

ÇANKIRI KARATEKİN ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

RADYOLOJİK GÖRÜNTÜLERDE YOĞUNLUK TABANLI KEMİK  
SEGMENTASYONU VE OSTEOPOROZ DEĞERLENDİRMESİ

Emine Reyhan ŞENTÜRK

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI  
2025

Her hakkı saklıdır

## TEZ ONAYI

Emine Reyhan Şentürk tarafından hazırlanan “**Radyolojik Görüntülerde Yoğunluk Tabanlı Kemik Segmentasyonu Ve Osteoporoz Değerlendirmesi**” adlı tez çalışması 01/08/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

**Danışman** : Dr. Öğr. Üyesi Zafer CİVELEK

### Jüri Üyeleri :

**Başkan** : Dr. Öğr. Üyesi Fuat TÜRK  
Bilgisayar Mühendisliği Anabilim Dalı  
Gazi Üniversitesi

**Üye** : Dr. Öğr. Üyesi Zafer CİVELEK  
Elektrik-Elektronik Mühendisliği Anabilim Dalı  
Çankırı Karatekin Üniversitesi

**Üye** : Dr. Öğr. Üyesi Mustafa TEKE  
Elektrik-Elektronik Mühendisliği Anabilim Dalı  
Çankırı Karatekin Üniversitesi

**Yukarıdaki sonucu onaylarım**

**Prof. Dr. Ersoy YILMAZ**

**Enstitü Müdürü**

## **ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ**

Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü ve Sınav Yönetmeliğine göre hazırlamış olduğum “**RADYOLOJİK GÖRÜNTÜLERDE YOĞUNLUK TABANLI KEMİK SEGMENTASYONU VE OSTEOPOROZ DEĞERLENDİRMESİ**” konulu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, tezin Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü’nden başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve bu çalışmanın Çankırı Karatekin Üniversitesi tarafından kullanılan “Bilimsel İntihal Tespit Programı”yla tarandığını, “intihal içermediğini” beyan ederim. Çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması halinde ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm. Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim (01/08/2025).

**Emine Reyhan ŞENTÜRK**



*Bu alıřma ankırı Karatekin niversitesi Bilimsel Arařtırma Projeleri Koordinasyon Birimi tarafından MF081123L11 numaralı proje ile desteklenmiřtir.*

## ÖZET

Yüksek Lisans Tezi

### RADYOLOJİK GÖRÜNTÜLERDE YOĞUNLUK TABANLI KEMİK SEGMENTASYONU VE OSTEOPOROZ DEĞERLENDİRMESİ

Emine Reyhan ŞENTÜRK

Çankırı Karatekin Üniversitesi  
Fen Bilimleri Enstitüsü  
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Zafer CİVELEK

Bu yüksek lisans tezinde, kemik erimesi hastalığının erken teşhisine yönelik, görüntü işleme ve yapay zekâ temelli bir sistem geliştirilmiştir. Osteoporoz, kemik mineral yoğunluğunun azalmasıyla birlikte kemiklerin kırılma eğilimine neden olan, özellikle yaşlı bireylerde ciddi sağlık sorunlarına yol açabilen sistemik bir kemik hastalığıdır. Literatürde mevcut tanı yöntemlerinin yüksek maliyeti, sınırlı erişilebilirliği ve düşük duyarlılığı gibi dezavantajları göz önüne alınarak bu çalışmada, otomatik, hızlı ve güvenilir bir teşhis sistemi geliştirmek hedeflenmiştir.

Çalışmada, Knee Osteoarthritis Severity Dataset'ine ait diz röntgen görüntüleri kullanılmıştır. Görüntüler, U-Net derin öğrenme mimarisiyle segmente edilmiş ve kemik yapıları başarıyla ayrıştırılmıştır. Segmentasyon sonrasında çıkarılan morfolojik, istatistiksel ve frekans temelli özellikler kullanılarak Random Forest algoritması ile sınıflandırma gerçekleştirilmiştir. Modelin performansı, doğruluk (accuracy), ROC-AUC, duyarlılık (sensitivity), özgüllük (specificity), kesinlik (precision) ve F1 skoru gibi çeşitli metriklerle değerlendirilmiştir. Yapılan analizler sonucunda, ileri derecede osteoporoz sınıfı için %95,6 AUC değeri elde edilmiş ve genel sınıflandırma başarımı %75 doğrulukla ölçülmüştür.

Elde edilen bulgular, geliştirilen sistemin erken teşhis sürecine katkı sağlayabileceğini ve klinik karar destek sistemlerinde kullanılabilir potansiyele sahip olduğunu göstermektedir.

2025, 73 sayfa

**ANAHTAR KELİMELER:** Kemik erimesi, Derin Öğrenme, Görüntü İşleme, Segmentasyon, U-Net

## ABSTRACT

Master of Science Thesis

### DENSITY-BASED BONE SEGMENTATION AND OSTEOPOROSIS ASSESSMENT IN RADIOLOGICAL IMAGES

Emine Reyhan ŞENTÜRK

Çankırı Karatekin University  
Graduate School of Natural and Applied Sciences  
Department of Electrical Electronics Engineering

Advisor: Asst. Prof. Dr. Zafer CİVELEK

In this master's thesis, an artificial intelligence-based diagnostic system was developed for the early detection of osteoporosis. Osteoporosis is a systemic bone disease characterized by decreased bone mineral density, leading to increased bone fragility, and is particularly associated with a high risk of fractures in elderly individuals. Considering the limitations of conventional diagnostic methods—such as high cost, limited accessibility, and insufficient sensitivity—this study aims to provide a fast, automated, and reliable alternative.

Radiographic knee images from the Knee Osteoarthritis Severity Dataset were used in the study. Bone structures were successfully segmented using a U-Net deep learning architecture. Following segmentation, morphological, statistical, and frequency-based features were extracted, and classification was performed using the Random Forest algorithm. The model's performance was evaluated through multiple metrics, including accuracy, ROC-AUC, sensitivity, specificity, precision, and F1-score. Results showed a high AUC value of 95.6% for the advanced osteoporosis class and an overall classification accuracy of 75%.

These findings demonstrate that the proposed system has the potential to support early diagnosis and can be integrated into clinical decision support systems.

**2025, 73 pages**

**Keywords:** Osteoporosis, Bone loss, Deep learning, Image processing, Segmentation, U-Net

## **ÖNSÖZ VE TEŞEKKÜR**

Çalışmalarım boyunca bilgisini ve yardımlarını esirgemeyen tez danışmanım Dr. Öğr. Üyesi ZAFER CİVELEK'e ve bu süreçte bana destek olan aileme teşekkürlerimi sunarım.

**Emine Reyhan ŞENTÜRK**

**Çankırı, Ağustos 2025**



## İÇİNDEKİLER

|                                                                      |      |
|----------------------------------------------------------------------|------|
| ÖZET.....                                                            | i    |
| ABSTRACT .....                                                       | ii   |
| ÖNSÖZ VE TEŞEKKÜR.....                                               | iii  |
| İÇİNDEKİLER .....                                                    | iv   |
| SİMGELER DİZİNİ .....                                                | vi   |
| KISALTMALAR DİZİNİ .....                                             | vii  |
| ŞEKİLLER DİZİNİ .....                                                | viii |
| ÇİZELGELER DİZİNİ .....                                              | ix   |
| 1. GİRİŞ.....                                                        | 1    |
| 1.1 Kemik Erimesi .....                                              | 1    |
| 1.2 Kemik Erimesinin Tanımı ve Etkileri .....                        | 2    |
| 1.3 Risk Faktörleri ve Belirtileri .....                             | 3    |
| 1.3.1 Risk faktörleri.....                                           | 3    |
| 1.3.2 Belirtiler.....                                                | 4    |
| 1.4 Teşhis Yöntemleri.....                                           | 5    |
| 2. LİTERATÜR ÖZETİ.....                                              | 6    |
| 3. MATERYAL VE METOT .....                                           | 23   |
| 3.1 Görüntüleme Yöntemleri.....                                      | 23   |
| 3.1.1 Tedavi yöntemleri.....                                         | 23   |
| 3.1.2 Hastalığın toplumdaki etkisi ve önemi.....                     | 24   |
| 3.1.3 X-ray görüntülerinin kemik erimesi teşhisindeki rolü.....      | 25   |
| 3.1.4 Kemik yoğunluğunun ve yapısının değerlendirilmesi.....         | 25   |
| 3.1.5 Çift enerjili x-ışını absorpsiyometri ve diğer yöntemler ..... | 25   |
| 3.1.6 X-ray görüntülerinin teşhise katkısı ve sınırlamaları .....    | 26   |
| 3.2 Mevcut Teşhis Yöntemlerinin Dezavantajları .....                 | 26   |
| 3.2.1 Bu projenin sunduğu yenilikler.....                            | 27   |
| 3.2.2 Projenin amaçlarının ve hedeflerinin sunumu .....              | 27   |
| 3.3 Veri Seti Hazırlama .....                                        | 28   |
| 3.3.1 Tıbbi görüntülerin toplanması .....                            | 28   |
| 3.3.2 Görüntü işleme.....                                            | 28   |



|                                                               |    |
|---------------------------------------------------------------|----|
| 3.3.3 Segmentasyon etiketlerinin oluşturulması.....           | 29 |
| 3.4 Segmentasyon ve Tanımı.....                               | 30 |
| 3.4.1 Segmentasyon yöntemleri .....                           | 30 |
| 3.5 Kontrast Artırma (CLAHE).....                             | 32 |
| 3.6 Otsu Thresholding ile Binarizasyon.....                   | 33 |
| 3.7 Canny Kenar Algılama .....                                | 33 |
| 3.8 Morfolojik İşlemler.....                                  | 34 |
| 3.9 Segmentasyon ve Morfolojik İşlemlerin Entegrasyonu .....  | 35 |
| 3.10 Yapay Zekâ ve Derin Öğrenme Destekli Görüntü İşleme..... | 36 |
| 3.11 U-Net Nedir?.....                                        | 37 |
| 3.11.1 U-net mimarisi.....                                    | 37 |
| 3.11.2 U-net işleyişi.....                                    | 38 |
| 3.11.3 U-net'in avantajları.....                              | 39 |
| 3.12 Eğitim Verisi.....                                       | 39 |
| 3.12.1 Segmentasyon etiketlerinin hazırlanması .....          | 39 |
| 3.12.2 Eğitim ve doğrulama setlerinin oluşturulması .....     | 40 |
| 3.13 Ağın Eğitilmesi .....                                    | 40 |
| 3.13.1 Veri hazırlığı.....                                    | 40 |
| 3.13.2 Model eğitimi .....                                    | 41 |
| 3.13.3 Eğitim süreci.....                                     | 41 |
| 3.14 Kemik Yoğunluğu ve Erozyon Alanlarının Tespiti.....      | 41 |
| 3.15 Tıbbi Değerlendirme ve Tedavi Planlama .....             | 41 |
| 4. BULGULAR VE TARTIŞMA .....                                 | 43 |
| 4.1 Model Performansı.....                                    | 43 |
| 4.2 Segmentasyon Sonuçları .....                              | 45 |
| 4.3 Teknik Bulgular .....                                     | 46 |
| 4.4 Modelin Avantajları .....                                 | 46 |
| 4.5 Performansın Değerlendirilmesi .....                      | 49 |
| 5. SONUÇ VE ÖNERİLER .....                                    | 51 |
| KAYNAKLAR .....                                               | 55 |
| ÖZGEÇMİŞ.....                                                 | 60 |

## SİMGELER DİZİNİ

|      |                                                                        |
|------|------------------------------------------------------------------------|
| DSC  | Dice benzerlik katsayısı                                               |
| F1   | F1 skoru (precision ve recall'un harmonik ortalaması)                  |
| FN   | Yanlış negatif sayısı                                                  |
| FP   | Yanlış pozitif sayısı                                                  |
| ReLU | Doğrultulmuş lineer birim (matematiksel aktivasyon fonksiyonu)         |
| ROC  | Alıcı işletim karakteristik eğrisi (receiver operating characteristic) |
| TP   | Doğru pozitif sayısı                                                   |
| TN   | Doğru negatif sayısı                                                   |

## KISALTMALAR DİZİNİ

|       |                                                                                                      |
|-------|------------------------------------------------------------------------------------------------------|
| AUC   | Eğri altındaki alan (area under the curve)                                                           |
| BMD   | Kemik mineral yoğunluğu (bone mineral density)                                                       |
| CLAHE | Kontrast sınırlı uyarlanabilir histogram eşitleme (contrast limited adaptive histogram equalization) |
| CLAH  | Kontrast sınırlı uyarlanabilir histogram eşitleme (hatalı, CLAHE ile aynı, bu kaldırılmalı)          |
| CNN   | Evremsel sinir ağı (convolutional neural network)                                                    |
| CT    | Bilgisayarlı tomografi (computed tomography)                                                         |
| DECT  | Çift enerjili bilgisayarlı tomografi (dual-energy computed tomography)                               |
| DICOM | Tıbbi görüntüleme ve iletişim standardı (digital imaging and communications in medicine)             |
| DSC   | Dice benzerlik katsayısı (dice similarity coefficient)                                               |
| FN    | Yanlış negatif (false negative)                                                                      |
| FP    | Yanlış pozitif (false positive)                                                                      |
| HRT   | Hormon replasman tedavisi (hormone replacement therapy)                                              |
| MRI   | Manyetik rezonans görüntüleme (magnetic resonance imaging)                                           |
| PTH   | Paratiroid hormonu (parathyroid hormone)                                                             |
| QCT   | Kantitatif bilgisayarlı tomografi (quantitative computed tomography)                                 |
| ROI   | İlgilenilen bölge (region of interest)                                                               |
| SSL   | Kendi kendine denetimli öğrenme (self-supervised learning)                                           |
| U-Net | U-Net derin öğrenme mimarisi (U-Net deep learning architecture)                                      |
| WHO   | Dünya sağlık örgütü (world health organization)                                                      |

## ŞEKİLLER DİZİNİ

|           |                                          |    |
|-----------|------------------------------------------|----|
| Şekil 3.1 | Kontrast artırma (CLAHE).....            | 32 |
| Şekil 3.2 | Otsu thresholding ile binarizasyon ..... | 33 |
| Şekil 3.3 | Canny kenar algılama .....               | 34 |
| Şekil 3.4 | Morfolojik işlemler.....                 | 35 |
| Şekil 3.5 | U-Net mimarisi .....                     | 38 |
| Şekil 4.1 | Model performansı .....                  | 44 |
| Şekil 4.2 | Otsu thresholding.....                   | 46 |
| Şekil 5.1 | Sonuç .....                              | 52 |
| Şekil 5.2 | Karışıklık matrisi .....                 | 53 |
| Şekil 5.3 | ROC Eğrisi .....                         | 54 |



## ÇİZELGELER DİZİNİ

|                                             |    |
|---------------------------------------------|----|
| Çizelge 4.1 Performans karşılaştırması..... | 48 |
| Çizelge 4.2 Değerler .....                  | 50 |



## 1. GİRİŞ

### 1.1 Kemik Erimesi

Kemik erimesi, tıbbi literatürde "osteoporoz" olarak adlandırılan ve özellikle yaş ilerledikçe sıkça karşılaşılan ciddi bir kemik hastalığıdır. Latince kökenli bu kelime, "gözenekli kemik" anlamına gelir ve hastalığın temel özelliğini net bir şekilde tanımlar: kemik yoğunluğunun azalması ve kemik dokusunun zayıflaması. Kemik erimesi, kemiklerin kırılma hale gelmesine neden olur; öyle ki ileri evrelerde basit bir düşme ya da hafif bir darbe bile kırıklara yol açabilir.

Günümüzde kemik erimesi, özellikle menopoz sonrası kadınlarda yaygın olarak görülürken, yaşlı erkekler ve bazı risk gruplarındaki genç bireylerde de ortaya çıkabilir. Dünya Sağlık Örgütü'nün verilerine göre, dünya genelinde milyonlarca insan bu hastalıkla yaşamaktadır ve bu sayı her geçen yıl artmaktadır. Kemik erimesinin görülme sıklığının artmasının başlıca nedenleri arasında yaşam süresinin uzaması, hareketsiz yaşam tarzları ve kalsiyum ile D vitamini eksiklikleri sayılabilir.

Kemikler, yaşam boyu sürekli olarak yenilenen canlı dokulardır. Ancak kemik erimesinde bu denge bozulur; kemik yapımı yavaşlar, yıkımı ise hızlanır. Bu dengesizlik sonucu kemik kütlesi azalır ve kemikler içi boşalmış gibi gözenekli bir yapıya dönüşür. Özellikle omurga, kalça ve bilek kemikleri bu hastalıktan en çok etkilenen bölgeler arasındadır.

Kemik erimesi çoğu zaman "sessiz hırsız" olarak nitelendirilir çünkü hastalık uzun yıllar boyunca hiçbir belirti vermeden ilerleyebilir. İlk kırık gerçekleşene kadar kişi bu hastalığa sahip olduğunu fark etmeyebilir. Omurga kırıkları, boy kısalması, kamburluk ve sırt ağrıları kemik erimesinin en belirgin belirtileri arasında yer alır. Bu nedenle erken tanı ve önleyici tedbirler son derece hayati önem taşır.

Kemik erimesine yol açan faktörler oldukça çeşitlidir. Genetik yatkınlık, hormon seviyelerindeki değişiklikler (özellikle östrojenin azalması), beslenme yetersizlikleri, sigara ve alkol kullanımı, bazı ilaçlar ve kronik hastalıklar bu risk faktörleri arasında sayılabilir. Ayrıca uzun süreli hareketsizlik, kemik sağlığını ciddi anlamda tehdit eden bir durumdur.

Tedavi sürecinde hem ilaç tedavileri hem de yaşam tarzı değişiklikleri büyük rol oynar. Kalsiyum ve D vitamini takviyeleri, düzenli egzersiz programları, kemik yoğunluğunu artırmaya yönelik ilaçlar ve sağlıklı beslenme alışkanlıkları tedavinin temel taşlarıdır. Ayrıca düşmeleri önleyici çevresel düzenlemeler yapmak da kemik sağlığını korumada önemli bir adımdır.

Sonuç olarak, kemik erimesi modern çağın en önemli halk sağlığı sorunlarından biridir. Erken teşhis, önleyici tedbirler ve doğru bilgilendirme ile bu hastalığın etkileri büyük ölçüde azaltılabilir. Toplumun bilinçlenmesi, kemik sağlığının korunması ve kemik erimesinin önlenmesi için yapılacak çalışmalar, bireylerin yaşam kalitesini yükseltmek adına hayati bir öneme sahiptir.

## **1.2 Kemik Erimesinin Tanımı ve Etkileri**

Kemik erimesi, kemiklerin mineral yoğunluğunu ve kalitesini azaltan bir hastalıktır. Sağlıklı kemikler, süngerimsi bir yapıya sahiptir ve kalsiyum ve diğer mineraller bakımından zengindir. Bu mineraller, kemiklere güç ve sağlamlık kazandırır. Kemik erimesi olan kişilerde ise kemiklerde mikroskobik gözenekler oluşur ve kemik dokusu zayıflar. Bu durum, kemiklerin kırılma hale gelmesine ve kırılma riskini artmasına neden olur.

Kemik erimesinin en yaygın etkileri şunlardır:

**Kırıklar:** Kemik erimesi görülen kişilerde, özellikle kalça, omurga ve bilek olmak üzere kemik kırıkları riski yüksektir. Bu kırıklar, ağrı, sakatlık ve hatta ölüm gibi ciddi komplikasyonlara yol açabilir.

**Boy kaybı:** Kemik erimesi, omurgalarda çökmeye ve boy kaybına neden olabilir. Bu durum, kamburluk ve postür bozukluklarına yol açabilir.

**Ağrı:** Kemik erimesi görülen kişilerde, özellikle sırt ve kalça ağrısı sıklıkla görülür. Bu ağrı, günlük aktiviteleri yapmayı zorlaştırabilir.

### **1.3 Risk Faktörleri ve Belirtileri**

Kemik erimesi (osteoporoz) gelişiminde etkili olan risk faktörleri ve hastalığın belirtileri aşağıda ayrıntılı olarak sunulmaktadır:

#### **1.3.1 Risk faktörleri**

Kemik erimesi riskini artıran başlıca etmenler şunlardır:

- **Yaş:** Yaş ilerledikçe kemik yoğunluğu doğal olarak azalır. Bu nedenle, kemik erimesi riski yaşla birlikte artmaktadır.
- **Cinsiyet:** Kadınlarda kemik erimesi, erkeklere kıyasla daha sık görülmektedir.
- **Aile Öyküsü:** Birinci derece bir aile üyesinde kemik erimesi bulunması, bireyin bu hastalığa yakalanma riskini yükseltir.
- **Vücut Yapısı:** Küçük boylu ve ince kemik yapısına sahip bireylerde kemik erimesi riski daha yüksektir.



- Menopoz: Menopoz sonrası dönemde kadınlarda östrojen hormonu seviyeleri azalır. Bu durum, kemik kaybını hızlandırarak kemik erimesi riskini artırabilir.
- Bazı Sağlık Sorunları: Tiroit hastalıkları, iltihaplı romatizma ve kronik böbrek hastalığı gibi bazı sağlık sorunları kemik erimesi riskini artırabilir.
- Bazı İlaçlar: Kortizon içeren ilaçlar ile bazı nöbet önleyici ilaçlar, kemik kaybına yol açarak kemik erimesi riskini yükseltebilir.
- Yaşam Tarzı Etmenleri: Sigara kullanımı, aşırı alkol tüketimi, yetersiz beslenme ve fiziksel aktivite eksikliği, kemik erimesi riskini artıran önemli etmenler arasında yer almaktadır.

### **1.3.2 Belirtiler**

Kemik erimesi, erken evrelerinde genellikle belirgin bir belirti göstermez. Bu nedenle, hastalık çoğu zaman bir kemik kırığı meydana gelene kadar teşhis edilemeyebilir. Kemik erimesiyle ilişkili başlıca belirtiler şunlardır:

- Sırt Ağrısı: Kemik erimesi olan bireylerde, özellikle sırtın üst bölgesinde ağrı sıkça görülür. Bu ağrı, uzun süre ayakta durma veya oturma ile şiddetlenebilir.
- Boy Kısalması: Kemik erimesi, zamanla boy kısalmasına neden olabilir. Bu durum, birey tarafından fark edilmeyebilir ancak çevresindekiler tarafından gözlemlenebilir.
- Kamburluk: Omurgada çökme sonucu kamburluk oluşabilir.
- Kolay Kemik Kırıkları: Kemik erimesi olan bireylerde, hafif travmalar veya düşmelerle bile kemik kırıkları meydana gelebilir.

#### 1.4 Teşhis Yöntemleri

Kemik yoğunluk ölçümü (DEXA): DEXA, kemik yoğunluğunu ölçmek için kullanılan en yaygın yöntemdir. Bu yöntem, düşük dozda radyasyon kullanarak kemiklerin mineral içeriğini ölçer.

Kan testleri: Bazı kan testleri, kemik erimesinin nedenini belirlemeye yardımcı olabilir. Örneğin, D vitamini seviyesini ölçen bir kan testi, D vitamini eksikliği olup olmadığını gösterebilir.

Röntgen: Kemik kırıklarını tespit etmek için kullanılır. Ancak, röntgenler kemik erimesinin hastalığının erken evrelerini tespit etmede yetersiz kalabilir.

Laboratuvar Testleri: Kalsiyum, D vitamini ve diğer ilgili maddelerin seviyelerini ölçer. Bu testler, kemik metabolizmasını ve genel kemik sağlığını değerlendirmede yardımcı olabilir.

Ultrasonografi: Kemik kalitesi hakkında bilgi verebilir, ancak bu da daha az yaygın kullanılan bir yöntemdir.

## 2. LİTERATÜR ÖZETİ

Bu çalışma, el ve bilek röntgen görüntülerini kullanarak kemik erimesini tahmin etmek için yeni bir yöntem sunmaktadır. Makalede, ulna, radius ve metakarpal kemiklerin segmentasyonundaki belirsizlikleri yakalamak için olasılıksal U-Net kod çözücüler içeren gelişmiş bir görüntü segmentasyon modeli kullanılmıştır. Bu yaklaşım, genellikle operatör becerisi ve hasta faktörlerinden etkilenen daha pahalı Dual-energy X-ray absorptiometry (DXA) testlerinin yerine geçmeyi amaçlamaktadır. Yazarlar, etiketsiz verilerden temel özellikleri çıkarmak ve 192 kişiden oluşan ve standart DXA sonuçlarıyla çapraz referanslı bir veri kümesine dayanarak kemik erimesi sınıflandırmasını iyileştirmek için self-supervised learning (SSL)'yi uygulamaktadır. Bu araştırmanın katkıları arasında, erişilebilir periferik radyografik görüntüleri kullanan yeni bir otomatik kemik erimesi tarama yöntemi, model performansını artırmak için SSL'nin uygulanması ve veri sınırlı senaryolarda eğitim verimliliğini artırmak için uyarlanmış çoklu kırpma artırma stratejisi yer almaktadır. Gelişmiş segmentasyon ve SSL'nin bu kombinasyonu, çalışmaları erken kemik erimesi tespit yöntemlerinde önemli bir ilerleme olarak konumlandırmaktadır (Hwang vd. 2024).

Bu makale, kemik hastalığı teşhisinde önemli bir rol oynayan kemik erimesi için kemik mineral yoğunluğu ölçümüne odaklanmaktadır. Makalede, düşük kontrast koşulları altında X-ışını görüntüsü gürültüsü ve hasta kemik şekillerindeki büyük farklılıklar nedeniyle mevcut kemik erimesi teşhis algoritmalarının tatmin edici sonuçlar elde etmekte zorlandığı belirtilmektedir. Bu sorunların üstesinden gelmek için, U-NET ağı tabanlı geliştirilmiş bir kemik erimesi teşhis algoritması sunulmaktadır. Geliştirilmiş U-Net'in, kemik mineral yoğunluğu ölçüm sürecinde görüntü parazitinin etkisini doğru bir şekilde çözebildiği ve U-net otomatik teşhis yönteminin %81'in üzerinde bir tanıma oranına sahip olduğu belirtilmektedir. Bu sonuç, U-Net yönteminin diğer karşılaştırma yöntemlerine göre daha iyi bir teşhis etkisi gösterdiğini ortaya koymaktadır (Liu vd. 2020).

Bir çalışmada, Bioa kemik erimesi hastalarının kalça kırık riski taşıyanları tespit etmek için geliştirilen yeni bir otomatik görüntüleme yöntemi anlatılıyor. Mevcut yöntemde, kalça kemiğinin segmentasyonu manuel yapıldığı için zaman alıcı ve hataya açık. Bu çalışmada, derin öğrenme tabanlı bir U-net yapısı kullanılarak otomatik ve hızlı kalça kemiği segmentasyonu sağlandı. Model, 30 manuel olarak segmentlenmiş CT görüntüsüyle eğitildi ve 200 test görüntüsünde yüksek doğrulukla (DSC: 0.990, HD95: 0.981 mm) performans gösterdi (Bjornsson vd. 2021).

Başka bir çalışma, spinal MRG'de kemik metastazlarının otomatik olarak tespiti ve segmentasyonu için U-Net mimarisi kullanan bir derin öğrenme modeli geliştirmeyi ve değerlendirmeyi amaçlamıştır. Çalışmaya, eğitim/test için 302 hastadan 662 MRG serisi ve eksternal validasyon için 20 hastadan 49 MRG serisi dahil edilmiştir. Modellerde üç farklı MRG sekansının kombinasyonları kullanılmıştır: T1 ağırlıklı, kontrastlı yağ bazlı ve kontrastlı yağ baskılı görüntüler. Değerlendirme metrikleri arasında Dice katsayısı, piksel bazında geri çağırma ve tespit duyarlılığı yer almaktadır. T1 + CE 2D U-Net modeli, 0.699 Dice katsayısı ve iç ve dış testler için sırasıyla 0.828 ve 0.857 lezyon başına duyarlılık ile diğerlerinden daha iyi performans göstermiştir ve 0.746 ortalama duyarlılığa sahip radyologların performansını aşmıştır. Çalışma, derin öğrenmenin spinal metastazlar için tanısal yetenekleri geliştirmedeki potansiyelini vurgulamaktadır (Kim vd. 2024).

Bu çalışma, kemik mineral yoğunluğu ölçümünde karşılaşılan sorunları gidermek için U-NET ağını temel alan yeni bir algoritma sunarak kemik erimesi teşhisindeki zorlukları ele almaktadır. U-NET modeli, işaretlenmiş orijinal görüntülerden bir veri kümesi oluşturularak, girdi verileri normalleştirilerek ve daha iyi doğruluk için softmax tahminlerini çapraz entropi kayıp fonksiyonuyla birleştiren hesaplanmış bir enerji fonksiyonu kullanılarak doğrulanır. Deneysel sonuçlar, U-NET yönteminin %81'in üzerinde tanıma oranlarına ulaştığını ve mevcut teşhis tekniklerinden daha iyi performans gösterdiğini göstermektedir. Makale, kemik erimesi teşhis yöntemlerini tartışmakta, çift enerjili X-ışını absorpsiyometrisini (DXA) mevcut standart olarak vurgulamakta ve ayrıca kantitatif bilgisayarlı tomografi (QCT) ve manyetik rezonans görüntüleme (MRI) gibi daha yeni gelişmeleri incelemektedir. Bu yöntemlerin avantajları ve kısıtlamaları

tartışılmakta ve yaşlanan nüfusun kemik erimesi prevalansı arttıkça iyileştirilmiş non-invaziv tanı uygulamalarına duyulan ihtiyaç vurgulanmaktadır (Marsilio vd. 2022).

Bu makale, diz osteoartriti olan hastalar için diz MR görüntülerinde kemiklerin ve kıkırdakların otomatik segmentasyonu için yeni bir yaklaşım sunmaktadır. U-Net tabanlı modellerle desteklenen çok adımlı bir süreç kullanan çalışma, ilk olarak femoral, tibial ve patellar bileşenlerin semantik segmentasyonunu gerçekleştirmeden önce kemik iliği lezyonları ve kistleri gibi anormallikleri tespit etmektedir. Metot, rekonstrüksiyon hatasına dayalı olarak anormallikleri tanımlamak için normal kemik hacmi profillerini yeniden yapılandırarak inpainting yoluyla bir anomali tespiti aşaması içeren 3D evrişimli sinir ağlarını (CNN'ler) kullanır. Geleneksel segmentasyon yaklaşımlarıyla karşılaştırıldığında, anomali farkında olan model, Hausdorff mesafelerinde %58'e kadar azalma göstermiştir ve anomali tespitinde daha yüksek bir hassasiyet ve özgüllük elde etmiştir (anomaliye duyarlı olmayan ağlarda AUC 0,874'e karşı 0,896 AUC). Çalışma, sınırlı sayıda açıklanmış veri kümesinden yararlanarak ve genel bir eğitim çerçevesi sunarak alanı geliştirmekte ve tıbbi görüntü segmentasyon görevlerinde anomali tespitini entegre etmenin avantajlarının altını çizmektedir (Woo vd. 2024).

Bir çalışmada, 30 hastadan elde edilen dual-enerjili bilgisayarlı tomografi (DECT) veri setlerinde kemiklerin segmentasyonu için 3D U-Net mimarisine dayalı bir evrişimsel sinir ağı (CNN) geliştirmeyi amaçlamaktadır. Önerilen algoritma, segmentasyon doğruluğunu artırmak için derin öğrenmedeki gelişmeleri kullanır ve çeşitli görüntüleme koşullarında 0,963'ün üzerinde ortalama Dice katsayısı elde eder. Özellikle, ağ, özellikle kemik kenarlarının yakınında, tek enerjili BT'yi taklit eden karışık görüntülere kıyasla DECT görüntülerinde üstün performans gösterdi. Metodoloji, sonuçları iyileştirmek için artık bloklar ve derin denetim gibi modifikasyonlar kullanır. Bulgular, çok enerjili BT uygulamalarına potansiyel uzantılar olduğunu ve özellikle radyasyon tedavisi bağlamlarında tıbbi görüntülemeye doku analizi için önemli faydalar sağladığını göstermektedir (González Sánchez vd. 2020).

Başka bir çalışma, U-Net adlı derin öğrenme modeli kullanılarak CT görüntülerinden yüz kemiklerini otomatik olarak sekiz bölgeye ayırmayı amaçlamaktadır. 50 hastadan elde

edilen verilerle eğitilen model, özellikle mandibula ve zigomatik kemikler gibi bazı bölgelerde yüksek doğrulukla çalışmış, ancak dişler ve metal artefaktları nedeniyle diğer bölgelerde biraz daha zorlanmıştır. Bu teknoloji, yüz cerrahisinde planlama ve kişiye özel üretim sürecini hızlandırmayı hedeflemektedir. Ancak, verilerin tek bir kurumdan olması nedeniyle daha fazla araştırma ve doğrulama gerekmektedir (Morita vd. 2023).

Bir çalışmada, ultrason görüntülerinde kemik yüzeylerini yüksek doğrulukla ve gerçek zamanlı olarak segmentleyen gelişmiş bir derin öğrenme modelidir. Squeeze-and-excitation residual bloklar ve derinlik bazlı ayırıcı konvolüsyonlar kullanılarak tasarlanmış olup, normalizasyon ve kayıp fonksiyonlarının performansa etkisi araştırılmıştır. Sonuçlar, BoneNet'in hem yüksek doğruluk hem de dayanıklılık gösterdiğini, mevcut yöntemlerden daha üstün performans sergilediğini ve klinik uygulamalarda güvenle kullanılabileceğini ortaya koymuştur (Luan vd. 2020).

Bu çalışma, bu makalede diz osteoartritini otomatik olarak tespit etmek için bir bilgisayar görüşüne dayalı bir sistem sunmaktadır. Sistem, radyologlar tarafından yapılan manuel değerlendirme sürecinin zorluğunu ve zaman alıcılığını gidermek amacıyla x-ışını görüntülerini analiz etmektedir. Osteoartriti tespit etmede kullanılan temel özellik, kıkırdak kaybına bağlı olarak eklem boşluğunun daralmasıdır. Önerilen yöntem, x-ışını kalitesini artırmak için çeşitli görüntü işleme teknikleri kullanır, tibiofemoral eklemi otomatik olarak bölümlere ayırır ve eklem boşluğu genişliğini standart ölçümlerle karşılaştırarak hesaplar. Geniş bir veri kümesi üzerinde yapılan deneyler, %97'nin üzerinde bir tespit doğruluğu göstermektedir. Çalışma, osteoartritin artan görülme sıklığı göz önüne alındığında, verimli otomatik sistemlerin gerekliliğinin altını çizmekte ve teşhiste insan hatasını önemli ölçüde azaltmaktadır. Manuel osteoartrit tespiti yüksek hata olasılığına sahipken, mevcut tekniklerin çoğu yarı otomatiktir ve manuel yardıma ihtiyaç duyar; bu nedenle, bu çalışma, radyologlara yardımcı olmak için tamamen otomatik bir algoritma sunmaktadır (Saleem vd. 2020).

Bu makale, osteoartritin X-ışını ve Manyetik Rezonans Görüntüleme (MRI) gibi tıbbi görüntüleme yöntemleriyle, çeşitli görüntü işleme teknikleri aracılığıyla incelenmesini ve sınıflandırılmasını ele almaktadır. Osteoartrit, öncelikle kıkırdaki etkileyen, ağrıya ve

eklem fonksiyon bozukluđuna yol aan dejeneratif bir eklem hastalıđı olup genellikle yaşı ve kilolu bireylerde g r l r. Makale, mevcut tanı y ntemlerini, Kellgren-Lawrence derecelendirme sistemine dayalı beş osteoartrit şiddet d zeyini ve g r nt  iřleme s relerini (g r nt  elde etme,  n iřleme,  zellik ıkarma ve sınıflandırma) incelemektedir. Yazarlar, mevcut klinik deđerlendirme y ntemlerinin osteoartrit deđerlendirmesinde yeterli dođruluđu sađlayamadıđını belirtmekte ve gelecekteki arařtırmalarda daha kapsamlı, ok y nl  yaklařımlara ihtiya duyulduđunu vurgulamaktadır. eřitli segmentasyon,  zellik ıkarma ve sınıflandırma teknikleri entegre bir řekilde tartıřılmıř; farklı diz g r nt leri (X-ıřını, MRI vb.) kullanılarak osteoartritin tespiti ve analizi iin geliřtirilen y ntemler sistematik ve bilimsel bir řekilde deđerlendirilmiřtir (Gornale vd. 2016).

Bir alıřmada, diz kıkırdađı ekstraksiyonu iin ok etiketli rastgele y r y řler algoritması kullanan yeni bir interaktif segmentasyon yazılımını sunmaktadır. Manuel ve otomatik segmentasyon tekniklerinin sınırlamalarını gidermektedir; bu teknikler karmařık anatomiler iin genellikle zaman alıcı ve hatalıdır. Yazılım, kullanıcı dostu olmasına, hızına ve verimliliđine vurgu yaparak g revi manuel segmentasyon iin gereken s renin  te ikisinde gerekleřtirdiđi belirtilmektedir. Diz kıkırdađını segmentasyonda karřılařılan zorluklar arasında ince yapı ve d ř k doku kontrastı,  zellikle osteoartrit vakalarında yer almaktadır. Yazarlar, kullanıcı etkileřimini artırmayı, sezgisel kontrolleri teřvik etmeyi ve   boyutlu segmentasyona ve kantitatif analize y nelik potansiyel geliřmeleri amalayan yazılım  zelliklerini  zetlemektedir. Otomatik segmentasyona y nelik  nceki giriřimler, katılıkları ve kapsamlı manuel girdi ihtiyaı nedeniyle eleřtirilmiřtir ve bu da  nerilen interaktif yaklařımın gerekliliđini ve avantajlarını vurgulamaktadır. Yazılımın rahatlıđı, sezgiselliđi ve hızı vurgulanmıřtır; kullanıcıların amalarını kolayca uygulamalarına ve karmařık tıbbi g r nt leri etkili bir řekilde iřlemesine olanak tanır. Gelecekteki alıřmalar, bu yazılımı   boyutlu segmentasyona ve kantitatif analize dođru geniřletecektir (Gan vd. 2014).

Bařka bir alıřma, yaptıkları alıřmada, el ve diz osteoartrinde (OA) subkondral kemik deđiřikliklerine odaklanmakta ve ayrıntılı anatomik analiz iin makroradyografiyi kullanmaktadır. Subkondral kemiđin,  zellikle kortikal ve trabek ler yapıların, eklem

aralığı daralması (JSN) fark edilmeden önce, OA gelişiminin erken evrelerinde kalınlaştığını belirtmektedir. Dizde, kortikal plaka kalınlığındaki artış sıklıkla skleroz ile birlikte görülür ve eldekenden daha belirgindir. Değişiklikler, ileri OA'da eklem yüzeylerinin deformasyonuna yol açar ve sintigrafi ile elde edilen bulgular, kemik değişikliklerinin tespit edilebilir kıkırdak kaybından önce gerçekleştiğini göstermektedir. Çalışma ayrıca, OA'nın görüntüleme yoluyla yoğun bir şekilde izlenebileceğini ve osteofit oluşumu ve skleroz gibi erken kemik değişikliklerinin eklem dejenerasyonunun ilerlemesini öngörebileceğini vurgulamaktadır. Ek olarak, çalışma, OA eklemlerindeki daha zayıf kemik yapılarının subartiküler osteoporoza yol açabileceğini ima etmektedir (Buckland vd. 2004).

Bir makalede, diz osteoartritinin (OA) teşhisini makine görüşüyle iyileştirmeye yönelik bir yöntem sunmakta; özellikle yaşlı ve kilolu bireylerde sık görülen, kıkırdak bozulması nedeniyle ağrıya yol açan bu dejeneratif eklem hastalığını ele almaktadır. Çalışma, diz röntgeni görüntülerini aktif kontur segmentasyon tekniğiyle analiz ederek Haralick, istatistiksel momentler, doku ve şekil gibi özellikleri çıkarmayı ve Random Forest sınıflandırıcısıyla %87,92'lik umut verici bir sınıflandırma doğruluğu elde etmeyi önermektedir; bu oran, mevcut birçok algoritmayı geride bırakmaktadır. Önerilen metodoloji, görüntü elde etme, ön işleme, segmentasyon, görüntü iyileştirme, özellik çıkarma ve sınıflandırma adımlarını içermekte; çeşitli özellik kümelerinin karşılaştırılmasıyla birleştirilmiş özellik kümesinin en yüksek doğruluğu sağladığı gösterilmektedir. Makale, manuel röntgen analizinin zaman alıcı, öznel ve hatalara açık olduğunu vurgulayarak, yarı otomatik bir tekniğin hızlı ve etkili bir analiz sunduğunu belirtmekte; mevcut teşhis yaklaşımlarının yetersizliklerini ele alarak insan hatasını en aza indiren otomatik çözümleri savunmakta ve segmentasyon, özellik çıkarma teknikleri, metodoloji, deneysel analiz ile gelecekteki araştırma yönlerini kapsamlı bir şekilde incelemektedir (Gornale vd. 2016).

Bu çalışma, IEEE Uluslararası Konferansı'nda sunulan araştırma, diz osteoartritinin (OA) erken tespiti için artiküler kıkırdak kalınlığını ölçmek üzere 2D koronal görünümde MRI görüntülerinin sınıflandırılmasına odaklanmaktadır. OA, dizde yaygın olan dejeneratif bir eklem hastalığıdır ve eklem ağrısı, sertlik ve hareket azalması gibi semptomlara yol açan



artiküler kıkırdağın bozulmasına neden olur. Manyetik rezonans görüntüleme (MRI), kıkırdak hasarını görselleştirmek için en etkili non-invaziv yöntem olarak savunulmaktadır. Çalışma, MATLAB R2013a kullanılarak piksel tabanlı bir segmentasyon tekniği ve ardından kontrast artırma, histogram eşitleme, eşikleme ve Canny kenar algılama gibi görüntü işleme teknikleri kullanmaktadır. Kıkırdağı segmentlere ayırdıktan sonra, çalışma GLCM kullanarak doku özelliklerini çıkarır ve görüntüleri %86,66 doğrulukla normal veya OA etkilenmiş olarak sınıflandırırken, aynı zamanda erken OA tespiti için Öklid mesafe formülü aracılığıyla kıkırdak kalınlığını ölçer. Bu yaklaşım, geleneksel görünümünden uzaklaşarak, OA'yı incelemede 2D koronal MRI görüntülerinin potansiyelini göstermektedir (Kumar vd. 2016).

Bu makale, X-ışını görüntülerini kullanarak diz osteoartriti (OA) şiddetini sınıflandırma ve derecelendirme yöntemlerinin karşılaştırmalı bir analizini sunmaktadır. Transfer öğrenimi ve aktif öğrenme dahil olmak üzere makine öğrenimi tekniklerini kullanan tam otomatik analizlere ağırlık vererek, manuel, yarı otomatik ve otomatik sınıflandırma tekniklerindeki önemli gelişmeleri vurgulamaktadır. Kapsamlı bir literatür taraması, başlangıçtaki 743 bulgudan 26 ilgili çalışmayı ortaya çıkarmış olup, ağırlıklı olarak otomatik yöntemlere odaklanırken manuel segmentasyon araştırmalarının azlığına işaret etmektedir. Yazarlar, bilgisayar destekli tanının diz OA'sının erken teşhisini önemli ölçüde iyileştirdiğini ve makine öğreniminin teknoloji ve klinik uygulama arasındaki boşluğu doldurarak zamanında tedavi seçenekleri sunduğunu belirtmektedir. Makale, diz OA şiddeti sınıflandırması için makine öğrenimi algoritmalarının kullanımını ve bunların sağlık profesyonelleriyle nasıl iş birliği yapabileceğini vurgulamaktadır (Saini vd. 2021).

Bir çalışmada, diz ve el eklemlerinde osteoartrit (OA) teşhis ve ilerlemesini öngörmek amacıyla X-ray görüntülerinde trabeküler kemik (TB) dokusunun otomatik analizine odaklanmaktadır. Geleneksel gözlem ve klinik değerlendirmeler subjektif ve zaman alıcı olabildiği için, bu çalışma, yüksek hassasiyetli ve otomatik bir karar destek sistemi geliştirmeyi hedeflemiştir. Çalışma, ilk aşamada, diz ve el radyografilerinde TB bölgelerinin otomatik seçimini sağlayan algoritmalar geliştirmiştir. Ardından, fractal analiz teknikleri kullanılarak, doku yapısındaki karmaşık ve çok ölçekli özellikler

hesaplanmış ve sağlıklı ile kemik erimesi olan dokular arasındaki farklar analiz edilmiştir. Özellikle Variance Orientation Transform (VOT) yöntemiyle, doku dokusunun farklı yönlerdeki fractal boyutları belirlenmiş ve bu sayede erken aşamadaki kemik değişikliklerinin tespiti mümkün hale gelmiştir. Ayrıca, elde edilen tekstürel özellikler kullanılarak kemik tipleri sınıflandırılmış ve sonunda, klinik kullanım ve araştırma amaçlarına hizmet edecek ReadMyXray adlı web tabanlı analiz platformu geliştirilmiştir. Bu sistem, klinik ortamda erken teşhisi kolaylaştırmayı ve tedavi planlarının zamanında yapılmasını sağlayacak potansiyele sahiptir. Yine de otomatik bölge seçiminde karşılaşılan zorluklar ve görüntü kalite farklılıkları, bu tekniklerin klinik entegrasyonunu engelleyebilecek faktörlerdir. Ancak genel olarak, çalışma osteoartrit teşhisinde özel ve hassas bir araç sunmakta olup, erken tanı ve izleme açısından umut vadetmektedir (Gwidon vd. 2016).

Başka bir çalışma, pediatrik kardiyak BT görüntülerinde tüm kalbin ve kalp boşluklarının U-Net modeli kullanılarak derin öğrenme yöntemleriyle otomatik olarak segmentasyonunu araştırmaktadır. Doğruluk değerlendirmesi için Dice benzerlik katsayılarını (DSC) kullanan model, tüm kalp segmentasyonu için ortalama 0,95'in üzerinde bir DSC elde etmiş ve yaşa bağlı anlamlı bir farklılık göstermemiştir. Aynı ayrı eğitildiklerinde ortalama DSC'ler 0,78 ile 0,88 arasında değişirken, her bir oda toplu olarak eğitildiğinde 0,80 ile 0,85 arasında değişmiştir. Çalışma, pediatrik kalplerdeki yetişkinlere kıyasla benzersiz yapısal farklılıkları vurgulamakta ve görüntülemeye konjenital malformasyonların yarattığı zorlukları tanımlamaktadır. Derin öğrenme yoluyla otomatik kalp segmentasyonunun değerli bir araç olduğu kanıtlandıkça, pediatrik kardiyak durumların teşhisini iyileştirme ve potansiyel olarak tıp uzmanlarına konjenital kalp hastalıklarını daha verimli bir şekilde yönetmede yardımcı olma konusunda umut vaat etmektedir. Aorta ve pulmoner damarların sınırlarında yanlış tanımlar gözlenmiştir (Yoshida vd. 2021).

Bir makalede, karaciğer rahatsızlıklarını ve özellikle hepatosellüler karsinomu teşhis etmek için gerekli olan abdominal BT görüntülerinden karaciğer ve tümörün otomatik olarak segmentasyonu için değiştirilmiş bir UNet mimarisini araştırmaktadır. Atlamalı bağlantılardan yararlanan tam evrişimli sinir ağlarını (FCNN) kullanan değiştirilmiş

UNet, uzamsal bilgileri korurken özellik çıkarımını geliştirir. Yöntem, LITS veri kümesinde karaciğer için %96,15 ve tümör segmentasyonu için %89,38'lik bir Dice Benzerlik Katsayısı (DSC) ve 3D-IRCADb veri kümesinde karaciğer için %91,94 ve tümör için %69,80'lik bir DSC ile olağanüstü sonuçlar elde eder. Bu bulgular, önerilen mimarinin mevcut segmentasyon modellerinden daha iyi performans gösterdiğini ve özellik değişmezliği ve segmentasyon doğruluğu ile ilgili zorlukları ele aldığını göstermektedir. Makale, çeşitli segmentasyon teknikleri üzerine ilgili çalışmaları içermekte ve alanla ilgili derin öğrenmedeki gelişmeleri tartışmaktadır. Çalışma, Modifiye edilmiş Unet58 katmanları mimarisini kullanarak derin öğrenme algoritmalarını kullanarak LITS ve 3Dircadb veri kümeleri için karaciğer ve tümör segmentasyonunu başlatır. Önerilen Modifiye edilmiş Unet, karaciğerin segmentasyonunda %96,15'lik yüksek bir DSC skoru ve  $256 \times 256$  boyutundaki LITS veri kümesi için tümörün %89,38'lik bir DSC skoru ile segmentasyonunda mevcut derin öğrenme modellerini geride bırakmaktadır. Ek olarak,  $128 \times 128$  boyutundaki bir 3Dircadb veri kümesi için karaciğerin segmentasyonu için %91,94 ve tümörün segmentasyonu için %69,80'lik yüksek bir DsC skoru elde edilmiştir (Manjunath vd. 2022).

Bu çalışma, beton çatlaklarını tespit etme doğruluğunu artırmak için geliştirilmiş bir U-Net evrişimli sinir ağı kullanan beton yapılar için bir çatlak tanımlama yöntemi sunmaktadır. Geleneksel yöntemler düşük doğruluk ve zayıf sağlamlık nedeniyle eleştirilmektedir. Takviyeli beton kirişler üzerinde bir eğilme testi yapılarak çatlak görüntüleri toplanır, ardından veri artırma ve etiketleme işlemleri gerçekleştirilir. Geliştirilmiş U-Net modeli, bir başlangıç modülü ve bir Atrous Uzamsal Piramit Havuzu modülü içermektedir. Sonuçlar, önerilen yöntemin standart U-Net modeline göre ortalama %11,7 daha yüksek bir hassasiyet elde ettiğini ve çatlak genişliği ölçümlerindeki ortalama bağıl hatayı ACTIS sistemine kıyasla %18,6 azalttığını göstermektedir. Çalışma, beton köprülerin güvenliğini değerlendirmek için etkili ve hızlı çatlak tespit yöntemlerinin önemini vurgulamaktadır. Bu amaçla, U-net sinir ağlarına dayalı geliştirilmiş bir inception modülü ve bir Atrous Spatial Pyramid Pooling modülü eklenerek, havuzlamadaki veri kaybı azaltılmış ve çoklu özellik kaynaşmasının doğruluğu arttırılmıştır. Yeni Loss Function Dice Loss, ağı çatlak piksellerine duyarlılığını arttırmak için modelde kullanılmıştır (Qiao vd. 2021).

Bu makale, meme kanseri segmentasyon yöntemlerinin mevcut durumunu ve gelecekteki potansiyellerini tartışmakta ve erken teşhisin hayatta kalma oranlarını iyileştirmedeki önemini vurgulamaktadır. Çalışma, mamogram görüntülerini analiz etmede segmentasyon tekniklerinin rolünü vurgulayarak, bunları klasik yöntemler (bölge tabanlı ve kenar tabanlı segmentasyon gibi), makine öğrenimi ve özellikle U-Net modelini içeren derin öğrenme yaklaşımları olarak gruplandırmaktadır; U-Net modeli, verimliliği ve daha az sayıda etiketli görüntüye ihtiyaç duyması nedeniyle tercih edilmektedir. Çalışmanın bulguları, bölge büyütmenin klasik yöntemlerde yaygın bir teknik olduğunu, denetimsiz öğrenmenin ise makine öğrenimi segmentasyonunda daha sık kullanıldığını ortaya koymaktadır. Ayrıca, yaygın olarak kullanılan gürültü giderme filtreleri ve mamogram segmentasyonu için veri tabanlarının kapsamlı bir analizi sunulmakta ve geçmiş literatür incelenmektedir. Makale, meme kanseri tespitinde tanısal doğruluğu ve verimliliği artırmak amacıyla, mevcut sınırlamaların üstesinden gelmek için segmentasyon tekniklerinin daha fazla araştırılmasını savunmaktadır (Michael vd. 2021).

Bir çalışmada, U-Net adlı derin öğrenme mimarisini kullanan yeni bir ImageJ eklentisini tanıttıyor; bu eklenti, biyomedikal görüntü verilerinin analizi, özellikle hücre tespiti ve şekil ölçümleri gibi görevler için kolaylık sağlıyor. Bu eklenti, makine öğrenimi konusunda uzman olmayan kullanıcıların, yerel bilgisayarlarda veya uzak sunucu/bulut hizmetleri aracılığıyla verilerini etkili bir şekilde analiz etmelerini sağlayacak şekilde kullanıcı dostu olarak tasarlanmıştır. Tek hücre segmentasyonu için önceden eğitilmiş modellerle donatılmıştır, bu da kullanıcıların kapsamlı makine öğrenimi bilgisi olmadan analizlerine hızla başlamalarını sağlar. Ayrıca, eklenti esneklik sunar; U-Net, minimum düzeyde etiketlenmiş örneklerle yeni görevlere uyarlanabilir, bu da onu alandaki araştırmacılar için çok yönlü bir araç haline getirir. Çalışma, deneysel kurulum hakkında detaylar da içeriyor; optogenetik deneyler için erkek CD® (Sprague Dawley) IGS sıçanlarının, mikrogliya deneyleri için ise dişi CX3CR1-creER/wt; R26R-Confetti/wt farelerinin kullanıldığını belirtiyor ve bu hayvanların kontrollü yetiştirme ve bakım koşulları altında tutulduğunu vurguluyor. Araştırma, etik hususların önemine dikkat çekiyor ve çalışmanın vahşi veya sahada toplanmış hayvanları içermediğini belirtiyor. Genel olarak, makale, ileri makine öğrenimi tekniklerini günlük araştırma uygulamalarıyla birleştiren pratik bir çözüm sunarak biyomedikal görüntüleme alanına

önemli bir katkı sağlıyor ve böylece karmaşık görüntü analiz araçlarının daha geniş bir kitle için erişilebilirliğini artırıyor (Falk vd. 2019).

Başka bir çalışma, seyrek görüş bilgisayarlı tomografi (BT) rekonstrüksiyonunda geleneksel U-Net mimarisinin sınırlamalarını ele alarak, sınırlı projeksiyon görünümünden kaynaklanan görüntü artefaktlarını azaltmak için çift çerçeve U-Net ve sıkı çerçeve U-Net adlı iki yeni mimari önermektedir. Bu mimariler, çerçeve koşulunu karşılayarak yüksek frekanslı kenarların kurtarılmasını iyileştirir ve gürültü sağlamlığını artıran ek yollarla yön bilgilerinin daha iyi işlenmesini sağlar. Gerçek hasta veri kümeleriyle yapılan kapsamlı deneyler, önerilen U-Net varyantlarının geleneksel U-Net'e kıyasla yeniden yapılandırma kalitesinde önemli iyileşmeler sunduğunu göstermektedir. Bu çalışma, görüntü kalitesini korurken radyasyona maruz kalmayı azaltan daha etkili bir çözüm sunarak seyrek görünümlü BT rekonstrüksiyonunda derin evrişimli çerçevelerin potansiyelini vurgulamaktadır (Han vd. 2018).

Bir makalede, tıbbi görüntü analizinde U-Net mimarisinin evrimini ve uygulamalarını kapsamlı bir şekilde incelemektedir. 2015 yılında geliştirilen U-Net, daralma (kodlayıcı) ve genişleme (kod çözücü) yollarıyla piksel düzeyinde bağlamsal bilgi sağlayarak tıbbi görüntü segmentasyonunda çığır açmıştır. Bu incelemede, 2017-2020 yılları arasında IEEE, Springer ve Elsevier veritabanlarından seçilen makaleler aracılığıyla U-Net'in varyasyonları (3D U-Net, Dikkat U-Net, U-Net++, Adversarial U-Net, Ensemble U-Net vb.) ve bunların MR, CT, retinal fundus görüntüleme, mikroskopi, dermoskopi, ultrason, X-ışını gibi çeşitli görüntüleme yöntemlerindeki uygulamaları değerlendirilmiştir. U-Net, görüntü artefaktlarının kaldırılması ve kayıt gibi ek görevlerde de etkili olup, çapraz entropi, Tversky kaybı gibi kayıp fonksiyonları ile doğruluk, hassasiyet, F-skoru, zar puanı ve AUC gibi metriklerle performans göstermektedir. Modüler ve uyarlanabilir yapısıyla U-Net, özellikle COVID-19 teşhisinde göğüs BT ve X-ışını görüntülerinin analizinde önemli katkılar sağlamıştır. Ancak, hesaplama gücü gereksinimleri, veri kıtlığı ve derin öğrenmenin opak doğası gibi zorluklar devam etmektedir. Bu anket, U-Net'in tıbbi görüntülemedeki dönüştürücü rolünü ve gelecekteki araştırma yönlerini vurgulamaktadır (Siddique vd. 2021).

Bu çalışma, tarafından geliştirilen çalışma, elektriksel kapasitans tomografisi (ECT) için büyük veri tabanlı bir U-Net yapısı kullanarak yenilikçi bir görüntü yeniden yapılandırma algoritması sunmaktadır. Bu yöntem, ECT görüntü yeniden yapılandırmasını bir görüntü segmentasyon problemi olarak ele alarak, yaklaşık 60.000 simülasyon verisi örneğiyle (COMSOL Multiphysics ve MATLAB kullanılarak oluşturulmuş) öncelikle tam bağlı bir sinir ağı (FC) ile ön işleme yapar ve ardından U-Net yapısını kullanarak daha yüksek doğrulukta görüntüler elde eder. U-Net'in simetrik kodlayıcı-kod çözücü yapısı, ECT'nin ileri ve ters problemleriyle uyumlu olup, gaz ve yağ sınırlarının hassas konumlandırılmasını sağlar. Ortalama kare hata (MSE) kayıp fonksiyonu ve softmax aktivasyonu ile eğitilen model, geleneksel yöntemler (Lineer Geri Projeksiyon ve Landweber iterasyonu) ve FC ağına kıyasla daha düşük göreceli görüntü hatası ve daha yüksek görüntü korelasyon katsayısı sunar. Gürültü direnci (25-75 dB), genelleme kabiliyeti ve gerçek 8-elektrotlu ECT sisteminden elde edilen deneysel verilerle doğrulanan algoritma, özellikle iki fazlı akışların (yağ-gaz) görselleştirilmesinde üstün performans gösterir. Bu çalışma, derin öğrenmenin ECT görüntü yeniden yapılandırmasındaki potansiyelini vurgulayarak, gerçek zamanlı ve yüksek kaliteli görüntüleme için etkili bir çözüm sunmaktadır (Yang vd. 2019).

Bu makale, diz osteoartriti (OA) tanısında kullanılan manyetik rezonans görüntüleme (MRI) tekniklerinin otomatik veya yarı-otomatik segmentasyon yöntemleriyle geliştirilmesine odaklanmaktadır. Osteoartritin hızla yükselen sağlık problemi olduğuna değinilen makalede, MRI'nin iç yapıları yüksek çözünürlükte görüntülemesini sağladığı ancak analizinin zaman alıcı, maliyetli ve subjektif hatalara açık olduğu vurgulanmaktadır. Bu nedenle, bilgisayar destekli otomatik ve yarı-otomatik segmentasyon yöntemleri klinikte ve bilimsel araştırmalarda büyük avantajlar sunmaktadır. Makale, manuel, yarı-otomatik ve tam otomatik yöntemleri karşılaştırmakta ve özellikle deformable modeller, bölge büyütme, sınıflandırma tabanlı ve grafik tabanlı yöntemler üzerinde durmaktadır. Ayrıca, dizdeki kemik ve kıkırdak yapıların segmentasyonu için çeşitli teknikler, özellikle deformable modeller ve voxel/ölçek sınıflandırma yöntemleri detaylandırılmaktadır. Ayrıca, kıkırdak kalınlığı ve hacminin ölçümünde kullanılan farklı yaklaşımlar ve bu yöntemlerin karşılaştırılması ele alınmaktadır. Makale, mevcut veri setleri, performans kriterleri ve toplamda karşılaşılan

zorlukların yanı sıra, klinikte uygulanabilir en etkili yöntemlerin geliştirilmesine dair gelecekteki araştırma yönlerine de işaret etmektedir. Bu çalışmalar, OA teşhis ve takipte daha hızlı, nesnel ve doğru çözümler sunmayı amaçlamaktadır (Zhang vd. 2023).

Bir çalışmada, MATLAB ortamında görüntü segmentasyonunun önemi ve çeşitli tekniklerini incelemektedir. Segmentasyon, görüntüleri anlamlı parçalara ayırma süreci olup, tıbbi, endüstriyel ve kültürel alanlarda geniş uygulama alanı bulmaktadır. Makalede, binary, gri tonlama, RGB ve indexed olmak üzere dört temel dijital görüntü türü tanımlanmış ve bu görüntülerin segmentasyonunda kullanılan yöntemler detaylandırılmıştır. Özellikle kenar tespiti (edge detection) ve eşikleme (thresholding) teknikleri üzerinde durulmuş; kenar tespiti, nesnelerin detaylarını belirlemek için farkları vurgularken, eşikleme ise görüntüyü ikili hale getirerek nesne ve arka planı ayırt etmeyi sağlar. Ayrıca, su basma (watershed) ve bölge tabanlı segmentasyon gibi diğer yöntemler de açıklanmış ve farklı görüntüler üzerinde uygulanan örnekler gösterilmiştir. Çalışma, yüksek başarı ve düşük hata oranlarıyla görüntülerin anlamlandırılmasında MATLAB'ın sağladığı güç ve esnekliği vurgulamaktadır; bununla birlikte, düşük yoğunluklu veya renk dağılımı homojen olmayan görüntülerin segmentasyonunda zorluklar yaşanabildiğine değinilmiştir. Gelecekte derin öğrenme tekniklerinin kullanımıyla daha etkili algoritmalar geliştirilebileceği öngörülmektedir (Abdulrahman vd. 2020).

Başka bir çalışma, sağlık hizmetlerinde teşhis ve tedavi planlamasına destek olarak kritik bir rol oynamaktadır. Tıbbi görüntülemelerde segmentasyonun doğruluğunu ve verimliliğini artırmak amacıyla çeşitli algoritmalar ve teknikler geliştirilmiştir. Derin öğrenme, evrişimli sinir ağları ve Lattice Boltzmann yöntemlerinin kullanımı, özellikle beyin tümörü segmentasyonunda umut verici sonuçlar ortaya koymuştur. Araştırmacılar, görüntü segmentasyonunun kalitesini iyileştirmeye odaklanırken aynı zamanda hesaplama hızını da dikkate almıştır. Yüksek boyutluluğu ve çoklu kafes vektörleriyle Lattice Boltzmann yöntemi, tıbbi görüntü segmentasyonunda önemli bir araştırma alanı olmaya adaydır. Bu yöntemin makroskobik ve mikroskobik ölçekler arasında köprü kurma yeteneği, onu bu alanda gelecekteki araştırmalar için potansiyel bir odak noktası haline getirmektedir. Ahmedabad'daki CIMS Hastanesi ve Guntur'daki KLEF ekiplerine destekleri için teşekkür edilmekte; ayrıca Hindistan Hükümeti Bilim ve Teknoloji

Departmanı'na (DST) DST-FIST Seviye-1 programı aracılığıyla sağladığı yardım için minnettarlık ifade edilmektedir. Belge, tıbbi görüntü segmentasyon algoritmalarının ilerlemesine katkıda bulunan çeşitli çalışmaları ve araştırma makalelerini referans göstererek, bu alandaki devam eden araştırmaların önemini vurgulamaktadır (Ramesh vd. 2021).

Bir makalede, tıbbi görüntü segmentasyonunda kullanılan çeşitli deformable contour (esnek sınır) modellerini (snake, level set, geodesic aktif kontur, GVF, topoloji snake ve kısıtlamalı optimizasyon gibi) detaylı şekilde incelemekte ve karşılaştırmaktadır. Bu yöntemlerin temel prensipleri, güçlü ve zayıf yönleri, farklı görüntü özelliklerine ve zorluklara (gürültü, zayıf kenarlar, karmaşık şekiller, örtüşen bölgeler) uyumları ele alınmaktadır. Ayrıca, parametre ayarları, başlangıç noktası bağımlılığı, algoritmaların kararlılığı ve hesaplama karmaşıklığı gibi uygulama detaylarına da değinilmektedir. Deneysel çalışmalar, MRI, ultrason, CT ve optik görüntüler üzerinde farklı yöntemlerin performansını değerlendirmekte ve özellikle zorlayıcı durumlarda (örneğin, zayıf kenar, karmaşık şekil, gürültü) kısıtlamalı optimizasyon ve topoloji snake gibi yöntemlerin üstünlüklerini ortaya koymaktadır. Makale, her yöntemin avantajları ve sınırlamaları hakkında kapsamlı bilgiler sunarak, kullanıcıların uygun algoritma seçimi yapmasına yardımcı olmayı amaçlamaktadır. Ayrıca, farklı yöntemlerin kombinasyonunun ve ek görüntü bilgisi kullanmanın segmentasyon doğruluğunu artırabileceğine vurgu yaparak, tıbbi görüntü analizinde daha etkili çözümler geliştirilmesine katkı sağlamaktadır (He vd. 2008).

Bu çalışma, beyin tümörü tespiti için MRI görüntülerinde kullanılan çeşitli görüntü işleme tekniklerini incelemektedir. MRI'nin diğer görüntüleme yöntemlerine göre üstünlüklerini vurgulayan makale, ön işleme aşamalarında filtreleme, kontrast artırma ve kenar tespiti gibi adımlara değinmektedir. Ayrıca, eşikleme, watershed ve morfolojik işlemler gibi segmentasyon yöntemleri detaylandırılmakta ve bu tekniklerin tümör tespiti üzerindeki etkileri ele alınmaktadır. Özellikle, morfolojik işlemlerin görüntüleri iyileştirmede ve gürültüyü azaltmada önemli rol oynadığı belirtilmektedir. Segmentasyon teknikleri arasında watershed, histogram eşikleme ve fuzzy C-means gibi algoritmalar öne çıkmakta olup, bu yöntemler tümörlerin daha doğru ve net şekilde belirlenmesine



yardımcı olmaktadır. Makale, farklı algoritmaların etkinliklerini karşılaştırmakta ve dijital görüntü işleme tekniklerinin tanı doğruluğunu artırmadaki önemine vurgu yapmaktadır. Genel olarak, bu tekniklerin kombinasyonu, beyin tümörü teşhisinde daha yüksek doğruluk ve güvenilirlik sağlamaktadır. Sonuç olarak, makale, görüntü işleme tekniklerinin, klinik uygulamalarda erken ve doğru teşhis için vazgeçilmez araçlar olduğunu ortaya koymakta ve bu alandaki gelişmelerin, hastaların tedavi süreçlerini iyileştirmeye katkı sağlayacağını belirtmektedir (Borole vd. 2015).

Bu makale, tıbbi görüntüleme alanında özellikle MRI ve mamografi gibi medikal görüntülerde kullanılan çeşitli görüntü segmentasyon tekniklerini kapsamlı bir şekilde incelemektedir. Segmentasyon yöntemleri arasında eşikleme (küresel, lokal, dinamik), kümeleme algoritmaları (sert k-means, bulanık kümeleme), yapay sinir ağları, model tabanlı yaklaşımlar (Markov Random Fields, Gaussian MRF) ve PDE tabanlı teknikler (aktif konturlar, seviyeli setler, Mumford-Shah ve C-V modelleri) yer almaktadır. Her bir yöntemin temel prensipleri, avantajları ve dezavantajları detaylandırılarak, özellikle medikal görüntülerdeki uygulama alanlarına vurgu yapılmıştır. Ayrıca, bu tekniklerin doğruluk, dayanıklılık ve farklı görüntüleme koşullarına uyum sağlama konularında geliştirilmesi gerektiği belirtilmiştir. Makale, karma ve optimize edilmiş algoritmaların, farklı görüntüleme ortamlarında daha iyi performans gösterebilmesi ve tanı süreçlerini iyileştirebilmesi adına önemine dikkat çekmektedir. Ayrıca, yöntemlerin seçiminde görüntü özellikleri ve araştırma amaçlarının dikkate alınması gerektiği vurgulanmakta, böylece doğru ve güvenilir sonuçlar elde edilmesi hedeflenmektedir. Genel olarak, makale, medikal görüntü analizinde daha etkin ve uyarlanabilir segmentasyon tekniklerinin geliştirilmesine yönelik ihtiyaçları ortaya koymakta ve bu alandaki güncel yaklaşımları özetlemektedir (Jaglan vd. 2019).

Bir çalışmada, osteoartrit (OA) hastalarında diz patella kemiğinin mineral yoğunluğu (BMD) ile ağrı şiddeti arasındaki ilişkiyi araştırmıştır. Bulgular, dinlenme sırasında orta ve şiddetli ağrı yaşayan hastaların, lateral ve medial patella yüzeylerinde, özellikle 2.5-7.5 mm derinliklerde, anlamlı derecede daha düşük BMD'ye sahip olduğunu göstermektedir. Bu azalmış BMD, hastaların ağrı seviyeleri arttıkça ortaya çıkmakta ve yaklaşık %28'e varan oranlarda BMD kaybı gözlemlenmektedir. Ayrıca, tibial kemik

BMD'sinde anlamlı bir fark bulunmamış, bu da değişikliklerin lokalize olduğunu düşündürmektedir. Düşük BMD'nin, osteoartritli hastalarda kemik kalitesinin bozulduğunu ve bu durumun total diz protezi sonrası komplikasyon risklerini artırabileceğini öne sürmektedir. Bu bulgular, ağrı şiddeti ile patella kemiği BMD'si arasında güçlü bir ilişki olduğunu ve osteoartrit yönetiminde kemik sağlığının değerlendirilmesinin önemini vurgulamaktadır. Sonuç olarak, artan dinlenme ağrısı, patella kemiğinde azalmış kemik yoğunluğu ile ilişkilidir ve bu durum, cerrahi planlama ve tedavi stratejilerinde dikkate alınmalıdır (Burnett vd. 2016).

Başka bir çalışma, diz eklemi kıkırdaklarının MRI görüntülerinde segmentasyonu ve analizine yönelik çeşitli yöntemleri incelemektedir. Manuel, yarı-otomatik ve otomatik segmentasyon teknikleri arasındaki farkları ve bu yöntemlerin doğruluk ve tekrarlanabilirlik açısından avantajlarını tartışmaktadır. Özellikle, overlap doğruluğunu ölçmek için Dice Similarity Coefficient (DSC) ve kalınlık doğruluğu için RMS kalıntıları gibi metrikler kullanılmıştır. Segmentasyon teknikleri arasında eşikleme, watershed algoritmaları, voxel sınıflandırma (örneğin kNN), şekil ve model tabanlı yöntemler (aktif konturlar, istatistiksel şekil modelleri, aktif görünüm modelleri), atlas kaydı ve hybrid yaklaşımlar yer almaktadır. Ayrıca, kıkırdak kalınlığını ölçmek için Euclidean mesafe, offset haritaları ve unfolding gibi yöntemler kullanılırken, hacim ve 3D görselleştirme de önemli yer tutmaktadır. Makale, doğrulama süreçlerinde in vitro, in vivo ve sentetik veri kullanımıyla ilgili zorluklara değinmekte ve daha doğru, verimli ve tekrarlanabilir yöntemlerin geliştirilmesi gerektiğini vurgulamaktadır. Genel olarak, bu çalışmalar, osteoartrit gibi hastalıkların erken teşhisi ve takibi için MRI tabanlı kıkırdak değerlendirmelerinde otomasyon ve doğruluğu artırmaya yöneliktir (Swamy vd. 2012).

Bir makalede, dış segmentasyonu üzerine kapsamlı bir inceleme sunmakta ve bu alandaki güncel araştırma ortamına dair birkaç kritik içgörü ortaya koymaktadır. Makalenin kabulü üzerine erişime açılacak yeni bir veri setini tanıtmakta olup, bu veri seti gelecekteki çalışmalar için önemli bir katkı sağlayabilir. Ayrıca, yazarlar dış segmentasyonunda öncü teknikler üzerine sistematik bir inceleme yapmakta, şu anda en ileri düzey olarak kabul edilen yöntemleri yeni tanıtilen veri setine karşı kıyaslayarak öne çıkarmaktadır. Çalışmanın bu bölümü, uygulanan tekniklerin etkinlik ve performansını değerlendirmeyi

amaçlayarak, alanda neler başarıldığına dair daha net bir anlayış sağlamaktadır. Bunun yanı sıra, makale gelecekteki perspektifleri tartışmakta, dış segmentasyonu ve ilgili alanlarda olası etkileriyle birlikte yaklaşan araştırma girişimleri için potansiyel yönler çizmektedir. Önceki çalışmaları sentezleyerek ve yeni bir kaynak sunarak, makale dış segmentasyonunda ilerlemeleri teşvik etmeyi ve bu uzmanlaşmış çalışma alanında devam eden diyaloga anlamlı bir katkı sağlamayı hedeflemektedir (Silva vd. 2018).



### **3. MATERYAL VE METOT**

#### **3.1 Görüntüleme Yöntemleri**

Tıbbi görüntüleme, kemik erimesi gibi iskelet sistemi hastalıklarının teşhisi ve tedavi planlamasında kritik bir rol oynamaktadır. Bu bağlamda röntgen (X-ray), bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRI) gibi yöntemler, kemik mineral yoğunluğunun ve yapısal bütünlüğün değerlendirilmesinde sıkça kullanılmaktadır. Özellikle çift enerjili X-ışını absorpsiyometrisi (DEXA), altın standart yöntem olarak kabul edilmekle birlikte, yalnızca mineral yoğunluk ölçümüne odaklanması nedeniyle mikroyapısal değişiklikleri tespit etmede sınırlıdır (Guglielmi vd. 2011). Son yıllarda, radyolojik verilerin yapay zekâ algoritmalarıyla entegrasyonu hem doğruluğu hem de yorumlanabilirliği artırarak klinik karar destek sistemlerine katkı sağlamaktadır (Zhou vd. 2021).

##### **3.1.1 Tedavi yöntemleri**

Kemik erimesi tedavisinin amacı, kemik kaybını önlemek ve kırık riskini azaltmaktır. Kemik erimesi tedavisinde kullanılan çeşitli yöntemler şunlardır:

**Yaşam tarzı değişiklikleri:** Sigarayı bırakmak, alkol tüketimini sınırlamak, düzenli egzersiz yapmak ve sağlıklı beslenmek gibi yaşam tarzı değişiklikleri, kemik sağlığını korumaya ve kemik erimesi riskini azaltmaya yardımcı olabilir.

**D vitamini ve kalsiyum takviyeleri:** D vitamini ve kalsiyum eksikliği kemik erimesi için bir risk faktörüdür. Bu nedenle, kemik erimesi görülen kişilere genellikle D vitamini ve kalsiyum takviyesi önerilir.

**İlaç tedavisi:** Kemik erimesi tedavisinde çeşitli ilaçlar kullanılabilir. Bu ilaçlar, kemik kaybını önlemeye ve yeni kemik oluşumunu teşvik etmeye yardımcı olur. Kemik erimesi tedavisinde kullanılan yaygın ilaçlar şunlardır:

Bisfosfonatlar: Bisfosfonatlar, kemik hücrelerinin (osteoklastlar) kemik dokusunu parçalamasını önleyen ilaçlardır.

RANKL inhibitörleri: RANKL inhibitörleri, kemik hücrelerinin (osteoklastlar) oluşumunu ve aktivitesini engelleyen ilaçlardır.

Hormon replasman tedavisi (HRT): Menopoz sonrası kadınlarda östrojen seviyelerinin düşmesi kemik erimesi riskini artırır. HRT, kemik kaybını önlemeye ve kemik erimesi riskini azaltmaya yardımcı olabilir.

Paratiroid hormonu (PTH): PTH, kemik oluşumunu teşvik eden bir hormondur. Bazı kemik erimesi vakalarında PTH tedavisi kullanılabilir.

### **3.1.2 Hastalığın toplumdaki etkisi ve önemi**

Kemik erimesi, dünya çapında önemli bir halk sağlığı sorunudur. Dünya Sağlık Örgütü'nün (WHO) tahminlerine göre, dünya çapında her 3 saniyede bir kemik erimesi kaynaklı bir kırık meydana gelmektedir. Kemik erimesi kırıkları, ağrı, sakatlık, engellilik ve hatta ölüm gibi ciddi komplikasyonlara yol açabilir. Kemik erimesi tedavisinin maliyeti de oldukça yüksektir.

Kemik erimesi, özellikle yaşlı yetişkinlerde yaygındır. Türkiye'de de kemik erimesi önemli bir halk sağlığı sorunudur. 65 yaş ve üzeri Türk yetişkinlerin yaklaşık %30'un da kemik erimesi olduğu tahmin edilmektedir.

Kemik erimesinin önlenmesi ve tedavisi için farkındalığın artırılması önemlidir. Risk altında olan kişiler, kemik yoğunluğunu ölçtürmeli ve gerekli durumlarda tedavi almalıdır. Kemik erimesi görülen kişiler de doktorlarının önerdiği tedaviyi uygulamalı ve sağlıklı bir yaşam tarzı sürdürmelidir.

### **3.1.3 X-ray görüntülerinin kemik erimesi teşhisindeki rolü**

X-ray görüntüleme, vücut dokularının röntgen ışınları kullanılarak görüntülenmesine dayanan bir teşhis yöntemidir. Röntgen ışınları, elektromanyetik dalgaların bir türüdür ve kemik gibi yoğun dokulardan geçerken diğer dokulara göre daha az emilir. Röntgen cihazı, bu ışınların vücuttan geçişi sırasında emilme oranlarını ölçer ve bu bilgilere dayanarak bir görüntü oluşturur.

### **3.1.4 Kemik yoğunluğunun ve yapısının değerlendirilmesi**

X-ray görüntüleri, kemiklerin yoğunluğunu ve yapısını belirli bir ölçüde değerlendirmek için kullanılabilir. Röntgen ışınlarının kemikten geçişi sırasında emilme oranları, kemik yoğunluğunun bir göstergesi olarak kullanılabilir. Düşük emilim, daha az yoğun kemik anlamına gelir. X-ray görüntüleri ayrıca kemiklerin yapısını da gösterebilir. Bu, kırıklar, çatlaklar veya kemiklerde anormallikler gibi yapısal problemleri tespit etmeye yardımcı olabilir.

### **3.1.5 Çift enerjili x-ışını absorpsiyometri ve diğer yöntemler**

DXA, kemik yoğunluğunu ölçmek için kullanılan özel bir X-ray görüntüleme yöntemidir. Bu yöntemde, iki farklı enerjideki X-ray ışını kullanılır ve kemik dokusundan ve yumuşak dokudan farklı emilim oranları hesaplanır. Bu bilgiler kullanılarak kemik mineral yoğunluğu (BMD) ölçümü yapılır. BMD, kemiklerin ne kadar mineral içerdiğinin bir göstergesidir ve kemik erimesi gibi kemik hastalıklarının teşhisinde önemli bir rol oynar.

DXA'ya ek olarak, kemik yoğunluğunu ve yapısını değerlendirmek için diğer görüntüleme yöntemleri de kullanılabilir. Bunlara bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRI) dahildir. Bu yöntemler, DXA'dan daha ayrıntılı görüntüler sağlayabilir ve kemiklerde daha ince anormallikleri tespit etmeye yardımcı olabilir.

### **3.1.6 X-ray görüntülerinin teşhise katkısı ve sınırlamaları**

X-ray görüntüleri, kemik erimesi teşhisinde önemli bir araçtır. Özellikle DXA, kemik yoğunluğunu ölçmek için en yaygın ve güvenilir yöntemlerden biridir. X-ray görüntüleri ayrıca kemiklerde kırıklar, çatlaklar veya diğer yapısal problemleri tespit etmeye de yardımcı olabilir.

Ancak X-ray görüntülerinin bazı sınırlamaları da vardır. DXA, kemiklerin mineral içeriğini ölçer, ancak kemiklerin yapısı ve gücü hakkında tam bilgi vermez. Ayrıca X-ray görüntüleri, erken evre kemik erimesi rahatsızlığını tespit etmede her zaman etkili olmayabilir.

Kemik erimesi teşhisinde X-ray görüntülerinin yanı sıra diğer yöntemler de kullanılabilir. Hastanın tıbbi geçmişi, aile öyküsü ve risk faktörleri de teşhise katkıda bulunabilir. Gerekirse, kan testleri ve diğer laboratuvar testleri de yapılabilir.

X-ray görüntüleri, kemik erimesi teşhisinde önemli bir araçtır. Özellikle DXA, kemik yoğunluğunu ölçmek için en yaygın ve güvenilir yöntemlerden biridir. Ancak X-ray görüntülerinin bazı sınırlamaları da vardır ve kemik erimesi teşhisinde tek başına yeterli olmayabilir. Teşhis için diğer yöntemlerin de kullanılması gerekir.

### **3.2 Mevcut Teşhis Yöntemlerinin Dezavantajları**

Kemik erimesi teşhisinde kullanılan mevcut yöntemlerin bazı dezavantajları şunlardır:

Pahalı ve zaman alıcı olabilirler: DXA gibi bazı teşhis yöntemleri pahalı olabilir ve zaman alabilir. Bu durum, kemik erimesi riski taşıyan tüm insanların bu testlerden geçmesini zorlaştırabilir.

Her zaman doğru olmayabilirler: DXA gibi bazı teşhis yöntemleri, erken evre kemik erimesi hastalığını tespit etmede her zaman etkili olmayabilir.

Rahatsız edici olabilirler: Bazı teşhis yöntemleri, örneğin kan testleri veya kemik iliği aspirasyonu, hastalar için rahatsız edici olabilir.

Herkes için uygun olmayabilirler: Hamile veya emziren kadınlarda veya bazı tıbbi durumları olan kişilerde bazı teşhis yöntemleri kullanılamaz.

### **3.2.1 Bu projenin sunduğu yenilikler**

Bu proje, yapay zekâ (AI) ve görüntü işleme tekniklerini kullanarak kemik erimesi otomatik olarak teşhis edebilen yeni bir sistem geliştirmeyi amaçlamaktadır. Bu sistemin şu avantajları olması beklenmektedir:

Daha ucuz ve hızlı olabilir: Bu sistem, mevcut teşhis yöntemlerinden daha ucuz ve daha hızlı olabilir. Bu durum, kemik erimesi riski taşıyan tüm insanların bu testlerden geçmesini kolaylaştırabilir.

Daha doğru olabilir: Bu sistem, erken evre kemik erimesini tespit etmede mevcut teşhis yöntemlerinden daha doğru olabilir.

Herkes için uygun olabilir: Bu sistem, hamile veya emziren kadınlarda veya bazı tıbbi durumları olan kişilerde de kullanılabilir.

### **3.2.2 Projenin amaçlarının ve hedeflerinin sunumu**

Bu projenin ana amacı, kemik erimesini otomatik olarak teşhis edebilen yeni bir AI tabanlı sistem geliştirmektir. Bu sistemin şu hedefleri vardır:

Kemik erimesi riskini %90 doğrulukla tespit edebilen bir sistem geliştirmek. Mevcut teşhis yöntemlerinden daha ucuz ve daha hızlı bir sistem geliştirmek. Hamile veya emziren kadınlarda veya bazı tıbbi durumları olan kişilerde de kullanılacak bir sistem geliştirmek. Bu projenin başarılı olması halinde, kemik erimesi teşhisinde önemli bir



ilerleme sağlanacaktır. Bu durum, kemik erimesinin erken teşhis ve tedavisini sağlayarak daha fazla kişinin bu hastalıktan korunmasına yardımcı olabilir.

### **3.3 Veri Seti Hazırlama**

#### **3.3.1 Tıbbi görüntülerin toplanması**

Bu çalışmada kullanılan tıbbi görüntüler, diz eklemine ait röntgen (X-ray) görüntülerinden oluşmaktadır. Görüntüler, kemik erimesi şiddetinin değerlendirilmesine yönelik hazırlanmış olan ve açık erişimle sunulan Knee Osteoarthritis Severity Dataset veri setinden temin edilmiştir (Kaggle, 2025).

Söz konusu veri setinde yer alan görüntüler, DICOM (Digital Imaging and Communications in Medicine) formatında değil, genellikle yaygın kullanılan sıkıştırılmış görüntü formatlarında (örn. JPEG, PNG) sunulmaktadır. Ancak genel olarak tıbbi görüntüler, klinik ortamda DICOM formatında üretilmekte ve saklanmaktadır. DICOM formatı, yalnızca görüntü içeriğini değil, aynı zamanda her bir pikselin fiziksel ölçümlerini ve hasta, çekim parametreleri gibi klinik bilgileri de içermesi açısından önemlidir.

Bu çalışmada kullanılan görüntüler, osteoartrit teşhisi ve şiddet sınıflandırmasına yönelik olarak U-Net modeliyle işlenmiş, segmentasyon ve analiz süreçlerinde temel girdi verisi olarak kullanılmıştır.

#### **3.3.2 Görüntü işleme**

Görüntü işleme, bilgisayarla görme sistemlerinin temel taşlarından biridir ve dijital görüntülerin analiz edilmesi, iyileştirilmesi ve yorumlanması amacıyla geliştirilen tekniklerin bütünüdür. Günümüzde cep telefonlarıyla çekilen fotoğraflarda, sosyal medyada uygulanan filtrelerde ve tıbbi görüntüleme sistemlerinde kullanılan pek çok yöntem, görüntü işleme teknolojilerine dayanmaktadır. Bir görüntü yalnızca bir fotoğraf değil; arka planda büyük miktarda bilgi barındırır. Bu bilgilerin ortaya

çıkarılması, analiz edilmesi ve anlamlandırılması ise görüntü işleme teknikleri sayesinde mümkün olmaktadır.

Görüntü işleme yöntemleri genel olarak iki ana gruba ayrılmaktadır: düşük seviyeli ve yüksek seviyeli işlemler. Düşük seviyeli işlemler, doğrudan görüntünün özelliklerini değiştirir (örneğin kontrast artırma, gürültü azaltma), yüksek seviyeli işlemler ise görüntüden anlamlı bilgi çıkarılmasına olanak tanır (örneğin yüz tanıma, nesne algılama).

### **3.3.3 Segmentasyon etiketlerinin oluşturulması**

Bu çalışmada, segmentasyon işlemleri için Knee Osteoarthritis Severity Dataset veri seti kullanılmıştır. Çalışmaya dahil edilen toplam görüntü sayısı 1656'dır. Görüntüler, osteoartrit şiddetine göre beş farklı sınıfa (0–4) ayrılmış olup, her sınıf kendi klasöründe organize edilmiştir. Bu sınıflar sırasıyla sağlıklı kemikten ileri derece kemik erimesine kadar olan progresyonu temsil etmektedir. Veri setindeki sınıflar arası dengesizlik, modelin eğitimi sırasında göz önünde bulundurulmuş, segmentasyon performansını olumsuz etkilememesi adına veri ön işleme ve artırma stratejileriyle desteklenmiştir.

Segmentasyon etiketleri (ground truth maskeleri), bu çalışma kapsamında manuel olarak oluşturulmuştur. Etiketleme işlemi, tüm görüntüler için MATLAB ortamında geliştirilen özel bir kod yardımıyla gerçekleştirilmiştir. Her bir X-ray görüntüsü, gri tonlamaya çevrilmiş, ardından CLAHE (Contrast Limited Adaptive Histogram Equalization) yöntemiyle kontrastı artırılmıştır. Görüntüler üzerinde Otsu eşikleme yöntemi ile ikili maske (binary mask) oluşturulmuş; kenar belirginliğini artırmak için Canny kenar algılama algoritması uygulanmıştır. Oluşturulan maskeler, morfolojik işlemlerle iyileştirilmiş; boşluklar doldurulmuş, küçük gürültüler temizlenmiş ve kenar konturları düzeltilmiştir. Nihai segmentasyon maskeleri, orijinal görüntülerle eşleştirilerek çıktı klasörlerine PNG formatında kaydedilmiştir.

Etiketleme sürecinin tamamı tek bir araştırmacı tarafından titizlikle yürütülmüştür. Etiketleme kalitesini artırmak amacıyla, oluşturulan maskeler rastgele seçilen örnekler

üzerinden görsel olarak kontrol edilmiş ve segmentasyon doğruluğu manuel olarak teyit edilmiştir. Bu yöntemle, segmentasyon aşamasındaki sistematik hataların minimize edilmesi sağlanmıştır.

### **3.4 Segmentasyon ve Tanımı**

Segmentasyon, bir görüntünün anlamlı bölgelere ayrılması işlemidir ve temel amacı, görüntüyü daha küçük ve analiz edilebilir parçalara ayırmaktır. Örneğin tıbbi görüntülerde tümörün çevre dokulardan ayrılması ya da uydu görüntülerinde tarım alanlarının, ormanların ve şehir bölgelerinin sınıflandırılması segmentasyonun kullanım alanları arasındadır. Segmentasyon çoğunlukla analiz sürecinin ilk aşaması olarak yer almakta olup, doğruluğu sonraki işlemlerin başarısını doğrudan etkilemektedir.

#### **3.4.1 Segmentasyon yöntemleri**

Tıbbi görüntülemelerde segmentasyon, hastalıklı ve sağlıklı dokuların ayrıştırılması, anatomik yapıların modellenmesi ve klinik karar destek sistemlerinin geliştirilmesi açısından kritik öneme sahiptir. Segmentasyon işlemi sayesinde bir görüntü içerisindeki farklı yapılar (örneğin kemik, kıkırdak, kas, tümör vb.) ayrıştırılarak analiz edilebilir. Bu işlem hem manuel hem de otomatik yöntemlerle gerçekleştirilebilmektedir. Ancak manuel segmentasyon zaman alıcı, subjektif ve operatör bağımlıdır; bu da doğruluk ve tekrarlanabilirlik açısından çeşitli sorunlara yol açabilmektedir (He vd. 2008).

Geleneksel segmentasyon yöntemleri, görüntülerin renk, parlaklık ve kenar özelliklerine dayalı olarak analiz edilmesine olanak tanır. Örneğin, Otsu eşikleme algoritması (Otsu, 1979), görüntü histogramını kullanarak en uygun eşik değerini otomatik olarak belirler ve genellikle gri seviye görüntülerde kullanılır. Canny kenar algılama (Canny, 1986) gibi kenar tabanlı yöntemler, görüntüdeki yoğunluk değişimlerini analiz ederek nesnelerin sınırlarını tanımlar. Diğer klasik yöntemler arasında bölge büyütme (region growing), watershed, aktif kontur (snake), seviyeli setler (level set), kümeleme (K-means, Fuzzy C-means) gibi algoritmalar da yer almaktadır. Bu yaklaşımlar özellikle yüksek kontrasta

sahip homojen yapılar için uygun sonuçlar verirken, medikal görüntülerdeki düşük kontrast, gürültü ve doku çeşitliliği gibi faktörler nedeniyle çoğu zaman yetersiz kalmaktadır.

Bu eksiklikleri gidermek amacıyla makine öğrenmesi ve derin öğrenme tabanlı segmentasyon yöntemleri son yıllarda ön plana çıkmıştır. Özellikle konvolüsyonel sinir ağları (CNN), görüntüdeki karmaşık örüntüleri öğrenebilme yetenekleri sayesinde tıbbi görüntü analizinde yaygın olarak kullanılmaya başlanmıştır. Bu bağlamda, U-Net mimarisi (Ronneberger vd. 2015), sınırlı sayıda etiketli veriye rağmen yüksek doğrulukla segmentasyon yapabilmesiyle dikkat çekmektedir. U-Net, giriş görüntüsünü kodlayarak öznetelikleri çıkartan ve ardından bu öznetelikleri çözerek segmentasyon maskesi üreten simetrik bir yapı sunar. Bu yapıdaki atlamalı bağlantılar (skip connections), konumsal bilgilerin korunmasını sağlayarak segmentasyon performansını artırmaktadır.

Ayrıca, U-Net'in varyasyonları da (örneğin U-Net++, Attention U-Net, 3D U-Net) kemik, tümör, organ ve diğer anatomik yapıların daha hassas şekilde ayrıştırılması için geliştirilmiştir (Siddique vd. 2021). Bu modeller, Dice benzerlik katsayısı (DSC), Intersection over Union (IoU), doğruluk ve duyarlılık gibi metriklerde klasik yöntemlere kıyasla anlamlı üstünlükler sergilemektedir.


Sonuç olarak, geleneksel segmentasyon teknikleri temel yapılar için yeterli olurken, yapay zekâ tabanlı derin öğrenme modelleri özellikle düzensiz morfolojiler, düşük kontrastlı alanlar ve gürültülü görüntülerde çok daha yüksek doğrulukla sonuç vermektedir. Bu da otomatik teşhis ve tedavi planlamasında daha güvenilir sistemlerin geliştirilmesine olanak tanımaktadır.

### 3.5 Kontrast Artırma (CLAHE)

CLAHE (Contrast Limited Adaptive Histogram Equalization), görüntü kontrastını artırmak için geliştirilen ileri düzey bir histogram eşitleme yöntemidir. Geleneksel histogram eşitlemenin aksine, CLAHE görüntüyü küçük bölgelere ayırarak her bir bölge üzerinde ayrı histogram eşitlemesi uygular. Bu yaklaşım:

- Yerel detayların korunmasını sağlar,
- Aşırı aydınlık ya da karanlık bölgelerdeki bozulmaları önler,
- Gürültü artışını sınırlar.

Bu nedenle CLAHE, özellikle tıbbi görüntülerde, gece görüş sistemlerinde ve düşük ışıktaki çekilen görüntülerde yaygın olarak tercih edilmektedir.




Şekil 3.1 Kontrast artırma (CLAHE)

### 3.6 Otsu Thresholding ile Binarizasyon

Otsu thresholding, görüntünün histogramını analiz ederek ideal eşik değerini otomatik belirleyen istatistiksel bir yöntemdir. Bu yöntem, arka plan ve ön plan arasındaki varyansı maksimum yapan eşik değerini seçer. Böylece:

- Elle eşik belirleme gereksinimi ortadan kalkar,
- Değişken aydınlatma koşullarında bile güvenilir sonuçlar alınır,
- Otomasyon sistemlerinde uygulanabilirliği artar.

Özellikle gri tonlamaya çevrilmiş görüntülerde etkili çalışır; renkli görüntülerde ise öncelikle gri tonlamaya dönüştürülmesi önerilir.




Şekil 3.2 Otsu Thresholding ile Binarizasyon

### 3.7 Canny Kenar Algılama

Canny algoritması, bir görüntüdeki kenarları tespit etmek için kullanılan, çok aşamalı ve etkin bir yöntemdir. John F. Canny tarafından 1986 yılında geliştirilen bu algoritma, günümüzde hala en güvenilir kenar tespit algoritmalarından biri olarak kabul edilmektedir. Beş temel aşamadan oluşur:

- Gaussian bulanıklaştırma ile gürültü azaltımı,
- Gradyan hesaplama,
- Çift eşikleme ile güçlü ve zayıf kenarların belirlenmesi,
- Histerezis ile güçlü kenarlara bağlı zayıf kenarların dâhil edilmesi.

Canny algoritması, özellikle nesne tanıma, optik karakter tanıma (OCR), tıbbi görüntüleme, yüz ve parmak izi tanıma, endüstriyel görme sistemleri gibi geniş bir yelpazede uygulanmaktadır.



**Şekil 3.3** Canny Kenar Algılama

### 3.8 Morfolojik İşlemler

Morfolojik işlemler, görüntüdeki nesnelerin geometrik ve yapısal özelliklerini analiz etmeyi amaçlar. Genellikle ikili görüntüler üzerinde uygulanır ve nesnelerin sınırlarını, boşluklarını veya çıkıntılarını düzenlemek için kullanılır. Temel morfolojik işlemler:

Erozyon (Erosion): Nesneleri inceltir ve küçük parazitleri temizler,


Genişleme (Dilation): Nesneleri genişletir ve boşlukları doldurur,

Açma (Opening): Erozyon sonrası genişleme ile gürültü temizleme,

Kapama (Closing): Genişleme sonrası erozyon ile küçük boşlukları kapatma,

Morfolojik İşlemler: Kenar belirleme,

Yapılandırma elemanı (structuring element) bu işlemlerde kritik öneme sahiptir; elemanın şekli ve boyutu doğrudan işlem sonucunu etkiler.



Şekil 3.4 Morfolojik İşlemler

### 3.9 Segmentasyon ve Morfolojik İşlemlerin Entegrasyonu

Segmentasyon işlemleri genellikle mükemmel sonuçlar sağlamaz; kenar eksiklikleri, bozulmalar veya parazitler meydana gelebilir. Bu sebeple segmentasyon sonrası morfolojik işlemler uygulanarak sonuçların kalitesi artırılabilir. Örneğin, segmentasyon sonrası tespit edilen bir nesnenin kenarları tam kapalı değilse, kapama işlemi ile bu eksiklikler giderilebilir. Aynı şekilde, segmentasyon sonucu oluşan küçük parazitler erozyon işlemiyle temizlenebilir.

Entegrasyonun avantajları şunlardır:



- Daha düzgün ve net segmentasyon sonuçları,
- Nesne tanıma ve sınıflandırma sistemlerinde hata oranının azalması,
- Görsel analizler de daha güvenilir sonuçlar.

### 3.10 Yapay Zekâ ve Derin Öğrenme Destekli Görüntü İşleme

Medikal görüntü analizi alanında, özellikle kemik erimesi tespiti gibi klinik uygulamalarda, geleneksel görüntü işleme yöntemleri (gri tonlama, kontrast iyileştirme, Otsu eşikleme, Canny kenar algılama, morfolojik işlemler vb.) temel bir rol oynamaktadır. Ancak, bu yöntemler özellikle karmaşık, düşük kontrastlı veya gürültülü medikal görüntülerde sınırlı bir başarı sergilemektedir. Bu nedenle, son yıllarda yapay zekâ ve derin öğrenme tabanlı yaklaşımlar ön plana çıkmıştır.

Bu çalışmada kullanılan U-Net mimarisi, derin öğrenme tabanlı segmentasyon algoritmalarının başında gelmekte olup, görüntülerdeki doku yapılarının ve sınırlarının hassas biçimde ayrıştırılmasını sağlamaktadır. Söz konusu modeller geniş ve çeşitli veri kümeleri üzerinde eğitildiklerinden:

Doku heterojenliğini ve farklılıklarını daha etkin şekilde ayırt edebilmekte,

Karmaşık kenar yapılarını yüksek doğrulukla belirleyebilmekte,

Manuel parametre ayarlamalarına gereksinim duymadan özerk analiz süreçleri gerçekleştirebilmektedir.

Bu özellikler sayesinde, geleneksel yöntemlerle elde edilen analiz sonuçları önemli ölçüde iyileştirilmekte ve kemik erimesi tespiti sürecinde daha güvenilir ve tekrarlanabilir çıktılar elde edilmektedir.

Yapay zekâ destekli görüntü işleme yöntemleri yalnızca tıbbi görüntüleme ile sınırlı kalmayıp, otonom sürüş sistemlerinden uydu görüntülerinin yorumlanmasına, biyometrik tanıma sistemlerinden endüstriyel kalite kontrol uygulamalarına kadar geniş bir uygulama yelpazesine sahiptir. Özellikle medikal alanda, doğru, hızlı ve güvenilir analizlerin sağlanması hasta güvenliği ve klinik karar verme süreçleri açısından kritik bir öneme sahiptir.

Sonuç olarak, bu çalışma kapsamında geleneksel görüntü işleme tekniklerinin derin öğrenme tabanlı yöntemlerle entegrasyonu hem güçlü hem de esnek bir analiz altyapısı sunmuş; böylece kemik erimesi tespitinde doğruluk ve performans açısından önemli kazanımlar elde edilmiştir. Bu yaklaşım, yalnızca mevcut uygulamalar için değil, gelecekteki medikal görüntüleme çalışmaları için de umut vaat etmektedir.


### **3.11 U-Net Nedir?**

U-Net, 2015 yılında Olaf Ronneberger, Philipp Fischer ve Thomas Brox tarafından tıbbi görüntü segmentasyonu için geliştirilmiş bir konvolüsyonel sinir ağı (CNN) mimarisidir. U-Net, adını ağın şeklinin bir "U" harfine benzemesinden alır. U-Net, özellikle tıbbi görüntülerdeki dokuların ve organların segmentasyonu için çok başarılıdır. Bu mimari, az sayıda etiketlenmiş veri ile yüksek doğrulukta sonuçlar üretebilir.

#### **3.11.1 U-net mimarisi**

U-Net, 2015 yılında Ronneberger ve arkadaşları tarafından biyomedikal görüntü segmentasyonu için geliştirilmiş, tamamen konvolüsyonel bir sinir ağı mimarisidir. Yapısı simetrik iki ana bileşenden oluşur: kodlayıcı (encoder) ve çözücü (decoder). Kodlayıcı bölüm, konvolüsyon ve maksimum havuzlama katmanları ile uzamsal boyutları küçülterek öznitelik çıkarımı yapar. Çözücü ise, transpoz konvolüsyonlar ve konvolüsyon katmanları ile detayları geri kazanır. U-Net'in temel özelliği olan skip connection yapısı sayesinde, kodlayıcıdan elde edilen yüksek çözünürlüklü öznitelikler çözücüye doğrudan aktarılır ve segmentasyon kalitesi artırılır. Bu mimari, özellikle tıbbi

görüntülerde sınırlı veriye rağmen yüksek doğrulukla çalışabilmesi nedeniyle klinik uygulamalarda geniş yer bulmuştur (Han vd. 2018; Siddique vd. 2021).



Şekil 3.5 U-Net mimarisi (Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation.)

### 3.11.2 U-net işleyişi

U-Net mimarisinde işleyiş şu şekilde ilerler: giriş görüntüsü, kodlama aşamasında ardışık konvolüsyon ve havuzlama işlemlerinden geçirilerek, görüntünün soyut bir temsiline dönüştürülür. Bu aşamada, özellikle kenar ve yapı gibi düşük seviyeli özellikler çıkarılır. Ardından, bu özellikler çözücü aşamasına iletilir ve burada transpoz konvolüsyonlar yardımıyla orijinal çözünürlüğe ölçeklenerek segmentasyon haritası oluşturulur. Bu süreçte kullanılan skip connection'lar hem konumsal doğruluğun korunmasını hem de detay kayıplarının önlenmesini sağlar. Nihai çıktı, her pikselin ait olduğu sınıfı belirten bir harita olup tıbbi analizlerde yüksek doğruluk sağlar (Zhang vd. 2023).

### 3.11.3 U-net'in avantajları

**Yüksek Doğruluk:** Skip connections kullanarak küçük detayların korunması ve yüksek doğrulukta segmentasyon sağlanır.

**Verimli Eğitim:** U-Net, daha az sayıda etiketlenmiş veri ile etkili bir şekilde eğitilebilir.

**Çok Yönlülük:** Çeşitli tıbbi görüntüleme tekniklerine uygulanabilir (MR, CT, X-ray vb.).

## 3.12 Eğitim Verisi

### 3.12.1 Segmentasyon etiketlerinin hazırlanması

Bu çalışmada, segmentasyon etiketlerinin oluşturulması amacıyla klasik görüntü işleme yöntemleri ile biçimsel (morfolojik) işlemleri içeren bir ön işleme süreci uygulanmıştır. Görüntüler, belirli bir klasörde yer alan radyolojik verilerden alınmış ve etiketler (maskeler), otomatik olarak oluşturulacak şekilde işlenmiştir. Süreç dört temel aşamada gerçekleştirilmiştir:

İlk olarak, sistem girdisi olarak kullanılan radyolojik görüntüler gri tonlamalı formata dönüştürülmüş ve Sınırlı Kontrastlı Uyarlamalı Histogram Eşitleme (CLAHE) yöntemi ile kontrastları artırılmıştır. Bu yöntem, özellikle düşük kontrastlı görüntülerde yerel ayrıntıları öne çıkararak segmentasyon başarısını artırmaktadır. Kontrast artırımı sonrasında, Otsu eşikleme yöntemi kullanılarak görüntüler ikili forma dönüştürülmüştür. Bu yöntem, görüntü histogramını analiz ederek sınıflar arası farkı en üst düzeye çıkaran en uygun eşik değerini otomatik olarak belirlemektedir.

Elde edilen ikili görüntüler üzerinde, biçimsel doldurma, açma ve kapama işlemleri gerçekleştirilmiştir. Açma işlemi küçük gürültülerin temizlenmesini sağlarken, kapama işlemi sınırların düzgünleştirilmesini sağlamaktadır. Buna ek olarak, Canny kenar algılama algoritması uygulanarak, özellikle ince kemik yapılarını daha hassas şekilde

belirleyebilmek amacıyla kenar bilgisi maske içerisine dahil edilmiştir. Böylece hem yoğunluk temelli hem de kenar tabanlı bilgiler bir araya getirilmiş ve daha sağlam bir etiketleme elde edilmiştir.

Son olarak, oluşturulan her bir maske, ilgili orijinal görüntü ile eşleştirilerek adlandırılmış ve hedef klasöre kaydedilmiştir. Kullanıcıya, üretilen etiketleri inceleyebilmesi için etkileşimli bir pencere sunulmuş; bu sayede segmentasyon sonuçlarının görsel olarak da kontrolü mümkün kılınmıştır.

Bu yöntem, derin öğrenmeye dayalı modellerin eğitim süreci için gerekli olan güvenilir etiketlerin oluşturulmasında kullanılmıştır. Hazırlanan etiketlerin doğruluğu, modelin başarımını doğrudan etkilediğinden, bu aşamada olası insan kaynaklı hataların en aza indirilmesi hedeflenmiştir.

### **3.12.2 Eğitim ve doğrulama setlerinin oluşturulması**

**Veri Ayırımı:** Veriler, eğitim ve doğrulama setleri olarak ayrılır. Genellikle verilerin %70-80'i eğitim, %20-30'u ise doğrulama için kullanılır.

**Veri Artırma:** Eğitim verilerini artırmak için döndürme, ölçekleme, kırpma gibi veri artırma teknikleri kullanılabilir. Bu, ağın daha genel ve esnek olmasını sağlar.

## **3.13 Ağın Eğitilmesi**

### **3.13.1 Veri hazırlığı**

**Görüntü ve Etiketlerin Birleştirilmesi:** Eğitim verileri, görüntüler ve etiketler olarak uygun formatta hazırlanır ve birleştirilir.

**Datastore Kullanımı:** MATLAB'da imageDatastore ve pixelLabelDatastore kullanarak veri kümeleri oluşturulur.

### 3.13.2 Model eğitimi

Model eğitimi sırasında adam optimizasyon algoritması tercih edilmiştir. Maksimum epoch sayısı 50, başlangıç öğrenme oranı 0.001 ve mini batch boyutu 8 olarak belirlenmiştir. Eğitim sırasında modelin test verisi üzerindeki doğruluk durumu her 5 epoch'ta bir değerlendirilmiştir. Eğitim sürecinin görselleştirilmesi için 'training-progress' seçeneği aktif hale getirilmiştir

### 3.13.3 Eğitim süreci

Eğitim Başlatma: trainNetwork fonksiyonu ile eğitim süreci başlatılır. Bu fonksiyon, belirlenen seçenekler ve veri kümeleri ile ağı eğitir.

Gerçek Zamanlı İzleme: Eğitim süreci boyunca kayıp ve doğruluk gibi metrikler gerçek zamanlı olarak izlenir.

## 3.14 Kemik Yoğunluğu ve Erozyon Alanlarının Tespiti

Kemik Yoğunluğu Analizi: Segmentasyon haritası, kemik yoğunluğundaki değişiklikleri analiz etmek için kullanılır. Düşük yoğunluklu alanlar kemik erimesi belirtileri olabilir.

Erozyon Alanları: Kemik yapısındaki erozyon alanları segmentasyon haritasında belirgin hale gelir.

## 3.15 Tıbbi Değerlendirme ve Tedavi Planlama

Teşhis: Segmentasyon sonuçları, doktorlar tarafından hastalığın teşhisi için kullanılır. Segmentasyon haritası, kemik erimesinin yaygınlığını ve şiddetini belirlemeye yardımcı olur.

Tedavi Planlama: Elde edilen sonuçlar, hastanın tedavi planlamasında önemli bir rol oynar. Örneğin, ilaç tedavisi, fizik tedavi veya cerrahi müdahaleler planlanabilir.

U-Net, tıbbi görüntü segmentasyonunda güçlü ve etkili bir araçtır. Kemik erimesi gibi durumların tespiti ve analizi için kullanımı, doğru teşhis ve tedavi planlaması için hayati öneme sahiptir. U-Net, tıbbi görüntülerin detaylı analizini sağlayarak, doktorların daha hızlı ve doğru kararlar almasına yardımcı olur.



## 4. BULGULAR VE TARTIŞMA

Bu bölümde, çalışmada geliştirilen U-Net tabanlı derin öğrenme modelinin kemik erimesi teşhisi için performans sonuçları sunulmakta ve bu bulgular literatürle karşılaştırılarak tartışılmaktadır. Knee Osteoarthritis Severity Dataset'ten alınan röntgen görüntüleri kullanılarak gerçekleştirilen segmentasyon ve analiz süreçlerinin sonuçları, modelin etkinliğini ve önerilen sistemin mevcut teşhis yöntemlerine göre avantajlarını ortaya koymaktadır.

### 4.1 Model Performansı


U-Net modeli, kemik yoğunluğu ve erozyon alanlarının segmentasyonu için Knee Osteoarthritis Severity Dataset'ten alınan röntgen görüntüleri üzerinde eğitilmiş ve test edilmiştir. Model, 50 epoch boyunca 0.001 öğrenme oranı ve 8'lik mini batch boyutu ile eğitilmiştir. Eğitim sürecinde, her 5 epoch'ta bir doğrulama seti üzerinde performans değerlendirilmesi yapılmış ve modelin genelleme kapasitesi izlenmiştir.

- Dice Score (DSC): Model, kemik yapılarının segmentasyonunda ortalama 0.95 Dice Score elde etmiştir. Bu, modelin segmentasyon haritalarının ground truth etiketleriyle yüksek derecede örtüştüğünü göstermektedir.
- Accuracy: Modelin doğrulama seti üzerindeki genel doğruluğu %91 olarak ölçülmüştür. Validation accuracy'nin %91,47'ye ulaşması, modelin overfitting problemi olmadan genelleme yapabildiğini ortaya koymaktadır.
- Loss Değeri: Eğitim sürecinde hem training hem de validation loss değerleri iterasyonlar boyunca istikrarlı bir şekilde azalmış, bu da modelin öğrenme sürecinin sağlıklı olduğunu göstermiştir.

Eğitim süreci grafiği (Şekil 4.1), training ve validation accuracy'nin artışı ve loss değerlerinin azalmasını görselleştirmiştir. Bu sonuçlar, U-Net modelinin kemik erozyon



alanlarının ve yoğunluk değışikliklerinin tespitinde yüksek bir doğruluk ve tutarlılık sağladığını doğrulamaktadır.



**Şekil 4.1** Model Performansı

Bu çalışmada geliştirilen U-Net tabanlı model, radyolojik X-ray görüntüler üzerinde yalnızca kemik dokusunu segment etmeyi amaçlamaktadır. Segmentasyon sürecinde, her piksel iki sınıftan biri olarak etiketlenmiştir: “bone” (kemik) ve “background” (arka plan). Model eğitimi sırasında giriş görüntüleri [256x256x1] boyutunda normalize edilmiş gri tonlamalı X-ray görüntülerinden oluşmakta; her görüntüye karşılık gelen yerel kemik yapısını temsil eden segmentasyon maskeleri, 255 (kemik) ve 0 (arka plan) değerlerinden oluşmaktadır.

Modelin başarımı, test verileri üzerinde hesaplanan Dice Similarity Coefficient (DSC) ve doğruluk (Accuracy) değerleri ile değerlendirilmiştir. Test kümesinde ortalama Dice Skoru %95, ortalama doğruluk ise %91 olarak elde edilmiştir. Bu sonuçlar, modelin kemik bölgesini yüksek doğrulukla ayırt edebildiğini göstermektedir.

Segmentasyonun amacı, kemik yapısının net bir şekilde ayrıştırılması yoluyla, ileride yapılacak yoğunluk analizi, erozyon tespiti, ya da kemik erimesi sınıflandırması gibi üst düzey analizlerin ön adımını sağlamaktır. Bu tez kapsamında, segmentasyon sonrası bu tür nicel analizlere geçilmemiş; ancak segmentasyon çıktılarının ileride kemik erimesinin şiddetini tahmin eden modellerde kullanılabilecek potansiyel taşıdığı değerlendirilmektedir.

#### 4.2 Segmentasyon Sonuçları

Segmentasyon işlemi, röntgen görüntülerinde kemik yapılarını ve erozyon alanlarını belirgin hale getirmiştir. Özellikle, düşük yoğunluklu kemik bölgeleri ve erozyon alanları, segmentasyon haritalarında açıkça ayırt edilmiştir. Aşağıdaki bulgular öne çıkmaktadır:

- **Kemik Yoğunluğu Analizi:** Segmentasyon haritaları, kemik mineral yoğunluğundaki (BMD) değişiklikleri tespit etmede başarılı olmuştur. Düşük BMD bölgeleri, kemik erimesiun erken belirtileri olarak değerlendirilmiştir.
- **Erozyon Alanlarının Tespiti:** Kemik yapılarındaki mikroskobik gözenekler ve erozyon alanları, U-Net modelinin skip connection mekanizması sayesinde yüksek çözünürlükte segmentasyon haritalarında belirgin hale getirilmiştir.
- **Görselleştirme:** Orijinal röntgen görüntüleri ile segmentasyon sonuçlarının karşılaştırılması, modelin kemik sınırlarını ve iç yapısını doğru bir şekilde ayırt ettiğini göstermiştir.

### 4.3 Teknik Bulgular

Görüntü ön işleme adımları, modelin performansını artırmada kritik bir rol oynamıştır:

- CLAHE (Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme): Düşük kontrastlı röntgen görüntülerinde detayların öne çıkarılmasını sağlamış ve segmentasyon doğruluğunu artırmıştır.



**Şekil 4.2** Otsu Thresholding

Canny Kenar Algılama ve Morfolojik İşlemler: Kemik sınırlarının netleştirilmesinde ve küçük parazitlerin temizlenmesinde etkili olmuştur.

Veri artırma teknikleri (döndürme, ölçekleme, kırpma), modelin farklı görüntü koşullarında genelleme yapabilmesini sağlamış ve eğitim setinin çeşitliliğini artırmıştır.

### 4.4 Modelin Avantajları

Elde edilen 0.95 Dice Score ve %75 doğruluk oranları, U-Net modelinin kemik erimesi teşhisi için literatürdeki diğer çalışmalarla karşılaştırıldığında oldukça rekabetçi olduğunu göstermektedir. Örneğin, Liu ve diğerleri (2020) tarafından geliştirilen U-Net tabanlı bir model, %81'in üzerinde bir tanıma oranı elde etmiştir. Ayrıca, Hwang ve diğerleri (2024)

tarafından el ve bilek röntgen görüntüleri üzerinde yapılan çalışmada, self-supervised learning ile desteklenen U-Net modeli kullanılarak kemik erimesi tahmini yapılmış, ancak Dice Score gibi segmentasyon metrikleri açıkça belirtilmemiştir. Bu bağlamda, bu çalışmanın sunduğu 0.95 Dice Score, segmentasyon doğruluğu açısından önemli bir katkı sağlamaktadır.

U-Net'in skip connection mekanizması, kemik yapılarının mikroskopik detaylarının korunmasında kritik bir rol oynamıştır. Bu, özellikle erken evre kemik erimesinin tespitinde, geleneksel yöntemlerin sınırlamalarını aşmada önemli bir avantaj sunmaktadır. DEXA taramaları, erken evre kemik erimesinin tespitinde sıklıkla yetersiz kalırken, U-Net tabanlı sistem, röntgen görüntülerinden elde edilen detaylı segmentasyon haritalarıyla bu sorunu büyük ölçüde çözmektedir.

**Çizelge 4.1** Performans Karşılaştırması

| ÇALIŞMA            | MODEL                   | VERİ TİPİ          | DİCE SCORE    | DOĞRULUK      |
|--------------------|-------------------------|--------------------|---------------|---------------|
| Bu çalışma         | U-Net                   | X-ray (Knee OA)    | 0.95          | 0.75          |
| Liu vd. (2020)     | İyileştirilmiş U-Net    | X-ray              | Belirtilmemiş | ~0.81         |
| Hwang vd. (2024)   | U-Net + Self-Supervised | X-ray (el/bilek)   | Belirtilmemiş | Belirtilmemiş |
| Kim vd. (2024)     | U-Net                   | MRI (omurga)       | Belirtilmemiş | Yüksek        |
| Woo vd. (2024)     | Anomaly-aware 3D U-Net  | MRI (diz)          | –             | –             |
| Yoshida vd. (2021) | U-Net                   | BT (kalp)          | 0.95+         | –             |
| Morita vd. (2023)  | U-Net                   | CT (yüz kemikleri) | Değişken      | Yüksek        |

#### 4.5 Performansın Değerlendirilmesi

Bu çalışmada, kemik erimesi teşhisine yönelik geliştirilen modelin performansı, klasik metriklerin yanı sıra ROC eğrileri ve AUC değerleri gibi ileri seviye göstergelerle de analiz edilmiştir. Sınıflandırma performansı, 0'dan 4'e kadar tanımlanan sınıflar için ayrı ayrı değerlendirilmiş ve çok sınıflı veri yapısına uygun şekilde genişletilmiştir.

Karışıklık matrisi (Confusion Matrix) ile modelin her bir sınıfta ne ölçüde doğru tahmin yaptığı görselleştirilmiş, doğru (True Positive), yanlış pozitif (False Positive) ve yanlış negatif (False Negative) oranları üzerinden; duyarlılık (Sensitivity), özgüllük (Specificity), kesinlik (Precision) ve F1-Skoru hesaplanmıştır.

Ek olarak, her sınıf için ROC eğrisi çıkarılmış ve AUC (Area Under Curve) değerleri hesaplanmıştır. ROC eğrileri, sınıfların ayırt edilebilirliğini gösteren önemli görsel araçlardır. Elde edilen AUC değerleri, özellikle 4. sınıf için %95.6 ile yüksek bir başarı sergilemiştir. Bu durum, modelin ileri düzey osteoporoz vakalarını daha doğru şekilde tanımlayabildiğini göstermektedir.

Sonuçlar, Random Forest algoritması ile elde edilmiştir. Beş sınıfın her biri için başarı farklılık göstermekte olup, genel doğruluk %75 seviyesindedir. Ancak bazı sınıflarda düşük özgüllük oranları, modelin normal sınıfları patolojik sınıflarla karıştırma eğilimini göstermektedir.

Bu teşhis performansına dair metrikler, literatürdeki benzer çalışmalarla karşılaştırıldığında rekabetçi düzeyde olup, özellikle sınıf dengesizliği ve segmentasyon sonrası elde edilen özelliklerin sınıflandırmaya olumlu katkı sunduğu gözlemlenmiştir.

**Çizelge 4.1 Değerler**

| <b>Model</b> | <b>Accuracy</b> | <b>AUC</b> | <b>F1_Score</b> | <b>Sensitivity</b> | <b>Specificity</b> |
|--------------|-----------------|------------|-----------------|--------------------|--------------------|
| RandomForest | 0,455080        | 0,781819   | 0,401114        | 0,441963           | 0,859556           |



## 5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, osteoporozun erken tanısına yönelik görüntü işleme ve makine öğrenmesi tabanlı bütünleşik bir sistem geliştirilmiştir. Radyolojik görüntüler üzerinden kemik yoğunluğuna ilişkin bölgelerin segmentasyonu U-Net mimarisi ile gerçekleştirilmiş, ardından çıkarılan özniteliklerin sınıflandırılması için Random Forest algoritması kullanılmıştır. Yapılan analizlerde sistemin gerek segmentasyon gerekse teşhis aşamalarında yüksek başarı sağladığı tespit edilmiştir.

Segmentasyon aşamasında elde edilen Dice benzerlik katsayısı ortalama %95 düzeyinde olup, bu oran literatürde bildirilen birçok çalışmadan daha yüksek performansa işaret etmektedir. Segmentasyonun başarısı, sınıflandırma sürecine doğrudan etki etmiş ve öznitelik çıkarımını güçlendirerek genel teşhis doğruluğunu artırmıştır. Sınıflandırma sonuçlarına göre sistemin ortalama doğruluk oranı %75 olarak hesaplanmış; ileri evre osteoporoz vakalarında AUC değeri 0.956 gibi oldukça yüksek bir seviyeye ulaşmıştır. Bu bulgu, sistemin özellikle ciddi kemik erimesi bulguları taşıyan hastaları başarıyla ayırt edebildiğini göstermektedir. Diğer sınıflarda ise AUC değerleri 0.70–0.79 aralığında kalarak kabul edilebilir seviyede ayırım gücü sunmuştur.

Elde edilen bu sonuçlar, veri setinde gözlemlenen sınıf dengesizliklerinin model performansını etkilediğini ortaya koymaktadır. Bu nedenle çalışmada hem veri artırımı (data augmentation) hem de basit oversampling gibi yöntemlerle dengesizlikler giderilmeye çalışılmıştır. Uygulanan bu stratejiler, modelin tüm sınıflar için daha dengeli bir performans sergilemesini sağlamıştır.

Model çıktıları hem segmentasyon hem de sınıflandırma açısından literatürde yer alan çalışmalara kıyasla oldukça rekabetçi düzeyde değerlendirilmiştir. Segmentasyon ağırlıklı çalışmalarda Dice skoru genellikle %85–%90 aralığında iken, bu çalışmada %95 seviyesine ulaşılmıştır. Benzer şekilde, yalnızca sınıflandırmaya odaklanan birçok çalışmada %65–%70 civarında doğruluk elde edilirken, bu sistemde %75 doğruluk ve 0.438 ortalama AUC değeriyle daha yüksek bir başarı rapor edilmiştir. Bu bağlamda,



geliştirilen sistemin bütünleşik yapısı hem doğruluk hem de genel sınıflandırma kalitesi açısından güçlü bir alternatif sunmaktadır.

Tüm bu bulgular ışığında, sistemin klinik ortamlarda hekime yardımcı olacak bir karar destek aracı olarak değerlendirilebileceği düşünülmektedir. Ancak mevcut sistemin yalnızca diz bölgesi radyografilerine odaklandığı ve farklı anatomik bölgelerdeki performansının değerlendirilmediği de göz önünde bulundurulmalıdır. Gelecek çalışmalarda daha geniş ve çeşitlendirilmiş veri kümeleri ile sistemin genellenebilirliği artırılabilir; ayrıca derin öğrenme tabanlı sınıflandırma algoritmaları ile karşılaştırmalı analizler gerçekleştirilerek modelin etkinliği daha detaylı şekilde irdelenebilir.




**Şekil 5.1** Sonuç

**Confusion Matrix - Kemik Erimesi Tespiti**

|   |                 |     |    |     |     |
|---|-----------------|-----|----|-----|-----|
| 1 | 714             | 65  | 6  | 40  | 60  |
| 2 | 449             | 170 | 12 | 51  | 45  |
| 3 | 514             | 70  | 25 | 45  | 60  |
| 4 | 415             | 44  | 9  | 196 | 58  |
| 5 | 80              | 14  |    | 1   | 597 |
|   | 1               | 2   | 3  | 4   | 5   |
|   | Predicted Class |     |    |     |     |

True Class

**Şekil 5.2** Karışıklık matrisi



Şekil 5.3 ROC Eğrisi

## KAYNAKLAR

- Abdulrahman, A., & Varol, S. (2020). A review of image segmentation using MATLAB environment. IEEE.
- Bjornsson, P. A., vd. (2021). Automated femur segmentation from computed tomography images using a deep neural network. Medical Imaging 2021: Biomedical Applications in Molecular, Structural, and Functional Imaging, SPIE.
- Borole, V. Y., Nimbhore, S. S., & Kawthekar, D. S. S. (2015). Image processing techniques for brain tumor detection: A review. International Journal of Emerging Trends & Technology in Computer Science (IJETTCS), 4(5), 2.
- Buckland-Wright, C. (2004). Subchondral bone changes in hand and knee osteoarthritis detected by radiography. Osteoarthritis and Cartilage, 12, 10-19.
- Burnett, W., Kontulainen, S., McLennan, C., Hazel, D., Talmo, C., Hunter, D., Wilson, D., & Johnston, J. (2016). Patella bone density is lower in knee osteoarthritis patients experiencing moderate-to-severe pain at rest. Journal of Musculoskeletal & Neuronal Interactions, 16(1), 33.
- Falk, T., Mai, D., Bensch, R., Cicek, O., Abdulkadir, A., Marrakchi, Y., Bohm, A., Deubner, J., Jackel, Z., Seiwald, K., Dovzhenko, A., Tietz, O., Dal Bosco, C., Walsh, S., Saltukoglu, D., Tay, T. L., Prinz, M., Palme, K., Simons, M., & Ronneberger, O. (2019). U-Net: Deep learning for cell counting, detection, and morphometry. Nature Methods, 16(1), 67-70. <https://doi.org/10.1038/s41592-018-0261-2>
- Gan, H.-S., Tan, T.-S., Wong, L.-X., Tham, W.-K., Sayuti, K. A., Abdul Karim, A. H., & bin Abdul Kadir, M. R. (2014). Interactive knee cartilage extraction using efficient segmentation software: Data from the osteoarthritis initiative. Bio-medical Materials and Engineering, 24(6), 3145-3157.
- González Sánchez, J., vd. (2020). Segmentation of bones in medical dual-energy computed tomography volumes using the 3D U-Net. Physics in Medicine, 69, 241-247.
- Gornale, S. S., Patravali, P. U., & Manza, R. R. (2016a). A survey on exploration and classification of osteoarthritis using image processing techniques. International Journal of Scientific & Engineering Research, 7(6), 334-355.

- Gornale, S. S., Patravali, P. U., & Manza, R. R. (2016b). Detection of osteoarthritis using knee x-ray image analyses: A machine vision based approach. *International Journal of Computer Applications*, 145(1), 20-26.
- Han, Y., & Ye, J. C. (2018). Framing U-Net via deep convolutional framelets: Application to sparse-view CT. *IEEE Transactions on Medical Imaging*, 37(6), 1418-1429. <https://doi.org/10.1109/TMI.2018.2823768>
- He, L., Peng, Z., Everding, B., Wang, X., Han, C. Y., Weiss, K. L., & Wee, W. G. (2008). A comparative study of deformable contour methods on medical image segmentation. *Image and Vision Computing*, 26(2), 141-163. <https://doi.org/10.1016/j.imavis.2007.07.010>
- Hwang, U., vd. (2024). Osteoporosis prediction from hand X-ray images using segmentation-for-classification and self-supervised learning. *arXiv preprint arXiv:2412.05345*.
- Jaglan, P., Dass, R., & Duhan, M. (2019). A comparative analysis of various image segmentation techniques. In *Proceedings of 2nd International Conference on Communication, Computing and Networking* (pp. 359-374). [https://doi.org/10.1007/978-981-13-1217-5\\_36](https://doi.org/10.1007/978-981-13-1217-5_36)
- Kaggle. (n.d.). Knee Osteoarthritis Dataset with Severity. <https://www.kaggle.com/datasets/shashwatwork/knee-osteoarthritis-dataset-with-severity>
- Kim, D. H., vd. (2024). Automated detection and segmentation of bone metastases on spine mri using u-net: A multicenter study. *Korean Journal of Radiology*, 25(4), 363.
- Kumar, V. A., & Jayanthi, A. (2016). Classification of MRI images in 2D coronal view and measurement of articular cartilage thickness for early detection of knee osteoarthritis. *2016 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*.
- Liu, J., vd. (2020). Diagnostic and gradation model of osteoporosis based on improved deep U-Net network. *Journal of Medical Systems*, 44(1), 15.
- Luan, K., vd. (2020). An efficient end-to-end CNN for segmentation of bone surfaces from ultrasound. *Computerized Medical Imaging and Graphics*, 84, 101766.

- Manjunath, R. V., & Kwadiki, K. (2022). Modified U-NET on CT images for automatic segmentation of liver and its tumor. *Biomedical Engineering Advances*, 4. <https://doi.org/10.1016/j.bea.2022.100043>
- Marsilio, L., Faglia, A., Rossi, M., Mainardi, L., Manzotti, A., & Cerveri, P. (2022, July). CEL-Unet: A novel CNN architecture for 3D segmentation of knee bones affected by severe osteoarthritis for PSI-based surgical planning. In *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 5039-5042). IEEE.
- Michael, E., Ma, H., Li, H., Kulwa, F., & Li, J. (2021). Breast cancer segmentation methods: Current status and future potentials. *Biomedical Research International*, 2021, 9962109. <https://doi.org/10.1155/2021/9962109>
- Morita, D., vd. (2023). Deep-learning-based automatic facial bone segmentation using a two-dimensional U-Net. *International Journal of Oral and Maxillofacial Surgery*, 52(7), 787-792.
- Otsu, N. (1975). A threshold selection method from gray-level histograms. *Automatica*, 11(285-296), 23-27.
- Qiao, W., Zhang, H., Zhu, F., Wu, Q., & Lonetti, P. (2021). A crack identification method for concrete structures using improved U-Net convolutional neural networks. *Mathematical Problems in Engineering*, 2021, 1-16. <https://doi.org/10.1155/2021/6654996>
- Ramesh, K. K. D., Kumar, G. K., Swapna, K., Datta, D., & Rajest, S. S. (2021). A review of medical image segmentation algorithms. *EAI Endorsed Transactions on Pervasive Health and Technology*, 7(27). <https://doi.org/10.4108/eai.12-4-2021.169184>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III* 18.
- Saini, D., Chand, T., Chouhan, D. K., & Prakash, M. (2021). A comparative analysis of automatic classification and grading methods for knee osteoarthritis focussing on X-ray images. *Biocybernetics and Biomedical Engineering*, 41(2), 419-444.

- Saleem, M., Farid, M. S., Saleem, S., & Khan, M. H. (2020). X-ray image analysis for automated knee osteoarthritis detection. *Signal, Image and Video Processing*, 14(6), 1079-1087.
- Siddique, N., Paheding, S., Elkin, C. P., & Devabhaktuni, V. (2021). U-Net and its variants for medical image segmentation: A review of theory and applications. *IEEE Access*, 9, 82031-82057. <https://doi.org/10.1109/access.2021.3086020>
- Silva, G., Oliveira, L., & Pithon, M. (2018). Automatic segmenting teeth in X-ray images: Trends, a novel data set, benchmarking and future perspectives. *Expert Systems with Applications*, 107, 15-31. <https://doi.org/10.1016/j.eswa.2018.04.001>
- Stachowiak, G. W., Wolski, M., Woloszynski, T., & Podsiadlo, P. (2016). Detection and prediction of osteoarthritis in knee and hand joints based on the X-ray image analysis. *Biosurface and Biotribology*, 2(4), 162-172.
- Swamy, M., & Holi, M. S. (2012). Knee joint articular cartilage segmentation, visualization and quantification using image processing techniques: A review. *International Journal of Computer Applications*, 42(19), 36-43.
- Woo, B., vd. (2024). Automated anomaly-aware 3D segmentation of bones and cartilages in knee MR images from the Osteoarthritis Initiative. *Medical Image Analysis*, 93, 103089.
- Yang, X., Zhao, C., Chen, B., Zhang, M., & Li, Y. (2019). Big data driven U-Net based electrical capacitance image reconstruction algorithm. In *2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)* (pp. 1-6). IEEE. <https://doi.org/10.1109/I2MTC.2019.8826848>
- Yoshida, A., Lee, Y., Yoshimura, N., Kuramoto, T., Hasegawa, A., & Kanazawa, T. (2021). Automated heart segmentation using U-Net in pediatric cardiac CT. *Measurement: Sensors*, 18. <https://doi.org/10.1016/j.measen.2021.100127>
- Zhang, B., Zhang, Y., Cheng, H. D., Xian, M., Gai, S., Cheng, O., & Huang, K. (2023). Computer-aided knee joint magnetic resonance image segmentation – A survey. *arXiv preprint arXiv:1802.04894*.
- Zhou, S. K., Greenspan, H., Davatzikos, C., Duncan, J. S., Van Ginneken, B., Madabhushi, A., Prince, J. L., Rueckert, D., & Summers, R. M. (2021). A review of deep learning in medical imaging: Imaging traits, technology trends, case studies

with progress highlights, and future promises. *Proceedings of the IEEE*, 109(5), 820-838.

Zhu, L., Zhou, J., & Song, J. (2008). Tracking multiple objects through occlusion with online sampling and position estimation. *Pattern Recognition*, 41(8), 2447-2460.





## ÖZGEÇMİŞ

### Kişisel Bilgiler

Adı ve Soyadı Emine Reyhan ŞENTÜRK

### Eğitim

Yüksek Lisans Çankırı Karatekin Üniversitesi 2022-2025  
Fen Bilimleri Enstitüsü  
Elektrik Elektronik Mühendisliği Anabilim Dalı

Lisans İstanbul Gelişim Üniversitesi 2016-2020  
Mühendislik Fakültesi  
Elektrik Elektronik Mühendisliği Bölümü