göstermiştir.

		Tahmin Edilen		
		normal	skolyoz	bel kayması
Gerçek	normal	69	1	1
	skolyoz	10	173	5
	bel kayması	4	2	73

Şekil 4.9. ResNet mimarisine ait karışıklık matrisi

ResNet mimarisinin karışıklık matrisine yer verilen şekil 4.9’da da görüldüğü üzere mimari üstün bir sınıflandırma performansı göstermiştir. Sınıf bazında başarıları kıyaslandığında ResNet’in en iyi sınıflandırma performansını normal kontrol grubuna ait görüntülerde sergilediğini skolyoz ve bel kayması arasında ise anlamlı bir fark olmadığını söylemek mümkündür.

	Gerçek	Tahmin Edilen		
		normal	skolyoz	bel kayması
	normal	66	2	3
	skolyoz	18	157	13
	bel kayması	9	4	66

Şekil 4.10. GoogleNet mimarisine ait karışıklık matrisi

GoogleNet mimarisinin karışıklık matrisinin yer aldığı Şekil 4.10’a göre mimari, normal kontrol grubuna ait görüntüleri sınıflandırmada diğer gruplara göre daha yüksek başarı göstermiştir. Skolyoz ve bel kaymasını sınıflandırma performansı arasında ise anlamlı bir fark görülmemiştir.

Karışıklık matrislerine göre değerlendirilme yapıldığında sınıflandırma performansları bakımından ResNet’in GoogleNet’e üstün geldiği bir kez daha görülmüştür. Sınıf bazında karşılaştırıldığında her iki mimari de en üstün sınıflandırma başarısını normal kontrol grubunda gösterirken skolyoz ve bel kaymasını sınıflandırma performansları açısından anlamlı bir fark sergilememiştir.

5. SONUÇLAR

Yapay zeka teknikleri günbegün kullanım sahasını artırmakta ve birçok alanda başarılı uygulamalara zemin hazırlamaktadır. Tıp dünyasında da uygulama alanlarını genişleten ve tıbbi teşhis koymada başvurulan bir yöntem olarak kullanılmaya başlayan yapay zeka teknikleri, teşhis ve tedavi süreçleri için güvenilir ve objektif bir standart oluşturma, insan hatalarını azaltma, maliyetleri optimize etme, teşhis ve tedavi süreçlerini kısaltma avantajlarına sahiptir.

Omurga deformitelerinin derin öğrenme tabanlı teşhisi üzerine deneyler yapılan bu tez çalışmasında evrişimli sinir ağları yaklaşımıyla oluşturulan GoogleNet ve ResNet mimarileri ImageNet veri kümesindeki önceden eğitilmiş ağırlıklarla transfer öğrenme yaklaşımıyla eğitilmiştir. Skolyoz, spondilolistezis ve normal kontrol grubuna ait omurga röntgen görüntülerinin olduğu veri seti ile eğitilen ResNet50 ve InceptionV3 mimarileri test aşamasına tabi tutularak performansları karşılaştırılmalı olarak değerlendirilmiştir.

Eğitim ve test aşamasının karşılaştırmalı değerlendirilmesine göre ResNet mimarisi %92 doğruluk, %91 duyarlılık, %93 özgüllük, %92 F1 skoru ve %94 kesinlik oranlarıyla üstün bir sınıflandırma başarısı göstermiştir. GoogleNet ise %85 doğruluk, %82 duyarlılık, %88 özgüllük, %84 F1 skoru ve %87 kesinlik değeri ile ResNet'e göre daha düşük performans göstermiş olsa da onun da başarılı bir sınıflandırma yapabildiği söylenebilir. Eğitim hızı açısından 30 saniye ile GoogleNet, 45 saniye ile ResNet'ten daha hızlı eğitim süresine sahip olurken 0,5 saniyelik test süresi ile de 0,6 saniye ile ResNet'ten daha hızlı olduğunu bir kez daha göstermiştir. Bu sonuçlar doğrultusunda katman sayısı arttıkça sınıflandırma performansı artarken eğitim ve test hızı düşmekte, katman sayısı azaldıkça eğitim ve test hızı artarken sınıflandırma performansı düşmektedir. Sınıflandırma performansına olumlu yönde etki eden diğer bir parametre de devir sayısıdır. Devir sayısının artması da sınıflandırma performansını artırıcı bir etkiye sahiptir.

Bu tez çalışması kapsamında yapılan denemeler sonucunda derin öğrenme tabanlı teşhis sistemlerin omurga deformitesi tespitinde kullanılabileceği gösterilmiştir.

Gelecekte yapılacak olan çalışmalara ışık tutacağı düşünülen bu çalışma, daha fazla hastalığa ait görüntülerle, geniş veri setleri, farklı derin öğrenme mimarileri ve farklı hiperparametre değerleri kullanılarak genişletilebilir ve sonuçlar optimize edilebilir.



KAYNAKLAR

- Abbas Din. (2024, Mayıs 2). *Spondilolistezis / Anterolistezis*. Doctors Of Osteo. <https://www.doctorsofoste.com.au/osteopathy-blog/spondylolisthesis-anterolisthesis>
- Aydođdu, A., Aydođdu, Y., Deniz YAKINCI, Z., Üniversitesi, G., Fakóltesi, F., Bölümü, F., Üniversitesi, Ė., & Hizmetleri Meslek Yüksek Okulu, S. (2017). TEMEL RADYOLOJİK İNCELEME YÖNTEMLERİNİ TANIMA Recognition Of Basic Radiological Investigation Methods. İçinde Zehra Deniz YAKINCI (C. 5).
- Baumrind. (2011). *Motion Simulator for Proton Therapy*. ResearchGate. https://www.researchgate.net/figure/Dr-Roentgens-first-X-ray-image-The-subject-was-his-wifes-hand-Baumrind-2011_fig7_277596746
- Chen, B., Xu, Q., Wang, L., Leung, S., Chung, J., & Li, S. (2019). An automated and accurate spine curve analysis system. *IEEE Access*, 7, 124596-124605. <https://doi.org/10.1109/ACCESS.2019.2938402>
- Dave Harrison, M. (2023). *Vertebrae: The Bones of the Spinal Column*. SpineInfo. <https://www.spineinfo.com/anatomy/vertebrae-the-bones-of-the-spinal-column/>
- David Bernard. (2020, Kasım). *History of X-rays – 125 years in the making* . Excillum. <https://www.excillum.com/history-of-x-rays-x-ray-tubes/>
- DeVries, Z., Locke, E., Hoda, M., Moravek, D., Phan, K., Stratton, A., Kingwell, S., Wai, E. K., & Phan, P. (2021). Using a national surgical database to predict complications following posterior lumbar surgery and comparing the area under the curve and F1-score for the assessment of prognostic capability. *Spine Journal*, 21(7), 1135-1142. <https://doi.org/10.1016/j.spinee.2021.02.007>
- Dođan, F., & Türkođlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*, 10(2), 409-445. <https://doi.org/10.24012/dumf.411130>
- Elliott, A. (2005). Medical imaging. *Nuclear Instruments and Methods in Physics Research, Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 546(1-2), 1-13. <https://doi.org/10.1016/j.nima.2005.03.127>
- Fraiwan, M., Audat, Z., Fraiwan, L., & Manasreh, T. (2022). Using deep transfer learning to detect scoliosis and spondylolisthesis from x-ray images. *PLoS ONE*, 17(5 May). <https://doi.org/10.1371/journal.pone.0267851>
- Frost, B. A., Camarero-Espinosa, S., & Johan Foster, E. (2019). Materials for the spine: Anatomy, problems, and solutions. İçinde *Materials* (C. 12, Sayı 2). MDPI AG. <https://doi.org/10.3390/ma12020253>
- Good, C. R. , Auerbach, J. D., O’Leary, P. T., & Schuler, T. C. (2011). Adult spine deformity. *Current Reviews in Musculoskeletal Medicine*, 4, 159-167.

- Grzybowski, A., Pawlikowska-Łagód, K., & Lambert, W. C. (2024). A History of Artificial Intelligence. *Clinics in Dermatology*. <https://doi.org/10.1016/j.clindermatol.2023.12.016>
- Guigui, P., & Ferrero, E. (2017). Surgical treatment of degenerative spondylolisthesis. İçinde *Orthopaedics and Traumatology: Surgery and Research* (C. 103, Sayı 1, ss. S11-S20). Elsevier Masson SAS. <https://doi.org/10.1016/j.otsr.2016.06.022>
- Haleem, S. , & Nnadi, C. ,. (2018). *Scoliosis: a review*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 770-778. <https://doi.org/10.1109/CVPR.2016.90>
- Hosseini Ashtari. (2022, Ağustos). *What Is a Neural Network? Definition, Working, Types, and Applications in 2022*. Spice Works. <https://www.spiceworks.com/tech/artificial-intelligence/articles/what-is-a-neural-network/>
- Important Facts About Scoliosis You Should Know*. (t.y.). Posture Works. Geliş tarihi 17 Mayıs 2024, gönderen <https://posture-works.com/articles/important-facts-about-scoliosis-you-should-know-pw/>
- İnik, Ö., Ülker B A Bilgisayar, E., Bölümü, M., Üniversitesi, G., Üniversitesi, S., Konya, T., & Sorumlu, : (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *GAZİOSMANPAŞA BİLİMSEL ARAŞTIRMA DERGİSİ*, 6(3), 85-104. <http://dergipark.gov.tr/gbad>
- Iorio, J., Lafage, V., Lafage, R., Henry, J. K., Stein, D., Lenke, L. G., Gupta, M., Kelly, M. P., Sides, B., & Kim, H. J. (2018). The Effect of Aging on Cervical Parameters in a Normative North American Population. *Global Spine Journal*, 8(7), 709-715. <https://doi.org/10.1177/2192568218765400>
- Izzo, R., Guarnieri, G., Guglielmi, G., & Muto, M. (2013). Biomechanics of the spine. Part I: Spinal stability. İçinde *European Journal of Radiology* (C. 82, Sayı 1, ss. 118-126). <https://doi.org/10.1016/j.ejrad.2012.07.024>
- Janicki, J. A., & Alman, B. (2007). Scoliosis: Review of diagnosis and treatment. İçinde *Paediatr Child Health* (C. 12, Sayı 9). <https://academic.oup.com/pch/article/12/9/771/2648067>
- Janis Savlovskis, M. (2019, Aralık). *Sagittal Alignment of the Neutral Spine*. Anatomy Standart. <https://www.anatomystandard.com/biomechanics/spine/neutral-spine.html#White1990>
- Kaul, V., Enslin, S., & Gross, S. A. (2020). History of artificial intelligence in medicine. İçinde *Gastrointestinal Endoscopy* (C. 92, Sayı 4, ss. 807-812). Mosby Inc. <https://doi.org/10.1016/j.gie.2020.06.040>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. İçinde *Nature* (C. 521, Sayı 7553, ss. 436-444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>
- Maaliw, R. R., Susa, J. A. B., Alon, A. S., Lagman, A. C., Ambat, S. C., Garcia, M. B., Piad, K. C., & Fernando - Raguro, M. C. (2022). A Deep Learning Approach for Automatic Scoliosis Cobb Angle Identification. *2022 IEEE*

- World AI IoT Congress, AIIoT 2022*, 111-117.
<https://doi.org/10.1109/AIIoT54504.2022.9817290>
- Manna, S. (2022). Small Sample Estimation of Classification Metrics. *2022 International Conference on Interdisciplinary Research in Technology and Management, IRTM 2022 - Proceedings*.
<https://doi.org/10.1109/IRTM54583.2022.9791645>
- Masood, R. F., Taj, I. A., Khan, M. B., Qureshi, M. A., & Hassan, T. (2022). Deep Learning based Vertebral Body Segmentation with Extraction of Spinal Measurements and Disorder Disease Classification. *Biomedical Signal Processing and Control*, 71. <https://doi.org/10.1016/j.bspc.2021.103230>
- Moustafa, E., & Tur, B. S. (2018). Spondylolisthesis: Etiology, Diagnosis, Clinical Features and Treatment. *Journal of Ankara University Faculty of Medicine*, 71(3), 118-126. <https://doi.org/10.4274/atfm.36844>
- Nguyen, T. P., Chae, D. S., Park, S. J., Kang, K. Y., & Yoon, J. (2021). Deep learning system for Meyerding classification and segmental motion measurement in diagnosis of lumbar spondylolisthesis. *Biomedical Signal Processing and Control*, 65. <https://doi.org/10.1016/j.bspc.2020.102371>
- Pranshu Sharma. (2023, Ağustos). *Basic Introduction to Convolutional Neural Network in Deep Learning*. Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2022/03/basic-introduction-to-convolutional-neural-network-in-deep-learning/>
- Roa H. Alharbi, Meshal B. Alshaye, Maryam M. Alkanhal, & Najla M. Alharbi. (2020). Deep Learning Based Algorithm For Automatic Scoliosis Angle Measurement. *National Center for Communication Systems and Command and Control Technology*.
- Röntgen, W. C. (1896). On a New Kind of Rays. *Science*, 3(59), 227-231.
- Sayar, B. . (2023). Tıp Alanında Yapay Zekanın Kullanımı. *Acta Medica Ruha*, 1(1).
- Spahn, M. (2013). X-ray detectors in medical imaging. *Nuclear Instruments and Methods in Physics Research, Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 731, 57-63. <https://doi.org/10.1016/j.nima.2013.05.174>
- Sun, Y., Xing, Y., Zhao, Z., Meng, X., Xu, G., & Hai, Y. (2022). Comparison of manual versus automated measurement of Cobb angle in idiopathic scoliosis based on a deep learning keypoint detection technology. *European Spine Journal*, 31(8), 1969-1978. <https://doi.org/10.1007/s00586-021-07025-6>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2014). *Going Deeper with Convolutions*. <http://arxiv.org/abs/1409.4842>
- Şeker, A. , Diri, B. , & Balik, H. . (2017). *Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme* (C. 3, Sayı 3).
- Tan, Z. , Yang, K. , Sun, Y. , Wu, B. , Tao, H. , Hu, Y. , & Zhang, J. . (2018). IEEE International Conference on Robotics and Biomimetics. *An automatic scoliosis diagnosis and measurement system based on deep learning.*, 439-443.

- Trinh, G. M., Shao, H. C., Hsieh, K. L. C., Lee, C. Y., Liu, H. W., Lai, C. W., Chou, S. Y., Tsai, P. I., Chen, K. J., Chang, F. C., Wu, M. H., & Huang, T. J. (2022). Detection of Lumbar Spondylolisthesis from X-ray Images Using Deep Learning Network. *Journal of Clinical Medicine*, 11(18). <https://doi.org/10.3390/jcm11185450>
- Tu, Y., Wang, N., Tong, F., & Chen, H. (2019). Automatic measurement algorithm of scoliosis Cobb angle based on deep learning. *Journal of Physics: Conference Series*, 1187(4). <https://doi.org/10.1088/1742-6596/1187/4/042100>
- Varçın, F., Hasan Erbay, Eyüp Çetin, İhsan Çetin, & Turgut Kültür. (2019). *Diagnosis of Lumbar Spondylolisthesis via Convolutional Neural Networks İhsan Çetin*.
- Veena, A., & Gowrishankar, S. (2023). Automatic context-based health informatics system for diagnosing spinal deformity using deep learning. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-023-17572-3>
- Zhang, J., Lin, H., Wang, H., Xue, M., Fang, Y., Liu, S., Huo, T., Zhou, H., Yang, J., Xie, Y., Xie, M., Cheng, L., Lu, L., Liu, P., & Ye, Z. (2023). Deep learning system assisted detection and localization of lumbar spondylolisthesis. *Frontiers in Bioengineering and Biotechnology*, 11. <https://doi.org/10.3389/fbioe.2023.1194009>
- Zhao, P., Hoi, S. C. H., Wang, J., & Li, B. (2014). Online transfer learning. *Artificial Intelligence*, 216, 76-102. <https://doi.org/10.1016/j.artint.2014.06.003>

ÖZGEÇMİŞ

Ad-Soyad : Tuğba ÖZMEN

ÖĞRENİM DURUMU :

- **Lisans** : 2020, Düzce Üniversitesi , Mühendislik Fakültesi, Biyomedikal Mühendisliği
- **Yükseklisans** : 2024, Sakarya Üniversitesi, Biyomedikal Mühendisliği Anabilim Dalı, Tezli

MESLEKİ DENEYİM:

- 2019, Düzce Üniversitesi Tıp Fakültesi Hastanesi, Stajyer Mühendis
- 2019, Turkuaz Sağlık A.Ş., Stajyer Mühendis

TEZDEN TÜRETİLEN ESERLER:

- Özmen, T., Eski, H., 2023. A Deep Learning-Based Approach to Detection of Spinal Deformities, *The Online Journal of Distance Education and e-Learning*, 12(2), 110-115.