



**KEMİK KIRIKLARININ GÖRÜNTÜ İŞLEME
YÖNTEMLERİ İLE TAM OTOMATİK TESPİTİ VE
YAPAY ZEKA ALGORİTMALARI İLE
SINIFLANDIRILMASI**

Salih BÜTÜNER

**2022
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı
Dr. Öğr. Üyesi Eftâl ŞEHİRLİ**

**KEMİK KIRIKLARININ GÖRÜNTÜ İŞLEME YÖNTEMLERİ İLE TAM
OTOMATİK TESPİTİ VE YAPAY ZEKA ALGORİTMALARI İLE
SINIFLANDIRILMASI**

Salih BÜTÜNER

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Dr. Öğr. Üyesi Eftâl ŞEHİRLİ**

**KARABÜK
Temmuz 2022**

Salih BÜTÜNER tarafından hazırlanan “KEMİK KIRIKLARININ GÖRÜNTÜ İŞLEME YÖNTEMLERİ İLE TAM OTOMATİK TESPİTİ VE YAPAY ZEKA ALGORİTMALARI İLE SINIFLANDIRILMASI ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Eftâl ŞEHİRLİ

.....

Tez Danışmanı, Tıp Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 28/07/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. İlker TÜRKER (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Eftâl ŞEHİRLİ (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Abdullah ELEN (BANÜ)

Çevrimiçi

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Salih BÜTÜNER

ÖZET

Yüksek Lisans Tezi

KEMİK KIRIKLARININ GÖRÜNTÜ İŞLEME YÖNTEMLERİ İLE TAM OTOMATİK TESPİTİ VE YAPAY ZEKA ALGORİTMALARI İLE SINIFLANDIRILMASI

Salih BÜTÜNER

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Eftâl ŞEHİRLİ

Temmuz 2022, 85 sayfa

Birçok alanda olduğu gibi biyomedikal ve tıp alanında da insanların hata oranlarını aza indiren, nicelleştiren, kullanıcılara parametrik ve görsel sonuçlar sunan yazılım uygulamaları geliştirmek giderek önem kazanmaktadır. Teşhisi mümkün olmayan veya yanlış teşhis edilmiş kırık vakaları ortopedide önemli sorunların başında gelmektedir. Yanlış teşhis ile birlikte yanlış uygulanan tedavi sonucu iyileşme süreçleri uzayabilmekte ve hasta bu durumdan kötü etkilenebilmektedir. Bununla birlikte, kemik kırıklarının sınıflandırılarak tespit edilmesi biyomedikal alanda en çok tercih edilen alanlardan biridir. Bu tez çalışmasında Python ve MATLAB ortamlarında makine öğrenmesi algoritmaları ile geliştirilen bir yazılım kullanılarak kemik kırıkları tam otomatik bir şekilde tespit edilmiştir. Kemik kırıklarını tespit etmek için ilk olarak, görüntü veri seti üzerinde görüntü ön işleme adımları uygulanmıştır. Sonrasında görüntülerin segmentasyon işleminde K-ortalama ve Otsu eşikleme metodu birlikte

kullanılmıştır. Bağlı Bileşen Etiketleme (Connected Component Labeling, CCL) algoritması kullanılarak iki farklı segmentasyon modeli sonucu oluşan görüntülerden standart bir veri seti elde edilmiştir. Yeni görüntü veri seti üzerinde dilimleme işlemi gerçekleştirilmiştir. Dilimleme işleminde 325x175 boyutundaki görüntüler, ilk adımda 12, sonraki 4 adımda 11 eşit parçaya (27x175) ayrılmıştır. Oluşturulan görüntü alt kümeleri üzerinde öznitelik çıkarım parametreleri uygulanarak 31 adet öznitelik çıkarılmıştır. Çıkarılan öznitelikler ve görüntü alt kümelerine (dilimlere) ait özellikler excel ortamına aktarılmıştır. Son olarak öznitelikler makine öğrenmesi algoritmalarına girdi olarak sınıflandırma işlemi yapılmıştır. Makine öğrenme algoritması olarak Destek Vektör Makineleri, K-En Yakın Komşu, Karar Ağacı, Topluluk Öğrenimi, Lojistik Regresyon ve Naive Bayes sınıflandırıcısı algoritmaları kullanılmış ve elde edilen sonuçlar karşılaştırılmıştır. En başarılı üç algoritma (Destek Vektör Makineleri, K-En Yakın Komşu, Topluluk Öğrenimi) ile çoğunluk oylaması (majority voting) yapılmıştır. Bu tez çalışması sonucunda Destek Vektör Makineleri %96.67 Accuracy, %97.78 Specificity, %95.56 Sensitivity, 0.93 MCC değerleri ile en başarılı algoritmadır. Başarıyı destekler nitelikte ki uygulanan majority voting sonucunda ise %95.56 Accuracy, %97.78 Specificity, %93.33 Sensitivity, 0.91 MCC değerleri elde edilmiştir.

Anahtar Sözcükler: Kemik Kırıkları, Kırık Tespiti, Yapay Zeka, Sınıflandırma, Makine Öğrenmesi

Bilim Kodu : 92418,92432

ABSTRACT

M. Sc. Thesis

FULL AUTOMATED DETECTION OF BONE FRACTURES BY IMAGE PROCESSING METHODS AND CLASSIFICATION BY ARTIFICIAL INTELLIGENCE ALGORITHMS

Salih BÜTÜNER

**Karabük University
Institute of Graduate Programs
Department of Computer Engineering**

Thesis Advisor:

Assist. Prof. Dr. Eftâl ŞEHİRLİ

July 2022, 85 pages

It has increasingly become important to develop software applications that reduce, quantify people's error rates, provide parametric and visual results to users, in the field of biomedical and medicine, as in many other fields. Undiagnosed or misdiagnosed fractures are one of the most important problems in orthopedics. As a result of the wrong diagnosis and the wrong treatment, the healing processes can be prolonged and the patient can be badly affected by this situation. In addition, classification and detection of bone fractures is one of the most preferred areas in the biomedical field. In this thesis, bone fractures were detected fully automatically with machine learning algorithms by using Python and MATLAB together. In order to detect bone fractures firstly, image preprocessing steps were applied on the image dataset. Then, K-means and Otsu Thresholding method were used together in the segmentation process of the

images. By using the Connected Component Labeling (CCL) algorithm, a standard dataset was obtained from the images formed as a result of two different segmentation models. Slicing process was performed on the new image dataset. In the slicing process, 325x175 images were divided into 12 equal parts (27x175) in the first step and 11 equal parts (27x175) in the next 4 steps. 31 features were extracted by applying feature extraction parameters on the created image subsets. Extracted features and features of image subsets (slices) were transferred to excel. Finally, the features were given to the machine learning algorithms and the classification process was carried out. As machine learning algorithms, Support Vector Machines, K-Nearest Neighbor, Decision Tree, Ensemble Learning, Logistic Regression and Naive Bayes Classifier algorithms are used and compared. Majority voting was performed with the three most successful algorithms (Support Vector Machines, K-Nearest Neighbor, Ensemble Learning). As a result of this thesis study, Support Vector Machines is the most successful algorithm with %96.67 Accuracy, %97.78 Specificity, %95.56 Sensitivity, 0.93 MCC. As a result of Majority Voting, it is obvious that %95.56 Accuracy, %97.78 Specificity, %93.33 Sensitivity, 0.91 MCC values obtained supporting success.

Key Word : Bone Fractures, Fracture Detection, Artificial Intelligence, Classification, Machine Learning

Science Code : 92418, 92432

TEŐEKKÜR

GeekleŐtirilen tez alıŐmasında desteklerini ve yardımlarını esirgemeyip, bilgi ve deneyimleriyle ıŐık tutan, bilgi alışveriŐlerinde bulunduđum, tez alıŐması dıŐında da her tÜrlÜ ihtiyaımda yanımda olan Dr. Öđr. Üyesi Eftâl ŐEHİRLİ'ye sonsuz teŐekkürlerimi sunarım.

Tüm eđitim hayatım boyunca emeđini ve desteklerini esirgemeyen tüm öđretmenlerime ve arkadaşlarıma teŐekkür ederim.

Bugüne dek hiçbir maddi ve manevi desteđini esirgemeyen sevgili aileme teŐekkürü bir bor olarak bilirim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiv
SİMGELER VE KISALTMALAR DİZİNİ	xv
BÖLÜM 1	1
GİRİŞ	1
1.1. TEZİN TANIMI.....	1
1.2. TEZİN AMACI	2
BÖLÜM 2	4
KEMİKLER	4
2.1. KEMİKLERİN YAPISI	4
2.2. KEMİKLERİN ÇEŞİTLERİ ve KEMİKLERİN SINIFLANDIRILMASI.....	5
2.2.1. Uzun Kemikler.....	6
2.2.2. Kısa, Yassı, Düzensiz Kemikler	7
2.3. KEMİK MİMARİSİ	8
2.3.1. Kompakt Kemikler	9
2.3.2. Süngerimsi Kemik	9
2.4. KEMİĞİN KİMYASAL YAPISI.....	10
2.5. KEMİK DOKUSU	11
2.6. KEMİK KIRIKLARI	12

	<u>Sayfa</u>
2.7. KEMİK KIRIKLARININ GÖRÜNTÜLENMESİ	16
2.7.1. Manyetik Rezonans Görüntüleme (MRI)	17
2.7.2. Bilgisayarlı Tomografi Görüntüleme Teknikleri (CT).....	19
2.7.3. Ultrasonografi	21
2.7.4. X-ray Radyografi	23
BÖLÜM 3	26
LİTERATÜR İNCELEMESİ.....	26
BÖLÜM 4	33
KULLANILAN PROGRAMLAR VE TEMEL PAKETLER.....	33
4.1. PYTHON.....	33
4.2. PYTHON TEMEL PAKETLERİ.....	35
4.2.1. NumPy	35
4.2.2. Python Imaging Library (PIL)	35
4.2.3. Matplotlib	35
4.2.4. OpenCV	36
4.3. MATLAB	36
BÖLÜM 5	38
KULLANILAN MATERYALLER.....	38
BÖLÜM 6	39
KULLANILAN METOTLAR	39
6.1. Görüntü Ön işleme.....	40
6.1.1. RGB Görüntüleri Gri Seviye Görüntüye Çevirme	40
6.1.2. Filtreleme	41
6.1.3. Bölütleme.....	41
6.1.3.1. K-ortalama Algoritması (K-means).....	42

Sayfa

6.1.3.2. OTSU Eşikleme Algoritması (Otsu Threshold)	43
6.2. GÖRÜNTÜLERİN DİKDÖRTGEN FORMDA DİLİMLENMESİ İLE GÖRÜNTÜ ÇOĞALTILMASI	46
6.3. ÖZELLİK ÇIKARIMI (FEATURE EXTRACTION)	47
6.4. SINIFLANDIRMA	58
6.4.1. Destek Vektör Makineleri (DVM).....	59
6.4.2. K En Yakın Komşu Algoritması (KNN)	61
6.4.3. Karar Ağacı.....	62
6.4.4. Naive Bayes Sınıflandırıcısı (The Naive Bayes Classifier).....	63
6.4.5. Lojistik Regresyon (Logistic Regression)	63
6.4.6. Topluluk Öğrenimi (Ensemble Learning)	64
6.5. PERFORMANS ANALİZİ	64
BÖLÜM 7	68
DENEYSEL SONUÇLAR	68
BÖLÜM 8	75
SONUÇLAR ve DEĞERLENDİRMELER.....	75
8.1. ÇALIŞMANIN KATKILARI	75
8.2. ÖNERİLER	76
KAYNAKLAR	77
ÖZGEÇMİŞ	85

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Kemik kırıklarının sınıflandırılması	6
Şekil 2.2. Uzun kemik yapısı	7
Şekil 2.3. Uzun, kısa, yassı, düzensiz kemik	8
Şekil 2.4. Kompakt kemik yapısı	9
Şekil 2.5. Süngerimsi kemik yapısı	10
Şekil 2.6. Kemik dokusu	12
Şekil 2.7. Kaval kemiği kırığına ait örnek	13
Şekil 2.8. AO/OTA sınıflandırmasına göre femur kemiği diafiz bölge kırıklarının sınıflandırması.....	14
Şekil 2.9. Kuvvet türleri ve sonucunda oluşan kırık türleri	15
Şekil 2.10. Medikal görüntüleme cihazlarının çalışma prensibi	16
Şekil 2.11. MRI cihazı ile kemik görüntülenmesi işlemi	17
Şekil 2.12. Bilgisayarlı tomografi ile kemik kırığı görüntülenmesi işlemi	20
Şekil 2.13. Ultrasonografi ile kemik kırığı görüntüleme	22
Şekil 2.14. a) X-ray görüntüleme b) Dönen X-ray tüpü	24
Şekil 2.15. X-ışını radyografisi ile edilmiş farklı kemik türlerine ait görüntüler	24
Şekil 5.1. Kırık ve sağlıklı kemik görüntüleri	38
Şekil 6.1. Çalışmanın iş akış diyagramı	40
Şekil 6.2. 8-komşu bağlantısı	46
Şekil 6.3. Görüntülerin sayısallaştırılması ile elde edilen excel çizelgesi	47
Şekil 6.4. Doğrusal Olarak Ayrılabilir Veriler için Hiper Düzlemler	60
Şekil 6.5. Optimum Hiper Düzlem ve Destek Vektörleri	60
Şekil 6.6. Yeni bir örneğin iki farklı kümeye göre durumu	62
Şekil 6.7. Lineer model ve lojistik model grafiği	64
Şekil 7.1. Orijinal görüntü ve Bölüm 6.1'deki adımların sonucu görüntüler a) Orijinal görüntü b) Gri seviye görüntü c) Median filtre sonucu d) İkili seviye görüntü	68

	<u>Sayfa</u>
Şekil 7.2. Maske görüntü ve dikdörtgen formda dilimlenmiş görüntüler	70
Şekil 7.3. Görüntülere ait öznelik çıkarımı	71
Şekil 7.4. Altı farklı sınıflandırma algoritması ve Majority Voting için ROC grafiği	73

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1 Doğrudan ve dolaylı kuvvetler ile meydana gelen kırık türleri	15
Çizelge 3.1. Yıllara göre kemik kırıkları tespiti hakkında ki çalışmaların sayısı.	27
Çizelge 3.2. Kemik kırıkları tespiti hakkında ki çalışmaların başarı yüzdeleri.	32
Çizelge 6.1. Ölçüm değerleri olasılık çizelgesi.....	66
Çizelge 7.1. Sınıflandırma algoritmaları başarımlarını değerlendirmeleri.	72
Çizelge 7.2. Yıllara göre kemik kırıkları tespiti hakkında ki çalışmaların ve gerçekleştirilen çalışmanın doğruluk değerleri.	74

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

Ca : Kalsiyum

P : Fosfor

Mg : Magnezyum

$\text{Ca}_3(\text{PO}_4)_2$: Kalsiyum Fosfat

CaCO_3 : Kalsiyum Karbonat

F^- : Florür

K : Potasyum

KISALTMALAR

IOF	: International Osteoporosis Foundation (Uluslararası Osteoporoz Vakfı)
MATLAB	: Matrix Laboratory (Matris Laboratuvarı)
CCL	: Connected Component Labeling (Bağlı Bileşen Etiketleme)
ML	: Machine Learning (Makine Öğrenmesi)
MV	: Majority Voting (Çoğunluk Oylaması)
MCC	: Matthews Correlation Coefficient (Matthews Korelasyon Katsayısı)
ACC	: Accuracy (Doğruluk)
MRI	: Magnetic Resonance Imaging (Manyetik Rezonans Görüntüleme)
CT	: Computer Tomography (Bilgisayarlı Tomografi)
DICOM	: Digital Imaging and Communications in Medicine (Tıpta Dijital Görüntüleme ve İletişim)
NN	: Artificial Neural Network (Yapay Sinir Ağları)
AO	: Arbeitsgemeinschaft für Osteosynthesefragen – Osteosentez Çalışma Grubu
OTA	: Orthopaedic Trauma Association (Ortopedik Travma Derneği)
TGT	: Tıbbi Görüntüleme Teknikleri
PET	: Positron Emission Tomography (Pozitron Emisyon Tomografisi)
SPECT	: Single Photon Emission Computed Tomography (Tek Foton Emisyon Bilgisayarlı Tomografi)
RF	: Radio Frequency (Radyo Frekansı)
SNR	: Signal-to Noise Ratio (Sinyal Gürültü Oranı)
ASM	: Active Shape Model (Aktif Şekil Modeli)
DWT	: Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
GO	: Gabor Orientation (Gabor Yönelimi)
MRF	: Markov Random Field (Markov Rastgele Alan)
IGD	: Intensity Gradient Direction (Yoğunluk Gradyan Yönü)
DVM	: Destek Vektör Makinesi
BPNN	: Back Propagation Neural Networks (Geri Yayılım Sinir Ağları)
TP	: True Positive (Doğru Pozitif)
TN	: True Negatives (Doğru Negatif)
FP	: False Positive (Yanlış Pozitif)

FN	: False Negative (Yanlış Negatif)
FCM	: Fuzzy C-Means (Bulanık K Ortalama)
MWA	: Multilevel Wavelet Algorithms (Çok Seviyeli Dalgacık Algoritmaları)
SIFT	: Scale-Invariant Feature Transform (Ölçek Değişmez Özellik Dönüşümü)
GLCM	: Gray-Level Co-Occurrence Matrix (Gri Düzey Eş-Oluşum Matrisi)
TIOBE	: Programming Community index (Programlama Topluluğu Endeksi)
PIL	: Python Image Library
GUI	: Graphical User Interface (Grafiksel Kullanıcı Arayüzü)
WAV2	: Ratio of Wavelet Coefficients (Dalgacık Katsayılarının Oranı)
KNN	: K-Nearest Neighbors (K-en Yakın Komşu)
NB	: Naive Bayes
MR	: Miss Rate (Kaçırma Oranı)
NPV	: Negative Predictive Value (Negatif Öngörü Yüzdesi)
ROC	: Receiver-Operating Characteristic (Alıcı İşletim Karakteristiği)

BÖLÜM 1

GİRİŞ

Bu tez çalışmasında, kemik görüntüleri üzerinde çeşitli görüntü işleme teknikleri kullanılarak kemik kırıklarının tam otomatik tespit edilmesi aşamaları sunulmuştur.

1.1. TEZİN TANIMI

Biyomedikal alanında tanı, teşhis (hekimin cihaz yardımı ile veya cihaz yardımı olmadan hastanın şikayetinin belirlenmesi) ve tedavi (hekimin hastaya dair teşhisinden sonra hastanın belirlenen şikayetinin giderilmesi süreci) için etkili bir yol olan medikal görüntüleme ve medikal yazılım uygulamaları giderek popüler hale gelmektedir. Bu iki büyük alan doktorlar, bilim adamları ve medikal cihaz kullanıcıları için büyük ölçüde kolaylıklar sağlamaktadır. Geliştirilen yazılımlar tanı ve tedavi için büyük öneme sahiptir. Bu bağlamda geliştirilen yazılımlar hastalıklar, vücutta meydana gelen hasarlar, kırık tespiti ve deneysel çalışmalar gibi konularda bilgi sahibi olmak için oldukça önemlidir.

Son yıllarda biyomedikal alanda gerçekleştirilen projeler hastalar hakkında hekimlere, klinisyenlere, bilim insanlarına ve medikal cihaz kullanıcılarına ipuçları vererek karar verme, yorum yapma aşamalarında yardımcı olmaktadır. Biyomedikal yazılım uygulamaları bunları gerçekleştirirken yine bir diğer alan olan biyomedikal görüntüleme uygulamalarından elde edilen görüntüler kullanılmaktadır. Bu görüntülerin kalitesi gerçekleştirilecek olan çalışmanın ve alınacak çıktılarının doğruluğu için oldukça önemlidir.

Kemikler, bizi ayakta tutan, vücudumuza şekil veren, koruyan ve sınırlı hareketleri gerçekleştirebilen iskelet sistemimizin en önemli yapıtaşlarından. Organik bir yapıya sahip kemik yaklaşık olarak %70 mineral, %22 protein ve %8 sudan oluşan

canlı bir organizmadır [1,2]. Kemik yapısı büyük oranda matriks adı verilen maddeden oluşmaktadır. Kemikler içerisinde barındırdıkları kalsiyum miktarının fazla olmasından dolayı oldukça serttir ve bu sertliğe bağlı olarak dışarıdan gelen doğrudan veya dolaylı kuvvet içeriklerinden çatlayabilir ve kırılabilir [3].

Kemiklerde meydana gelen kırıklar, dıştan veya içten etki eden kuvvetler doğrultusunda kemikte meydana gelen ayrılma ve bununla birlikte kemik bütünlüğünün bozulmasıdır. Kemikteki kırılma, kemiğin maruz kaldığı kuvveti absorbe etme özelliğine göre ufak bir çatlaktan, birkaç kemiğin katıldığı açık bir kırığa kadar çeşitlendirilebilir. Kemik kırıkları farklı ve birçok etmen sonucu oluşabilirler. Fakat öne çıkan nedenlerinin en başında Travmalar (Kazalar), Stres, Aşırı kullanım (Overuse) ve Patolojik Unsurlar (Osteoporoz) gelir[4,5]. Uluslararası Osteoporoz Vakfı (IOF) verilerine göre osteoporoz görülme oranı kadınlarda %40-50 iken erkeklerde bu oran %13-22 civarlarındadır [6].

Kemik kırıkları günümüzde biyomedikal görüntüleme cihazları olan Röntgen cihazları, Manyetik Rezonans Görüntüleme (MRI), Bilgisayarlı Tomografi (CT) ve Ultrasonografi cihazları ile görüntülenmektedir.

Kemik kırıklarının, bilgisayar desteği ile sınıflandırılması doktorların, klinisyenlerin ve röntgen teknisyenlerinin kırık tanısı konusunda sahip oldukları yeteneklerin artmasını sağlayacaktır. Geliştirilen yazılımların doğru bir şekilde kemiğin kırık olup olmadığını ve kırık olan parçayı işaretlemesi aşamaları için kemik görüntüleri üzerinde sırasıyla görüntü ön işleme adımları gerçekleştirilecek, segmentasyon işlemi sonucu ile kemik ve diğer dokular birbirlerinden ayrılacaklar, görüntüler dilimlendirilerek çoğaltılacak ve özellik çıkarımı (features extraction) gerçekleştirilecektir. Son olarak, farklı sınıflandırma algoritmaları kullanımıyla sınıflandırılarak bir kemik yapısının kırık olup olmadığı ve varsa kırık bulunan bölge ortaya konulacaktır.

1.2. TEZİN AMACI

Kemik kırığı mevcut hastalarda kırığın teşhis edilememesi, kırık türünün, tipinin yanlış değerlendirilmesi, bu iki durumun sonucunda hastalara uygulanacak tedavinin

yanlıř olma ihtimali ortaya ıkar. Bu durumun nihai sonucu olarak yanlıř bir tedavi neticesinde, tedavi srecinin uzaması ve kemiđin yanlıř bir řekilde kaynamasına sebebiyet verecektir. Bu komplikasyonların tespiti ve sınıflandırılması, tanı ve tedavi srelerine iyi ynde etki ederek yařam standartlarını etkileyecektir. Bu nedenle, bu tez alıřmasında genel olarak kemik grntlerinden kemiđin kırık olup olmadıđı ve kırık varsa hangi dilimde olduđunun tespit edilmesi amalanmaktadır. Bu bađlamda, kemik grntleri zerinde farklı sınıflandırma algoritmaları kullanılarak sınıflandırılacaktır. En bařarılı olan sınıflandırma algoritması ortaya koyulacaktır. Bununla birlikte kemik grntleri kullanılarak kırık olup olmadıđı, kırık varsa hangi dilimde olduđu gsterilecektir.

BÖLÜM 2

KEMİKLER

İskelet sistemi, kemikler, kıkırdaklar, bağlar ve kemik iliği dahil olmak üzere dört ana yapıdan oluşur. Kemikler vücudumuzda yoğun bir şekilde yer almakla birlikte, ağırlıkları açısından oldukça hafif yapıdadırlar. Kemikler, vücudu destekleyerek ayakta tutan iskelet sisteminin en temel yapısıdır. Kaslar ile beraber kaldıraç görevi görerek hareket sağlarlar. Göğüs kafesi vb. bir yapı ile kritik iç organları, yapıları korur bünyesinde bulundurduğu kemik iliği sayesinde kanın mineral, asit-baz dengesini korur ve kanın hücresele bileşenlerinin oluşumunu sağlarlar [7].

2.1. KEMİKLERİN YAPISI

Kemikler, yapılarında Kalsiyum (Ca) bulduran oldukça sert yapılardır ve sanılanın aksine cansız değildirler. Kemikler %35 oranında organik ve %65 oranında ise inorganik madde içerir. Organik içerikler kemiğe elastikiyet kazandırırken, inorganik içerikler kemiğe sertlik kazandırır. Kemikten genellikle vücudun koruyucu ve destekleyicisi olan iskelet sisteminin bir parçası olarak bahsedilir [3]. En temelde bu fonksiyonların yanı sıra kemik, mekanik yüklere ve hormonal aktivitelere yanıt olarak iç yapısını (gövdesini) ve dış şeklini adapte etme yeteneğine sahip oldukça dinamik bir organdır. Bununla birlikte kemiğin işlevlerini yerine getirebilecek kadar hafif, aynı zamanda gerekli mukavemeti sağlamak için de bir demir gibi güçlü olması gerekir [3,8].

Kemiğin beş temel amacı destek, koruma, hareket, mineral depolama ve kan hücresi üretimidir [9]. Bu fonksiyonlar aşağıda kısaca açıklanmıştır.

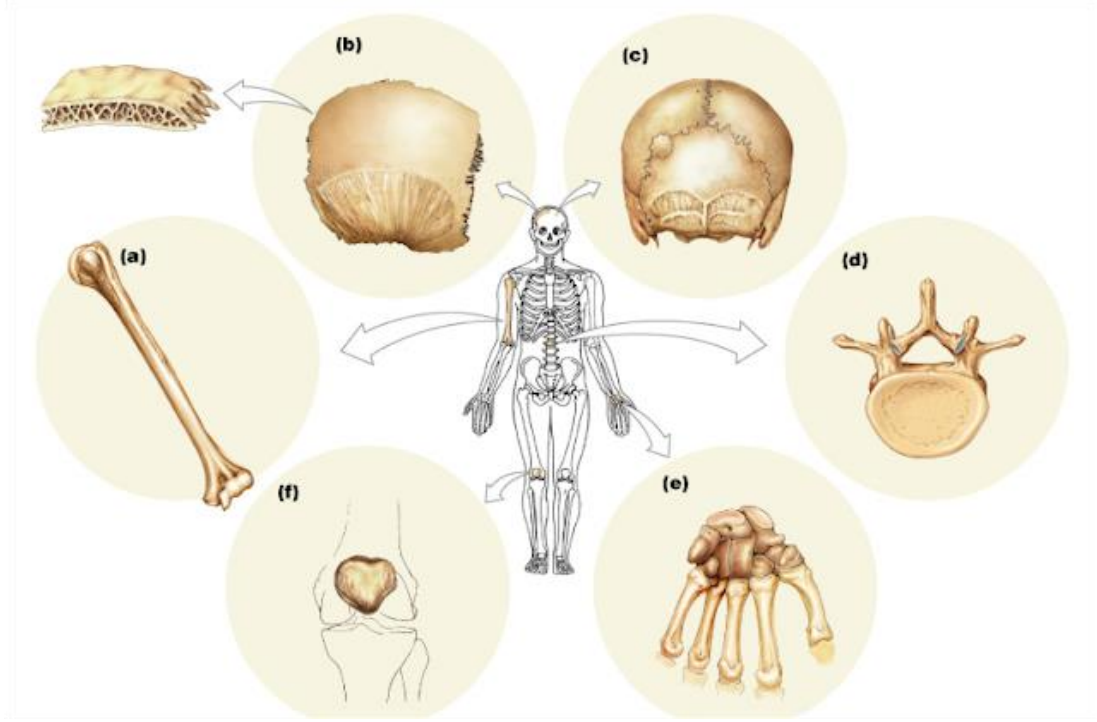
- Destek: Kemikler iskelet sisteminin bütünlüğünü sağlayacak şekilde dokuların ve kasların bağlanabileceği bir ortam sağlar. Kemiklerin kaslar ve dokularla bu

şekilde ilişkilerinin olmaması durumunda iskelet sistemi çöker organlar ve sistemlerde zarar görürler [9].

- Koruma: Kemikler aynı zamanda organları korur. Örneğin kafatası beyni korurken, göğüs kafesi hem kalbi hem de akciğerleri korur. Omur kemikleri omurilik sinirlerini korur [9].
- Harekete yardımcı olmak: Kemikler üzerinde kasların, bağların bağlanabilmesi için tendonlar bulunur. Tendonları kemiklere bağlamak için kemikte yüzeyler veya noktalar bulunur. Bununla birlikte, tendonların, kasların, bağların hareketleri ile iskelet sistemi hareket eder. Bunun sonucunda insanların hareketleri meydana gelir [9].
- Minerallerin depolanması: Kemikler, çeşitli hücrel aktiviteler için Fosfor (P), Magnezyum (Mg) ve Ca mineralleri depolar. Kandaki mineral seviyesi çok yükseldiğinde, minerallerin bir kısmı vücuttan uzaklaştırılır veya kemiklerde depolanır. Kandaki mineral seviyesi düşer ise kemiklerden mineral geri alınır [9].
- Kan hücrelerinin üretimi: Birçok kemik, kırmızı kemik iliği ile dolu boşluklar içerir ve kan hücresi (kırmızı ve beyaz kan hücreleri) oluşumunun çoğu bu iliklerde gerçekleşir. Bu kırmızı kemik ilikleri kafatası, göğüs kafesi kemiği gibi yassı kemiklerde, düz kemiklerde ve uzun kemiklerde bulunur [9].

2.2. KEMİKLERİN ÇEŞİTLERİ ve KEMİKLERİN SINIFLANDIRILMASI

206 kemikten oluşan insan iskelet sistemi vücut kitlesinin %20 sini oluşturmaktadır. Kemikler aksiyel ve apendiküler olmak üzere iki gruba ayrılır. Ana işlevi vücudu korumak, desteklemek ve taşımak olan, kafatası, omurga ve göğüs kafesi kemikleri aksiyel kemiklere dahildir. Diğer yandan, üst-alt ekstremitte kemikler ve eklemler apendiküler kemiklere dahildir. Uzun kemikleri, bir yerden bir yere hareket etmemize ve çevremizi yönetmemize yardımcı olur. Esas olarak şekillerine göre sınıflandırılan kemikler uzun, kısa, yassı ve düzensiz kemiklerdir. Uzun kemikleri uzun kemiklere örnek olarak verilirken, karpal ve tarsal kemikler kısa kemiklere örnek olarak verilir. Kaburgalar, kafatası, kürek kemiği, göğüs kafesi kemiği, yassı kemiklere örnek verilir. Omur kemikleri, düzensiz kemiklere örnek olarak verilir [8,10]. Kemik şekillerine ait örnek görüntüler Şekil 2.1’de sunulmuştur.



Şekil 2.1 Kemik kırıklarının sınıflandırılması. (a) Uzun kemik kol kemiği örneği (b) Yassı kemik. (c) Yassı kemik kafatası örneği. (d) Düzensiz kemik omurga kemiği örneği. (e) Kısa kemik karpal kemik örneği.


2.2.1. Uzun Kemikler

Uzun kemiklerin enine kesitleri boyuna kesitlerine göre daha uzundur. Üç ana bileşenleri vardır bunlar. Bunlar: Diyafiz, epifiz ve metafizdir. Uzun kemiğin iki ucu arasındaki ekseni, boru şeklindeki şaft ile oluşturan kısma diyafiz denir. Temel olarak ilik boşluğunu çevreleyen az sayıda gözenekli kompakt kemikten oluşur. Bu süngerimsi kemiğin gözenekleri ile ilik boşluğu kırmızı ve sarı kemik iliği ile doludur. Şaft, Osteoblastları (kemiği oluşturan hücreler), Osteoklastları (kemiği yok eden hücreler), sinir liflerini ve lenf damarlarını içeren bir zar olan Periosteom ile kaplıdır [9,10].

İlik (medüller) boşluğunu, ince bir bağ doku tabakası ve kemik astar hücrelerinden oluşmuş olan endosteum oluşturur. Bunun anlamı endosteum tabakası periosteom tabakasının altında oluşan bir yapıdır. Kemiğin baş kısmına epifiz denir. Epifiz esas

olarak süngerimsi kemikten oluşur. Eklem yüzeylerindeki epifiz eklem kıkırdağı ile kaplıdır [9,10].

Trabekula (dallanmış kemik spiküllerinin süngerimsi kemikte meydana getirdiği üç boyutlu ağ yapısının en kalın kısmı) epifiz ile diyafiz arasında yer alır ve kemiğin bu bölgesine metafiz denir. Metafiz, diyafiz ve epifizi ayıran epifiz çizgisini içerir. Epifiz çizgisi, kemik büyümesinin meydana geldiği epifiz plakasının kemikleşmesi ile meydana gelir [9,10]. Şekil 2.2’de uzun kemiğin yapısı sunulmuştur.

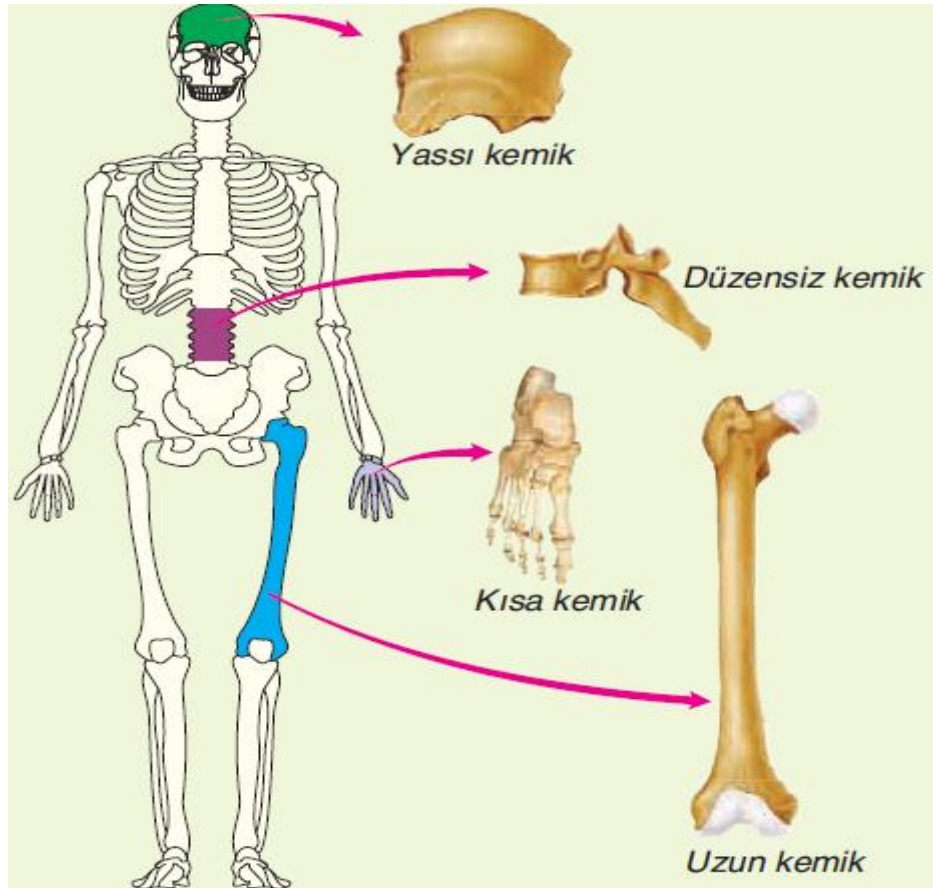


Şekil 2.2 Uzun kemiğin yapısı.

2.2.2. Kısa, Yassı, Düzensiz Kemikler

Kısa kemikler küp şekline benzer yapıdadır. Bir başka deyişle, enine kesit uzunlukları ile boyuna kesit uzunlukları hemen hemen aynıdır. Yassı kemikler bir miktar eğrilik barındıran ince yapıda kemiklerdir. Düzensiz kemikler, belli bir formu olmayan karmaşık şekillere sahip kemiklerdir.

Bu 3 tür kemiklerde diyafiz ve epifiz bulunmamaktadır. Kısa ve düzensiz kemikler süngerimsi, ince bir kortikal kemik tabakası ile çevrili iken, yassı kemiklerde süngerimsi kısım iki tabaka kortikal kemik dokusu arasında sıkıştırılır. Uzun kemikler gibi, kısa ve yassı kemiklerin dış yüzeyi periosteom, iç yüzeyi ise endosteum ile kaplıdır. Omur kemikleri, kaburga kemikleri, göğüs kemiği vb. kemiklerin trabeküller arasındaki gözenekler kırmızı ilik içerir [9,10]. Kısa, yassı, düzensiz kemik örnekleri Şekil 2.3'te sunulmuştur.



Şekil 2.3 Uzun, kısa, yassı, düzensiz kemik.


2.3. KEMİK MİMARİSİ

İki ana tip kemik mimarisi vardır; kompakt (kortikal) ve süngerimsi (spongiöz) kemik. Genel olarak, kemikler hem kompakt hemde süngerimsi dokuya sahiptir. Bunların kompozisyonu kemiklere göre değişir. Kompakt kemikler, kemiklerin dış kısmını ve

uzun kemiklerin yapısının çoğunu oluşturur iken, süngerimsi kemikler, genellikle kemiklerin merkezini ve kemik baş kısımlarının iç kısmını oluşturur [9,10].

2.3.1. Kompakt Kemikler

Kompakt kemiklerin temel yapı taşı osteon adı verilen silindirik birimlerden oluşur. Osteonlar, Haversian (Merkezi) kanalların çevresinde sert kalsifiye matristen oluşan silindirik lameller (tabakalar) içerir. Osteositler (kemik hücreleri), tabakalar arasındaki boşluklara (lakuna) yerleştirilir. Kompakt kemiklerin yapısında bulunan Kanalikül adı verilen uzantılar ile besinlerin, atıkların osteositler ve kan damarları arasında alışverişi yapılır [9,10]. Kompakt kemik yapısı Şekil 2.4'te sunulmuştur.




Şekil 2.4 Kompakt kemik yapısı.

2.3.2. Süngerimsi Kemik

Süngerimsi kemik herhangi bir osteon (temel yapıtaşı) içermemektedir. İnce ve düzensiz şekilli plakalar, çubuklar veya trabekül adı verilen kırımlardan oluşur. Ayrıca lamel, osteosit, lakün (küçük boşluk) ve kanalikül içerir. Trabekülün şekli nedeniyle süngerimsi kemik yani gözenekli hücresel bir katı olarak sınıflandırılabilir ve bu gözenekler kemik iliği ile doludur. Bunun sonucu olarak, her osteosit, yakındaki kan

damarıyla besin alışverişi yapabilir. Bununla birlikte, kortikal kemiğin aksine merkezi bir kanala ihtiyaç yoktur. Trabeküller, mekanik ortamdaki değişikliklere yanıt olarak morfolojisini değiştirme yeteneğine sahiptir. Bu işleme kemiğin yeniden şekillenmesi denir [9,10]. Şekil 2.5'te süngerimsi kemik yapısı sunulmuştur.



Şekil 2.5 Süngerimsi kemik yapısı.

2.4. KEMİĞİN KİMYASAL YAPISI

Organik ve inorganik bileşenlere sahip kemiğin, toplam kütesinin yaklaşık %35'i organik bileşenlerden oluşurken, %65'i inorganik bileşenlerden oluşmaktadır [9]. Organik bileşenler, osteoblastlar, osteositler, osteoklastlar, osteojenik hücreler ve osteoid gibi kemik hücrelerinden meydana gelir. Osteoid ve osteoblastlar tarafından üretilen ve salgılanan Kollajen lifleri, temel madde matriksin üçte birini oluşturmaktadır. Bu temel madde ve Kollajen, kemiklerin esnekliğine katkıda bulunur. Örnek olarak kollajen çıkarılırsa, mineral bazlı bileşenler birincil bileşen olur ve kemik aşırı kırılabilir bir hal alabilir.

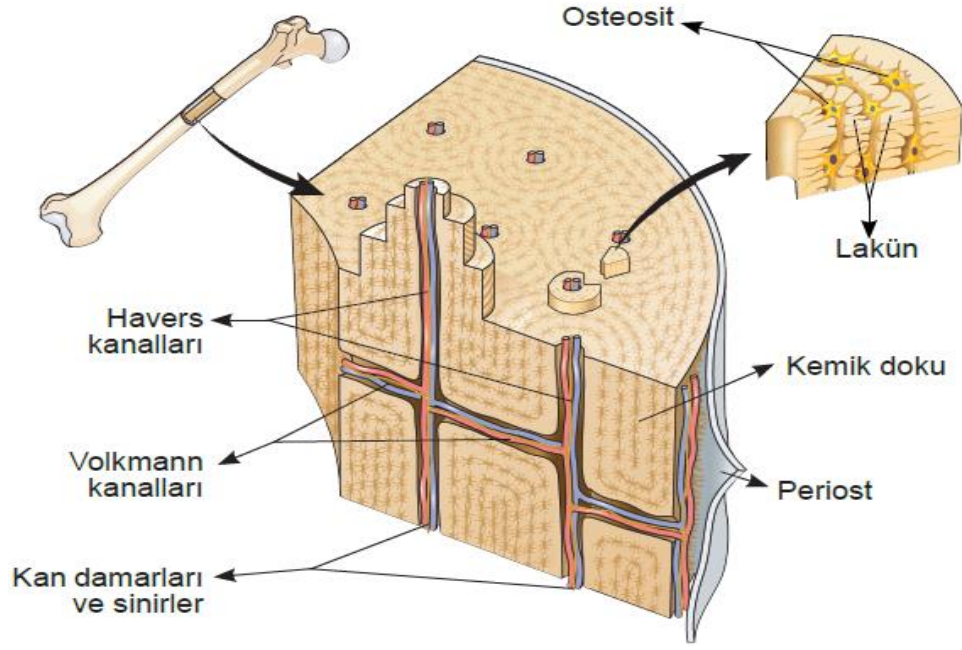
Kemiğin %65 lik kısmını oluşturan inorganik bileşenler, Kalsiyum Fosfat ($Ca_3(PO_4)_2$), Kalsiyum Karbonat ($CaCO_3$) ve bunların yanı sıra sırasıyla %85, %10 ve %5 oranlarında Florür (F^-), Potasyum (K), Magnezyum (Mg) minerallerinden oluşur.

Kalsiyum Fosfat, matrikste ki kollajen liflerinin çevresinde veya içinde bulunan, sıkıca paketlenmiş küçük kristaller biçimindedir. Bu form, kemiğin kompresyona (sıkıştırma basıncı) direnmesini ve sertliğini en iyi şekilde korumasını sağlar. Mineral çıkarılırsa, kollajen birincil bileşen haline gelir, o zaman kemik bükülebilir organ haline gelir [9,10].

Kısaca, organik ve inorganik bileşenlerin uygun kombinasyonu ile kompresyon ve gerilime karşı direnç gösteren, mineraller ve kollajen sayesinde kemiğin fazlasıyla dayanıklı ve güçlü hale geldiği söylenebilir [9,10].

2.5. KEMİK DOKUSU


Üç tip kemik hücresi vardır: Osteoblastlar, osteositler ve osteoklastlar. Osteoblastlar (kemiği oluşturan hücreler), kollajen ve proteoglikanlar, dayanıklı bir süreç olan ekzositoz ile hücreden salınana kadar Golgi aygıtı tarafından Veziküllerde paketlenir. Bu veziküller, kalsiyum fosfat kristalleri olarak da adlandırılan hidroksiapatit kristallerini oluşturmak için kullanılır. Bu işlemler sonucunda mineralize kemik matriksi oluşur. Ossifikasyon ve osteogenez, osteoblastlar tarafından kemik oluşumudur. Osteoblastlar, kemik matriksi ile çevrelendikten sonra, osteosit adı verilen olgun kemik hücresine dönüştürülür. Osteositler, osteoblastlara kıyasla pasif olmalarına rağmen, kemik matrisini korumak için gerekli bileşenleri üretirler. Osteoklastlar kemik içerisindeki emilimlerden sorumludur. Osteoklastların zarı kemik matriksine temas ettiğinde, fırırlı kenar adı verilen birçok çıkıntı oluşturur. Hidrojen iyonları, kıvrımlar boyunca pompalanır ve kemik matrisinin kireçten arındırılmasına neden olan bir asit ortamı üretir. Osteoklastlar ayrıca kemik matrisinin protein bileşenlerini sindiren enzimleri de serbest bırakır [9,10]. Şekil 2.6'da kemik dokusuna ait görüntü sunulmuştur.



Şekil 2.6 Kemik dokusu.

2.6. KEMİK KIRIKLARI

İskelet sisteminin en temel yapısı olan kemikler, dışarıdan veya içerden, dolaylı veya doğrudan etki eden kuvvet bileşenleri etkisiyle yapısal bozukluklara maruz kalabilir. Bu yapısal bozukluklar kemik bütünlüğünün ve devamlılığın sağlanmamasına sebep olurlar. Kemiklerde meydana gelen bozukluklar üzerine etki eden kuvvetleri tolere etme yetenekleri ile ters orantılı olarak, ufak bir çatlaktan, birkaç kemiğin katıldığı açık bir kırığa kadar çeşitlendirilebilir. Hatta buna kırık bölgesinde etkin olan eklemlerin çıkması da eklenebilir. Kırığı oluşturan kuvvet sadece kemiğe zarar vermeyebilir, kemik ile beraber kaslara, tendonlara, ligamentlere, damarlara, sinirlere ve komşu organlara da zarar verebilir [7,11,12]. Şekil 2.7’de kaval kemiğine ait kırık gösterilmiştir.



Şekil 2.7 Kaval kemiği kırığına ait örnek.

Kırıkların farklı sınıflandırma sistemleri vardır. Bunlar sadece adlandırma, tanımlama ve karşılaştırma gibi amaçları kapsar. Sınıflandırma sistemleri kırıkları üç ana kategoriye ayırır; kırığa özgü (Garden, Schatzker, Neer), evrensel (Arbeitsgemeinschaft für Osteosynthesefragen (AO) ve Orthopaedic Trauma Association (OTA)) ve yumuşak dokuya özgü (Gustila) [13].


AO/OTA evrensel kırık sınıflandırma sisteminde, uzun kemiklerin her kırığı için 4 adet soruya cevap verilmelidir.

- Hangi kemik kırık? (1,2,3,4...)
- Kırık kemiğin neresinde? (1,2 ve 3)
- Hangi tip kırık? (A,B ve C)
- Kırık hangi grupta? (1,2 ve 3)

Buna göre Humerus (1), önkol (2), femur (3), tibia (4), omurga (5), pelvis (6), el (7), ayak (8) ve kafatası (9) olarak kemikler sınıflandırılır. Daha sonra 2. seviye olan kemik bölgesi, proksimal bölge kırıklar (1), diafiz bölge kırıkları (2) ve distal bölge kırıkları (3) olmak üzere numaralandırılır. 3. Seviye olarak kırık tipi Basit (A), Kama (B) ve

Karmaşık (C) olmak üzere 3 kategoriye ayrılmaktadır. Son seviye olan kırığın büyüklüğüne göre A1, A2, A3; B1, B2, B3; C1, C2, C3 alt gruplara ayrılır [13].

AO/OTA sınıflandırma tekniği ile elde edilmiş 32-A1 şeklinde kodlanmış bir kırık ele alındığında; Femur (3) kemiği, Diafiz (2) bölgesi, Basit(A) ve Spiral (1) bir kırık olduğu anlaşılmaktadır. Kemik türünün bu şekilde tespit edilmesinde sonra uygulanacak tedavi AO/OTA sınıflandırma sistemi yardımıyla belirlenecektir [13]. Şekil 2.8’de AO sınıflandırma sistemine göre femur diafiz kırıklarının sınıflandırılması gösterilmiştir.



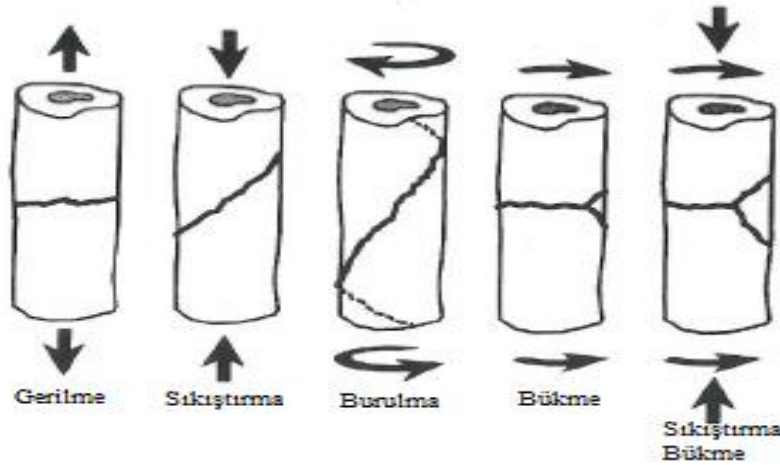
Şekil 2.8 AO/OTA sınıflandırmasına göre femur kemiği diafiz bölge kırıklarının sınıflandırması [13].

AO/OTA ya göre basit, kama ve karmaşık tipteki kırıkların spiral kırıkları burulma veya burulma ile oluşabilecek farklı kuvvetlerinden kaynaklanmaktadır. Eğilme kuvvetleri, basit eğik, parçalanmış kama, bükülme kaması veya düzensiz karmaşık kırıklara neden olabilir. Ancak AO/OTA'nın sınıflandırılması kırılmaya neden olan kuvvetleri doğrudan karakterize etmemektedir [13]. Upadhyay ve Tanwar çalışmalarında kırılmaya etki eden kuvvetler nedeniyle, dolaylı veya doğrudan yaralanma mekanizmalarını daha spesifik bir şekilde sınıflandırmıştır. Çizelge 5.1’de Upadhyay ve Tanwar’ın çalışmalarında bahsedilen, kırığa sebep olan kuvvet ve kuvvet

bileşenleri sunulmuştur [14]. Şekil 2.9’da kuvvet türleri ve sonucunda oluşan kırık türleri gösterilmiştir.

Çizelge 2.1 Doğrudan ve dolaylı kuvvetler ile meydana gelen kırık türleri.

Kuvvet Türü	Kırık Türü
Gerilme	Enine
Sıkıştırma	Eğik
Burulma	Sarmal
Bükme	Enine & Kelebek
Sıkıştırma & Bükme	Enine & Eğik




Şekil 2.9 Kuvvet türleri ve sonucunda oluşan kırık türleri.

Kırıkların bu doğal sebeplerinin yanı sıra, kemikleri kısaltmak, uzatmak veya yönünü değiştirmek için bazen suni kesiler veya kırıklar oluşturulması gibi sebepleri de vardır. Kemiklerin tamamen kesildiği, yeniden şekillendirildiği veya yeniden hizalanması için kısmen çıkarılması operasyonlarına osteotomi denir. Kalça ve diz osteotomileri de dahil olmak üzere uzun kemiklerde bu tür cerrahi müdahaleler, uzun kemik kırıklarının yapay mekanizasyonu olarak adlandırılır [15].

2.7. KEMİK KIRIKLARININ GÖRÜNTÜLENMESİ

Tıbbi Görüntüleme Teknikleri (TGT) insan vücudunda görüntülenmek istenen kısımlarını cerrahi olarak açmadan, görüntülenmesini sağlayan invaziv olmayan yöntemlerdir. Farklı tıbbi durumların teşhis veya tedavisine yardımcı olmak için kullanılır. Birçok görüntüleme tekniği ve her tekniğin farklı riskleri ve faydaları vardır. Genel olarak, tıbbi görüntüleme alanında kullanılan cihazlar; X-ışını radyografisi (Röntgen), Bilgisayarlı Tomografi (CT), Manyetik Rezonans Görüntüleme (MRI), Ultrasonografi, Elastografi, Optik Görüntüleme, Radyonüklid Görüntüleme (Sintigrafi, Pozitron Emisyon Tomografisi (PET) ve Tek Foton Emisyon Bilgisayarlı Tomografi (SPECT)), Termografi ve Terahertz tıbbi görüntüleme cihazlarıdır. Bu tez çalışmasında kemik kırıklarının teşhisi için en çok tercih edilen X-ışını Radyografisi, CT, MRI ve Ultrasonografi ele alınmıştır. Şekil 2.10'da medikal görüntüleme cihazlarının genel çalışma prensibi anlatılmıştır [16,17].




Şekil 2.10 Medikal görüntüleme cihazlarının çalışma prensibi.

Radyografi, 1895 yılında Röntgen tarafından X-ray'in keşfedilmesi ile başladı. Tıbbi kullanımı Röntgen'in eşinin elini, X-ışını ile oluşturulmuş bir fotoğraf plakasında resmini görmesi ile keşfedilmiştir. Bir görüntüleme tekniği olarak CT 1963 yılında Cormack tarafından tanımlanmıştır ve 1972'de Hounsfield ilk klinik CT tarayıcısını sunmuştur. O zamandan beri, klinik X-ray ve CT tıbbi görüntülemede devrim yaratmıştır ve X-ray keşfinden bu yana radyolojide en büyük ilerleme olarak kabul edilir. MRI üzerine araştırmalar 1970'lerin başında başlamıştır ve ilk MRI prototipleri 1980'de test edilmiştir [18,19].

2.7.1. Manyetik Rezonans Görüntüleme (MRI)

Manyetik rezonans görüntüleme ilk kez insan vücudunda 1973 yılında Paul Lauterbur tarafından uygulanan ve yüksek çözünürlükte görüntüleme imkanı sağlayan bir görüntüleme sistemidir [20]. Manyetik rezonans görüntüleme (MRI) suda bulunan hidrojen atomlarından ve kemik iliğinin yağ içeriklerinde geri gelen sinyali ölçerek kemiğin 3 boyutlu görünümünü hakkında bilgi sağlayan, iyonlaştırıcı bir yapısı olmayan görüntüleme tekniğidir. Radyo frekansı (RF) ile birlikte bir manyetik alan uygulanması sonucunda, hidrojen atomları uyarılır. Manyetik alan etkisinin kaldırılması ile hidrojen atomları serbest kalır, RF bobinleri tarafından algılanan bir RF sinyali yayarlar. Bu RF sinyalleri, hidrojen atomlarının yeri ve çevresi hakkında bilgi sağlar [18]. Şekil 2.11’de MRI cihazı ile kemik görüntülenmesi işlemi gösterilmiştir.



Şekil 2.11 MRI cihazı ile kemik görüntülenmesi işlemi.

Kemikte bulunan su miktarının düşük olması ve çevre dokuların varlığı MRI görüntülerinde düşük sinyal-gürültü oranına (SNR: Bu değer sinyal gürültü oranıdır. Yüksek olursa görüntünün kalitesi yüksek, düşük olursa görüntü granüllü ve kalitesi anatomik detaydan yoksun olur) neden olur. Ayrıca SNR, vokselle boyutundan olumsuz

etkilenir ve sonuç olarak analiz çözünürlüğünü birkaç yüz μm civarında sınırlar. Bu nedenle MRI genellikle periferik bölgelerde (Distal Radius, distal tibia ve kalkaneus) kullanılır [16,20].

SNR'yi ve analiz sonuçlarını iyileştirmek için yararlanılan stratejilerden biri, RF dedektör boyutunun küçültülmesidir. Bu nedenle, özel olarak tasarlanmış sarmal dedektörler ile birleştirilmiş klinik MRI tarayıcılar kullanılarak yüksek çözünürlüklü MRI geliştirilmiştir. Bu teknikle, kemik yapısının çözülmesine ve ana mimari özelliklerinin (kalınlık, ayrılma, sayı, anizotropi ve bağlanma derecesi) değerlendirilmesine izin veren 110 μm kadar düzlem içi çözünürlükle çalışmak mümkündür [16,20].

Katı hal MRI deneysel aşamada olan bir başka manyetik tabanlı görüntüleme cihazıdır. Özel yapım bobinler kullanarak, kemik dokusu mineral yoğunluğunu belirlemek için kemiğin mineral fazında bulunan fosfor atomlarının rezonans sinyalini algılamayı amaçlar. Bu yöntem, hayvan modellerinde kemik yoğunluğunun değerlendirilmesinde umut verici sonuçlar göstermiştir. Ancak uygulanan güçlü manyetik alan (en az 4,7 tesla) etkisi ile birlikte uzayan görüntüleme süreleri sebebi ile klinik kullanıma uygun değildir [16,20].

Genel olarak, MRI teknikleri pahalı ekipman ve karmaşık bir son işlem aşaması gerektirir. Bu yüzden klinik uygulamalarda MRI cihazının kullanılabilirliğini azaltır.

Aşağıda MRI cihazının avantajları, dezavantajları ve kullanıldığı alanlar belirtilmiştir [20,21].

Manyetik Rezonans Görüntüleme Avantajları;

1. Noninvaziv ve ağrısız.
2. İyonlaştırıcı radyasyon kullanmaz radyo frekansı kullanır.
3. Yüksek çözünürlük.
4. Operatörden bağımsız çalışma sağlar bu sayede hata oranı düşüktür.
5. Kontrast madde kullanımına ihtiyaç yoktur.
6. Yumuşak dokularda iyi sonuçlar sunar.

Manyetik Rezonans Görüntüleme Dezavantajları;

1. Hasta bünyesinde bulunan bazı yardımcı sistemlere karşı duyarlıdır (kalp pili, anevrizma klipsleri vb.).
2. Tetkik süresi uzundur.
3. Diğer görüntüleme tekniklerine göre pahalı bir yöntemdir.
4. Gerçek zamanlı değildir.
5. Bazı insanları klostrufobik hissettirebilir.

MRI kullanılan alanlar;


1. Kemik kırıklarının görüntülenmesi.
2. Beyin ve omurilik anormalliklerinin incelenmesi.
3. Tümör, kist ve diğer anormalliklerin incelenmesi.
4. Ameliyat planlama süreçleri.
5. Vücuttaki patolojik dokuların teşhis edilmesi.

2.7.2. Bilgisayarlı Tomografi Görüntüleme Teknikleri (CT)

CT X-ışınının kullanıldığı kesitsel bir görüntüleme tekniğidir. Bilgisayar desteği ile görüntülerin oluşturulduğu ilk biyomedikal görüntüleme yöntemidir [22]. CT görüntüleme teknikleri, kemiği farklı yönlerde bir X-ray ışınına maruz bırakarak, kemikten geri iletilen radyasyonun tespiti ile 3 boyutlu kemik organizasyonunun değerlendirilmesine olanak sağlar. X-ışını demetinin zayıflaması ışığa maruz bırakılan malzemenin yoğunluğuna bağlı olduğundan, açığa çıkan radyasyonun yoğunluk profili, analiz edilen yön boyunca kemik yapısının bileşim bilgilerini içerir. Spesifik yeniden yapılandırma algoritmaları sayesinde, gri tonlamalı görüntüleri oluşturmak için çeşitli doğrultular boyunca radyasyon profilleri değerlendirilir. Bu görüntüler sırasıyla taranan kemik numuneleri üzerinde morfometrik ve dansitometrik analizler yapmak için detaylandırılmıştır [16,23].

Günümüzde, kliniklerde in vivo numunelerde kullanılan CT cihazlarının gösterdiği performans ile ex vivo (canlı dışında) numunelerin veya küçük hayvanların kemik yapılarının 3D organizasyonunu analiz etmek için kullanılan laboratuvar CT'lerin performansları arasında fark vardır. Klinik CT'ler görüntüleri, aslında birkaç yüz μm civarında düşük çözünürlüklerde elde ederken, laboratuvar CT'leri 1 μm daha az

çözünürlüklerde elde edebilir. Araştırma amaçlı tasarlanan CT'lerin yüksek çözünürlüğe sahip olmasının nedeni, güçlü kaynakları, güçlü detektörlere sahip olması, yüksek radyasyon dozları ve hastalarda gerçekleştirilemeyen uzun tarama süreleridir. Şekil 2.12'de CT ile kemik kırığı görüntülenmesi işlemi gösterilmiştir [16,23].



Şekil 2.12 Bilgisayarlı tomografi ile kemik kırığı görüntülenmesi işlemi.

Aşağıda CT cihazının avantajları, dezavantajları ve kullanıldığı alanlar belirtilmiştir [21].

CT avantajları;

1. İnvaziv olmayan, hızlı ve ağrısız.
2. İyi uzamsal çözünürlük sunması.
3. Ayrıntılı kesitler halinde görüntülerin elde edilmesi.
4. Hasarlı doku ve sağlıklı doku ayrımının hızlı ve bariz olması.

CT dezavantajları;

1. İyonlaştırıcı radyasyona maruz kalmak, yaşamın ilerleyen safhalarında kansere yakalanma riskini oluşturması.
2. Gerçek zamanlı değildir.

3. Yumuşak doku kontrastının az olduğu yerlerde daha az çözünürlük sağlar.


CT kullanılan tıbbi alanlar;

1. Kemik kırıklarını detaylı ve etkili görüntülenmesi.
2. Kaza, düşme gibi travmatik durumlarda iç organların görüntülenmesi ve iç kanama tespiti.
3. Kafa, boyun, göğüs, batin bölgelerinde ve iç organlarda şüphelenilen hastalıklara tanı konulması sürecinde.
4. Tedavi etkinliğinin izlenmesi (kanser tedavisi gibi).

2.7.3. Ultrasonografi

Medikal görüntüleme de teşhis amacıyla kullanılan Ultrasonografi tekniği ilk sıralarda gelmektedir. Ultrason ile görüntülemenin temelini insan kulağının duyamayacağı frekans değerlerinde ses dalgalarının kullanılması oluşturmaktadır. İnsan kulağının duyarlı olduğu ses frekansı aralığı 20 Hz ile 20 Khz'dir. Bu frekans değerlerinin üzerinde olan insan kulağının işitemeyeceği ses dalgalarına ultrasonik dalgalar denir. Medikal görüntüleme de kullanılan ultrason cihazının kullandığı ses dalgalarının frekans aralığı 2-10 Mhz aralığındadır [21].

Ultrason kullanımı kas-iskelet sistemi rahatsızlıklarının tanısında yaygın olarak kullanılsa da kırık teşhisi bakımından yaygın olarak benimsenmemektedir. Ultrason, pediatrik kırık teşhisinde, uzun kemik kırıklarının hastane öncesi klinik ortamda tanımlanmasında ve stres kırıklarının saptanmasında nadir olarak kullanılabilir. Ancak erken kallusu (kırık kemiklerin kaynaması esnasında oluşan bağ doku) tespit etme konusunda oldukça iyidir. Ek olarak, uzun kemik kırıklarındaki kaynamama ile birlikte oluşan, kallusun ultrason ile değerlendirilebilmesi, belirgin bir kalsifikasyon (dokularda Ca mineralinin depolanması) ve yoğunluk eksikliğini gösterir [21]. Şekil 2.13'te Ultrasonografi cihazı ile kemik kırığı görüntülenmesi gösterilmiştir.



Şekil 2.13 Ultrasonografi ile kemik kırığı görüntüleme [24].

Aşağıda Ultrasonografi cihazının avantajları, dezavantajları ve kullanıldığı alanlar belirtilmiştir [21].

Ultrasonografi Avantajları

1. Noninvaziv ve ağrısızdır.
2. İyonlaştırıcı radyasyon kullanmaz.
3. Yüksek çözünürlük.
4. Real time olarak çalışır.

Ultrasonografi Dezavantajları

1. Standart yönergeler olmadığı için görüntü kalitesi operatöre bağlı.
2. Çok zaman alabilir.
3. Hidrasyon durumundan etkilenir.

Ultrasonografi kullanılan tıbbi alanlar

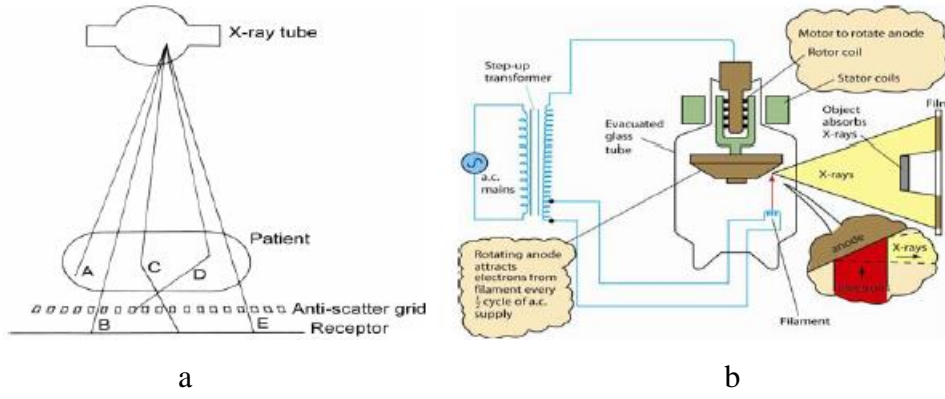
1. Hamilelik sırasında fetüsün gelişiminin kontrol edilmesi.
2. Abdomen bölge organlarının görüntülenmesi; pankreas, aort, karaciğer vb.

3. Kırık kemiklerin kaynaması sırasında oluşan bağ dokunun (kallus) görüntülenmesi.
4. Klinik ortamlarda kırıkların ön tanımlanması.


2.7.4. X-ray Radyografi

Günümüzde kullanılan biyomedikal görüntüleme sistemlerinin temelini oluşturan X-ışınları 1895 yılında Alman Fizikçi Wilhelm Conrad Roentgen tarafından geliştirilmiştir. Sonraki yıllarda X-ışınlarına röntgen adı verilmiştir [25].

Radyografi, insan vücudundaki bölümleri görüntülemek için X-ışını gibi iyonlaştırıcı elektromanyetik radyasyon kullanan medikal görüntüleme tekniğidir. X-ışını, katılara nüfuz edebilen ve gazı iyonize edebilen yüksek enerjili bir elektromanyetik radyasyondur. X-ışını, 0.01 ile 10 manometre arasında dalga boyuna sahiptir. Tıbbi görüntülemede X-ışını vücuttan içeri girer, farklı dokuların yoğunluğuna ve atom numarasına göre farklı seviyelerde emilir veya zayıflatılır sonucunda bir X-ışını profili oluşturulur. X-ışını profili, görüntüyü oluşturan bir detektöre kaydedilir ve görüntüye dönüştürülür. X-ışın tüpünün yapısı Şekil 2.14'te gösterildiği üzere, filament tel elektrik akımı ile ısıtıldığında elektronlar yayılır. Dönen bir metal anot, filament telinde alternatif akım sağlayan elektronları çeker. Bu olayın gerçekleştiği anot alanına odak noktası denir. Kullanılan X-ışını enerjileri 17-150 KeV aralığındadır. Alınmak istenen görüntü için kabul edilebilir radyasyon dozu ile ulaşılabilir görüntü kontrastı birbiriyle bağımlıdır [19,21,26]. Şekil 2.15'te X-ışını radyografisi ile elde edilmiş görüntüler sunulmuştur.



Şekil 2.14 a) X-ray görüntüleme b) Dönen X-ray tüpü.



Şekil 2.15 X-ışını radyografisi ile edilmiş farklı kemik türlerine ait görüntüler.

Aşağıda X-ray radyografi avantajları, dezavantajları ve kullanıldığı alanlar belirtilmiştir [21].

- X-Ray Radyografi Avantajları
 - Noninvaziv, hızlı ve ağrısız olması.
 - Tıbbi ve cerrahi tedavi planlamalarında etkin kullanılması.
 - Pahalı bir görüntüleme tekniği olmaması.
- X-Ray Radyografi Dezavantajları
 - İyonlaştırıcı iyonlara maruz kalmak, yaşamın ilerleyen safhalarında kansere yakalanma riskine sebep olabilir.
 - Nispeten yüksek radyasyona maruz kalma durumunda meydana gelen katarakt, cilt kızarması ve saç dökülmesi gibi istenmeyen durumlara neden olabilir.

- X-ray Radyografi kullanılan tıbbi alanlar
 - Kemik kırığının tipini ve derecesini belirlemek için kullanılan projeksiyonlu radyografiler.
 - Mide, bağırsak, kolon gibi organların vücuttaki hareketlerini görüntülemek için kullanılan floroskopi radyografileri ayrıca kalp ve beyin damarlarını incelemek için de kullanılabilir.
 - Meme dokusunun teşhis ve taranması için kullanılan mamografi.
 - Kemik mineral içeriğini ve yoğunluğunu ölçmek için kullanılan kemik dansitometresi.
 - Eklem için kullanılan artrografi.
 - Rahim ve Fallop tüplerinin incelenmesinde kullanılan histerosalpingogram.

BÖLÜM 3

LİTERATÜR İNCELEMESİ

Son yıllarda yapılan biyomedikal alandaki akademik çalışmalar bilgisayar donanımı ve yazılımı alanlarını oldukça etkili ve yoğun kullanmaktadır. Biyomedikal alanda bu gelişmeyi sağlayan birçok alan içerisinde tercih edilen konular tıbbi görüntüleme ve analiz uygulamalarıdır [27]. Tıbbi görüntüleme ile hastalardan (anlık veya daha önce) alınan görüntüler, görsel bilgiler sunarken analiz uygulamaları görüntülerden elde edilen farklı özellikler doğrultusunda görüntü, sinyal, sayısal veya sözel sonuçlar verir. Bu sayede, tıbbi görüntüleme ve analiz uygulamaları hekimlere büyük ölçüde destek sağlar ve hastaların hayatlarını kolaylaştırır.

Görüntü işleme, bilgisayar biliminde oldukça önemli ve popüler bir konudur. Dijital sinyal işlemenin alt konusudur. Dijital görüntü işleme temelde dijital görüntüler girdi olarak kullanılır işlem sonucunda çıktının dijital görüntü ve veya sayısal bir değer olmasını amaçlar. Sağlık sektöründe sayısal görüntü işleme kullanılan yazılım uygulamalarında görüntülerin ön işlenmesi, bölütleme ve sınıflandırma gibi birçok yöntem kullanılır. Literatürde 2010 yılından bu yana kemik kırıklarının tespiti hakkındaki çalışmaların yıllara göre sayıları Çizelge 3.1’de gösterilmiştir.

Çizelge 3.1 Yıllara göre kemik kırıkları tespiti hakkında ki çalışmaların sayısı.

Yıllar	Yayın Sayısı
2010	2
2012	2
2015	4
2017	5
2018	1
2019	1
Toplam	15

Zheng vd. çalışmalarında uzun kemikler üzerinde kırıkların teşhisini gerçekleştirmişlerdir. Gerekçe olarak kemik kırıklarının teşhisinin tamamı ile hekim bilgi birikimine ve görsel tanımlama becerilerine bırakılmaması gerektiğini öne sürmüşlerdir. Kemik kırıklarını sınıflandırmada AO (Arbeitsgemeinschaft für Osteosynthesefragen – Osteosentez Çalışma Grubu) sınıflandırma sistemini kullanmışlardır. Bir femur kemiği proksimal, diafiz, distal kısımlardan oluşmaktadır. Zheng vd. uygulamalarında ise sırasıyla üst kemik, orta kemik, alt kemik olarak tanımlamıştır. AO sınıflandırma sistemine göre oluşturulacak kırık kodlamaları için ilk olarak kırık bölgesini tespit etmişlerdir. Uygulamalarında sırasıyla bölge doldurma (kenarları belirtilen kemik parçasının içerisini boyama işlemi), bölge inceltme ve etiketleme (içeriği doldurulan kemik görüntüsünü tek pikseller şeklinde bir çizgi olarak elde edilmesi), hough dönüşümü, görüntü döndürme (hough dönüşümü ile elde edilen tepe noktası açısına göre parçaların döndürülmesi), dikey integral iz düşüm (döndürülen parçaların gri değerlerinin toplanması ve grafiksel gösterilmesi), elde edilen eğrilerin farklarının alınması (grafik değerlerinin ani düştüğü yerleri kırık başlangıcı olarak alınır), eğrilerin birleştirilmesi (kırık başlangıcı olabilecek yerlerden eğriler birleştirilir) adımlarını gerçekleştirerek kırık görüntüsünü teşhis etmişlerdir [28].

Smith vd. travmatik yaralanmalar ile meydana gelen pelvik kırıklarını tespit etmişlerdir. Çalışmalarında düşük maliyet ve kolay ulaşım imkanları nedeniyle tercih

edilen röntgen görüntülerini kullanmışlardır. Ancak düşük kalitede olduklarını ve bazı görüntü özelliklerinin gözden kaybolabileceğini vurgulamışlardır. Deformasyonu önlemek için Spline Enterpolasyon (SP) kullanarak Aktif Şekil Modeli (ASM) yaklaşımını iyileştiren, birleşik eğri algoritmasını geliştirmişlerdir. Pelvik kemiği üzerinde halkalar oluşturmuşlardır. Halkalara yakın kırıkları tespit edebilmek için halkaları üst üste bindirmişlerdir. DWT (Ayrık Dalgacık Dönüşümü) kullanılarak kırıkları tespit etmişlerdir. Tüm işlemler sonucunda kırıklar hakkında kırık yok, küçük kırık, şiddetli kırık bilgilerini vermişlerdir [29].

Mahendran vd. görüntü sınıflandırmasına dayalı kırık tespiti gerçekleştirmişlerdir. Çalışmalarında sınıflandırmaya ek olarak alan ve hacim bilgisi de sunmuşlardır. X-ray görüntülerinde kırıkları tespit etmek amacıyla sınıflandırıcı algoritmalar kullanmışlardır. Görüntülerden çıkarılan farklı özellikler kontrast, homojenlik, ortalama, varyans, standart sapma, korelasyon, Gabor Yönelimi (GO), Markov Rastgele Alan (MRF), Yoğunluk Gradyan Yönü (IGD) dır. Sınıflandırıcı olarak BPNN, DVM, NB füzyon tabanlı sınıflandırıcılar kullanılmıştır. Bu özellikleri ve sınıflandırıcıları kullanarak dört çoklu sınıflandırıcı geliştirmişlerdir. Deneysel sonuçlarda ise füzyon tabanlı sınıflandırıcıların algılama kapasitesini artırdığı ve DVM ve BPNN kombinasyonunun %97,97 ile en iyi sonucu verdiğini ortaya koymuşlardır [30].

Chowdhury vd. pelvik kırıklarını hacimsel CT görüntülerini kullanarak kırıkları tespit edebilen otomatik bir yöntem geliştirmişlerdir. Kemik görüntüsü üzerinde kırığı içeren potansiyel bölgeyi ilk olarak yoğunluk ve eğrilik bilgileri kullanılarak tespit edilmiştir. İkinci olarak yerelleştirme algoritması, ortalama ve gauss eğriliğinin dayalı olarak tespit etmişlerdir. Eğrilerde minimum kesim noktaları ve uzamsal olarak tutarlı eğri bölgelerinin FP (yanlış pozitif) sonuçları ürettiği görülmüş ve ortak hacimsel grafik kesimlerine ve uzamsal olarak tutarlı olan bölgelerin kullanımı sayesinde sonuçlarda FP oranı minimize edilmiştir [31].

Ekşi vd. gerçekleştirdikleri çalışmalarında sadece uzun kemikler üzerindeki kırıkları tespit edebilecek ANN (Yapay Sinir Ağları) tabanlı bir uygulama geliştirmişlerdir. Uygulamada x-ışını görüntüleri üzerine önce aritmetik ortalama filtresi ve

segmentasyon içinde üç farklı bölütleme algoritmalarından (K-ortalama, Bulanık C ortalama ve Otsu) Otsu kullanılarak çalışma gerçekleştirilmiştir. Ön işleme adımlarının ardından işlenmiş görüntüler ANN kullanılarak kırık tespiti gerçekleştirilmiştir ve kırıkların %89 oranında doğru tespit edebildiği [12].

Bulut vd. hekimlerin hastalardan elde edilen x-ray görüntülerinden yola çıkarak teşhis koyduğu sistemde gözden kaçmalar ve yanlış teşhisler olabildiğine dikkat çekmiş ve klasik teşhis yöntemleri yerine bilgisayar destekli otonom bir teşhis yöntemi geliştirmeyi amaçlamıştır. Bu sayede insanlardan kaynaklı hataların önüne geçmek istemiştir. Sabri vd. literatürün aksine uygulamayı üç kısımda oluşturmuş ve ilk olarak segmentasyon ile başlamıştır ardından görüntü iyileştirme yapmıştır ve son olarak kırığı tespit etmiştir. Segmentasyon işleminde ilk DICOM formatındaki görüntüleri MATLAB ortamına aktarmışlardır ve sırasıyla yumuşatma (görüntüde bölgeleri belirgin kılmak), alt şapka metodu (disk yapısal elementi kullanarak bölgelerin farklı olan piksel değerlerini yakınlaştırmak), toplam piksel değeri ortalaması (eşik değeri olarak atanarak siyah beyaz görüntü elde edilir) yöntemleri kullanılmıştır. Görüntü iyileştirme aşamasında, kemik dokusu ve arka planı bozucu nitelikteki küçük görüntülerin temizlenmesi yer almaktadır. Bu işlem yapılırken ufak da olsa istenilen görüntüden ayrıntı kayıpları yaşanmıştır. Kemik kırığının tespitinde önemli olan kırık niteliği taşıyan piksel gruplarının belirlenmesi işlemidir. Kemik kırık tespiti, muhtemel kırık kısımların belirlenmesi (alınan parçalar koordinat değerlerine göre gruplandırılması), muhtemel kırık kısımların alınması (gruplandırılan parçalar üzerinde ortalama yer analizi), kırık bölge analizinin yapılması (analizden elde edilen koordinat çevresi çember içerisine alınır), muhtemel kırık bölgelerin gösterimi (çember içerisinde kalan piksel gruplarının görüntülenmesi) olarak gruplandırılabilir. Sabri vd. sonuç olarak bazı görüntülerde iyi sonuç almalarına karşın tüm görüntülerde tam etkili bir sonuç için daha iyi bir segmentasyon algoritmasının gerekliliğini vurgulamıştır [32].

Kaur vd. 2016 yılında gerçekleştirdikleri “Görüntü Segmentasyonu Kullanarak Kemik Kırığı Tespiti” adlı çalışmada otomatik bir şekilde kemik kırığı tespiti yapan çalışma gerçekleştirdiler. Bu çalışmada segmentasyon yöntemi olarak, Bulanık C-Ortalamalar (FCM) ve Çok Seviyeli Dalgacık Algoritmalarını (MWA) kullanmışlardır. Threshold

ve morfolojik operatörlerde uygulanarak verimli bir algoritma oluşturulmuştur. Çalışma sonucunda %89.6 Doğruluk (Accuracy), %93.1 oranında Kesinlik (Precision) ve %95.5 Duyarlılık (Sensitivity) değerleri elde edilmiştir [33].

Myint vd. “X-RAY Görüntülerinde Bacak kemiği kırığı tespiti” adlı çalışmalarında bacak kemiklerinde oluşan kemik kırıklarını tespit etmek için bir görüntü işleme tekniği sunmuşlardır. Önerilen bu çalışmada, bölütleme için Canny kenar bulma algoritması ve çizgileri algılamak için ise Hough dönüşümü tekniğini kullanmışlardır. Sistemde yer alan üç ana adım, ön işleme, segmentasyon ve kırık tespiti için geliştirilen algoritmadır [34].

Nascimento vd. “Ultrason Görüntüleri Baz Alınarak Bilgisayar Destekli Kemik Kırığı Tespiti” adlı çalışmalarında kemik kırıklarını bilgisayar destekli teşhis edebilmek için kemik hatlarında çizgilerin bulunmasını esas almışlardır. Gerçekleştirilen çalışmada sırası ile gürültü azaltma, kemik hattının tanımlanması ve son olarak elde edilen kemik hattı üzerindeki olası kırıkların teşhis edilmesi adımları gerçekleştirilmiştir. Çalışmada kullanılan 44 görüntü için %89 oranında başarı elde edilmiştir [35].

Dimililer “Akıllı Kemik Kırığı Tespit Sistemi” adlı çalışmasında kemik kırıklarını otomatik tespit edebilen bir sınıflandırma sistemi geliştirmiştir. Gerçekleştirilen çalışma geri yayılım sinir ağlarını kullanır. İlk aşaması görüntülerin işlenmesi, ikinci aşaması da görüntülerin sınıflandırılması olan iki aşamadan oluşmaktadır. Çıkarımlar, Ölçek Değişmez Özellik Dönüşümü (Scale Invariant Feature Transform, SIFT) algoritması kullanıldığında 70 adet görüntüden 64 adet kırık görüntüsünü doğru tahmin ederek %91.4 oranında, Geri Yayılımlı Sinir Ağları (Back Propagation Neural Networks, BPNN) algoritması kullanıldığında 70 adet görüntüden 66 adet kırık görüntüsünü doğru tahmin ederek %94,3 oranında başarı elde etmiştir [36].

Malashree vd. “Kemik kırığının Yarıçapının Otomatik Tespiti ” adlı çalışmalarında, kemik kırığını tespit eden ve kemik kırığının yarıçapını otomatik bir şekilde saptayabilen bir sistem geliştirmiştir. Çalışma, görüntü ön işleme, segmentasyon, özellik çıkarma ve kemik kırığının yarıçapının tespit edilmesi olarak üç adımdan oluşmaktadır. Programa dili olarak MATLAB kullanmışlardır. Çalışmada 20 adet

röntgen görüntüsü kullanılmış ve algoritma (sistem) 18 tanesinin kırık yarıçapını doğru tahmin ederek %90 oranında başarı sağlamıştır [37].

Manjari vd. “Kemik Kırıklarının Teşhisi ve Sınıflandırılmasında Gri Düzey Eş-Oluşum Matrisi (GLCM) Özellik Çıkarım Algoritmasının Kullanımı” adlı çalışmalarında kemik kırıklarının tespiti için ilk olarak X-Ray görüntülerinde ön işleme ardından kenar bulma algoritması Canny kullanılmıştır. Segmentasyon işlemi K-ortalama kümeleme algoritması kullanılarak gerçekleştirilmiştir. Algoritma son olarak özellik çıkarım aşamasında GLCM öznitelik çıkarma algoritması kullanılarak sınıflandırma yapar. Çalışmada kullanılan görüntü sayısı hakkında bilgi verilmemiş ancak %94 oranında başarı elde edilmiştir [38].

Kaur vd. “Ortopedik Röntgen Görüntülerinde Kırıkların Tespiti” adlı çalışmalarında çeşitli türlerdeki kemik kırıklarından bir araya gelen veri seti kullanmışlardır. Görüntüler üzerine medyan filtresi ve Wiener filtresi kullanılarak çeşitli gürültüler giderilmiştir. Segmentasyon aşamasında FCM kümeleme algoritması kullanılmıştır. Daha sonra, görüntüde olası maksimum kırık alanını tanımak için çeşitli yoğunluk yöntemleri uygulanmıştır. Çalışmada 2 adet sağlıklı 33 adet kırık görüntü kullanılmış ve %93.96 oranında başarı elde edilmiştir [39].

Öztürk vd. “Görüntü işleme teknikleri ve yapay ağlar kullanılarak kemik kırıklarının tespiti” başlıklı makalesinde, kırık tespiti için bir yapay sinir ağı önermişlerdir. Görüntü bölütleme için K-ortalamalar yöntemi kullanılan yöntem %89 başarı oranına sahiptir [40].

Bhakare vd. “Görüntü İşleme Kullanarak Kemik Kırığı Tespiti İçin Yeni Bir Yaklaşım” adlı çalışmaların da X-Ray veya CT görüntüleri kullanarak kemik kırığının tespiti için analitik teknikler sunmuşlardır. Çalışmada sırasıyla görüntü ön işleme, kenar algılama, segmentasyon, görüntü sınıflandırıcı ve son olarak da kırılma tespiti aşamaları gerçekleştirilmiştir. Çalışmada kullanılan görüntü sayısı hakkında bilgi verilmemiş ancak %85 oranında başarı elde edilmiştir [41].

Rani vd. “Gelişmiş Morfolojik Teknikler Kullanılarak Bacak kemiği kırığı Segmentasyonu ve Tespiti” adlı çalışmalarında kemik kırıklarının doğrudan tespitinde hata oranının yüksek olması nedeniyle görüntü işlemenin kırık tespitinde önemli rol oynadığını öne sürmüşlerdir. Çalışmalarında X-ray/CT görüntüleri üzerinde kırık alanın doğru tanımlanması için Laplacian kenar algılama yöntemini kullanan bir görüntü işleme tekniği sunmuşlardır. Kullanılan tekniğin doğruluğunu ve hassasiyetini analiz etmek için kırık alanın ortalama ve standart sapma değerlerini hesaplamışlardır. NIVISION asistan yazılımını kullanmışlardır ve istatistiksel parametreler hesaplamışlardır [42]. Literatürde 2010 yılından bu yana kemik kırıklarının tespiti hakkındaki çalışmaların paylaşılan başarı yüzdeleri Çizelge 3.2’de gösterilmiştir.

Çizelge 3.2 Kemik kırıkları tespiti hakkındaki çalışmaların başarı yüzdeleri.

Referanslar	Yıl	Accuracy (%)
Ekşi vd.	2012	89.00
Kaur vd.	2015	89.60
Nascimento vd.	2015	89.00
Dimililer	2017	94.30
Malashree vd.	2017	90.00
Manjari vd.	2017	94.00
Kaur vd.	2017	93.90
Öztürk vd.	2017	89.00
Bhakare vd.	2018	85.00
Sudha vd.	2019	90.00

BÖLÜM 4

KULLANILAN PROGRAMLAR VE TEMEL PAKETLER

Programlama dilleri, barındıkları çeşitlilik ve farklı alanlara hitap edebilme yetenekleri sayesinde akademik ve sektörel alanlarda önemli bir yere sahiptir. Teknolojik gelişmeler ile bilgisayarların üzerine düşen yükte gittikçe artmaktadır. Bu durum dezavantaj gibi gözükse de geliştirilen uygulamalar görüntü işleme, yapay zeka, finansal analizler, kontrol sistemleri, elektronik haberleşme gibi bir çok alana hitap hitap ediyor olması büyük avantajdır. MATLAB'ın ve Python'ın sayısal görüntü işleme üzerine ve için çeşitli kütüphaneleri bulunmaktadır. Bünyesinde bulundurdukları birçok hazır paket, sınıf ve fonksiyon sayesinde dijital görüntü işleme uygulamalarının geliştirilmesinde oldukça etkili programlama dilleridir. [43] Hem MATLAB hem Python yorumlanabilen dillerdir. Her ikisi de dinamik olarak yazılmış programlama dilleridir. Her iki dil içinde değişkenlerin kullanılmadan önce tanımlanması gerekir. Her ikisi de hızlı programlamaya izin verir.

4.1. PYTHON

Python güçlü programlama dillerinden biri olması, kolay söz dizimi ile C++ veya Java'ya genişletilebilir bir dil işleyicidir. Popülaritesi gün geçtikçe artmaktadır [44,45]. Programlama Topluluğu Endeksi (TIOBE), ayda bir kez güncellenen ve programlama dillerinin popülarliğini gösteren endekstir. TIOBE'ye göre Temmuz ayında, Python en çok tercih edilen programlama dili ilan edilmiştir [46]. Python, güncel olarak kullanılan birçok programlama dilinde olduğu gibi biyoinformatik uygulamaları, masaüstü yazılımları, web programlama uygulamaları, veritabanı uygulamaları, bilimsel analizler ve hesaplamaları, mikrodenetleyici kontrol sistemleri, paralel programlama, sayısal görüntü ve işaret işleme uygulamaları, ağ programlama vb. gibi uygulamaları gerçekleştirebilmektedir [47].

Python'ın avantajları;

1. Açık kod kaynak olduğu için ücretsizdir.
2. Windows, Mac ve Linux gibi popüler işletim sistemlerinde kullanılabilir.
3. Python ile yazılan programlar çok az değişiklikle veya hiç değiştirilmeden bir çok işletim sisteminde çok rahat bir şekilde çalıştırılabilir.
4. Yorumlanabilen bir dildir böylelikle, programcılar kod bloklarını ayrı ayrı çalıştırabilir. Derlemeye veya bağlamaya gerek yoktur.
5. Daha hızlı programlama yetisi sağlar.
6. C/C++/Fortran gibi programlardan sözdizimsel (programlama veya kodlama) olarak daha basittir.
7. Son derece okunabilir ve hata ayıklaması kolaydır.
8. Python birçok standart modülden oluşur. Bu modüller dosyaları okuma ve yazma, bilimsel hesaplama, verilerin görselleştirilmesi vb. çeşitli görevleri kolaylıkla gerçekleştirebilir
9. Python dinamik olarak yazılmış bir dildir. Değişkenlerin, kullanılmadan önce beyan edilmesi gerekmez bu sayede kodlama deneyimi olmayan kullanıcılar için de kolaydır.
10. Özel geliştiriciler ve Python kullanıcı toplulukları mevcuttur bu sayede güncel tutulabilmektedir [27,44].

Python'ın dezavantajları;

1. Python'ın odak noktası hızlı programlama yeteneği olduğu için, Python'da geliştirilen bir programın çalışma (yürütme) hızı, C/C++ de gerçekleştirilen aynı programa göre daha yavaştır. Bu durumun üstesinden Python'da yavaş çalışan kod bloklarının C/C++ de geliştirilerek Python'a dahil edilmesi ile gelinebilir.
2. Python'da kod satırları girintileri isteğe bağlı bir durum değildir. Bu durum kodu okunur hale getirir. Ancak, birden çok döngüye ve diğer yapılara sahip bir kod sağa girintili olacağı için kodun okunması zorlaşacaktır [24,27].

4.2. PYTHON TEMEL PAKETLERİ

Python kurulumu ile kullanıcıya birçok çeşitli modül ve kütüphaneler yerleşik(gömülü) olarak sağlanır. Bu modül ve kütüphaneler modüler hesaplama, veritabanı yönetimi, web sunucusu işlevleri vb. işlemler gerçekleştirmektedir. Bu çalışma kemik kırıklarının tam otomatik tespiti ve sınıflandırılmasına odaklandığı için, NumPy, Python Imaging Library (PIL), Matplotlib, OpenCV paketleri açıklanmıştır.

4.2.1. NumPy

NumPy aslında artık kullanılmayan Numeric ve Numarray modüllerinden türetilmiştir. NumPy, bilimsel hesaplama için temel ve güçlü bir Python kütüphanesidir. Numpy, kompleks matematiksel fonksiyonlar, finansal fonksiyonlar, rastgele sayı üretme, lineer cebir, Fourier dönüşümü gibi yetenekleri barındırır. Bunun yanı sıra hızlı ve çok yönlü vektörleştirme, indeksleme, C/C++ ve Fortran kodlarını entegre etmek için araçlar ve kullanışlı doğrusallık sağlar [48,49]. Bu çalışmada ağırlıklı olarak matrisler kullanıldığı için NumPy'ın matris işleme yeteneklerinden faydalanılmıştır.

4.2.2. Python Imaging Library (PIL)

Python Image Library (PIL), Python'ın temel görüntü işleme kütüphanelerinden biridir. PIL görüntü okuma, görüntü yazma, .point operatörü, konvolüsyon kernel ile filtreleme işlemleri, renk uzayı dönüştürme, yeniden boyutlandırma, döndürme, histogram temelli işlemleri JPEG, JPG, PNG, TIFF vb. gibi birçok görüntü formatında gerçekleştirebilir [29,50].

4.2.3. Matplotlib

Matplotlib, 2B çizim kütüphanesidir. Matplotlib, Python'ın matematiksel bir kütüphanesi olan Numpy için çizim kütüphanesidir. GUI araç takımlarını kullanarak çizimleri web sitesi, masaüstü gibi uygulamalara yerleştirmek için nesne yönelimli API sağlamak içinde kullanılır. Matplotlib ile grafikler, resimler, histogramlar

çizdirilebilir. Matplotlib grafikler üzerinde başlık, eksen isimleri, grafik renk deęiřtirme, grafik iřaretleme gibi özellikleri de ierir [29,51].

4.2.4. OpenCV

OpenCV, akademik kurumlar, ticari kuruluřlar, devlet kurumları gibi geniř kullanıcı aęına sahip bir kütüphanedir. Python, Java, C, C++ gibi çeřitli diller iin geliřtirilmiř açık kod kaynak bir kütüphanedir. OpenCv GUI özelliklerini yönetme, görüntü iřleme, nesne algılama, video analizi, camera kalibrasyonu vb. iřlevleri saęlar. Aynı zamanda ierisinde 2000’den fazla görüntü iřleme algoritması bulunduran bilgisayarlı görme, makine öęrenimi yazılım kütüphanesidir. Bu alıřmada görüntü ön iřleme kısmında kullanılmıřtır [49].

4.3. MATLAB

MATLAB matematiksel bilgi iřlem konusunda oldukça iyi bir Amerikan kuruluřu olan Mathworks firmasının geliřtirdięi bir programlama dilidir. MATLAB MATrix LABoratory kelimelerinin kısaltılmasıyla oluřturulmuřtur. Büyük görüntü matrisleri ile iyi alıřmaktadır. MATLAB kod yazılarak veya hazır arayüzler ile programlama yapabilen bir programlama dilidir [52,53].

MATLAB’in avantajları;

1. Windows, Mac ve Linux gibi güncel iřletim sistemlerinde kullanılabilir.
2. Yorumlanabilen bir dildir böylelikle, programcılar kod bloklarını ayrı ayrı alıřtırabilir. Derlemeye veya baęlamaya gerek yoktur.
3. Hızlı ve basit programlama yetisi saęlar.
4. Fonksiyon özme ve grafiklendirme, matrisler ile iřlemler, algoritma iřlemlerinin yanı sıra C, C++, Java gibi birok dil ile geliřtirilmiř programlar ile alıřabilme yetisi sunar.
5. C ve Fortran’da bulunan fonksiyonlar MATLAB’a aęırılabilir ve alt programlanabilir.

6. Lineer cebir, istatistik, optimizasyon, nümerik analiz, optimizasyon, fourier analizi gibi pek çok matematiksel hesaplamaları etkili ve hızlı şekilde yapabilir.
7. Program çıktıları 2B ve 3B şekilde grafiklendirilebilir.
8. MATLAB GUI ile arayüz tasarlanabilir ve geliştirilebilir.
9. Son derece okunabilir ve hata ayıklaması kolaydır.
10. MATLAB yaygın olarak kullanılan dosya okuma yazma, bilimsel hesaplama, verilerin görselleştirilmesi vb. araç kitlerine sahiptir.
11. MATLAB Mathworks tarafından geliştirilmekte ve sürekli güncel tutulmaktadır.

MATLAB'in dezavantajları;

1. MATLAB Lisanslı bir ürün olup özel bir kuruluş olan Mathworks tarafından geliştirildiği için ücretsiz değildir.
2. Nesne yönelimli programlamaya uygun olmadığı için ileri programlama tekniklerine kapalıdır.
3. Ticari kullanımlardan çok akademik kullanımlara yöneliktir [25,33-35].

BÖLÜM 5

KULLANILAN MATERYALLER

Bu tez çalışmasında, Karabük Eğitim ve Araştırma Hastanesi bünyesinde bulunan Ortopedi kliniğinden etik kurul izni alınarak elde edilen 47 adet kırık 18 adet sağlıklı kemik görüntüleri kullanılmıştır.

Bu görüntüler kullanılarak geliştirilen uygulama MATLAB R2019a ve Python programları kullanılarak kodlanmıştır. Uygulamanın ilk aşaması olan görüntü ön işleme (görüntü okuma, boyutlandırma, görüntü renk dönüşümü, filtreleme) ve segmentasyon aşaması Python dile kullanılarak gerçekleştirilmiştir. Python’da görüntü dikdörtgenler halinde dilimlendirilmiştir. Öznitelik çıkarım prosedürü kullanılmıştır. Çıkarılan öznitelikler ile MATLAB ortamında makine öğrenmesi algoritmaları ile sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen veri setinde bulunan kırık ve sağlıklı kemik görüntülerine ait beş örnek Şekil 5.1’de gösterilmiştir.

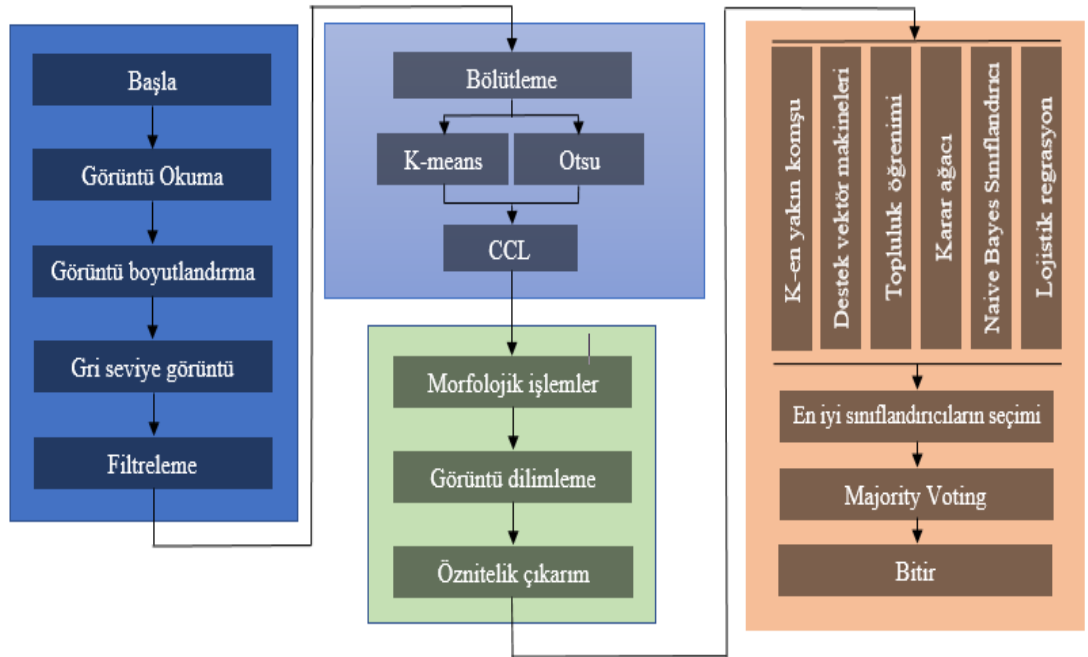


Şekil 5.1 Kırık ve sağlıklı kemik görüntüleri.

BÖLÜM 6

KULLANILAN METOTLAR

Kemik Kırıklarının Görüntü İşleme Yöntemleri ile Tam Otomatik Tespiti ve Yapay Zeka Algoritmaları ile Sınıflandırılması çalışması dört ana bölümden oluşmaktadır. Birinci bölümde görüntülerin ön işlenmesi aşaması yer almaktadır. Görüntülerin okunması, görüntülerin boyutlandırılması, görüntülerin renk uzayı dönüşümü, görüntüler için filtreleme bu bölümde yer alırlar. İkinci bölümde görüntülerin dilimlenmesi yer alır. Üçüncü bölümde dilimlenmiş görüntüler üzerinde morfolojik işlemlerin uygulanması, dilimlere ayrılarak görüntülerin çoğaltılması işlemi ve dilimlere ayrılmış görüntüleri öznelik çıkarımı ile elde edilen verilerin excel formatında kaydetme işlemleri yer almaktadır. Dördüncü ve son adım elde edilen özellik excel dosyalarının MATLAB’da okunması görüntülerin sınıflandırılması işlemidir. Şekil 6.1’de çalışmanın iş- akış diyagramı gösterilmiştir.



Şekil 6.1 Çalışmanın iş akış diyagramı.

6.1. GÖRÜNTÜ ÖNİŞLEME

Gerçekleştirilen çalışmanın ilk basamağı görüntü önışlemedir. Bu aşamada JPEG ve JPG formatındaki karışık olan görüntüler Python ortamında okunmaktadır. Daha sonra okunan görüntüler yeniden boyutlandırma (resize) işleme tabi tutularak 175x325 boyutunda ve JPG formatında kaydedilmiş ve veri seti standart hale getirilmiştir. Yeni görüntüler üzerindeki gürültülerin giderilmesi için öncelikle görüntüler gri seviye haline getirilmiştir. Ardından filtreleme işlemi gerçekleştirilmiştir.

6.1.1. RGB Görüntüleri Gri Seviye Görüntüye Çevirme

Çalışmada RGB görüntü formatında olan sağlıklı ve kırık görüntüler, önışleme safhasında RGB renk uzayından gri seviyeye dönüştürülmüştür. RGB görüntüler R(kırmızı), G(yeşil), B(mavi) olarak kodlanmış yine gri düzeyli üç farklı görüntünün üst üste gelmesi olayı gibi düşünülebilir. Gri seviye görüntüler ise 2 boyutlu matriste piksel değerlerini sadece yoğunluk değerini taşıdığı görüntülerdir. Gri seviyede renk sınırları siyah (0) ve beyaz (255) dır. Bu seviyeler arasında optimize edilmiş değerlerle oluşturulmuş görüntülere de gri seviye (gray scale, monochromatic) görüntüler denir. Denklem 5.1'de, Image değişkeninde tanımlı RGB formatlı bir görüntünün Gri seviye bir görüntüye dönüştürülüşü açıklanmıştır.

$$Image_{Gray} = (Image_R(x, y) + Image_G(x, y) + Image_B(x, y))/3, \quad (6.1)$$

$Image_{Gray}$ (gri seviye görüntüyü temsil eder) $Image$ görüntüsünün x ve y koordinatlarındaki $Image_R$ (RGB görüntünün kırmızı banttaki renk yoğunluk değerini temsil eder), $Image_G$ (RGB görüntünün yeşil banttaki renk yoğunluk değerini temsil eder), $Image_B$ (RGB görüntünün mavi banttaki renk yoğunluk değerini temsil eder) piksel değerleri ayrı ayrı elde edilir. Bununla birlikte aritmetik ortalamaları alınarak RGB bir görüntü, Gri seviye görüntüye dönüştürülmüştür.

6.1.2. Filtreleme

Filtreleme işlemi, görüntülerden elde edilmek istenilen durumlara göre, kenar keskinleştirme, kenar belirleme, görüntü yumuşatma gibi işlemlerde tercih edilmektedir. Filtreler, görüntünün elde edildiği cihazlar veya ortamdan kaynaklanabilen, gürültülerin giderilmesi için de kullanılmaktadır. Filtreleme işlemi, görüntü üzerinde gezdirilen $n \times n$ boyutlarında bir çekirdek matrisin amacına yönelik işlemler gerçekleştirilmesi mantığına dayanmaktadır. Örnek olarak, $n \times n$ boyutunda bir çekirdek matrisin görüntü üzerinde gezdirilmesi ve gezdirilen matrisin merkezindeki piksel gürültülü medyan pikseldir. Medyan filtre uygulanırken ilk olarak, çekirdek matris içerisinde kalan tüm piksel değerleri küçükten büyüğe veya büyükten küçüğe doğru sıralanır. İkinci adım olarak sıralanan piksel değerlerinin medyanı alınır. Üçüncü olarak, gürültülü medyan pikseli ile sıralama sonucunda elde edilen medyan değeri değiştirilir. Bu işlem görüntü üzerindeki tüm pikseller de gerçekleşene kadar devam ettirilir. Medyan filtre genel olarak görüntü üzerinde tuz-biber gürültüsü, Gaussian gürültüsü gürültüleri ortadan kaldırmak için kullanılır ve görüntüde mean filtre kadar olmasa da yumuşatma işlemine sebep olur [55]. Bu çalışmada her bir görüntü üzerinde yapılan testler beraberinde en iyi sonuç 3×3 boyutundaki çekirdek matris ile alınmıştır.

6.1.3. Bölütleme

Kemiklerde kırık tespitinin doğru bir şekilde gerçekleştirilmesinin en temelinde kemik dokusunun ve dışında kalan dokuların (kaslar, bağ dokular, arka plan vb.) başarılı bir şekilde birbirlerinden ayrılması yatar. Ancak X-ışını görüntülerde kemik ile dokuların renk yoğunlukları birbirlerine oldukça yakın değerdedir. Kemikte oluşan kırıkların tespit edilmesi açısından öncelikle kemik dokunun diğer dokulardan ayrılması gerekir. Kemik dokunun ve diğer dokuların birbirine benzerliklerinin bu derece fazla olması sebebi ile karşılaşılabilecek kemik doku kaybının en aza indirilmesi ancak bölütleme yönteminin başarısı ile mümkündür. Literatürde kemik kırıklarını konu alan birçok çalışmada farklı bölütleme yöntemleri kullanılmıştır. Bu tez çalışmasında K-ortalama (K-means), Otsu eşikleme (Otsu threshold) yöntemleri kullanılarak bölütleme işlemi gerçekleştirilmiştir.

6.1.3.1. K-ortalama Algoritması (K-means)

K-ortalama metodu, 1967 yılında MacQueen tarafından tanıtılan veri madenciliği ve makine öğreniminde yaygın olarak kullanılan denetimsiz bir kümeleme yöntemidir. K-ortalama metodu temelde verileri, benzer özelliklerini esas alarak k adet kümeye ayırma esası üzerine çalışır [12]. Benzer özelliklere sahip veriler merkezi bir noktaya olan uzaklıklarına göre kümelenmektedir. Bu kümeleme işlemi ile birlikte aynı kümede yer alan veriler arasındaki benzerlik en yüksek seviyede iken, herhangi iki küme arasındaki benzerlik oldukça düşük olmalıdır [56].

K-ortalama algoritması temelde 4 farklı adımdan oluşur;

- Kullanıcı tarafından küme adedi, k seçilir ve k adet rastgele küme merkezi oluşturulur.
- Küme merkezleri ile veriler arasındaki tüm uzaklıklar belirlenir ve uzaklık matrisi oluşturulur. Veriler kendilerine en yakın kümeye atanır.
- Aritmetik ortalama alınarak kümelerin yeni merkezleri hesaplanır.
- Küme merkezi değişmeyene kadar ikinci ve üçüncü adımlar tekrar hesaplanır. Tüm kümeler için merkezler sabit kalana kadar işlemler tekrarlanır. Küme merkezleri değişmemişse, algoritma sonlanır [56,57].

Verilerin en yakın kümeye taşımak için genellikle nesnelere ve küme merkezleri arasındaki öklid mesafesi hesaplanır. Tüm nesnelere k farklı kümeye yerleştirildiğinde ve küme merkezleri değişmediğinde kümeleme gerçekleşmiş olur. Küme merkezleri değişmeye devam ettiği sürece yineleme (2. ve 3. adımlar) işlemleri devam eder. Küme merkezleri sabit kaldığında algoritma sonlandırılır ve k küme elde edilmiş olur. Küme merkezleri ve nesnelere arasındaki uzaklık hesabı denklem 6.2’de verilmiştir.

$$d(i) = \sqrt{\sum_{i=1}^n (x - x_i)^2 + (y - y_i)^2}, \quad (6.2)$$

x, y = küme merkezinin koordinatları,

x_i, y_i = i . nesnenin koordinatları,

$d(i)$ = Merkez ile i . nesnenin birbirlerine olan uzaklıkları.

Öklid mesafesi, tüm nesnelere en yakını olan küme merkezi arasındaki mesafedir. Bununla birlikte küme içerisindeki nesnelere benzerlik oranları artarken kümeler arasında ki nesnelere benzerlik oranları da giderek azalır [56,57].

Bu çalışmada kullanılan görüntüler itibari ile kemik doku, kemik doku dışında ki kemiğe benzer dokular ve arka plan mevcuttur. Bu nedenle kümelenecek istenen 3 farklı nesne (kemik, kemik dışındaki doku, arka plan) olduğu için bu çalışmada k değeri 3 olarak seçilmiştir.

6.1.3.2. OTSU Eşikleme Algoritması (Otsu Threshold)

Nobuyuki Otsu'nun geliştirdiği Otsu eşikleme algoritması görüntü bölütleme algoritmaları arasında sıkça kullanılan algoritmalarındandır [58]. Otsu metodu görüntüyü threshold tabanlı kümelemek için veya gri seviye görüntüyü siyah beyaz görüntüye çevirmek için kullanılır [59].

Otsu metodu, görüntülerde piksel değerlerinin dağılımlarına göre kümeleme işlemini gerçekleştirir. Otsu metodu uygulanacak görüntülerde gözle görülür şekilde ya iki ayrı piksel yoğunluk değeri olmalı ya da iki farklı histogram (arka plan, nesne) olmalıdır. Sonra bu iki sınıf ayrılarak ve sınıflar arası varyans değeri minimum da tutularak optimum bir threshold değeri hesaplanır [60]. Eğer gri seviye bir görüntü, siyah beyaz görüntüye dönüştürülmek isteniyorsa piksel değerlerine göre bir eşik değeri belirlenir. Belirlenen eşik değeri altında kalan pikseller siyah yani 0 değerini alır yok eğer eşik değeri üzerindeyse beyaz yani 1 değerini alır. Siyah ve beyaz hale gelen pikseller gri seviye görüntünün binary halini oluşturur. Threshold değeri eşitlik 6.3'te ki gibi hesaplanır.

$$\sigma_{\omega}^2(t) = \omega_1(t)\sigma_1^2(t) + \omega_2(t)\sigma_2^2(t), \quad (6.3)$$

Eşitlikte;

$\omega_i(t)$ = t eşiği ile belirlenen iki farklı sınıfın olasılıklarıdır,

$\sigma_i^2 =$ sınıfların varyansı.

Otsu metodu, sınıflar arası varyans değerini minimize olduğunu, sınıflar arası varyans değerinin maksimum olduğunu ifade eder [60].

$$\sigma_b^2(t) = \sigma^2(t) - \sigma_\omega^2(t), \quad (6.4)$$

$$\sigma_b^2(t) = \omega_1(t)\omega_2(t)[\mu_1(t) - \mu_2(t)]^2, \quad (6.5)$$

Sınıflar içi ortalama μ_i ile ifade edilir.

$$\omega_i(t) = \sum_0^t p(i), \quad (6.6)$$

$\omega_1(t)$ değeri t için histogram değerleri hesaplanarak elde edilir.

$$\mu_2(t) = \left[\sum_0^t p(i)x(i) \right] / \omega_1, \quad (6.7)$$

Eşitlikte $x(i)$, i. indexteki histogramın merkezi değeridir. Sınıfların ağırlıkları ve ortalamaları iteratif bir şekilde hesaplanır [45].


Bu çalışmada kullanılan görüntü veri seti içerisinde farklı özelliklerde görüntüler bulunduğu için bölütleme algoritması olarak k-ortalama ve otsu eşikleme metodu birlikte kullanılmıştır. Tüm görüntüler hem otsu eşikleme metodu hemde k-ortalama metodu ile bölütlenmiştir. İki farklı algoritma ile elde edilen bölütlenmiş ikili görüntüler üzerinde CCL algoritması uygulanmıştır. Bununla birlikte, iki bölütleme algoritması sonucu oluşan görüntüler arasında CCL ile seçim yapılarak yeni görüntü veri seti oluşturulmuştur.

CCL yöntemi, dijital görüntü işleme alanında bağlantılı bileşen analizi, blob (binary large object) ikili büyük nesne çıkarma, bölge etiketleme, bölge çıkarma işlemi olarak

bilinir. Bađlı bileşen algoritmasının amacı, her bir farklı beyaz bölgeyi algılamak ve pikselleri etiketlemektir. Etiketleme her bir bölgeye farklı numaralar verilerek gerçekleştirilir. Aynı bölgedeki beyaz piksellere aynı etiket verilir [61].

CCL, birinci tarama ve ikinci tarama aşağıdan yukarıya ve soldan sağa olmak üzere iki aşamadan oluşur. İlk taramada, gözlemlenen bileşenler arasında bir denklik ilişkisi kurulur. İlk taramadaki bu denklik ilişkisi, ikinci taramada doğru şekilde etiketlemek için kullanılan bileşenlerin topolojisini saklar. İkinci taramada, gözlemlenen bađlı bileşenlere etiketler veya farklı numaralar atanır [62].

CCL de ilk taramada her piksel, sol üst köşeden sağ alt köşeye kadar tek tek doğrusal olarak kontrol edilir. Pikselleri kontrol ederken Moore komşuluđu (Moore Neighborhood) ve dolaylı komşular olarak da bilinen 8-komşu bađlantısı (8-neighbors connectivity) kullanılmış ve Şekil 6.2’de gösterilmiştir. Bir piksel arka plan pikseli ise etiket verilmez bir sonraki piksele geçilir. Bir piksel yoğunluk değeri 0 dan farklı bir değere sahip ise, komşunun var olup olmadığı kontrol edilir. Komşu yok ise, mevcut piksel için yeni bir etiket verilir. Üzerinde aynı etikete sahip komşular varsa, mevcut piksel için komşusu ile aynı etiket atanır. Üzerinde farklı etiket bulunan komşular varsa, mevcut piksel için daha düşük değeri etiket atanır. Ancak yüksek değeri etiket, düşük değeri etiketin alt ögesi olarak depolanır. İlk tarama, son piksel için bir etiket atanana kadar devam eder.



Şekil 6.2 8-komşu bađlantısı.

İkinci taramada, farklı etiketler de dahil olmak üzere bađlı bileşenlerin etiketlerini düzeltme işlemi yapılır. Her piksel, ilk taramada olduđu gibi sol üst köşeden sağ alt

köşeye kadar tek tek kontrol edilir. Bir pikselin etiketi kontrol edilirken herhangi bir etiketin alt ögesi değilse, o etiket bir öge olarak atanır ve bir sonrakine geçilir. Eğer herhangi bir etiketin alt ögesi ise, üst etiketin kendisinin komşusu olup olmadığına bakılır komşusu ise, alt etiket üst etiketle değiştirilir. Komşusu değilse üst ögesi bulunur ve alt etiket de üst etiket ile değiştirilir. İkinci tarama, son pikselin etiketi artık değişmeye kadar devam eder. Bunun sonucunda bağlı bileşen etiketlemesi tamamlanır.

Bu çalışmada Otsu eşikleme ve K-ortalama algoritmaları kullanılarak elde edilen görüntüler üzerinde CCL uygulanarak, kemik dokunun tamamının elde edildiği görüntü seçilir. Bununla birlikte, en iyi sonucu veren algoritma ile çalışmaya devam edilmiştir.

6.2. GÖRÜNTÜLERİN DİKDÖRTGEN FORMDA DİLİMLENMESİ İLE GÖRÜNTÜ ÇOĞALTILMASI

Bu çalışmada kullanılan görüntü veri seti içerisinde yer alan kırık ve sağlıklı görüntüler, CCL ile Otsu eşikleme algoritması ve K-ortalama algoritması kullanılarak elde edilen görüntülerden tekrar oluşturulmuştur. Bununla birlikte görüntü veri seti artık 325x175 boyutlarında CCL metodu ile Otsu eşikleme algoritması ve K-ortalama algoritması sonuçlarından karışık bir şekilde oluşturulmuştur.

Görüntülerin dilimlere ayrılması bölümünün ilk aşamasında 325x175 boyutlarındaki görüntüler eşit olacak şekilde 12 eşit parçaya ayrılmışlardır. Yani her bir görüntü için 27x175 boyutlarında yeni görüntü alt kümesi oluşturulmuştur. İkinci adımda ise görüntü üzerindeki her bir dikdörtgen aşağı yönde 5 er piksel ötelenerek 11 eşit parçadan oluşan yeni görüntü alt kümesi elde edilmiştir. İkinci adım, ilk dikdörtgen görüntüyü 12 eşit parçaya ayırdığımızda oluşan 2. dikdörtgen üzerine binene kadar tekrarlanır. Bu sayede düşeyde 0, 5, 10, 15, 20 piksel ötelenmiş şekilde birbirinden farklı görüntü alt kümeleri elde edilmiştir.

Elde edilen görüntü alt kümeleri, adım sayıları ile isimlendirilerek öznitelik çıkarımı ile birlikte excel ortamına aktarılmıştır. Excel içerisinde alt kümeye ait Id, ReId

(Regtangle Id), SId (Step Id), öznitelik çıkarımına ait değerler ve son olarak RId (Result Id) yer almaktadır. Görüntülere ait verilerin tutulduğu excel çizelgesi Şekil 6.3'te gösterilmiştir.

Id	Reld	SId	Standart Deviati	Entropy	Mean	Image Contrast	Chebyshev Mo...	Energy og Grac	Variance of La	Image Curvatur	RId
29	3	5	0,092483668	1,420942174	0,1097943	0,137458183	164,7752654 ...	0,015907769	0,026214886	0,970526951	0
6	11	0	0,106365563	3,371298172	0,1987939	0,26740056	104,8000854 ...	0,019563534	0,030298462	0,923402204	0
36	5	10	0,022724843	1,923239231	0,1631589	0,111397359	4,45134689 ...	0,012573447	0,014350744	0,977237274	0
46	1	15	0,055989548	3,8543688	0,3681265	0,167054822	0,599358485 ...	0,014505608	0,010044282	0,975738916	0
43	8	5	0,083921671	2,15012717	0,131587	0,182978792	4,170079286 ...	0,015382668	0,02403836	0,944198139	0
7	1	5	0,050007311	2,327824401	0,1667595	0,106322529	1,916833099 ...	0,009291679	0,010302268	0,979235085	0
6	6	0	0,137132232	3,635466863	0,241523	0,246066427	43,38279981 ...	0,018562967	0,021286449	0,930308459	1
41	3	5	0,049543337	0,971370176	0,0214782	0,123129252	484,0604853 ...	0,008299715	0,020735721	0,964452699	1
35	7	5	0,112430959	1,856826973	0,0835406	0,225010004	15,95862335 ...	0,0215064	0,036652619	0,958412014	1
42	4	20	0,088818139	2,383985953	0,1556575	0,128836335	2,223835088 ...	0,009573897	0,013613925	0,967521894	1
5	3	10	0,105263021	2,436322992	0,185888	0,126571429	1,77953602 ...	0,011952317	0,012713418	0,971257526	1
12	9	5	0,081402332	2,21398216	0,1481088	0,131382153	2,691500484 ...	0,009375154	0,010251077	0,967881089	1
21	9	15	0,120355722	3,243441224	0,1993766	0,16207603	1,249708834 ...	0,008624708	0,00776807	0,964371237	1
46	8	5	0,123999639	3,691364289	0,2962233	0,287086034	0,951351179 ...	0,029385662	0,047747988	0,939421085	1
18	12	0	0,088426421	1,772310445	0,0740848	0,149207683	5,05390217 ...	0,008518284	0,013146457	0,957081281	0
18	4	5	0,085980412	2,451519955	0,1637023	0,117442977	2,370381406 ...	0,008055002	0,006459156	0,967593733	0
3	6	15	0,040399456	1,619669861	0,0645386	0,061935974	174,3963399 ...	0,002538468	0,002064687	0,974304798	0
6	3	5	0,091596703	3,442182947	0,259403	0,214288916	80,60487303 ...	0,016354915	0,015803627	0,945681278	0
37	11	0	0,156676766	5,045889046	0,4281937	0,274072029	13,06555503 ...	0,019444296	0,009402378	0,94181434	0
20	12	0	0,0975515	0,911238698	0,0327019	0,052966787	5,168890883 ...	0,002440794	0,005023452	0,989395183	0

Şekil 6.3 Görüntülerin sayısallaştırılması ile elde edilen excel çizelgesi.

6.3. ÖZİNİTELİK ÇIKARIMI (FEATURE EXTRACTION)

Görüntüler üzerinde elde edilen öznitelikler, görüntü işleme barındıran yazılım uygulamalarında oldukça önemlidir. Öznitelikler elde edilmeden önce örneklenen görüntü üzerinde renk uzayı dönüşümleri, yeniden boyutlandırma, filtreleme, bölütleme gibi çeşitli görüntü ön işleme teknikleri uygulanır. Bu işlemler sonrasında görüntülerin sınıflandırılması ve görüntüler hakkında bilgiler verilebilmesinde faydalı olacak özniteliklerin elde edilmesi için öznitelik çıkarma teknikleri veya algoritmaları uygulanır [63,64]. Öznitelik çıkarma teknikleri, medikal görüntü işleme uygulamalarında faydalıdır. Öznitelikler, görüntülerin istenilen özellikte davranışlarını tanımlar bunun yanı sıra kullanılacak olan depolama alanını, direkt görüntü işleyerek algoritmanın kaybedeceği zamanı en aza düşürücü etkileri de bulunmaktadır.

Özellik çıkarmanın temel amacı, orijinal verilerden en uygun bilgiyi elde etmek ve bu bilgiyi daha düşük boyutlu bir uzayda temsil etmektir. Bir algoritmanın girdi verileri eşlenemeyecek kadar büyük olduğunda ve gereksiz olma durumundan şüphe edilmesi

sonucu öznitelik çıkarımı kullanılır. Bu bağlamda girdi verileri artık özniteliklerin indirgenmiş bir temsil kümesine dönüştürülür buna öznitelik çıkarımı denir [63][64]. Yaygın olarak kullanılan öznitelik çıkarma yöntemleri, Şablon eşleştirme (Template matching), Deforme edilebilir şablonlar (Deformable templates), Üniter Görüntü Dönüşümleri (Unitary Image Transforms), Graf Açıklaması (Graph Description), Projeksiyon Histogramları (Projection Histograms), Kontur Profilleri (Contour Profiles), Zoning, Geometrik Moment Değişmezleri (Geometric Moment Invariants), Zernike Momentleri (Zernike Moments), Spline Eğri Yaklaşımı (Spline curve approximation), Fourier Dönüşümleri, Gradyan özelliği, Gabor özelliğidir.

Çalışmada kullanılan özellik çıkarım yöntemleri aşağıda açıklanmıştır.

Odak Ölçüm Operatörleri (Focus Measure Operators): Literatürde, Shape From Focus (SFF) ve otomatik odaklama gibi farklı uygulamalar için tüm görüntünün veya bir görüntü pikselinin odak derecesini ölçmek amacıyla çok çeşitli algoritmalar ve operatörler önerilmiştir. Pertuz vd. odak ölçüm operatörlerini, çalışma prensiplerine göre altı grupta incelenebilir [63]. Bu bölümde her bir grubun kısa bir açıklaması sunulmaktadır.

Gradyan Tabanlı Operatörler (Gradient-Based Operators): Bu gruptaki operatörler, görüntünün gradyanına veya birinci türevine dayalı odak ölçüm operatörlerini barındırırlar. Bu algoritmalar, odaklanmış görüntülerin bulanık olanlardan daha keskin kenarlar sunduğu varsayımını öne sürer. Bu nedenle, gradyan odak derecesini ölçmek için kullanılırlar [63].

Laplacian Tabanlı Operatörler (Laplacian-Based Operators): Önceki grup operatörlerine benzer şekilde, bu operatörlerin amacı, Laplacian'ın ikinci türevi aracılığı ile, görüntülerde bulunan kenarların miktarını ölçmektir [63].

Dalgacık Tabanlı Operatörler (Wavelet-Based Operators): Bu grup içindeki odak ölçüm operatörleri, görüntülerin frekansını ve uzamsal içeriğini tanımlamak için ayrık dalgacık dönüşümünün katsayılarından yararlanırlar. Bu nedenle, bu katsayılar odak düzeyini ölçmek için kullanılabilir [63].

İstatistik Tabanlı Operatörler (Statistics-Based Operators): Bu gruptaki odak ölçümü operatörleri, odak seviyesini hesaplamak için doku tanımlayıcıları olan çeşitli görüntü istatistiklerinden yararlanır [63].

DCT Tabanlı Operatörler (DCT-Based Operators): Dalgacık tabanlı operatörlere benzer şekilde bu grup operatörler, bir görüntünün odak seviyesini frekans içeriğinden hesaplamak için ayırık kosinüs dönüşümü (DCT) katsayılarından yararlanır [63].

Çeşitli Operatörler (Miscellaneous Operators): Bu gruptaki operatörler, önceki beş grubun hiçbirine ait olmayan operatörleri gruplandırır.

Çalışmada kullanılan parametrelerin-operatörlerin açıklamaları ve matematiksel metotları aşağıda yer almaktadır.

- Görüntü kontrastı (Image Contrast):

Nanda vd. otomatik odaklama için bir odak ölçüsü olarak görüntü kontrastını kullanmışlardır [64].

$$C(x, y) = \sum_{i=x-1}^{x+1} \sum_{j=y-1}^{y+1} |I(x, y) - I(i, j)|, \quad (6.8)$$

Burada $C(x, y)$, $I(x, y)$ 'inci piksel için görüntü kontrastıdır.

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} C(i, j), \quad (6.9)$$

- Görüntü Eğriliği (Image Curvature):

Bu operatör, Helmlı vd. mikro-skopiye uygulanan SFF için önermişlerdir. Görüntü gri seviyeleri ortalama sofa yüzeyi ile enterpole edilirse, bu yüzeyin eğriliği bir odak ölçüsü olarak kullanılabilir.

$$\phi = |c_0| + |c_1| + |c_2| + |c_3|, \quad (6.10)$$

Denklemden $C = (c_0, c_1, c_2, c_3)^T$, ikinci dereceden (parabolik) bir yüzey olan $f(x, y) = c_0x + c_1y + c_2x^2 + c_3y^2$ enterpolasyonu için kullanılan katsayıların vektörüdür. C , iki konvolüsyon maskesi uygulanarak en küçük kareler metodu ile hesaplanır.

$$c_0 = M_1 * I, \quad c_2 = \frac{3}{2} M_2 * I - M_2^T * I$$

$$c_1 = M_1^T * I, \quad c_3 = \frac{3}{2} M_2^T * I - M_2^T * I \text{revx},$$

Burada M_1, M_2

$$M_1 = \frac{1}{6} \begin{pmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{pmatrix} \quad M_2 = \frac{1}{5} \begin{pmatrix} 1 & 0 & 1 \\ 1 & 0 & 1 \\ 1 & 0 & 1 \end{pmatrix}$$

- Gauss Türevi (Gaussian Derivation):

Odaksızlığı modellemeye dayalı olarak, Geusebroek vd. birinci dereceden Gauss türevini temel alan mikroskopide otofokus için bir odak ölçüsü önermişlerdir.

$$\phi = \sum_{(x,y)} (I * \Gamma_x)^2 + ((I * \Gamma_y)^2), \quad (6.11)$$

Burada, Γ_x ve Γ_y sırasıyla, $\Gamma_{(x,y,\sigma)}$ Gauss fonksiyonunun x ve y göre kısmi türevleridir.

$$\Gamma_{(x,y,\sigma)} = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (6.12)$$

- Gradyan Enerjisi (Energy of Gradient):

Birinci türevin x ve y yönlerindeki karelerinin toplamı, bir odak ölçüsü olarak önerilmiştir.

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} (I_x(i,j)^2 + I_y(i,j)^2), \quad (6.13)$$

- Brenner's Focus Measure:

Bir görüntü olan I 'nin gri seviyelerinin ikinci farkına dayanan bir odak ölçüsü tanımlanmıştır [63].

$$\phi = \sum_{(i,j)} |I(i,j) + I(i,2j)|^2, \quad (6.14)$$

Denklem 6.14 görüntünün dikey varyasyonlarının hesaba katılmasına izin verir [63]. Belirgin bir eşiğin üzerindeki değerler sadece toplanabilir.

- Mutlak Merkez Moment (Absolute central moment):

Shirvaikar vd. istatistiksel ölçümlere ve H görüntü histogramına dayalı olarak mutlak merkezi moment (ACM) olan AF için bir odak ölçüsü önermişlerdir [65].

$$ACM_o = \sum_{k=1}^L |k - \mu| P_k, \quad (6.15)$$

Denklemden μ , H 'ın ortalama yoğunluk değeridir, L görüntüdeki gri-seviyelerin sayısıdır ve P_k , k 'nci gri seviyenin nispi frekans değeridir. Bu operatör, $I(x,y)$ pikselinin, $\Omega(x,y)$ komşuluğu üzerinden hesaplanan ACM_o değerlerinin toplanması ile SFF'ye uyarlanmıştır.

- Dalgacık Katsayılarının Toplamı (Sum of Wavelet Coefficients):

Dalgacık tabanlı odak ölçümü operatörleri çoğunlukla Ayrık Dalgacık Dönüşümü (DWT) katsayılarının istatistiksel özelliklerine dayanır. Birinci seviye DWT'de, görüntü dört alt görüntüye ayrıştırılır bunlar, W_{LH1} , W_{HL1} , W_{HH1} ve W_{LL1} 'dir. Üç detay alt bandını ve kaba yaklaşım alt bandını gösterir. Daha yüksek seviyeli bir DWT için, kaba yaklaşım art arda ayrıntılı ve kaba alt bantlara ayrıştırılır. Detay ve kaba alt bantların bilgileri daha sonra odak ölçüsünü hesaplamak için kullanılır [63].

Yang ve Nelson alt bantlardan hesaplanan otomatik odaklama için bir odak operatörü önermişlerdir [66].

$$\phi = \sum_{(i,j) \in \Omega_v} |W_{LH1}(i,j)| + |W_{HL1}(i,j)| + |W_{HH1}(i,j)|, \quad (6.16)$$

Denklemden Ω_D , DWT alt bantlarında karşılık gelen Ω penceresidir. Pertuz vd. çalışmalarında, tüm damlacık tabanlı parametrelerin odak ölçüsü, aşırı tamamlanmış (over-complete) dalgacık dönüşümünün katsayıları kullanılarak hesaplanmıştır, böylece her bir alt-bant içinde karşılık gelen komşuluk hesaplama ihtiyacından kaçınılmıştır. Böylece, Ω_D basitçe Ω ile aynıdır.

- Dalgacık Katsayılarının Oranı (Ratio of Wavelet Coefficients WAV2):

Xie vd., odak ölçüsü olarak dalgacık dönüşümünün yüksek frekans katsayıları M_H ile düşük frekans katsayıları M_L arasındaki oranın kullanılmasını önermişlerdir.

$$\phi = \frac{M_H^2}{M_L^2}, \quad (6.17)$$

Denklemden, M_H ve M_L aşağıdaki gibi tanımlanır.

$$M_H^2 = \sum_k \sum_{(i,j) \in \Omega_v} W_{LHk}(i,j)^2 + W_{HLk}(i,j)^2 + W_{HHk}(i,j)^2, \quad (6.18)$$

$$M_L^2 = \sum_k \sum_{(i,j) \in \Omega_v} W_{LLk}(i,j)^2, \quad (6.19)$$

Alt indeks k , katsayıları hesaplamak için k 'inci seviye dalgacığın kullanıldığını gösterir. Lee vd. göre birinci seviye DWT katsayıları denklem 6.18'de, üçüncü seviye katsayılar 6.19'da kullanılır [67]. WAV1, WAV2 parametreleri başlangıçta otomatik odaklama uygulamaları için önerildi. SFF'ye uyarlamak için, Eşitlik 6.18 ve Eşitlik 6.19'deki toplamları karşılık gelen $\Omega(x,y)$ ile sınırlandırarak her piksel $I(x,y)$ için bir odak ölçüsü hesaplanır [63].

- Helmlı ve Scherer'in Ortalama Yöntemi (Helmlı and Scherer's Mean Method):

Helmlı ve Scherer, her pikselin $I(x,y)$ yoğunluk seviyesi ile komşuluğun ortalama gri seviyesi $\mu(x,y)$ arasındaki $R(x,y)$ oranını hesaplayarak yerek kontrastı ölçmeyi önermişlerdir [68].

$$R(x,y) = \begin{cases} \frac{\mu(x,y)}{I(x,y)}, & \mu(x,y) \geq I(x,y) \\ \frac{I(x,y)}{\mu(x,y)}, & \text{otherwise.} \end{cases} \quad (6.20)$$

Bu oran, sabit bir gri değer veya düşük kontrast varsa ise birdir. (x, y) merkezli bir MXN komşuluğu, $\mu(x,y)$ 'yi hesaplamak için kullanılır. $I(x, y)$ için odak ölçüsü, $\Omega(x, y)$ içindeki $R(x, y)$ değerleri toplanarak hesaplanır [63].

- Yönlendirilebilir Filtre Tabanlı Ölçü (Steerable Filters- Based Measure):

Minhas vd. görüntünün filtrelenmiş haline dayalı bir odak ölçüsü önerdiler [69].

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} (I_f(i,j)), \quad (6.21)$$

$$I_f(i,j) = \max \{ R_{(i,j)}^{\theta_1}, R_{(i,j)}^{\theta_2}, \dots, R_{(i,j)}^{\theta_N} \}, \quad (6.22)$$

6.22'de R^{θ_n} , $n=1,2,\dots,N$, olarak tanımlanan n'inci yönlendirilebilir filtreye verilen görüntüdür [69].

$$R^{\theta_n} = \cos(\theta_n) (I * \Gamma_x) + \sin(\theta_n) (I * \Gamma_y), \quad (6.23)$$

Γ_x ve Γ_y gauss türevleridir (5.4).

Minbas vd. entegre görüntüler aracılığıyla yönlendirilebilir filtrelere dayalı odak ölçüsünün hesaplanması için verimli bir algoritma önermişlerdir [70].

- Mekansal Frekans Ölçümü (Spatial Frequency Measure):

Huang vd. çok odaklı görüntülerin birleştirilmesi için önermişlerdir [71].

$$\phi_{x,y} = \sqrt{\sum_{(i,j) \in \Omega(x,y)} I_x(i,j)^2 + \sum_{(i,j) \in \Omega(x,y)} I_y(i,j)^2}, \quad (6.24)$$

Denklemden, I_x ve I_y sırasıyla X ve Y görüntülerinin ilk türevlerini gösterir.

- Eşikli mutlak gradyan (Thresholded absolute gradient):

Görüntünün yatay boyuttaki ilk türevi, odak derecesinin basit bir ölçüsüdür. Bu ölçümün performansı, T 'nin seçiminden etkilenir [63].

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} |I_x(i,j)|, \quad |I_x(i,j)| \geq T, \quad (6.25)$$

- Kare Gradyan (Squared gradient):

Eşitlik 6.25'i uygulamak yerine, daha büyük gradyanların etkisini arttırmak için birinci türevin karesi alınır. Hem dikey hem de yatay türevler dikkate alınır ve eklenirse, bu ölçü görüntü gradyanının enerjisine eşdeğerdir [63].

- Laplacian Enerjisi (Energy Of Laplacian):

Görüntünün ikinci türevinin enerjisi, hem otomatik odaklama hem de SFF için odak ölçüsü olarak kullanılmıştır [63].

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} \Delta I(i,j)^2, \quad (6.26)$$

Denklemdede ΔI , I görüntüsünden laplasyan maskesi ile elde edilen Laplasyan görüntüsüdür.

- Değiştirilmiş Laplasyan (Modified Laplacian):

Nayar vd. Laplasyanın alternatif bir tanımına dayanan bir odak ölçüsü önerdi [72].

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} \Delta_m I(i,j), \quad (6.27)$$

Denklemdede $\Delta_m I$, I 'nin değiştirilmiş laplasyanıdır, denklem 6.28'de ki gibi hesaplanır.

$$\Delta_m I = |I * \mathcal{L}_X| + |I * \mathcal{L}_Y|, \quad (6.28)$$

Değiştirilmiş laplasyanı hesaplamak için kullanılan evrişim maskeleri vardır.

$$\mathcal{L}_X = [-1 \ 2 \ -1], \quad \mathcal{L}_Y = \mathcal{L}_X^T \quad (6.29)$$

- Diagonal Laplacian:

Thelen vd. görüntünün değiştirilmiş laplasyan değerini hesaplamak için görüntünün dikey varyasyonlarını da dahil etmişlerdir [73].

$$\Delta_m I = |I * \mathcal{L}_X| + |I * \mathcal{L}_Y| + |I * \mathcal{L}_{X1}| + |I * \mathcal{L}_{X2}| \quad (6.30)$$

\mathcal{L}_{X1} ve \mathcal{L}_{X2} Eşitlik 6.31'de ki hesaplanır.

$$\mathcal{L}_{X1} = \frac{1}{\sqrt{2}} \begin{bmatrix} 0 & 0 & 1 \\ 0 & -2 & 0 \\ 1 & 0 & 0 \end{bmatrix}, \quad \mathcal{L}_{X2} = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 0 & 0 \\ 0 & -2 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (6.31)$$

- Laplace Varyansı (Variance of Laplacian):

Bu parametre, otomatik odaklama için odak ölçüsü olarak laplasyan görüntüsünün varyansını kullanır [74]. SFF'de bu ölçü şu şekilde tanımlanabilir:

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} (\Delta I(i,j) - \overline{\Delta I})^2, \quad (6.32)$$

Denklemden, $\overline{\Delta I}$ laplasyan görüntüsünün $\Omega(x,y)$ cinsinden ortalama değeridir.

- Gri Seviye Varyansı (Gray-Level Variance):

Gri seviye görüntü varyansı, bir görüntünün odak ölçüsünü hesaplamak için en popüler yöntemlerden biridir. Hem otomatik odaklamaya hem de SFF'ye uygulanabilir [63].

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} (I(i,j) - \mu)^2, \quad (6.33)$$

Denklemden μ , $\Omega(x,y)$ cinsinden piksellerin ortalama gri seviyesidir.

- Gri Seviye Yerel Varyansı (Gray-Level Local Variance):

Peche vd. parlak alan mikroskobunda diatomların otomatik odaklanması için bir odak ölçüsü olarak gri seviyelerinin yerel varyansını önerdi. SFF'ye uygulanması için bu operatör şu şekilde yeniden formüle edilmiştir [74].

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} (L_v(i,j) - \overline{L_v})^2, \quad (6.34)$$

Denklemden $L_v(i,j)$, (i, j) merkezli w_x, w_y büyüklüğünde bir alanın gri seviyelerinin varyansı olarak hesaplanır. $\overline{L_v}$, L_v 'nin ortalama değeridir.

- Normalleştirilmiş Gri Seviye Varyansı (Normalized Gray-Level Variance):

Gri seviye varyansı, farklı görüntüler arasındaki ortalama görüntü parlaklığındaki farklılıklar için ϕ in Denklem 6.33'te ki değerini ortalama gri düzeyi değeri μ ile normalleştirerek elde edilir [63].

- Değiştirilmiş Gri Seviye Varyansı (Modified Gray-Level Variance):

Denklem 6.33'te gri seviye değişkeninin hesaplanması, görüntünün doğrusal olmayan bir filtrelemesi olarak düşünülebilir. $\Omega(x, y)$ komşuluğunda ki her pikselin ortalama değeri $\mu(x, y)$ hesaplanırsa alternatif bir odak ölçüsü elde edilir [63].

$$\phi_{x,y} = \sum_{(i,j) \in \Omega(x,y)} (I(i,j) - \mu(i,j))^2, \quad (6.35)$$

Denklemde $\mu(x, y)$ doğrusal bir evrişim filtresi yoluyla elde edilir.

- Chebyshev Moments Based:

Chebyshev momentlerine dayalı AF için bir görüntü odak ölçüsüdür. Chebyshev momentleri kullanılarak görüntüden çıkarılan yüksek geçiren bandın enerjisi ile alçak geçiren bandın enerjisi arasındaki oran olarak önerilmiştir [75].

$$\phi = \frac{||\mathbb{H}(\tilde{I}; p)||}{||\mathbb{L}(\tilde{I}; p)||} \quad (6.36)$$

Denklemde $||\mathbb{H}(\tilde{I}; p)||$ ve $||\mathbb{L}(\tilde{I}; p)||$ normalleştirilmiş görüntünün \tilde{I} derecesine kadar sırasıyla yüksek ve düşük dereceli Chebyshev momentlerini gösterir. Denklem 6.36'da olduğu gibi hesaplanır.

$$\tilde{I} = \frac{I}{\sqrt{\sum_{(i,j)} [I(i,j)]^2}} \quad (6.37)$$

6.4. SINIFLANDIRMA

1950'lerde yapay zeka kavramının ortaya ıkması ve gelişmesinin ardından 1980'lerde yapay zeka öğrenme süreçleri başlatılmış ve bu bağlamda makine öğrenmesi kavramı geliştirilmiştir. 2010'lu yıllarda derin öğrenme kavramı ortaya çıkmıştır. Makine öğrenimi, bir algoritmanın eğitim verileri kullanarak tahminler yapmasını ve buna bağlı olarak kararlar almasını sağlar [72,73]. Makine öğrenmesi, eğitim verilerini belirli sınırlar içinde gözlemleyerek, bu verilerden yararlanarak ve zaman içinde geliştirerek öğrenme eyleminin tamamlanması, bu bağlamda makinelerin, makine öğrenme algoritmaları desteğiyle öğrenebilmesi, düşünebilmesi ve hatta insan gibi davranabilmesi kavramıdır. Makine öğreniminin temel amacı, kendini geliştirebilen, karmaşık kalıpları tespit edebilen ve önceki verileri kullanarak (öğrenilmiş verileri) yeni problemlere çözüm bulabilen modeller oluşturmaktır [73,76].

Makine öğrenmesi, dört başlık altında incelenebilir;


- **Denetimli öğrenme:** Bu yöntem, var olan verileri girdi olarak kullanarak sonuca ulaşmak için kullanılan bir makine öğrenmesi tahmin yöntemidir. Denetimli öğrenmenin amacı, bir dizi girdi değerine bağlı olarak çıktı değerlerini tahmin etmek için işlevsellik oluşturmak ve hem girdi hem de çıktı değerlerinin dahil olduğu veri kümelerinden çıktı değerlerini arasındaki ilişkiyi açıklamaktır. Sınıflandırma ve Regresyon analizi bu yöntemler arasındadır [72,77].
- **Denetimsiz öğrenme:** Bu yöntem, veri setinin sonuç değerlerinin olmadığı durumlarda mevcut verileri girdi olarak kullanan bir tahmin yöntemidir. Bu yöntem, mevcut verilerle bir ilişki ve örüntü oluşturmaya çalışır. Bilindiği gibi veri kendine özgü bir yapıya sahiptir. Verinin içerisinde düzenlemeler yapabilmek için örneklemlerin az veya çok olmasına göre kümeleme yapar. Bunun yanı sıra, veri yoğunluğuna ve benzerliğine göre kümeleme yapılır. Temelde, küme içerisinde bir verinin temel özelliklerine bakarak, genellikle ilişkili oldukları diğer nitelikleri tahmin etmeye çalışır [72,73].

- **Yarı denetimli öğrenme:** Bu yöntem, denetimli öğrenme ile denetimsiz öğrenme arasında bir öğrenmedir. Etiketlenmemiş verileri ve bazı etiketlenmiş verileri birlikte kullanan bir öğrenme türüdür [72,73].
- **Pekiştirmeli öğrenme:** Bu öğrenme yönteminde, öğrenmenin gerçekleştirilmesi için bir hedef belirlenir ve deneme yanılma yoluyla bu hedefe ulaşması beklenir. Sistem, deneme yanılma süreçlerini ödüllendirici eylemlere göre düzenler ve verilen amaca nasıl ulaşacağını öğrenir. Pekiştirmeli öğrenme, oyun kuramı, kontrol kuramı, yöneylem araştırması, bilgi kuramı, benzetim tabanlı eniyileme ve istatistik gibi birçok alanda kullanılır [72,73,78] .

6.4.1. Destek Vektör Makineleri (DVM)


Destek vektör makineleri yöntemi hem regresyon hem de sınıflandırma amacıyla kullanılsa da makine öğrenmesinde daha çok sınıflandırma için kullanılmaktadır. Denetimli öğrenme algoritması olan DVM, hem doğrusal hem de doğrusal olmayan verileri sınıflandırabilir, ancak çoğunlukla verileri doğrusal olarak sınıflandırmaya çalışır. DVM daha az hesaplama ile önemli doğruluk ürettiği için oldukça tercih edilen bir yöntemdir. Destek vektör makineleri esas olarak iki sınıfa ait verileri en uygun şekilde ayırt etmek için kullanılır. Bunun için hiper düzlemler (karar sınırları) belirler, bununla birlikte sınıfları birlerinden ayıran en iyi çizgiyi bulmaya çalışır.

İki sınıfın verilerini birbirinden ayıran bu yöntem, verimli bir sınıflandırma gerçekleştirebilmek için en iyi karar fonksiyonu (hyperplane) belirlemeyi amaçlar [79]. Temelde DVM'nin amacı, iki sınıfa ait verilerin sınıflandırılmasını sağlayan sonsuz hiperdüzlem arasında en verimli sınıflandırmayı yapan hiperdüzlemi belirlemektir. Optimal hiperdüzlem seçimi Şekil 6.4 ve Sekil 6.5'te gösterilmiştir.



Şekil 6.4 Doğrusal Olarak Ayrılabilir Veriler için Hiper Düzlemler.

Hiperdüzlemler belirlenirken, yapısal risk minimizasyonu ilkesi kullanılarak iki hiperdüzlem arasındaki sınır mesafesi maksimize edilir.



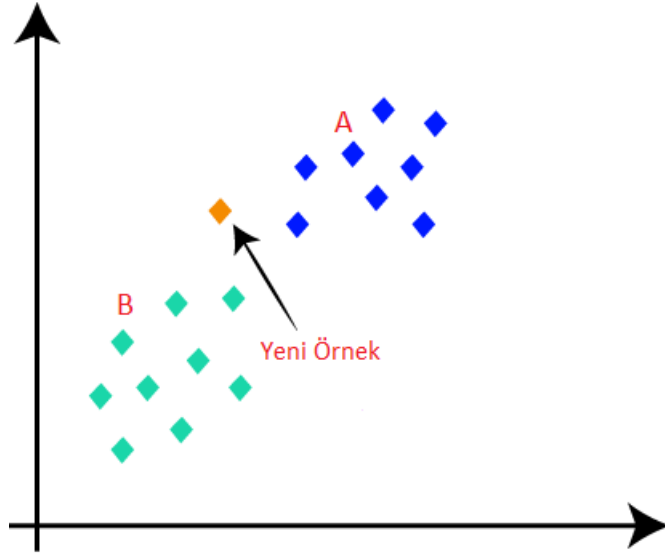
Şekil 6.5 Optimum Hiper Düzlem ve Destek Vektörleri.

Sonuç olarak, Şekil 5.8'de görüldüğü gibi, sınıfların düzleme en yakın noktaları arasındaki mesafenin maksimize edildiği optimum hiperdüzlem elde edilir [79].

6.4.2. K En Yakın Komşu Algoritması (KNN)

KNN, basit ama bir o kadar da etkili bir sınıflandırma tekniğidir. Denetimli makine öğrenmesi algoritması olan KNN, örüntü tanımada sınıflandırma ve regresyon için kullanılan parametrik olmayan bir yöntemdir [80]. KNN algoritmasında çıktı bir sınıf üyeliğidir. Bir nesne komşularının çoğunluk oyu ile sınıflandırılır ve nesne, en yakın k farklı komşusu arasında en yakın olanına atanır (k, pozitif tam sayıdır, ve genel olarak küçüktür) [81]. Fonksiyon yalnızca yerel olarak tahmin edilir ve tüm hesaplamaların sınıflandırmaya kadar ertelendiği bir tür örnek tabanlı öğrenme veya tembel öğrenme olarak isimlendirilebilir. KNN algoritması, tüm makine öğrenmesi algoritmalarının en basitleri arasındadır. O yüzden komşuların katkılarını ağırlıklandırmak faydalı olabilir, böylece yakın komşular uzak olan komşulardan daha fazla ortalamaya katkıda bulunur. Örneğin, yaygın bir ağırlıklandırma şeması olarak, her komşuya, olan uzaklığın dışında, $1/d$ 'lik bir ağırlık verilmesi öngörülebilir. Komşular, sınıfın kendisine ait olduğu bir dizi nesne içerisinde alınır (KNN sınıflandırma için) veya nesne özellik değerinin (KNN regresyon için) bulunduğu bir dizi nesneden alınır. Bu, açık bir eğitim olarak değerlendirilmese bile, algoritma için eğitim seti olarak düşünülebilir [81,82].

Eğitim örnekleri, her biri bir sınıf etiketine sahip çok boyutlu bir özellik uzayındaki vektörlerdir. Algoritmanın eğitim aşaması, yalnızca eğitim örneklerinin özellik vektörlerini ve sınıf etiketlerini depolamaktan oluşur. Şekil 6.6'da yeni bir örneğin iki farklı kümeye göre durumu gösterilmiştir.



Şekil 6.6 Yeni bir örneğin iki farklı kümeye göre durumu.

6.4.3. Karar Ağacı

Karar ağacı, örnek uzayının yinelemeli bir bölümü olarak ifade edilen sınıflandırıcıdır. Karar ağacı, köklü bir ağaç oluşumuna benzetilmektedir. En üst kısım da kök olarak değerlendirilen ilk düğüm ve bu düğümden yönlendirilmiş bir ağaç yapısıdır. Kök hariç tüm düğümlerin tam olarak geldiği bir kenar (dal) vardır. Giden dalları olan bir düğüme dahili veya test düğümü denir. Diğer tüm düğümlere yaprak denir, terminal veya karar düğümleri olarak da bilinir. Bir karar ağacında, her bir dahili düğüm, girdi öznitelik değerlerinin belirli bir ayrık fonksiyonuna göre örnek uzayını iki veya daha fazla alt uzaya böler [83].


Her test tek bir özneliği dikkate alır, örnek alanı özneliğin değerine göre bölünür. Sayısal öznitelikler söz konusu olduğunda, koşul bir aralığa karşılık gelir. Her yaprak, en uygun hedef değeri temsil eden bir sınıfa atanır. Alternatif olarak yaprak, hedef özelliğin belirli bir değere sahip olma olasılığını gösteren bir vektörü tutabilir. Örnekler, yol boyunca yapılan testlerin sonucuna göre ağacın kökünden bir yaprağa kadar gezinerek sınıflandırılır. İç düğümler daireler, yapraklar ise üçgenler olarak gösterilir. Bu karar ağacı hem nominal hem de sayısal öznitelikler bulundurmaktadır [83].

6.4.4. Naive Bayes Sınıflandırıcısı (The Naive Bayes Classifier)

Naive Bayes (NB) algoritması, her bir özellik çifti arasında bağımsızlık varsayımına dayanır [84]. Metin sınıflandırma, belge ve spam filtreleme gibi birçok durumda hem ikili hem de çok sınıflı kategoriler için kullanılabilir. Verilerdeki gürültülü örnekleri etkin bir şekilde sınıflandırmak ve doğru bir tahmin modeli oluşturmak için NB sınıflandırıcı kullanılabilir [85]. NB diğer yaklaşımlarla karşılaştırıldığında, hızlı bir şekilde tahmin için az miktarda eğitim verisine ihtiyaç duyar [86]. Ancak, özelliklerin bağımsızlığına ilişkin güçlü varsayımları nedeniyle performansı etkileyebilir. Gaussian, Multinomial, Complement, Bernoulli ve Categorical, NB sınıflandırıcısının ortak varyantlarıdır [73].

6.4.5. Lojistik Regresyon (Logistic Regression)

Lojistik regresyon, sınıflandırma amacıyla kullanılan denetimli bir makine öğrenme algoritmasıdır. Veriler, ikili yani 0 ve 1 biçiminde olduğunda kullanılır, bu sınıfın istenilen kategoriden mi yoksa diğer kategoriden mi olduğu anlamına gelir [87]. Lojistik regresyonun aslında lojistik fonksiyondur. Gerçek değerli herhangi bir sayıyı alan ve bu sayıyı 0 ile 1 arasında bir değerde haritalayan S-şekilli bir eğridir, ancak hiçbir zaman tam olarak 0 ve 1'de değildir [88]. Şekil 6.7'de bir $b_0 + b_1x$ lineer denklemi için lojistik model ve grafiği gösterilmiştir.



Şekil 6.7 Lineer model ve lojistik model grafiği.

6.4.6. Topluluk Öğrenimi (Ensemble Learning)

Topluluk öğrenimi, genellikle denetimli makine öğrenimi işlemlerinde, karar vermek için birden çok uyarıcıyı birleştiren yöntemdir. Temel öğrenen olarak da adlandırılan bir indükleyici, girdi olarak bir dizi etiketli örnek alır ve bu örnekleri genelleştiren, modeli üreten algoritmadır. Üretilen model kullanılarak yeni etiketlenmemiş örnekler için tahminler üretilebilir. Bir topluluk indükleyicisi, herhangi bir türde makine öğrenme algoritması olabilir (örneğin, karar ağacı, sinir ağı, doğrusal regresyon modeli, vb.). Toplu öğrenmenin amacı, birden fazla modeli birleştirir. Tek bir indükleyicinin hatalarının diğer indükleyiciler tarafından telafi edileceği ve sonuç olarak topluluğun genel tahmin performansının tek bir indükleyiciden daha iyi olacağı savunur [89].

6.5. PERFORMANS ANALİZİ

Bu çalışmada 47 adet kırık ve 18 adet sağlıklı görüntü kullanılmıştır. Görüntü dilimleme işlemi ile toplamda 570 adet bölümlendirilmiş (27x175 boyutunda) kırık kemik görüntüsü, 570 adet bölümlendirilmiş (27x175 boyutunda) sağlıklı kemik görüntüsü elde edilmiştir.

Bu görüntüler kullanılarak elde edilen sınıflandırma sonuçları ile gerçek sonuçların karşılaştırılması aşamasında MCC (Matthews Correlation Coefficient, Matthews Korelasyon Katsayısı) ve ROC (Receiver Operating Characteristics, Alıcı İşletim Karakteristiği) analizlerinden yararlanılmıştır.

MCC, -1 ile 1 arasında değerler alabilir. MCC +1 değerini aldığı anda gerçekte olan ile tahmin edilenler birebir birbirlerinin aynısıdır. MCC -1 değerini aldığı anda gerçekte olan ile tahmin edilenler birbirinden tamamıyla farklıdır. MCC 0 değerini aldığı anda gerçekte olanlar ile tahmin edilenler arasında rastlantısal birliktelik vardır. Ara değerler (-1, 1) tanımlanan sınır değer çerçevesinde değerlendirilmeli. Yani -1 den 1 e kadar değişen ara değerlerde giderek artan bir doğruluk durumu vardır [90,91].

MCC, temelde TP (True Positive, Doğru Pozitif), FP (False Positive, Yanlış Pozitif), FN (False Negative, Yanlış Negatif) ve TN (True Negative, Doğru Negatif) analiz değerlerinden oluşmaktadır. MCC gibi ACC (ACCuracy, doğruluk değeri), PPV (Positive Predictive Value, Pozitif Öngörü Yüzdesi), NPV (Negative Predictive Value, Negatif Öngörü Yüzdesi) ve MR (Miss Rate, Kaçırma Oranı) kontrol parametreleride, bu ölçüm değerlerini kullanarak hesaplanır.

Kontrol parametrelerinde kullanılan ölçüm değerlerinden; TP, görüntülerde kırık olarak değerlendirilmiş olan ve geliştirilen yazılımda da kırık olarak değerlendirilen sonuçların örtüşme sayısıdır. FN, görüntülerde kırık olarak değerlendirilmeyen ama geliştirilen yazılımda kırık olarak değerlendirilen sonuçların örtüşme sayısıdır. FP, görüntülerde kırık olarak değerlendirilmiş ama geliştirilen yazılımda kırık olarak değerlendirilmeyen sonuçların örtüşme sayısıdır. TN, görüntülerde kırık olarak değerlendirilmeyen ve geliştirilen yazılımda da kırık olarak değerlendirilmeyen sonuçların örtüşme sayısıdır [60]. Çizelge 6.1’de ölçüm değerlerinin elde edilmesi gösterilmiştir.

Çizelge 6.1 Ölçüm değerleri olasılık çizelgesi.

Olasılık Çizelgesi		Kesin Sonuç	
		Kırık	Kırık değil
Çalışma ile elde edilen sonuç	Kırık	TP	FP
	Kırık değil	FN	TN

Sensitivity ve specificity, ikili sınıflandırılmış çalışmanın performansını ölçmeye yarayan istatistiksel verilerdir. Sensitivity, tüm kırık görüntüler arasında “kırık” olarak sınıflandırılanların yüzdesidir. Specificity ise tüm sağlıklı görüntüler arasında “sağlıklı” olarak sınıflandırılanların yüzdesidir [92,93].

İyi bir sınıflandırma tahmini, sınıflandırma çıktılarının sensitivity ve specificity değerlerinin ikisinin birden +1 değerine en yakın konumda olması anlamına gelmektedir [92-94]. Verilen tüm bu bilgiler ile sensitivity ve specificity değerleri Eşitlik 6.38 ve eşitlik 6.39’da ki denklemler ile hesaplanabilir.

$$Sensitivity = TP / (TP + FN) \quad (6.38)$$

$$Specificity = TN / (TN + FP) \quad (6.39)$$

ACC, MCC parametrelerinin değerleri ise yine TP, FN, FP ve TN kullanılarak aşağıdaki eşitliklerde olduğu gibi hesaplanmaktadır [94].

$$ACC = (TP + TN) / (TP + TN + FP + FN) \quad (6.40)$$

$$MCC = (TP \times TN - FP \times FN) / \sqrt{(TP + FN) \times (TP + FP) \times (TN + FN) \times (TN + FP)} \quad (6.41)$$

Her bir sınıflandırma algoritmasının tek tek başarı ölçütünün değerlendirilmesinde ve majority voting ile elde edilen sonuçların başarı değerlendirilmesinde ROC analizi kullanılmıştır. Bir diğer deyimle ROC eğrisi olarak da bilinen bu başarı değerlendirme

analizi, TP oranının FP oranına olan bölümü olarak da ifade edilir. ROC eğrisi $y = x$ grafiğinden uzak ve $y = 1$ doğrusuna yakın ise sınıflandırmanın başarılı olduğunu gösterir. Eğer ROC eğrisi $y = x$ grafiğine ve hatta $y = 0$ doğrusuna yakın ise sınıflandırmanın başarısız olduğunu gösterir [92,93].

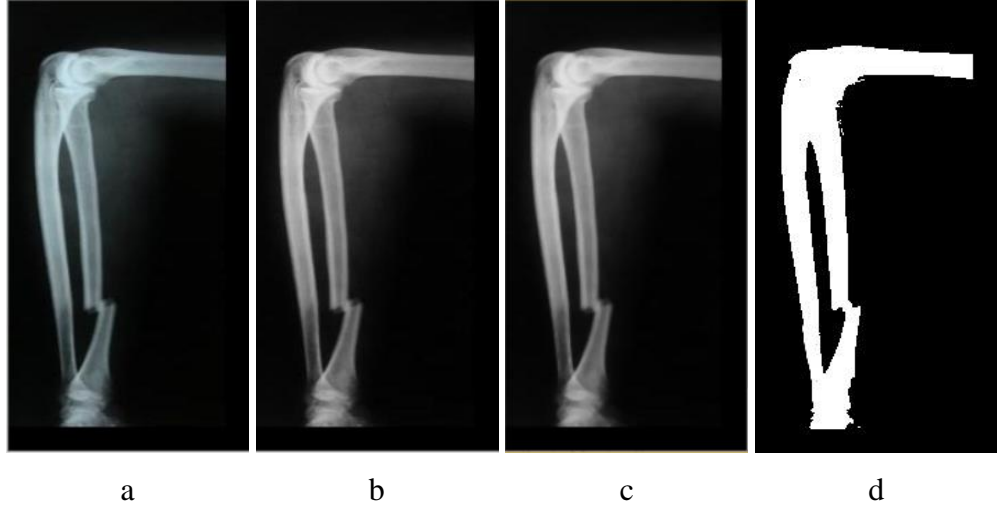
TP, FN, FP ve TN değerlerinin elde edilmesi işlemi kodlarla dinamik bir şekilde MATLAB programında geliştirilen algoritma ile gerçekleştirilmiştir. Yazılım tarafında sınıflandırma algoritmaları tarafından değerlendirilmiş ve 0, 1 olarak etiketlenmiş görüntü ile uzmanın bilgisayar ortamında değerlendirip 0, 1 olarak etiketlediği görüntüler karşılaştırılarak TP, FN, FP, TN değerleri hesaplanmıştır. Kısaca uzman tarafından 1 olarak etiketlenmiş (yani kırık olarak) bir görüntü, yazılım tarafından da 1 olarak etiketlenmiş ise TP değeri bir artmış olur. Uzman tarafından 0 olarak etiketlenmiş (yani sağlıklı) bir görüntü, yazılım tarafından 1 olarak etiketlenmiş ise FN değeri artmış olur. Uzman tarafından 1 olarak etiketlenmiş bir görüntü, yazılım tarafından 0 olarak etiketlenmiş ise FP değeri artmış durumdadır. Uzman tarafından 0 olarak etiketlenmiş bir görüntü, yazılım tarafından da 0 olarak etiketlenmiş ise TN değeri artmış olur. Tüm bu sayım işlemi sonuçta TP, FN, FP ve TN değerleri oluşmuş olur. Sonrasında ACC ve MCC değerleri de MATLAB da hesaplanmış ve ROC eğrisi çizdirilmiştir.

BÖLÜM 7

DENEYSEL SONUÇLAR

Bu tez çalışmasında, ortopedi alanında çok sık karşımıza çıkan kemik kırıklarının tam otomatik tespiti ve sınıflandırılması ele alınmıştır. Çalışma, Karabük Eğitim ve Araştırma Hastanesi'nden elde edilen kemik görüntüleri üzerinde uygulanan ön-işleme, bölütleme, görüntü iyileştirme, görüntülerin dilimlenmesi, özellik çıkarımı ve sınıflandırma aşamaları ile kemik kırıkları tespit edilmiş ve kırık olup olmadığı açısından sınıflandırılmıştır. Öngörülen sınıflandırma işleminin test edilme aşaması MATLAB ortamında gerçekleştirilmiş ve doğruluğu ACC ve MCC değerleri ile ortaya konulmuştur.

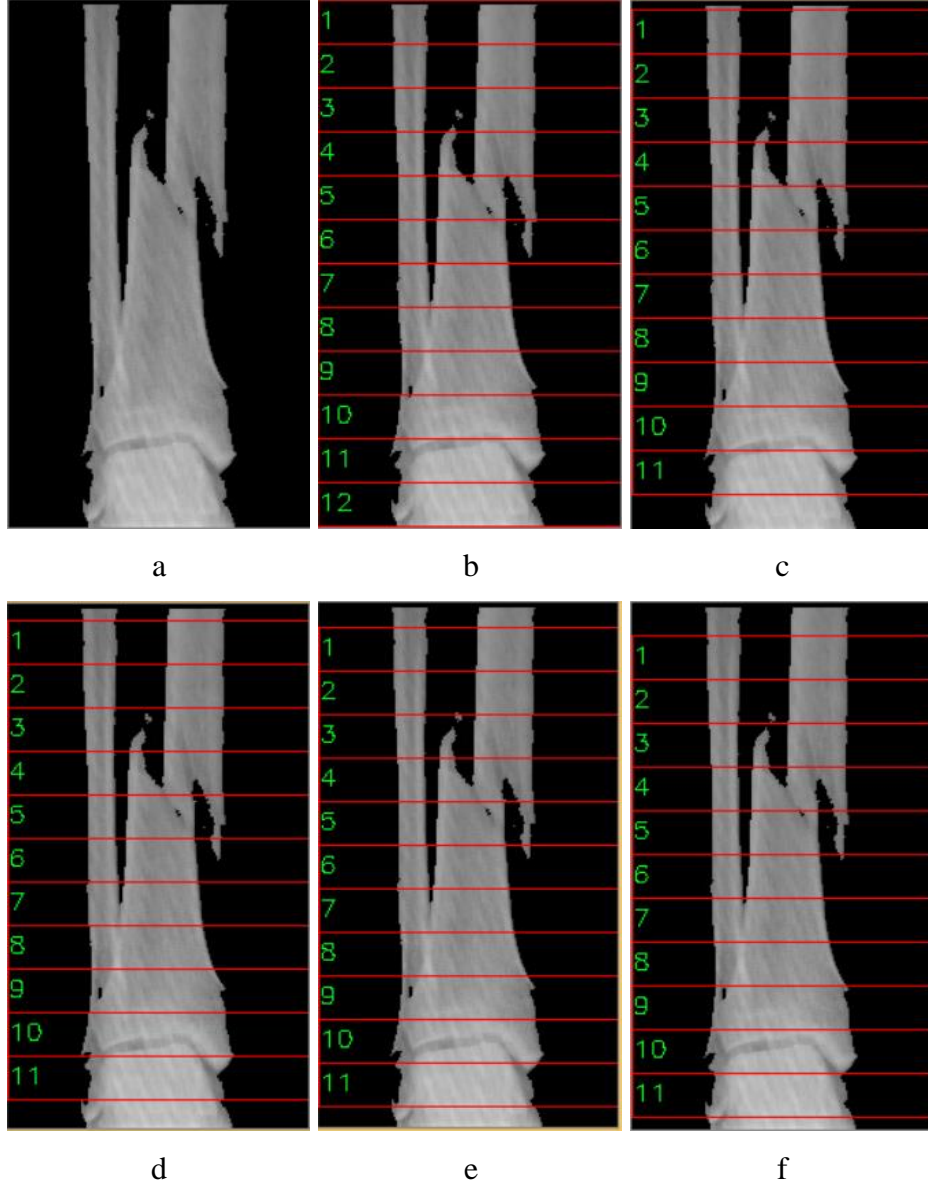
Bölüm 6.1'de anlatılan işlemler, kemik görüntüleri üzerinde uygulanarak kemik bütünü başarılı bir şekilde arka plandan ve kemik dışındaki dokulardan arındırılmıştır. Genel olarak veri setini oluşturan görüntülerin her biri farklı özelliklerde olsalar dahi bölütleme algoritmaları oldukça başarılı bir şekilde ayırt edilmiştir. Orijinal görüntüsü Şekil 7.1.a'da gösterilen ve Bölüm 6.1'de ki aşamaların sırası ile uygulanması sonucu elde bölütlendirilmiş görüntü Şekil 7.1.b, Şekil 7.1.c, Şekil 7.1.d'de gösterilmiştir.



Şekil 7.1 Orijinal görüntü ve Bölüm 6.1’deki adımların sonucu görüntüler a) Orijinal görüntü b) Gri seviye görüntü c) Median filtre sonucu d) İkili seviye görüntü.

Bölüm 6.1.3’te bölütleme aşamasında iki farklı bölütleme algoritması kullanılmıştır. Bu algoritmalar K-ortalama algoritması ve Otsu bölütleme algoritması kullanılmış ve hangisi iyi konusunda Bölüm 6.1.3’te anlatıldığı gibi CCL kullanılarak standart veri seti oluşturulmuştur.

Bölüm 6.2’de K-ortalama ve Otsu bölütleme algoritmaları ile elde edilen yeni veri setinde yer alan 325×175 boyutundaki tüm görüntüler ilk adımda, 27×175 boyutunda 12 eşit parçaya ayrılarak her görüntü için 12 farklı bölüm oluşturulmuştur. İkinci adımda, hayali olarak görüntü üzerinde gezdirilen 27×175 boyutundaki dikdörtgen 5 piksel ötelenerek görüntü 11 parçaya bölünmüştür. İkinci adımda kullanılan ilk dikdörtgen, ilk adımda yer alan 2. dikdörtgen ile üst üste gelinceye kadar 5 er piksel ötelenerek devam eder. Bununla birlikte düşeyde her bir görüntü için 0, 5, 10, 15, 20 piksel ötelenmiş farklı içeriklerde görüntü bölümleri elde edilmiştir. Şekil 7.2’de maske görüntü ve dilimlemiş görüntüler gösterilmiştir.



Şekil 7.2 Maske görüntü ve dikdörtgen formda dilimlenmiş görüntüler a) maske görüntü b) düşeyde ötelenmemiş c) düşeyde 5 piksel ötelenmiş d) düşeyde 10 piksel ötelenmiş e) düşeyde 15 piksel ötelenmiş f) düşeyde 20 piksel ötelenmiş görüntü.

Dilimleme işlemi sonucu oluşan 27x175 boyutundaki yeni görüntüler, görüntü numarası (Id), görüntü içerisinde kaçınıcı bölüm olduğu bilgisi ReId (Regrangle Id), kaç adım ilerlendiğinin bilgisi SId (StepId) gibi bilgileri tutularak özellik çıkarımı işlemi sırasında excel ortamına aktarılmıştır.

Bölüm 6.3'te anlatılan görüntü üzerinde özellik çıkarım işlemi, dilimleme sonucu oluşan görüntüler üzerinde uygulanmıştır. Özellik çıkarımı aşamasında 31 adet farklı parametre kullanılmıştır. Bunlar; Görüntü kontrastı, Görüntü Eğriliği, Gauss Türevi, Gradyanın Enerjisi, Brenner's Focus Measure, Mutlak Merkez Moment, Dalgacık Katsayılarının Toplamı, Dalgacık Katsayılarının Oranı, Helmlı ve Scherer'in Ortalama Yöntemi, Yönlendirilebilir Filtre Tabanlı Ölçü, Mekansal Frekans Ölçümü, Eşikli mutlak gradyan, Kare Gradyan, Laplacian Enerjisi, Değiştirilmiş Laplasyan, Diagonal Laplacian, Laplace Varyansı, Gri Seviye Varyansı, Gri Seviye Yerel Varyansı, Normalleştirilmiş Gri Seviye Varyansı, Değiştirilmiş Gri Seviye Varyansı, Chebyshev Moments Based. Bu parametreler sonucu elde edilen değerler, görüntülerin Id, ReId, SId, bilgileri ile birlikte excel ortamına aktarılmıştır. Ek olarak her görüntü dilimi içerisinde kalan kemik parçası için kırık olup olmadığı (ResultId, RId) etiketlenmiştir. Şekil 7.3'te görüntülere ait kimlik bilgileri, öznelik çıkarım parametreleri sonuçları ve kırık olup olmadığının etiket bilgisi bulunmaktadır.

Id	ReId	SId	Standart Deviatı	Entropy	Mean	Image Contrast	Chebyshev Moi ...	Energy og Grac	Variance of La	Image Curvatu	RId
29	3	5	0,092483668	1,420942174	0,1097943	0,137458183	164,7752654 ...	0,015907769	0,026214886	0,970526951	0
6	11	0	0,106365563	3,371298172	0,1987939	0,26740056	104,8000854 ...	0,019563534	0,030298462	0,923402204	0
36	5	10	0,022724843	1,923239231	0,1631589	0,111397359	4,45134689 ...	0,012573447	0,014350744	0,977237274	0
46	1	15	0,055989548	3,8543688	0,3681265	0,167054822	0,599358485 ...	0,014505608	0,010044282	0,975738916	0
43	8	5	0,083921671	2,15012717	0,131587	0,182978792	4,170079286 ...	0,015382668	0,02403836	0,944198139	0
7	1	5	0,050007311	2,327824401	0,1667595	0,106322529	1,916833099 ...	0,009291679	0,010302268	0,979235085	0
6	6	0	0,137132232	3,635466863	0,241523	0,246066427	43,38279981 ...	0,018562967	0,021286449	0,930308459	1
41	3	5	0,049543337	0,971370176	0,0214782	0,123129252	484,0604853 ...	0,008299715	0,020735721	0,964452699	1
35	7	5	0,112430959	1,856826973	0,0835406	0,225010004	15,95862335 ...	0,0215064	0,036652619	0,958412014	1
42	4	20	0,088818139	2,383985953	0,1556575	0,128836335	2,223835088 ...	0,009573897	0,013613925	0,967521894	1
5	3	10	0,105263021	2,436322992	0,185888	0,126571429	1,77953602 ...	0,011952317	0,012713418	0,971257526	1
12	9	5	0,081402332	2,21398216	0,1481088	0,131382153	2,691500484 ...	0,009375154	0,010251077	0,967881089	1
21	9	15	0,120355722	3,243441224	0,1993766	0,16207603	1,249708834 ...	0,008624708	0,00776807	0,964371237	1
46	8	5	0,123999639	3,691364289	0,2962233	0,287086034	0,951351179 ...	0,029385662	0,047747988	0,939421085	1
18	12	0	0,088426421	1,772310445	0,0740848	0,149207683	5,05390217 ...	0,008518284	0,013146457	0,957081281	0
18	4	5	0,085980412	2,451519955	0,1637023	0,117442977	2,370381406 ...	0,008055002	0,006459156	0,967593733	0
3	6	15	0,040399456	1,619669861	0,0645386	0,061935974	174,3963399 ...	0,002538468	0,002064687	0,974304798	0
6	3	5	0,091596703	3,442182947	0,259403	0,214288916	80,60487303 ...	0,016354915	0,015803627	0,945681278	0
37	11	0	0,156676766	5,045889046	0,4281937	0,274072029	13,06555503 ...	0,019444296	0,009402378	0,94181434	0
20	12	0	0,0975515	0,911238698	0,0327019	0,052966787	5,168890883 ...	0,002440794	0,005023452	0,989395183	0

Şekil 7.3 Görüntülere ait öznelik çıkarımı.

Bölüm 6.4'te anlatılan sınıflandırma işlemi excel ortamına aktarılan özellikler ile gerçekleştirilmiştir. Toplamda 47 adet kırık 18 adet sağlıklı görüntüden elde edilen bölümlendirilmiş 3640 görüntü alt kümesinden rastgele 570 adet kırık, 570 adet sağlıklı görüntü bölümü seçilmiştir. Seçilen 570 er adet görüntü içerisinde her iki sınıf için 525 adedi eğitim 45 adedi test verisi olacak şekilde ayrılmıştır. Sınıflandırma adımı Destek Vektör Makineleri, KNN En Yakın Komşu Algoritması ve Topluluk

Öğrenimi, Lojistik Regresyon, Karar Ağacı, Naive Bayes Sınıflandırıcısı kullanılarak gerçekleştirilmiştir.

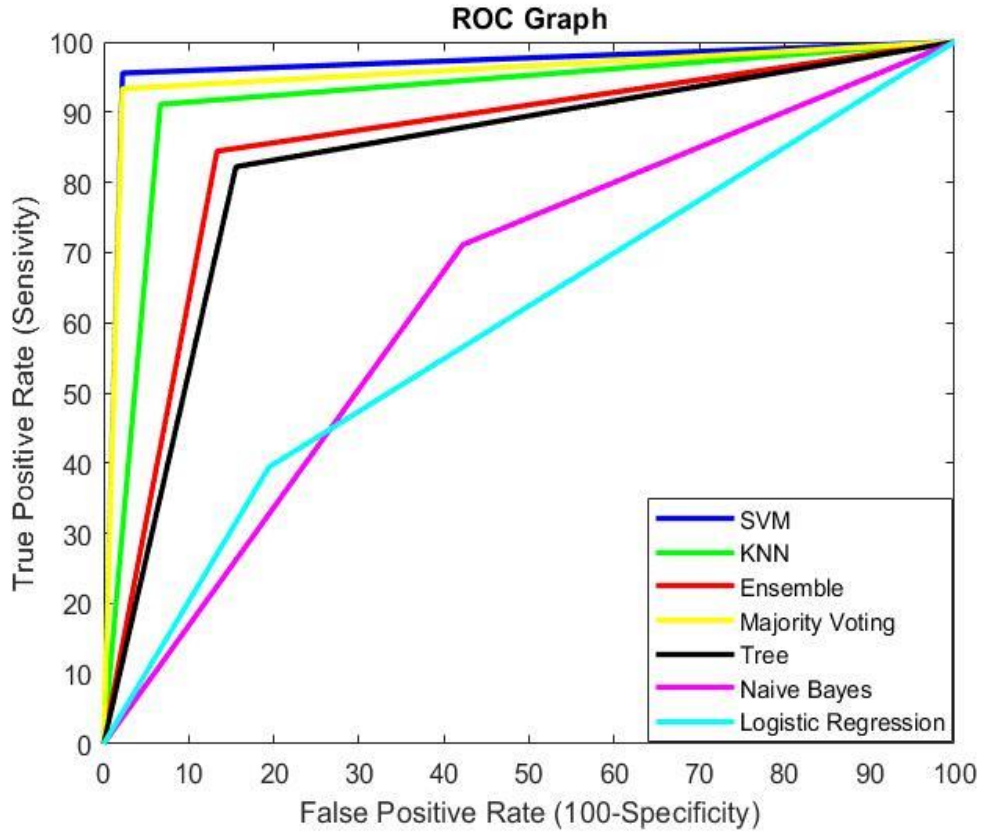
Görüntüler üzerinde kemiğin kırık olup olmadığının tespit başarısı Bölüm 6.5'te performans analizi parametrelerine göre ölçülmüştür. Sınıflandırma algoritmaları için test sonuçları Accuracy, Specificity, Sensitivity ve MCC parametreleri olarak Çizelge 7.1'de gösterilmiştir.

Çizelge 7.1 Sınıflandırma algoritmaları başarımlarını değerlendirmeleri.

	Accuracy %	Specificity %	Sensitivity %	MCC
K-En Yakın Komşu	92.22	93.33	91.11	0.84
Destek Vektör Makineleri	96.67	97.78	95.56	0.93
Topluluk Öğrenimi	85.56	86.67	84.44	0.71
Karar Ağacı	83.33	84.44	82.22	0.67
Lojistik Regresyon	60.00	80.57	39.42	0,22
Naive Bayes Sınıflandırıcısı	64.44	57.78	71.11	0.30
Majority Voting	95.56	97.78	93.33	0.91

Tüm sınıflandırma algoritmaları karşılaştırıldığında en iyi sonucu veren K-En Yakın Komşu, Destek Vektör Makineleri, Topluluk Öğrenimi algoritmaları ile elde edilen sonuçları daha güvenilir hale getirmek için üç algoritma arasında majority voting uygulanmış ve elde edilen başarı parametreleri Çizelge 7.1' de gösterilmiştir.

Çizelge 7.1'de paylaşılan değerlere göre ROC analizi yapılmıştır. Tüm Sınıflandırma algoritmaları ve Majority Voting'in Sensitivity değerleri y eksenini, (1-specificity) değerleri de x eksenini oluşturmuş ve bir ROC grafiği elde edilmiştir. Elde edilen ROC grafiği Şekil 7.4'te gösterilmiştir.



Şekil 7.4 Altı farklı sınıflandırma algoritması ve Majority Voting için ROC grafiği

Kemik kırıklarının tespiti için gerçekleştirilen bu çalışma, Literatür incelemesi bölümünde bahsedilen, 2010 ve 2022 yılları arasında aynı yönde gerçekleştirilmiş çalışmalar ile kıyaslandığında daha başarılı olduğu kanıtlanmıştır. Çizelge 7.2'de yıllara göre kemik kırıkları tespiti hakkında ki çalışmaların ve gerçekleştirilen çalışmanın doğruluk değerleri karşılaştırılmıştır.

Çizelge 7.2 Yıllara göre kemik kırıkları tespiti hakkında ki çalışmaların ve gerçekleştirilen çalışmanın doğruluk değerleri.

Referanslar	Yıl	Accuracy (%)
Ekşi vd.	2012	89.00
Kaur vd.	2015	89.60
Nascimento vd.	2015	89.00
Dimililer	2017	94.30
Malashree vd.	2017	90.00
Manjari vd.	2017	94.00
Kaur vd.	2017	93.90
Öztürk vd.	2017	89.00
Bhakare vd.	2018	85.00
Sudha vd.	2019	90.00
Çalışma	2022	96.67

BÖLÜM 8

SONUÇLAR ve DEĞERLENDİRMELER

İnsan iskelet sisteminin temelini oluşturan kemikte meydana gelen kırıklar, insan hareket ve aktivitelerini kısıtlayacağı için hastadan elde edilen kemik görüntüsü üzerinde kırık olup olmadığını tespit etmek oldukça önem kazanmaktadır. Kemik kırıklarını bir bilgisayar yazılımı ile tespit edebilmek doktorun, kemiğin kırık olup olmadığı noktasındaki yorumlama gücüne katkıda bulunacak, hastaya bilgi verecek ve bu bağlamda doktorunda işini kolaylaştıracaktır. Gerçekleştirilen çalışma 4 adımdan oluşmaktadır. Birinci bölümde görüntülerin ön işlenmesi aşaması yer almaktadır. Görüntülerin okunması, görüntülerin boyutlandırılması, görüntülerin renk uzayı dönüşümü, gürültüler için filtreleme bu bölümde yer alırlar. İkinci bölümde görüntülerin dilimlenmesi yer alır. Üçüncü bölümde dilimlenmiş görüntüler üzerinde morfolojik işlemlerin uygulanması, dilimlere ayrılarak görüntülerin çoğaltılması işlemi ve dilimlere ayrılmış görüntüleri öznelik çıkarımı ile elde edilen verilerin excel formatında kaydetme işlemleri yer almaktadır. Dördüncü ve son adım elde edilen özellik excel dosyalarının MATLAB’da okunması görüntülerin sınıflandırılması işlemidir. Gerçekleştirilen çalışmanın performans analizleri Accuracy, Sensitivity, Specificity, MCC parametreleri ile gerçekleştirilmiştir. Sınıflandırma aşamasında kullanılan altı farklı algoritma içerisinde, Destek Vektör Makineleri %96.67 Accuracy, %97.78 Specificity, %95.56 Sensitivity, 0.93 MCC değerleri ile en başarılı algoritmadır. Başarıyı destekler nitelikteki majority voting sonucunda %95.56 Accuracy, %97.78 Specificity, %93.33 Sensitivity, 0.91 MCC değerleri elde edilmiştir. Gerçekleştirilen bu çalışmanın, literatür incelemesi bölümünde bahsedilen diğer tüm çalışmalardan daha başarılı olduğu görülmüştür.

8.4. ÇALIŞMANIN KATKILARI

- Bu tez çalışmasında Bölüm 2’de sunulan kemiklerin yapısı, kemiklerin çeşitleri ve kemiklerin sınıflandırılması, kemik mimarisi, kemiğin mimari yapısı ile ilgili literatür taraması sunulmuştur. Bununla birlikte, tez çalışması bu alanda çalışacak yeni araştırmacılar için bir ön çalışma niteliğindedir.
- Tez çalışmasında Bölüm 5’te gerçekleştirilen bölütleme algoritmalarının birlikte kullanılarak en optimum görüntü veri setinin CCL yolu ile oluşturulabileceği gösterilmiştir.
- Kemik kırıklarının bilgisayar destekli teşhis edilebileceği ve bilgisayar desteği ile hekime kırık teşhisi konusunda yardımcı olacağı gösterilmiştir.

8.5. ÖNERİLER

- Bu çalışmada önerilen sınıflandırma tabanlı kırık tespiti ilerde farklı kemik kırığı türlerini de kapsayacak şekilde genişletilebilir.
- Daha fazla veri ve farklı teknikler kullanılarak sistemin başarısı artırılabilir.

KAYNAKLAR

1. Marolt, D., Knezevic, M., and Novakovic, G. V., "Bone tissue engineering with human stem cells Bone tissue engineering with human stem cells", *Stem Cell Research & Therapy*, 10 (2) (2010).
2. Veysi, A., "Kemik mineral yoğunluğunun yapay sinir ağlarıyla saptanması", *Dicle Üniversitesi*, (2007).
3. EKŞİ, Z., "Yapay sinir ağları ile kemik kırıklarının görüntü işleme tabanlı tespiti", (2012).
4. Soylak, M., "Uzun Kemik Kırıkları İçin Yeni Bir Sabitleyici Çivi Geliştirilmesi", 7 (1): 363–369 (2020).
5. Wang, X. and Puram, S., "The toughness of cortical bone and its relationship with age", *Annals Of Biomedical Engineering*, 32 (1): 123–135 (2004).
6. "Uluslararası Osteoroz Vakfı", <https://www.iofbonehealth.org/fixe-d-risk-factors> (2020).
7. Doblaré, M., García, J. M., and Gómez, M. J., "Modelling bone tissue fracture and healing: A review", *Engineering Fracture Mechanics*, 71 (13–14): 1809–1840 (2004).
8. Clarke, B., "Normal bone anatomy and physiology.", *Clinical Journal Of The American Society Of Nephrology : CJASN*, 3: 131–139 (2008).
9. Tuna, M., "Computer Simulation Of Bone Remodeling", (2013).
10. Yenigün, Ç., "Mechanical Design And Analysis of a Novel Fixation Device For Human Bone Fractures", (2016).
11. Upadhyay, R. S. and Tanwar, P., "A review on bone fracture detection techniques using image processing", *2019 International Conference On Intelligent Computing And Control Systems, ICCS 2019*, (Iciccs): 287–292 (2019).
12. Eksi, Z. and Cakiroglu, M., "Performance evaluation of the popular segmentation algorithms for bone fracture detection", *AWERProcedia Information Technology & Computer Science*, 1: 1245–1249 (2012).
13. M. Müller, "Journal of Orthopaedic Trauma", 173 (2018).

14. Tripathi, A. M., Upadhyay, A., Rajput, A. S., Singh, A. P., and Kumar, B., "Automatic detection of fracture in femur bones using image processing", *Proceedings Of 2017 International Conference On Innovations In Information, Embedded And Communication Systems, ICIIECS 2017*, 2018-Janua: 1–5 (2017).
15. Mcgee, A. M., Qureshi, A. A., and Porter, K. M., "Review of the biomechanics and patterns of limb fractures", *Trauma*, 6 (1): 29–40 (2004).
16. Kumrular, R. K. and Polat, A., "Klinik Uygulamalarda İleri Biyomedikal Görüntüleme Teknolojileri", *European Journal Of Science And Technology*, (23): 207–221 (2021).
17. Hounsfield, G. N., "Computerized transverse axial scanning (tomography): Part I. Description of system", *British Journal Of Radiolog*, 46: 1016–1022 (1973).
18. Jacob, N. E. and Wyawahare, M. V., "Survey of Bone Fracture Detection Techniques", *International Journal Of Computer Applications*, 71 (17): 31–34 (2013).
19. Ophir, J., Ponnekanti, H., Cespedes, I., Yazdi, Y., and Li, X., "Elastography: a method for imaging the elasticity in biological tissues", *Ultrasonic Imaging*, 13 (2): 111–134 (1991).
20. Oyar, O., "Magnetik Rezonans Görüntüleme (Mrg)'Nin Klinik Uygulamaları Ve Endikasyonları", *Harran Üniversitesi Tıp Fakültesi Dergisi*, 5 (2): 31–40 (2008).
21. El-Bendary, M., Salama, D., Kasban, H., El-Bendary, M. A. M., and Salama, D. H., "A comparative study of medical imaging techniques", *International Journal Of Information Science And Intelligent System*, 4 (2): 37–58 (2015).
22. Internet: Wikipedia the free encyclopedia, "Computed Tomography", https://en.wikipedia.org/wiki/CT_scan (2022).
23. Molino, G., Montalbano, G., Pontremoli, C., Fiorilli, S., and Vitale-Brovarone, C., "Imaging techniques for the assessment of the bone osteoporosis-induced variations with particular focus on micro-ct potential", *Applied Sciences (Switzerland)*, 10 (24): 1–27 (2020).
24. Internet: InformedHealth, "How Does Ultrasound Work", <https://www.informedhealth.org/how-do-ultrasound-examinations-work.html> (2022).
25. ÜNAL, D., "Tıpta Kullanılan Görüntüleme Teknikleri", *Gazi Üniversitesi*, (2008).
26. ARSLAN, T., "X-ışınları ve Kullanım Alanları", *Gazi Üniversitesi*, (2010).

27. Bulut, S., Özçınar, A., Çiftçioğlu, Ç., and Akpek, A., "X-Işini Görüntülerinde Segmentasyon ve Kirik Tespiti için Yeni Algoritma", *2015 Medical Technologies National Conference, TIPTEKNO 2015*, (October 2015): (2016).
28. Zheng, W. and Zhang, L., "Study on recognition of the fracture injure site based on X-ray images", *Proceedings - 2010 3rd International Congress On Image And Signal Processing, CISP 2010*, 4 (d): 1947–1950 (2010).
29. Smith, R., Ward, K., Cockrell, C., Ha, J., and Najarian, K., "Detection of fracture and quantitative assessment of displacement measures in pelvic X-ray images", *ICASSP, IEEE International Conference On Acoustics, Speech And Signal Processing - Proceedings*, 682–685 (2010).
30. Mahendran, S. K., "Ensemble Systems for Automatic Fracture Detection", *International Journal Of Engineering And Technology*, 4 (1): 7–10 (2012).
31. Chowdhury, A. S., Burns, J. E., Mukherjee, A., Sen, B., Yao, J., and Summers, R. M., "Automated detection of pelvic fractures from volumetric CT images", *Proceedings - International Symposium On Biomedical Imaging*, 1687–1690 (2012).
32. Bulut, S., Özçınar, A., Ftç, Ç. İ., Akpek, A., and Yeni, İ., "X-I ş 1 n 1 Görüntülerinde Segmentasyon ve K 1 r 1 k Tespiti için Yeni Algoritma A New Algorithm for Segmentation and Fracture Detection in X-Ray Images", 1–4 (2015).
33. Kaur, T. and Garg, A., "Bone Fraction Detection using Image Segmentation", *International Journal Of Engineering Trends And Technology*, 36 (2): 82–87 (2016).
34. Myint, S., Khaing, A. S., and Tun, H. M., "Detecting Leg Bone Fracture In X-Ray Images", *International Journal Of Scientific & Technology Research*, 4 (8): 140–144 (2015).
35. Nascimento, L. and Ruano, M. G., "Computer-aided bone fracture identification based on ultrasound images", *Proceedings - 2015 IEEE 4th Portuguese Meeting On Bioengineering, ENBENG 2015*, (February): 26–28 (2015).
36. Dimililer, K., "IBFDS: Intelligent bone fracture detection system", *Procedia Computer Science*, 120: 260–267 (2017).
37. Malashree and Swamy, G. N., "Automatic Detection of Radius of Bone Fracture", *International Research Journal Of Engineering And Technology(IRJET)*, 4 (6): 4–7 (2017).
38. Manjari, A. V., Kamal, A., Devi, S., and Satyanarayana, M., "Detection and Classification of Bone Fractures Using GLCM Features", *International Journal For ReseaArch In Applied Science & Engineering Technology (IJRASET)*, 5 (9): (2017).

39. Kaur, H. and Jain, A., "Detection of Fractures in Orthopedic X-Ray Images", 8 (3): 545–551 (2017).
40. Öztürk, Ö. and Kutucu, H., "Detection of Bone Fractures using Image Processing Techniques and Artificial Neural Networks", *2017 International Artificial Intelligence And Data Processing Symposium (IDAP)*, 1–5 (2017).
41. Bhakare, D. B., Jawalekar, P. A., and Korde, S. D., "A Novel Approach for Bone Fracture Detection Using Image Processing", 193–195 (2018).
42. Sudha Rani, K., Mani Kumari, K., Amulya, G., Pothineni, E., Pavani, V., and Reddy, P. S., "Leg bone fracture segmentation and detection using advanced morphological techniques", *International Journal Of Recent Technology And Engineering*, 8 (2 Special issue 3): 1246–1249 (2019).
43. PERİHANOĞLU, G. M., "Dijital Görüntü İşleme Teknikleri Kullanılarak Görüntülerden Detay Çıkarımı", (2015).
44. Chityala, R. and Pudipeddi, S., "Image Processing and Acquisition Using Python", Second edi. Ed., *CRC Press*, Boca Raton, 3–21 (2020).
45. Umesh, P., "Image Processing in Python", *CSI Communications*, 36 (9): 23–24 (2012).
46. "Internet: TIOBE (Programlama Topluluğu Endeksi)", <https://www.tiobe.com/tiobe-index/> (2022).
47. Şehirli, E., "A FULLY AUTOMATED APPLICATION FOR ANALYSIS AND QUANTIFICATION OF DNA DAMAGE ON COMET ASSAY IMAGES Ph . D . Thesis Computer Engineering", *Karabük Üniversitesi*, (2018).
48. Internet: NumPy Developers, "NumPy", <https://numpy.org/> (2022).
49. Chityala, R. and Pudipeddi, S., "Image Processing and Acquisition Using Python", *Image Processing and Acquisition Using Python*, 1–351 (2014).
50. Internet: Clark, A., "Python Imaging Library", <https://pillow.readthedocs.io/en/stable/handbook/overview.html> (2022).
51. Internet: Matplotlib development Team, "Matplotlib", <https://matplotlib.org/> (2022).
52. Internet: The MathWorks "Matworks", <https://www.mathworks.com/> (2022).
53. Gunjal, B. L. and Mali, S. N., "Image Processing with Matlab, Scilab, and Octave", 36 (9): 19–21 (2012).

54. Azemi, A. and Pauley, L. L., "Teaching the introductory computer programming course for engineers using Matlab", *Proceedings - Frontiers In Education Conference, FIE*, (2008).
55. Erkan, U., Gökrem, L., and Enginoğlu, S., "Different applied median filter in salt and pepper noise", *Computers And Electrical Engineering*, 70: 789–798 (2018).
56. Butuner, S. and Şehirli, E., "Comparison of segmentation methods used for bone fracture images", *International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences - ISPRS Archives*, 46 (4/W5-2021): 137–141 (2021).
57. Na, S., Xumin, L., and Yong, G., "Research on k-means Clustering Algorithm: An Improved k-means Clustering Algorithm", *Third International Symposium On Intelligent Information Technology And Security Informatics*, 63–67 (2010).
58. Otsu, N., "Otsu_1979_otsu_method", *IEEE Transactions On Systems, Man, And Cybernetics*, C (1): 62–66 (1979).
59. Sezgin, M. and Sankur, B., "Survey over image thresholding techniques and quantitative performance evaluation", *Journal Of Electronic Imaging*, 13 (2): 146–165 (2004).
60. Şehirli, E., "Diyabetik Hastalarda Retinal Damar Paketinin Bilgisayarlı Görü Yöntemleri İle Görüntülenmesi Ve Olası Mikroanevrizma Lezyonlarının Ortaya Koyulması", (2014).
61. Vyavahare, A. J., "Connected Component based Medical Image Segmentation", 2 (8): (2014).
62. Foltz, M., "Connected Components in Binary Images", *Massachusetts Institute Of Technology*, (1997).
63. Pertuz, S., Puig, D., and Garcia, M. A., "Analysis of focus measure operators for shape-from-focus", *Pattern Recognition*, 46 (5): 1415–1432 (2013).
64. Nanda, H. and Cutler, R., "Practical calibrations for a real-time digital omnidirectional camera", *CVPR Technical Sketch*, (January 2001): (2001).
65. Shirvaikar, M. V., "An optimal measure for camera focus and exposure", *Proceedings Of The Annual Southeastern Symposium On System Theory*, 36: 472–475 (2004).
66. Yang, G. and Nelson, B. J., "Wavelet-Based Autofocusing and Unsupervised Segmentation of Microscopic Images", *IEEE International Conference On Intelligent Robots And Systems*, 3 (October): 2143–2148 (2003).

67. Lee, S. Y., Kumar, Y., Cho, J. M., Lee, S. W., and Kim, S. W., "Enhanced autofocus algorithm using robust focus measure and fuzzy reasoning", *IEEE Transactions On Circuits And Systems For Video Technology*, 18 (9): 1237–1246 (2008).
68. Helmlı, F. S. and Scherer, S., "Adaptive shape from focus with an error estimation in light microscopy", *International Symposium On Image And Signal Processing And Analysis, ISPA*, 2001-Janua: 188–193 (2001).
69. Minhas, R., Mohammed, A. A., Wu, Q. M. J., and Sid-Ahmed, M. A., "3D Shape from Focus and Depth Map Computation Using Steerable Filters", *Lecture Notes In Computer Science (Including Subseries Lecture Notes In Artificial Intelligence And Lecture Notes In Bioinformatics)*, 5627 LNCS: 573–583 (2009).
70. Minhas, R., Mohammed, A. A., and Wu, Q. M. J., "An efficient algorithm for focus measure computation in constant time", *IEEE Transactions On Circuits And Systems For Video Technology*, 22 (1): 152–156 (2012).
71. Huang, W. and Jing, Z., "Evaluation of focus measures in multi-focus image fusion", *Pattern Recognition Letters*, 28 (4): 493–500 (2007).
72. Nayar, S. K., "Shape from focus", *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 16: 824–831 (1994)
73. Thelen, A., Frey, S., Hirsch, S., and Hering, P., "Improvements in shape-from-focus for holographic reconstructions with regard to focus operators, neighborhood-size, and height value interpolation", *IEEE Transactions On Image Processing*, 18 (1): 151–157 (2009).
74. Pech-Pacheco, J. L., Cristöbal, G., Chamorro-Martínez, J., and Fernández-Valdivia, J., "Diatom autofocusing in brightfield microscopy: A comparative study", *Proceedings - International Conference On Pattern Recognition*, 15 (3): 314–317 (2000).
75. Yap, P. T. and Raveendran, P., "INTELLIGENT DISTRIBUTED SURVEILLANCE SYSTEMS A network of co-operative cameras for visual surveillance", *IEEE Proceedings—Vision, Image and Signal Processing*, 151 (2): 128–136 (2004).
76. ÖZDEMİR, R. and TURANLI, M., "Comparison of Machine Learning Classification Algorithms for Purchasing Forecast", *Journal Of Life Economics*, 59–68 (2021).
77. Mohri, M., Rostamizadeh, A., and Talwalkar, A., "Foundations of Machine Learning", 2. Ed., *The MIT Press Cambridge*, London,UK, 457 (2018).
78. Internet: Wikipedia The Free Encyclopedia, "Reinforcement Learning", (2022).

79. Vapnik, V. N., "The Nature of Statistical Learning Theory", Second. Ed., *Springer-Verlag*, USA, New York, 206 (2000).
80. Altman, N. S., "An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression", *The American Statistician*, 46: 175–185 (1992).
81. Lin, Y. and Wang, J., "Research on Text Classification Based on BERT-BiGRU Model", (2014).
82. Wasule, V. and Sonar, P., "Classification of brain MRI using SVM and KNN classifier", *Proceedings Of 2017 3rd IEEE International Conference On Sensing, Signal Processing And Security, ICSSS 2017*, 218–223 (2017).
83. Rokach, L. and Maimon, O., "DECISION TREES", *Cycle*, 1897 (Figure 1): 44–45 (1989).
84. John, G. H. and Langley, P., "Estimating Continuous Distributions in Bayesian Classifiers George", *Proceedings Of The Eleventh Conference On Uncertainty In Artificial Intelligence.*, 338–345 (1995).
85. Sarker, I. H., "A machine learning based robust prediction model for real-life mobile phone data", *Internet Of Things (Netherlands)*, 5: 180–193 (2019).
86. Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Blondel M, Prettenhofer P, Weiss R, D. V., "Scikit-learn: Machine Learning in Python Fabian", *Journal Of Machine Learning Research*, 127 (3): 2825–2830 (2011).
87. Hassan, S. U., Ahamed, J., and Ahmad, K., "Analytics of machine learning-based algorithms for text classification", *Sustainable Operations And Computers*, 3 (February): 238–248 (2022).
88. Gianey, H. K. and Choudhary, R., "Comprehensive Review On Supervised Machine Learning Algorithms", *Proceedings - 2017 International Conference On Machine Learning And Data Science, MLDS 2017*, 2018-Janua: 38–43 (2018).
89. Sagi, O. and Rokach, L., "Ensemble learning: A survey", *Wiley Interdisciplinary Reviews: Data Mining And Knowledge Discovery*, 8 (4): 1–18 (2018).
90. Internet: Wikipedia The Free Encyclopedia, "Matthews Correlation Coefficient", https://en.wikipedia.org/wiki/Phi_coefficient (2022).
91. Matthews, B. W., "Comparison of the predicted and observed secondary structure of T4 phage lysozyme", *BBA - Protein Structure*, 405 (2): 442–451 (1975).
92. Internet: Wikipedia The Free Encyclopedia, "Sensitivity and Specificity", http://en.wikipedia.org/wiki/Sensitivity_and_specificity (2022).

93. Fawcett, T., "An introduction to ROC analysis", *Pattern Recognition Letters*, 27 (8): 861–874 (2006).
94. Şehirli, E. and Turan, M. kami., "A novel method for segmentation of QRS complex on ECG signals and classification of cardiovascular diseases via a hybrid model based on machine learning", *International Journal Of Intelligent Systems And Applications In Engineering*, 9 (1): 12–21 (2021).

ÖZGEÇMİŞ

Salih BÜTÜNER, ilkokul ve ortaokul öğrenimini Zile’de Alparslan Türkeş İlköğretim okulunda tamamladı. Lise öğrenimini Zile Dinçerler 75. Yıl Anadolu Lisesi’nde 2014 yılında tamamladı. Yine 2014 yılında Karabük Üniversitesi İngilizce Hazırlık Programına başladı. 2015 yılında Karabük Üniversitesi Mühendislik Fakültesi Biyomedikal Mühendisliği Bölümü’ne başladı ve aynı yerde lisans öğrenimini tamamlayarak 2019 yılında iyi bir ortalama ile mezun oldu. Yüksek lisans öğrenimine 2019 yılında Karabük Üniversitesi Yüksek Lisans Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalı’nda başladı. 2020-2021 yılları arasında 1180059 numaralı 1003 TÜBİTAK projesi olan Saf Hat Yumurtacı Tavuklarda Bazı Verim Özelliklerine Yönelik Markör Destekli Seleksiyon için Markör-Qtl Temelli Panel Sistemlerinin Oluşturulması projesinde araştırmacı öğrenci olarak görev almıştır. 2022 yılından itibaren Beykent Üniversitesi Yazılım Mühendisliği Bölümünde araştırma görevlisi olarak çalışmaktadır.