

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ DOKTORA PROGRAMI**

**DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK KEMİK
KIRIĞI TESPİTİ VE SINIFLANDIRMASI**

HAZIRLAYAN

KORAY AÇICI

DOKTORA TEZİ

ANKARA - 2021

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ DOKTORA PROGRAMI**

**DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK KEMİK
KIRIĞI TESPİTİ VE SINIFLANDIRMASI**

HAZIRLAYAN

KORAY AÇICI

DOKTORA TEZİ

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ EMRE SÜMER

ANKARA – 2021

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Doktora Programı çerçevesinde Koray Açıcı tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 21 / 06 / 2021

Tez Adı: Derin Öğrenme Teknikleri Kullanılarak Kemik Kırığı Tespiti ve Sınıflandırması

Tez Jüri Üyeleri

İmza

Dr. Öğr. Üyesi Tülin ERÇELEBİ AYYILDIZ, Başkent Üniversitesi

Dr. Öğr. Üyesi Emre SÜMER, Başkent Üniversitesi

Prof. Dr. Hamit ERDEM, Başkent Üniversitesi

Doç. Dr. G. Erkan BOSTANCI, Ankara Üniversitesi

Doç. Dr. M. Serdar GÜZEL, Ankara Üniversitesi

ONAY

Prof. Dr. Faruk ELALDI
Fen Bilimleri Enstitüsü Müdürü

Tarih: ... / ... /

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 27 / 06 / 2021

Öğrencinin Adı, Soyadı : Koray AÇICI

Öğrencinin Numarası : 21510192

Anabilim Dalı : Bilgisayar Mühendisliği

Programı : Bilgisayar Mühendisliği Doktora

Danışmanın Unvanı/Adı, Soyadı : Dr. Öğr. Üyesi Emre SÜMER

Tez Başlığı : Derin Öğrenme Teknikleri Kullanılarak Kemik Kırığı Tespiti ve Sınıflandırması

Yukarıda başlığı belirtilen Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 120 sayfalık kısmına ilişkin, 27 / 06 / 2021 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %4'tür. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:.....

ONAY

Tarih: ... / ... / 2021

Öğrenci Danışmanı Dr. Öğr. Üyesi Emre SÜMER

TEŞEKKÜR

Yazar, bu çalışmanın gerçekleşmesinde katkılarından dolayı, aşağıda adı geçen kişilere içtenlikle teşekkür eder.

Değerli annem Dr. Fatma AÇICI'ya bu süreçteki desteklerinden dolayı...

Bugünleri göremeyen rahmetli babam Zekeriya AÇICI'ya...

Sayın Dr. Öğr. Üyesi Emre SÜMER'e (tez danışmanı), çalışmanın sonuca ulaştırılmasında ve karşılaşılan güçlüklerin aşılmasında her zaman yardımcı ve yol gösterici olduğu için...

Tez komitemin üyeleri olan Prof. Dr. Hamit ERDEM ve Doç. Dr. Mehmet Serdar Güzel'e tez çalışmam esnasında destekleri ve yol gösterici oldukları için...

Sayın Doç. Dr. Salih BEYAZ, Dr. Öğr. Üyesi Tunç AŞUROĞLU, Dr. Öğr. Üyesi Tülin ERÇELEBİ AYYILDIZ ve Arş. Gör. Çağatay Berke ERDAŞ'a, destek ve yardımlarından dolayı...

Bu süreç boyunca desteklerini hiçbir zaman eksik etmeyen ve her zaman yanımda olan arkadaşlarım Dr. Öğr. Üyesi Harun ÇAKAN, Emrah MARAŞO, Fırat KAYAÖNÜ, Umut DERVİŞ ve Görkem SOYSAL'a...

ÖZET

Koray AÇICI

DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK KEMİK KIRIĞI TESPİTİ VE SINIFLANDIRMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

2021

Proksimal femur kırıklarının özellikle yaşlı nüfusu etkileyen ciddi bir sağlık sorunu olduğu bilinmektedir. Önemizdeki yıllarda artan nüfusla birlikte vaka sayısının ikiye katlanacağı tahmin edilmektedir. Femoral kırıkların teşhisi için düz frontal pelvik radyografiler (PXR'ler) düşük maliyetleri nedeniyle yaygın olarak kullanılmaktadır. Ne yazık ki, tüm kalça kırıklarının %2'sinin PXR ile teşhis edilemediği belirtilmektedir. Bu durum yanlış tanıya yol açmakta, iyileşme sürecini engellemekte, tedavi maliyetlerini artırmakta ve hastaların yaşam kalitelerini düşürmektedir. Bu nedenle, kanonik makine öğrenimi algoritmalarının ve derin öğrenme mimarilerinin kırık tespiti ve sınıflandırmasında kullanımı, doğru teşhis ve tedaviye yardımcı olmak için artmaktadır. Buradan yola çıkılarak, tez çalışması kapsamında femur boyun kırığı tespiti ve femur kırığı sınıflandırması çalışmaları gerçekleştirilmiştir. Femur boyun kırığı tespiti çalışmasında sıfırdan bir CNN mimarisi önerilerek tasarlanmış ve dengeli ve dengesiz iki veri kümesi üzerinde deneyler yapılmıştır. GA ve PSO üst-sezgisel optimizasyon algoritmaları kullanılarak, önerilen CNN mimarisinin evrimsel katmanlarındaki filtre boyutları ve bu katmanlarda üretilen öznitelik haritası sayıları optimize edilmeye çalışılmış ve başarımlar ölçütleri üzerinden performans artışı sağlandığı ortaya konmuştur. Femur kırığı sınıflandırması çalışmasında ise hazır CNN mimarileri transfer öğrenme yöntemiyle mevcut probleme uyarlanarak deneyler yürütülmüş ve performansları karşılaştırılmıştır. Hazır CNN mimarilerinin evrimsel katmanlarında otomatik olarak üretilen öznitelikler kanonik makine öğrenme sınıflandırıcılarını beslemek için kullanılmıştır. Tespit ve sınıflandırma çalışmalarında elde edilen performanslara göre derin öğrenme mimarilerinin kanonik sınıflandırıcılara üstün geldiği gözlemlenmiştir.

ANAHTAR KELİMELER: Femur, Kırık Tespiti ve Sınıflandırması, Derin Öğrenme, Kanonik Makine Öğrenme, Üst-Sezgisel Optimizasyon

ABSTRACT

Koray AÇICI

BONE FRACTURE DETECTION AND CLASSIFICATION USING DEEP LEARNING TECHNIQUES

Baskent University Institution of Science and Engineering

Department of Computer Engineering

2021

It is known that proximal femur fractures are a serious health problem affecting especially the elderly population. It is estimated that the number of cases will double in the next three decades with the increasing population. To diagnose femoral fractures plain frontal pelvic radiographs (PXR) are widely used due to their low cost. Unfortunately, it was stated that 2% of all hip fractures could not be diagnosed by a PXR. This situation leads to misdiagnosis, hinders the recovery process, increases the treatment costs, and decreases the life quality of the patients. Therefore, the utilization of canonical machine learning algorithms and deep learning architectures in fracture detection and classification has increased to aid in accurate diagnosis and treatment. Starting from this point of view, within the scope of the thesis, femoral neck fracture detection and femur fracture classification studies were carried out. The femoral neck fracture detection study was designed by proposing a CNN architecture from scratch and the experiments were conducted on the balanced and the imbalanced data sets. Using the meta-heuristic optimization algorithms, the filter sizes in the convolutional layers of the proposed CNN architecture and the number of feature maps generated in these layers have been tried to be optimized and it has been revealed that performance increases are achieved through performance criteria. In the femur fracture classification study, the experiments were carried out by adapting the pretrained CNN architectures to the existing problem with the transfer learning method. Automatically generated features of the pretrained CNN architectures were used to feed canonical machine learning classifiers. According to the performances obtained in the detection and classification studies, it has been observed that deep learning architectures are superior to canonical classifiers.

KEYWORDS: Femur, Fracture Detection and Classification, Deep Learning, Canonical Machine Learning, Meta-Heuristic Optimization

İÇİNDEKİLER

TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLOLAR LİSTESİ	vi
ŞEKİLLER LİSTESİ	viii
SİMGELER VE KISALTMALAR LİSTESİ	x
1. GİRİŞ.....	1
1.1. Motivasyon ve Amaç	1
1.2. Arka Plan Bilgisi.....	3
1.3. Epidomoloji	7
1.4. Ekonomik Yük ve COVID-19	10
1.5. X-ışını Görüntüleme	12
1.6. Tez Çalışmasının Genel Katkıları.....	14
1.7. Tez Planı.....	15
2. KIRIK TESPİTİ VE SINIFLANDIRMASI İLE İLGİLİ ÇALIŞMALAR	17
3. VERİ KÜMELERİ	31
3.1. Femur Boyun Kırığı Tespitinde Kullanılan Veri Kümeleri	31
3.1.1. Dengesiz veri kümesi	31
3.1.2. Dengeli veri kümesi	33
3.1.3. Bağımsız veri kümesi.....	33
3.2. Femur Kırığı Sınıflandırmasında Kullanılan Veri Kümesi.....	34
4. YÖNTEMLER.....	36
4.1. Kırık Tespiti İçin Önerilen Yapı.....	36
4.1.1. Öznitelik çıkarımı.....	39
4.1.2. Kanonik makine öğrenme yöntemleri	48
4.1.3. Derin öğrenme yöntemleri.....	53
4.1.4. Üst-sezgisel optimizasyon yöntemleri	63
4.1.5. Yeni yöntem - üç kanallı görüntü	66
4.1.6. Çoğunluk oylaması.....	67
4.1.7. CNN ve LSTM/BILSTM hibrit mimarileri	68

4.2. Kırık Sınıflandırması İçin Önerilen Yapı	68
4.2.1. Hazır CNN mimarileri	70
4.2.2. Eğitim aşamasında geri yayılım	77
5. DENEYSEL SONUÇLAR	79
5.1. Deneysel Kurulum	79
5.2. Başarım Ölçütleri	83
5.3. Analiz Sonuçları.....	86
5.3.1. Femur boyun kırığı tespiti için analiz sonuçları.....	86
5.3.2. Femur kırığı sınıflandırması için analiz sonuçları	109
6. SONUÇ	117
KAYNAKLAR.....	121
EKLER	
EK 1: Tez Çalışması Kapsamında Yayımlanan Makalelerin ve Sunulan Bildirilerin Künyeleri	

TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. Sınıflandırma çalışmasında kullanılan veri kümesi	35
Tablo 5.1. Sınıflandırma hata matrisi	85
Tablo 5.2. Farklı görüntü boyutları için performans karşılaştırması	86
Tablo 5.3. GA ile elde edilen sonuçlar	87
Tablo 5.4. HOG özniteliklerinin SVM ile sınıflandırılması	87
Tablo 5.5. HOG özniteliklerinin kNN ile sınıflandırılması	88
Tablo 5.6. HOG özniteliklerinin NB ile sınıflandırılması	89
Tablo 5.7. HOG özniteliklerinin RF ile sınıflandırılması	89
Tablo 5.8. LBP özniteliklerinin SVM ile sınıflandırılması	90
Tablo 5.9. LBP özniteliklerinin kNN ile sınıflandırılması	90
Tablo 5.10. LBP özniteliklerinin NB ile sınıflandırılması	92
Tablo 5.11. LBP özniteliklerinin RF ile sınıflandırılması	92
Tablo 5.12. Geleneksel özniteliklerin SVM ile sınıflandırılması	93
Tablo 5.13. Geleneksel özniteliklerin kNN ile sınıflandırılması	93
Tablo 5.14. Geleneksel özniteliklerin NB ile sınıflandırılması	94
Tablo 5.15. Geleneksel özniteliklerin RF ile sınıflandırılması	94
Tablo 5.16. Çoğunluk oylaması	96
Tablo 5.17. Üç kanallı görüntüler için sonuçlar	97
Tablo 5.18. LSTM ve BiLSTM ile sınıflandırma	97
Tablo 5.19. AE mimarisi ile sınıflandırma	100
Tablo 5.20. CNN/PSO ile sınıflandırma	101
Tablo 5.21. Farklı veri kümeleri için CNN mimarileri ile sınıflandırma	102
Tablo 5.22. Farklı veri kümeleri için HOG ile sınıflandırma	102

Tablo 5.23. Farklı veri kümeleri için LBP ile sınıflandırma	103
Tablo 5.24. Geleneksel öznitelikler ile sınıflandırma.....	103
Tablo 5.25. LSTM/BILSTM ile sınıflandırma	104
Tablo 5.26. Farklı veri kümeleri için çoğunluk oylaması	104
Tablo 5.27. GA ve PSO ile elde edilen CNN hiper parametreleri.....	108
Tablo 5.28. Bağımsız testler için AUC performansları	109
Tablo 5.29. Sınıflandırma için geçerleme testleri.....	109
Tablo 5.30. Geçerleme testleri AUC skorları	110
Tablo 5.31. Geçerleme testleri kesinlik, duyarlılık ve F_1 skorları.....	111
Tablo 5.32. Sınıflandırma için bağımsız testler.....	111
Tablo 5.33. Bağımsız testler için AUC skorları	112
Tablo 5.34. Bağımsız testler için kesinlik, duyarlılık ve F_1 skorları	113
Tablo 5.35. Kanonik sınıflandırıcıların performansı	114
Tablo 5.36. Kanonik sınıflandırıcılar ile SqueezeNet karşılaştırması (1)	114
Tablo 5.37. Kanonik sınıflandırıcılar ile SqueezeNet karşılaştırması (2)	115
Tablo 5.38. Kanonik sınıflandırıcılar ile SqueezeNet karşılaştırması (3)	115

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Kemiklerin AO sınıflaması	5
Şekil 1.2. Femurun üst uç anatomisi.....	5
Şekil 3.1. Kırık ve kırık olmayan PXR görüntüleri	32
Şekil 3.2. Elde edilen sentetik görüntülerden bazı örnekler	33
Şekil 3.3. Sınıflandırmada kullanılan femur kırık türleri	34
Şekil 4.1. Kırık tespiti için genel çerçeve	36
Şekil 4.2. Kırık tespiti için önerilen CNN mimarisi	37
Şekil 4.3. Kanonik makine öğrenme için genel çerçeve.....	38
Şekil 4.4. Önerilen derin öğrenme hibrit yapısı.....	38
Şekil 4.5. AE mimarisi ile öz niteliklerin elde edilmesi	39
Şekil 4.6. Yığılı sinir ağı.....	39
Şekil 4.7. GLCM'nin oluşturulması	42
Şekil 4.8. LBP öz niteliklerinin çıkarılması	44
Şekil 4.9. LBP histogram öz nitelik vektörünün oluşturulması.....	45
Şekil 4.10. HOG öz nitelikleri elde edilmiş bir görüntü.....	46
Şekil 4.11. Bir hücre için elde edilen gradyan değerleri	47
Şekil 4.12. HOG öz nitelik vektörünün oluşturulması	48
Şekil 4.13. Örnek bir CNN mimarisi	54
Şekil 4.14. Evrişimsel katmanda 3x3'lük bir filtrenin uygulanması	55
Şekil 4.15. 2x2'lik filtre boyutuna ve 2 adım sayısına sahip havuzlama katmanı	57
Şekil 4.16. Tam bağlantılı katmanın işlevi	57
Şekil 4.17. ReLU katmanının işlevi.....	58
Şekil 4.18. Seyreltme katmanının işlevi	59

Şekil 4.19. LSTM mimarisi	60
Şekil 4.20. LSTM bloğundaki kapılar	61
Şekil 4.21. Örnek bir AE mimarisi	63
Şekil 4.22. Üç kanallı görüntünün elde edilmesi	67
Şekil 4.23. Çoğunluk oylaması	67
Şekil 4.24. Örnek bir CNN/RNN hibrit mimarisi	68
Şekil 4.25. Kırık sınıflandırması için genel çerçeve	69
Şekil 4.26. AlexNet mimarisi	71
Şekil 4.27. VGG mimarisi	71
Şekil 4.28. Başlangıç katmanı	72
Şekil 4.29. ResNet artık blok yapısı	73
Şekil 4.30. Yoğun blok ve geçiş bloğu	74
Şekil 4.31. Ateşleme modülü	75
Şekil 4.32. Farklı başlangıç modülleri	76
Şekil 4.33. InceptionResNet-v2 mimarisi	77
Şekil 5.1. Saçılmış çaprazlama	80
Şekil 5.2. 5-kat çapraz geçiş	82
Şekil 5.3. ROC eğrisi	84
Şekil 5.4. k parametresi ve Kappa ilişkisi	88
Şekil 5.5. k parametresi Kappa ilişkisi	91
Şekil 5.6. CNN mimarilerinde duyarlılık ölçütü	105
Şekil 5.7. HOG ve LBP ile duyarlılık ölçütü	106
Şekil 5.8. Farklı yöntem bölümleri için duyarlılık ölçütü	106
Şekil 5.9. Farklı yöntem bölümleri için ortalama Kappa değeri	107

SİMGELER VE KISALTMALAR LİSTESİ

AE	Oto kodlayıcı (Auto Encoder)
AO	Ostesentez sorunu çalışma gurubu (Arbeitsgemeinschaft für Osteosynthesefragen)
AUC	Area Under Curve
BILSTM	İki yönlü uzun kısa süreli hafıza (Bidirectional Long Short Term Memory)
CNN	Evrişimsel sinir ağı (Convolutional Neural Network)
CT	Bilgisayarlı görüntüleme (Computerized Tomography)
FFT	Hızlı Fourier dönüşümü (Fast Fourier Transformation)
GA	Genetik algoritma (Genetic Algorithm)
GLCM	Gri seviye ortak oluşum matrisi (Gray Level Co-Occurence Matrix)
HOG	Yönlü gradyanların histogramı (Histogram of Oriented Gradients)
kNN	k-en yakın komşu (k Nearest Neighbour)
LBP	Yerel ikili örüntü (Local Binary Pattern)
LSTM	Uzun kısa süreli hafıza (Long Short Term Memory)
MRI	Manyetik rezonans görüntüleme (Magnetic Resonance Imaging)
NB	Naïve Bayes
RF	Rastgele orman (Random Forest)
RNN	Tekrarlı sinir ağı (Recurrent Neural Network)
PSO	Parçacık sürü optimizasyonu (Particle Swarm Optimization)
PXR	Pelvik X-ışını (Pelvic X-ray)
ROC	Alıcı işletim karakteristik eğrisi (Receiver Operating Characteristic Curve)
SVM	Destek vektör makinesi (Support Vector Machine)

1. GİRİŞ

1.1. Motivasyon ve Amaç

Yapay zeka, özellikle tıp alanı olmak üzere çeşitli araştırma alanlarında önemli bir rol oynamaktadır. Yapay zeka alanındaki gelişmelerden etkilenen alanlardan biri de ortopedidir. Proksimal femur kırıkları yaşlı nüfus tarafından karşılaşılan önemli bir sağlık sorunudur [1], [2]. Yaşlanan küresel nüfusa paralel olarak önümüzdeki 30 yıl içinde insidansın iki katına çıkacağı tahmin edilmektedir [3], [4], [5]. Erken teşhis ve tedavi sadece eklem korunmasını kolaylaştırmakla kalmaz, aynı zamanda hastaların postoperatif dönemde yaşam kalitelerini ve ambulasyon (herhangi bir yardıma ihtiyaç duymadan yürüyebilme) kapasitelerini sürdürmelerine yardımcı olur [6]. Pelvik X-ışını (PXR) en basit, en ucuz ve femur kırıklarının tanısı için en hızlı yöntemdir. Ancak %100 doğruluk sağlamaz. Tüm kalça kırıklarının yaklaşık %2'sinin basit PXR ile teşhis edilemediği bildirilmiştir [7], [8]. Bu durumda yanlış teşhis zincirleme sorunlara yol açmaktadır. Yanlış teşhis sırayla geç tedaviye, ameliyat sonrası iyileşme süresinin uzamasına ve tedavi maliyetlerinin artmasına neden olur. Manyetik rezonans görüntüleme (MRI), bilgisayarlı tomografi (CT) ve radyonüklid görüntüleme yöntemleriyle femur boyun kırığı tespit oranları daha yüksek olmasına rağmen, rutin kullanımları uygun maliyetli değildir [9].

Tıbbi görüntü işleme alanında derin öğrenme tekniklerinin kullanımı son yıllarda popüleritesini artırmıştır. Bilgisayarların çevresel faktörlerden etkilenmemesi, öğrendiklerini unutmaması ve yüksek hafıza kapasitesine sahip olması, genel doğruluk oranları iyileştirilirse algoritmaların yakın gelecekte doktorların hastalarına yönelik karar verme süreçlerini doğrudan etkileyeceğini düşündürmektedir. Derin öğrenme tekniklerini kullanmanın faydaları; kırıkların erken teşhisi, tedaviye erken başlanması, postoperatif iyileşme süresinin kısaltılması, yanlış teşhis nedeniyle artan maliyetlerin önlenmesi, hastaların yaşam kalitelerinin ve ambulasyon kapasitelerinin artırılması olarak gösterilebilir. Tıbbi görüntülerin işlenmesi ve değerlendirilmesinde bu teknolojinin kullanımının, hastalıkların teşhisini ve tedavilerin düzenlenmesini kolaylaştıracağı tahmin edilmektedir. Bu nedenle, kanonik makine öğrenimi algoritmalarının ve derin öğrenme mimarilerinin kırık tespiti ve sınıflandırmasında kullanımı, doğru teşhis ve tedaviye yardımcı olmak için artmaktadır.

Yapay zeka alanındaki gelişmeler, derin öğrenme mimarilerinin sağlık uzmanları düzeyinde teşhis koyma kapasitesine sahip olduğunu da göstermektedir [10], [11], [12], [13],

[14], [15], [16], [17]. Bu gelişmeler, yapay zeka sistemlerinin sağlık uzmanlarının yerini alabileceği sorusunu akla getirmektedir. Bu durum şu anda mümkün görünmese de, bu sistemlerin tıp doktorlarına tanı koyma aşamasında yardımcı olması ve tedavi planlamasını kolaylaştırması gerçeğini değiştirmemektedir.

Yapay zeka alanındaki teknik gelişmeler ortopedik cerrahi alanına iki şekilde katkı sunmuştur:

- Teşhis ve tedavide yapay zekanın karar destek sistemi olarak kullanılması
- Cerrahi tedavide robotik cerrahinin kullanılması

Ortopedik cerrahide tıbbi karar destek mekanizmaları arasında en yararlı dallardan biri olan radyoloji, evrimsel sinir ağlarının (CNN) bu alanda kullanılmasıyla büyük bir atılım yapmıştır. Kemik kırıklarının sınıflandırılmasında, inter-gözlemci (iki veya daha fazla gözlemci arasında aynı materyali incelerken ortaya çıkan değişim miktarı) ve intra-gözlemci (bir gözlemcinin aynı materyali birden fazla incelerken ortaya çıkan değişim miktarı) güvenilirliği kapsamlı bir şekilde tartışılmış ve araştırılmıştır. İlgili araştırmalara göre CT görüntülerindeki kırıklar literatüre giren yeni algoritmalar kullanılarak %98 hassasiyetle sınıflandırılabilmektedir [18], [19], [20]. Ek olarak, derin bir CNN mimarisi aracılığıyla, düz radyografilerden total kalça protezi tasarımını belirlemek için yeni, tam otomatik ve yorumlanabilir bir yaklaşım kullanan bir çalışma, CNN'nin çok yüksek bir doğruluk elde ettiğini ve sağlık bakım maliyetlerini düşürdüğünü göstermektedir [21].

Maliyeti nedeniyle X-ışını görüntüleme sistemleri hemen hemen her klinikte mevcuttur. Gelen hastanın X-ışını görüntüsü çekilerek teşhisin konması ve yapılacak olan tedavinin planlanması mümkündür. Ancak teşhisin konması X-ışını görüntüsünün yorumlanmasına ve anlaşılmasına sıkı sıkıya bağlıdır. Tecrübeli doktorlar yorumlamayı tecrübesiz doktorlara göre daha doğru ve daha hızlı bir şekilde yapabilmektedirler. Buna karşın teşhis sırasında aynı görüntü üzerinde uzmanlar arasında farklı yorumlar da ortaya çıkabilmektedir. Buna ek olarak, her sağlık kuruluşunda doğru sınıflandırmayı yapabilecek ve doğru teşhisi koyabilecek bir uzmana ulaşmak her zaman mümkün olmamaktadır. Özellikle COVID-19 ile birlikte doktorların omuzlarındaki yük katlanarak artmaktadır. Acil servislerde artan nöbet yükü ile birlikte her hastaya ayrılan süre giderek azalmakta ve doktor tarafından yanlış teşhis konma ihtimali de yorgunlukla birlikte artmaktadır. Yanlış teşhis, kırığın yanlış sınıflandırılmasına, yanlış planlamaya ve tedaviye, tedavinin maliyetinin artmasına ve hastanın yaşam kalitesinin düşmesine, cerrahların iş yüklerinin artmasına neden olmaktadır.

Yukarıda bahsi geçen motivasyonlarla özellikle küçük yerleşim birimlerindeki sağlık kuruluşlarında kullanılabilecek, doktora veya cerraha teşhisinde yardımcı olabilecek veya teşhisini doğrulayacak böylelikle iş yükünü ve maliyeti azaltacak, doktorun veya cerrahın tedaviyi planlamasını hızlandıracak ve hastanın yaşam kalitesini düzenleyecek bir sistemin derin öğrenme mimarileri ile tasarlanması bu tez çalışması kapsamında gerçekleştirilmiştir. CNN, uzun kısa-süreli hafıza (LSTM), iki yönlü LSTM (BILSTM) ve otomatik kodlayıcı (AE) olarak adlandırılan derin öğrenme mimarilerinin yanı sıra destek vektör makinesi (SVM), rastgele orman (RF), Naïve Bayes (NB) ve k-en yakın komşu (kNN) gibi kanonik makine öğrenme yöntemleriyle de proksimal femur boyun kırıklarının tespiti için çalışmalar yapılmıştır. Bunlara ek olarak femurdaki farklı kırık türlerinin sınıflandırılması için de hazır derin öğrenme mimarileri kullanılarak en yüksek doğrulukla teşhisi koyan mimarinin bulunması için çeşitli deneyler tasarlanmış ve yürütülmüştür.

1.2. Arka Plan Bilgisi

Kemik, hayvanlarda omurgalı iskeletinin bir parçasını oluşturan sert bir dokudur. Kemikler vücutta çeşitli organların korunmasından, kırmızı ve beyaz kan hücrelerinin üretiminden, minerallerin depolanmasından, vücuda yapı ve destek sağlanmasından sorumludur. Hareketliliğin olanaklı hale gelmesi kemikler sayesinde. Kemikler çeşitli şekil ve boyutlarda bulunur ve karmaşık bir iç ve dış yapıya sahiptir. Hafif olmalarına rağmen güçlü ve serttir ve birden fazla işleve hizmet eder.

Travmatik kemik kırıkları kalıcı sakatlığa sebep olabileceği gibi bazen de ölüm nedeni olabilir. Kemik kırığı vücuttaki yaralanmalarla birleştiğinde ölüm oranını artırma olasılığı yüksektir. Belirli bölgelerdeki travmatik kemik kırığı, ciddi kanamaya, çoklu organ yetmezliği sendromuna (MODS), sinir hasarlarına ve iç organlarda çeşitli hasarlara neden olabilmektedir. Kırığın semptomları, belirli bir kemiğe ve yaralanmanın ciddiyetine bağlı olmakla birlikte; ağrı, şişme, morarma, şekil bozukluğu ve uzuv kullanamama olarak sayılabilir.

Kemik kırığına, spor yaralanmaları, trafik kazaları ve düşmeler gibi travmatik olaylar sebep olabileceği gibi osteoporoz ve bazı kanser türleri kemiklerin daha kolay kırılmasına yol açabilir. Bu durumlarda küçük travmalar ve düşmeler bile ciddi sonuçlar doğurabilir.


Doğuştan insan vücudunda yaklaşık olarak 270 kemik mevcutken bunların bazıları büyüme sırasında kaynaşarak yetişkin bir insanda 206 adet ayrı kemiği oluşturur. İnsan

vücudundaki en büyük kemik femur (uyluk kemiği), en küçük kemik ise orta kulaktaki üzengidir [22].


En basit konvansiyonel radyolojik yöntem olan X-ışını görüntüleme, özellikle ortopedi alanında kırık tanısının konulmasında kullanılmaktadır. Kırığın lokalizasyonu ve morfolojisi tedavinin planlanmasında önemlidir. Kırığa cerrahi müdahale gerekip gerekmediği, cerrahi müdahale gereken durumlarda cerrahi yaklaşımın karar verilmesinde, kullanılacak implant seçiminde ve olası komplikasyonların tahmin edilerek önlem alınmasında, sınıflama çok önemlidir. Spesifik kırıklar için çeşitli sınıflama yöntemleri mevcuttur. Örneğin proksimal tibia (Plato) kırıkları için Shatzker, proksimal humerus kırıkları için Neer, distal humerus kırıkları için Jüpter sınıflamasına başvurulmaktadır. Bu sınıflama sistemlerinin güvenilirliklerini belirlemek için çeşitli çalışmalar yapılmıştır. AO (Arbeitsgemeinschaft für Osteosynthesefragen, Osteosentez sorunu çalışma gurubu) Müller sınıflaması, 1960 yılında geliştirilen, uzun kemik kırıklarının sınıflandırılmasında kullanılan alfa numerik bir sistemdir [23]. 3 rakam ve 1 harften oluşur. İlk iki rakam kırığın vücuttaki yerini tarif ederken takip eden 1 harf ve 1 rakam kırığın morfolojisini gösterir. İlk rakam kemiği belirtir (1 humerus, 2 radius/ulna, 3 femur ve 4 tibia/fibula). İkinci rakam kemiğin bölgesini işaret eder (1 proksimal, 2 diafizer, 3 distal) (Şekil 1.1). Bu sınıflamanın kullanımı tecrübeli cerrahlar tarafından daha kolay iken tecrübesi az olan cerrahlar tarafından anlaşılması daha zordur. Kırığın yanlış sınıflanması beraberinde yanlış tedavi ve kötü sonucu getirmektedir.

Femur, dört farklı kemikleşme merkezinden gelişen baş, boyun, büyük ve küçük trokanterden oluşmaktadır (Şekil 1.2). İskelet sisteminin en uzun, geniş ve kuvvetli kemiğidir. Kalça ve diz eklemi fonksiyonlarında önemli bir işleve sahiptir. Yaklaşık olarak vücut uzunluğunun dörtte birini oluşturur. Femurun büyük bölümü silindirik bir yapıya sahipken öne doğru eğilimli olan femur cisminin proksimalinde kısa bir boyun üzerinde yuvarlak artiküler kafa yer almaktadır. Femurun bir önemli işlevi de ayağı vücut ağırlığı çizgisinde bulundurmasıdır [24].

Proksimal femur kırıkları, femur boyun kırığı, intertrokanterik kırık ve subtrokanterik kırık olmak üzere kırığın anatomik konumuna göre sınıflandırılırlar. Bu kırık tiplerinin her biri özel tedavi yöntemleri gerektirir ve kırıkların nasıl ele alınacağı ve tedavi edileceği hakkında komplikasyonlar ve tartışmalar vardır [25]. Femur boyun kırıkları, femurun baş bölgesi ile intertrokanterik bölge arasında yer almaktadır. Bu kırıklar kaynamaya karşı diğer kırıklara göre daha dirençlidir. Genellikle cerrahi müdahale gerektirir. Kesin tedavi yöntemi hastanın yaşına, kırık özelliklerine ve yaralanmayı takiben süreye bağlıdır [26].



Şekil 1.1. Kemiklerin AO sınıflaması [23]



Şekil 1.2. Femurun üst uç anatomisi [24]

Genç bir yetişkinde femur boyun kırığı nadir görülen bir durumdur ve yüksek enerjili bir travmaya işaret eder. Tedavinin prensibi, avasküler nekroz ve kaynamama olasılığını azaltmak için mümkün olan en erken dönemde anatomik redüksiyon ve fiksasyondur [27]. Mümkün olan en iyi tedavi yöntemini bulmak için AO sınıflandırmasına, Garden sınıflandırmasına ve Pauwel sınıflandırmasına bakılır. Günümüzde çoğu cerrah bahsi geçen sınıflandırmalar yerine femur boyun kırıklarını deplase (yerinden çıkmış) veya deplase değil olarak incelemektedir. Uluslararası bir araştırmada Bhandari et al., [28] cerrahların %92'sinin deplase olmamış femur boyun kırığının fiksasyonu için çok sayıda kanüllü vida kullanmayı tercih ettiğini ortaya koymuşlardır. Deplase kırıklarda dahili fiksasyon kullanan cerrahların %68'i ise çoklu vida kullanımını tercih etmektedirler. Geriatrik yaş grubundaki hastalar vakaların çoğunu oluşturmaktadır. Femur boyun kırığı, geriatrik yaş grubunda yüksek ölüm oranı ile ilişkilidir (yaralanmanın ilk yılında %20-35) [29]. Geriatrik hastalarda femur boyun kırıklarının protez replasmanının tercih edilen tedavi yöntemi olduğu genel olarak kabul edilmektedir [30]. Çeşitli meta analizler ve rastgele kontrol denemeleri, artroplastiden sonra tekrar ameliyat oranının (%9), dahili fiksasyon sonrasına (%35) kıyasla azaldığını göstermiştir [31]. İntertrokanterik kırıklar büyük ve küçük trokanter arasındaki bölgede meydana gelir ve bu iki yapıyı da içerebilir. İntertrokanterik kırıklar tüm kalça kırıklarının %45'ini oluşturur [32]. Bahsi geçen bölge ağırlık taşıyan trabeküllerden oluşur ve iyi miktarda süngerimsi kemik ve damar yapısına sahiptir. Böylece avasküler nekroz ve kaynamama riski en aza indirgenmiş olur [33]. İntertrokanterik kırıklar tedavi için, AO sınıflandırması, Evan sınıflandırması ve Jenson sınıflandırması altında incelenir. Her sınıflandırma yöntemi bu tip kırıkları stabil ve stabil olmayan kırıklar (ters oblik ve koronal bölünmüş kırıklar) olarak ikiye ayırır. İntertrokanterik kırıklar genellikle cerrahi fiksasyonla tedavi edilir. İmplant seçimi kırık örüntüsüne, hastanın yaşına ve mevcut komorbiditelere (eş zamanlı hastalık) bağlıdır. Stabil intertrokanterik kırıkların tedavisi için implant seçenekleri, ekstramedüller kayar vida sistemleri (DHS), femur başında vidalı/flanşlı intramedüller çiviler (PFN, Gamma çivi) ve protezdir. Subtrokanterik kırıklar küçük trokanter ve femur gövdesinin istmusu arasında meydana gelir. Bu kırıkların görülme sıklığı femur boyun kırıklarına ve intertrokanterik kırıklara göre daha azdır. Subtrokanterik kırıklar tüm kalça kırıklarının %10 ile %30'unu oluşturmaktadır. Bu kırıklar, ameliyat sırasında redüksiyonda zorluk, kaynamama ve yanlış kaynama gibi ameliyat sonrası komplikasyonlarla kötü bir üne sahiptir. İntramedüller implantların bu kırıkların tedavisinde artan başarı oranlarına sahip olduğu kanıtlanmıştır [25].

1.3. Epidomoloji

Yaşlı insanlarda, femur boyun kırıkları ağır sakatlıklara yol açabilecek en yaygın travmatik yaralanmalardır [34], [35]. Toplum yaşlandıkça, vaka sayısının 2050 yılında istikrarlı bir şekilde yaklaşık olarak 6,3 ile 8,2 milyon arasına yükselmesi beklenmektedir [35]. Femur boyun kırıklarının insidansı (yeni vakaların ortaya çıkış sıklığı) yaklaşık olarak pertrokanterik kırıkların insidansına eşittir ve bahsi geçen kırıklar tüm proksimal femur kırıklarının %90'ından fazlasını oluşturmaktadır [36], [37], [38], [39]. Geriye kalan %5 ile %10'luk kısım ise subtrokanterik kırıklardan oluşmaktadır. Genç yetişkinlerde bu tür kırıklar 50 yaşın altındaki hastaların sadece %2'sinde görülmekle beraber oldukça nadirdir [40]. 50 yaşın üzerinde insidansa 2 ile 3 kat artış bulunmakta ve genellikle kadın cinsiyetini etkilemektedir [35]. Mevsimsel değişimlere bakıldığında, proksimal femur kırıklarının türleri arasında herhangi bir dağılım tanımlanamamasına rağmen, kış aylarında daha yüksek insidans bildirilmiştir [41], [42].

Kalça kırıklarının çoğu düşme sonrası ortaya çıkmaktadır. Yaşam boyu kalça kırığı riskinin erkeklerde %23,3, kadınlarda ise %11,2 olduğu tahmin edilmektedir [43]. Bu kırıkların %80'i kadınlarda meydana gelirken 50 yaşın üzerindeki insanların %90'ında görülmektedir [35]. Beyaz kadınlarda kalça kırığı insidansı siyah kadınlara göre 2 veya 3 üç kat fazladır [36], [44]. Yaşa göre standartlaştırılmış oranlar, hem femur boyun kırıkları hem de trokanterik kırıklar için beyaz kadınlarda siyah kadınlara göre daha yüksektir (4,33 – 1,91 ve 4,23 – 1,54; 1000 kişide) [37]. En yüksek kalça kırığı insidansı İskandinavya'da ve Kuzey Amerika toplumlarında görülürken Güney Avrupa ülkelerinde, Asya ve Latin Amerika toplumlarında daha düşüktür. Kalça kırığı riski kırsal alanlarda kentsel alanlara göre daha düşüktür [35].

Çeşitli toplumlarda insanların yaşlarının ilerlemesi ile kalça kırığı insidansındaki artış, proksimal femurdaki kemik kütlesinin azalmasının yanı sıra düşme insidansındaki artışın da bir sonucudur.

New England'da femur boyun kırıkları üzerine yapılan bir çalışma, insidansın 65 ve 69 yaşları arasındaki beyaz kadınlarda yılda 1000 kişide 2,2 olduğunu ortaya çıkarmıştır. Bu oran 90 ve 94 yaşları arasında yılda 1000 kişide 31,8'e yükselmiştir. Beyaz erkeklerde ise bu oran 65 ve 69 yaşları arasında 0,9 iken 90 ve 94 yaşları arasında 20,8'e yükselmiştir [45]. İngiltere'de oranlar, 65 ve 69 yaşları arasındaki kadınlarda yılda 1000 kişide 1,6, 90 ve 94 yaşları arasındaki kadınlarda 0,7 iken erkeklerde 65 ve 69 yaşları arasında 0,7, 90 ve 94 yaşları arasında 14 olarak tespit edilmiştir [46].

Dhanwal et al., [47] dünya çapında femur boyun kırığı insidansının geniş ırksal ve coğrafi farklılıklara bağlı olduğunu belirtmişlerdir. Endüstrileşmiş ülkeler geliştirmekte olan ülkelere kıyasla daha yüksek insidansa sahiptir. Asya toplumları arasında daha düşük femur boyun kırığı insidansı kaydedilmiştir. Japonya’da oran erkeklerde yılda 100000 kişide 99, kadınlarda ise 368 olarak tespit edilmiştir. 1990 yılında Çin’de yaşa göre standartlaştırılmış kalça kırığı insidansı kadınlarda 100000 kişide 87, erkeklerde ise 97 olarak kayıtlara geçmiştir. Asya’daki en yüksek insidans, erkeklerde yılda 100000 kişide 152 ve kadınlarda 402 olmak üzere Singapur’da kayıtlıdır. 2005 yılında Meksika’da yılda 100000 kişide erkeklerde 98 kadınlarda ise 169 olarak raporlanmıştır. İnsidans, Arjantin’de erkeklerde 137 ve kadınlarda 405 olarak kayıtlara geçmiştir. Afrika kıtasında ise insidans erkeklerde 43,7 ve kadınlarda 57,1 olarak tespit edilmiştir.

Dünyada en yüksek insidans Kuzey Amerika kıtasında ortaya çıkmaktadır. Yılda 100000 kişide erkeklerde 201 kadınlarda ise 511 olarak bulunmuştur [48]. Avrupa kıtasında ise insidans kuzeyden güneye doğru değişiklik göstermektedir. En yüksek insidans İskandinav ülkeleri olan İsveç ve Norveç’te, yılda 100000 kişide erkeklerde 399 ve kadınlarda 920 ile, en düşük insidans ise Fransa ve İsviçre’de erkeklerde 137 kadınlarda 346 ile kayıtlara geçmiştir. Bu çeşitlilik etnik köken ve bölgelerin sahip olduğu iklimin yanı sıra yaşam standartlarındaki farklılıklar ile de açıklanmaktadır.

İnsidanstaki yıllar boyunca gözlemlenen artış bazı dönemlerde kesintiye uğramıştır. Amerika Birleşik Devletleri’nde, yaşa göre düzeltilmiş kırık insidansı 1986’dan 1995’e kadar olan dönemde artmış ve ardından 1995-2005 döneminde kademeli olarak azalmıştır. Danimarka’da proksimal femur kırığı insidansı 60 yaş üstü kişilerde 1997 ve 2006 yılları arasında çarpıcı bir biçimde %20 azalmıştır. Anti-osteoporotik terapi yöntemlerinin kullanılmasıyla insidanstaki düşüşler ilişkilendirilmiştir [49].

Almanya’da insidans artmaya devam etmekteyken Finlandiya’da 1997 ve 2004 yılları arasında hafif bir düşüşe doğru belirgin bir eğilim gözlemlenmiştir. İsveç’te 50 yaş üzeri nüfustaki yaşa göre düzeltilmiş insidans düşme eğilimi göstermişken 90 yaş üzeri kadınlarda artmaya devam etmiştir [50], [51].

Güney Kore’de yapılan bir çalışmanın sonuçlarına göre proksimal femur kırıkları olan femur boyun, intertrokanterik ve subtrokanterik kırıkların insidansı sırasıyla 100000 kişide 29,3, 26,8 ve 2 olarak tespit edilmiştir. 60 yaş üzeri bireylerde kalça kırığı olarak kabul edilen femur boyun ve intertrokanterik kırıkların insidansı 100000 kişide erkeklerde 260 kadınlarda 527 olarak bulunmuştur. Erkeklerde ve kadınlarda subtrokanterik kırık insidansı ise sırasıyla 100000 kişide 7,2 ve 13,2 olarak ortaya konmuştur. Subtrokanterik kırıkların insidansı artma

eğilimi gösterirken femur boyun ve intertrokanterik kırıkların insidansının yaşlanma ile birlikte üssel olarak arttığı belirtilmiştir. Subtrokanterik kırıklara sahip olan hastaların demografik karakteristik örüntülerinin, osteoporoz ile ilişkili kırıklar olarak kabul edilen femur boyun ve intertrokanterik kırıklara sahip hastaların örüntüleriyle benzerlik göstermediği de ortaya konmuştur [52].

İtalya’da 2007 ve 2017 yılları arasını kapsayan bir çalışmada, ilk teşhis olarak femur kırığı vakası konan ve hastanede tedavi gören 991059 vakadan %91,4’ünün kalça kırıkları olduğu, %76,5’inin ise kadınlarda görüldüğü belirtilmiştir. 11 yıllık süreçte kalça kırığı insidansı kadınlarda %14,3 (58525’ten 66902’ye), erkeklerde ise %29,4 (17089’dan 22111’e) artmıştır. Kaba kalça kırığı insidansı yıllık 100000 kişide kadınlarda %1,5 (855,3’ten 868,4’e), erkeklerde ise %8,4 (346,7’den 375,9’a) artış göstermiştir. Kalça kırığı insidansı yaşa göre standartlaştırıldığında kadınlarda ve erkeklerde zaman içerisinde bir düşüş gözlemlenmiştir. Bu düşüş kadınlarda %8,7 (789,9’dan 721,5’e), erkeklerde ise %4,3’tür (423,9’dan 405,6’ya). Distal femur kırıklarında ise insidans yükselme eğilimindedir. Kadınlarda %54 (4947’den 7616’ya), erkeklerde ise %55,7 (1218’den 1896’ya) artış görülmüştür. Kaba insidans kadınlarda %36,7 (72,3’ten 98,86’ya), erkeklerde %37,8 (24,71’den 34,06’ya) artmıştır. Yaşa göre standartlaştırılmış insidans ise kadınlarda %23,9 (67,78’den 83,95’e), erkeklerde %22,7 (27,76’den 34,06’ya) artış göstermiştir. Kalça kırığı insidansının düşüş eğilimi anti-osteoporoz ilaçların büyük oranlarda alımıyla ilişkilendirilirken, distal femur kırıklarının insidansının artmasının ise nüfusun yaşlanmasına ve bifosfonatlar ve denosumab gibi ilaçların kullanılmasına bağlı olabileceği ileri sürülmüştür [53].

Türkiye’de 12 ili ve iki hastaneyi kapsayan bir çalışmada, 50 yaş ve üzeri nüfus içinde 26424 kişi kullanılarak kalça kırığı insidansı tespit edilmeye çalışılmıştır. Yaşa göre standartlaştırılmış insidansın erkeklerde ve kadınlarda 1988-1999 yıllarında yayımlanan değerlere göre önemli ölçüde arttığı belirtilmiştir. 2009 yılında yaklaşık olarak 24000 kalça kırığı vakasının bulunduğu Türkiye’de bu sayının %73’ünün kadınlarda görülen vakalar olduğu söylenmiştir. 2035 yılında kalça kırığı vaka sayısının 64000’e yaklaşması öngörülmektedir. Çalışmada Türkiye’nin genel nüfusunu yansıtmaması bakımından, Ankara, Antalya, Bursa, Diyarbakır, Edirne, Erzurum, İstanbul, İzmir, Kayseri, Malatya, Samsun ve Rize’de; kentsel/kırsal alan ayrımı, yaş, cinsiyet, sosyo-ekonomik ve sosyo-kültürel durum göz önüne alınarak sonuçlar elde edilmiştir. Buna göre erkeklerde 10000 kişide 11,9 ve 10,9 (iki hastane için ve 12 il için), kadınlarda 22,7 ve 22,6 olarak insidans tespit edilmiştir. Kalça kırığı insidansının 50 ve 64 yaşları arasında kadınlarda ve erkeklerde benzer olduğu fakat 64

yaşından sonra kadınlarda istikrarlı bir şekilde arttığı belirtilmiştir. Her iki cinsiyet için de yaşı ilerlemesiyle birlikte insidansın üssel olarak arttığı gözlemlenmiştir. Yaşam boyu kalça kırığına sahip olma olasılığının 50 yaşında, kadınlarda %15, erkeklerde %3,5; ortalama 10 yıl içinde kalça kırığına sahip olma olasılığının ise erkeklerde %0,2 ve kadınlarda %0,3 olarak bulunmuştur. 80 yaşında ise 10 yıllık olasılıkların erkeklerde %3,6 kadınlarda ise %7,3 olacağı belirtilmiştir. Türkiye'nin Avrupa'da düşük kalça kırığı insidansına sahip olduğu belirtilirken son yıllara göre ciddi bir artışın söz konusu olduğu ve kırık riski değerlendirme modellerinin gözden geçirilmesi gerektiği vurgulanmıştır [54].

Yeni Zelanda'da yapılan bir çalışmaya göre bakımevlerinde kalan geriyatrik hastaların femur boyun kırığı riskine daha yüksek oranda maruz kaldığı ortaya konmuştur. Ülkede kendi evlerinde yaşayan yaşlı insanlar arasında insidans, yıllık 100000 kişide 348 iken herhangi bir kurumda veya bakımevinde kalan yaşlı insanlar arasında 10 kat artarak 3975 olarak tespit edilmiştir [55].

Bilişsel durum bozukluğuna sahip olan hastalar daha yüksek femur boyun kırığı riskine sahiptirler. İsveç'te bir akıl hastanesinin nüfusu ile ülke nüfusunun geri kalanı karşılaştırıldığında insidansda önemli bir artış gözlemlenmiştir. Buna ek olarak kalça kırığı riskinin, ruhsal bozukluğa sahip kadınlarda 7 kat, ruhsal bozukluğa sahip erkeklerde ise 12 kat daha fazla olduğu ortaya konmuştur [56].

Osteoporozun yanı sıra femur boyun kırıkları ile ilişkilendirilen başka risk faktörleri de bulunmaktadır. Femoroasetabuler sıkışmanın (kalça sıkışması) hastaları osteoartrite yatkın hale getirdiği bilinmektedir. Özellikle femoroasetabuler sıkışma, CAM ve Pincer sıkışma morfolojileri altında incelenmektedir [57]. Dahası, bu morfolojiler başka patolojilere de yatkın olabilir. Beck et al., [58] bilinen diğer tüm zemin hazırlayan faktörler hariç tutulduğunda, femoral boyun kırığı fiksasyonundan sonra kaynamamanın nedeni olarak femoroasetabuler sıkışmanın düşünüldüğü bir vaka serisini incelemişlerdir. Buna dayanarak yazarlar, sıkışmanın, kırık tespitiyle aynı zamanda ele alınması gerektiği sonucuna varmışlardır. Bu bağlamda, femoroasetabuler sıkışma ve femur boyun stres kırıkları arasında, Pincer morfolojisinin femur boyun kırığının %78'i ile ilişkili olduğunu tespit eden bir korelasyon da tarif edilmiştir [59].

1.4. Ekonomik Yük ve COVID-19

Dünya çapında yaşlı insanların sayısının 2040 yılına kadar iki katına çıkması beklenmektedir ve kalça kırığı insidansındaki artışın halk sağlığı, sağlık sistemleri ve sağlık

kurumları için önemli bir yük haline gelmesi muhtemeldir [60]. Özellikle proksimal femur kırıkları osteoporozun en yıkıcı sonucudur. Bahsi geçen kırıklar cerrahi tedavi gerektirir, sıklıkla sakatlığa yol açar ve yüksek ölüm oranı ile ilişkilidir.

Kalça kırıkları dünyadaki sağlık hizmeti sistemleri üzerinde büyük bir ekonomik yükü temsil etmektedir. Amerika Birleşik Devletleri'nde 65 yaş ve üzerindeki hastalar için kalça kırığıyla ilişkili düzeltilmiş ilk yıl maliyetleri 15196 dolar iken bu maliyet vertebra kırığı için 6701 dolardır [61]. 1997'deki verilere göre kalça kırığı tedavisinin yıllık maliyeti dünya çapında 131,5 milyar dolardır [62]. 2005 yılında Amerika Birleşik Devletleri'nde 50 yaşın üzerindeki hastalarda 2 milyon kırık vakası kaydedilmiştir ve tedavi maliyeti 17 milyar dolar olarak belirtilmiştir. Tüm kayıtlı kırıkların %14'ü proksimal femur kırıkları olmasına rağmen bütün kırıkların tedavisi için harcanan paranın %72'sini oluşturmaktadır. Tedavinin türüne göre masrafların dağılımı, hastanede yatan hastalar için %57, ayakta tedavi için %13, uzun süreli yatan hastalar ve kurumsal tedavi için %30 olarak belirlenmiştir. Kırık tedavisinin toplam maliyetinin %89'u, 65 yaşın üzerindeki hastalara ait olarak hesaplanmıştır [63].

2019 koronavirüs hastalığına (COVID-19) neden olan ve şiddetli akut solunum sendromu koronavirüs 2 (SARS-CoV-2) olarak da bilinen yeni bir koronavirüs salgını, Aralık 2019'da Çin Halk Cumhuriyeti'nin Hubei Eyaleti'nin Wuhan şehrinde ortaya çıkan ilk vaka ile başlamıştır [64]. 11 Mart 2020'de Dünya Sağlık Örgütü (WHO) hastalığı bir pandemi olarak ilan etmiştir. O zamana kadar 113 ülkede ve bölgede 118.000'den fazla enfekte bireyin olduğu tahmin edilmekteydi [65]. COVID-19 hızla halk sağlığı için küresel bir tehdit haline gelerek dünyadaki tüm insanların, özellikle de en savunmasız olanların sağlığını tehlikeye atmıştır [66]. İspanya, 145.000'den fazla enfekte kişiyle ve %9,9 ölüm oranıyla pandeminin en çok etkilediği ülkelerden biri olmuştur [67]. Salgın durumunun sağlık sistemini çökertmekle tehdit eden sosyal ve ekonomik sonuçları olmuştur. COVID-19'un yayılmasının kontrolü, birçok ülkenin ana hedefi haline gelmiş ve hastalığın etkilerini ortadan kaldırmak, hızlıca bilimsel kanıtları yaymak ve iş birliği yapmak için dünya çapında eşi görülmemiş bir çaba oluşmuştur [68]. Bu patolojiye sahip hastaların cerrahi tedavisi, hasta kadar cerrah ve ameliyathanedeki personel için de büyük bir zorluk teşkil etmektedir. Özellikle proksimal femur kırığına sahip olan yaşlı hastalar pandemi sırasında savunmasız bir grup haline gelmiştir. İnsidans salgından önce yıllık 100000 kişide 620 olarak tespit edilmiş ve salgın eş zamanlı hastalıklarla birlikte ortaya çıkmıştır [69], [70].

Proksimal femur kırığına sahip hastalarda ilk yılda ölüm oranı %20 ile %40 arasında ilişkilendirilirken, ilk ayda %7 ile %8 arasında ilişkilendirilmektedir [71]. Ameliyatsız

tedavi veya gecikmiş cerrahi müdahale daha yüksek ölüm oranlarına sebep olmaktadır [71], [72]. Ölüm oranlarının pandemi sırasında nasıl etkileneceği araştırmaların azlığı nedeniyle bilinmemekle birlikte kalça kırığı olan yaşlı hastaların, yaşları nedeniyle COVID-19 bulaşması durumunda daha yüksek ölüm riski altında olduğu öne sürülmüştür [73], [74]. Solunum semptomları olan hastaların endişe verici bir şekilde artması nedeniyle sağlık merkezlerinin aşırı kalabalıklaşması, hastane personelini bu durumla başa çıkmak için bazı değişiklikler yapmaya sevk etmiştir. Diğer uzmanlık alanlarına ayrılmış tüm hastane alanları kapatılmış ve COVID-19 hastalarına uyarlanmıştır. Acil olmayan vakalar için ameliyathaneler yoğun bakım ünitelerine dönüştürülmüş ve çoğu İspanyol hastanesinde acil olmayan tüm cerrahi müdahaleler iptal edilmiştir. Cerrahi müdahale bekleyen yaşlı hastalar için tedavinin gecikmesinin iyileşme sürecini yavaşlatmada önemli bir risk faktörü olacağı aşikardır. Vives et al., [67] COVID-19 testi pozitif çıkan ve kalça kırığına sahip hastalarda ölüm oranının daha yüksek olduğunu ortaya koymuşlardır.

1.5. X-ışını Görüntüleme

Tıbbi görüntüleme teknikleri vücudu cerrahi olarak açmadan vücudun içine bakmak için kullanılan invazif olmayan yöntemlerdir. Farklı tıbbi durumların teşhis veya tedavisine yardımcı olmak için kullanılır. Birçok tıbbi görüntüleme tekniği vardır ve her tekniğin farklı faydaları ve riskleri bulunur. Bu tekniklere örnek olarak X-ışını (X-ray) radyografisi, bilgisayarlı tomografi (computed tomography, CT) ve manyetik rezonans görüntüleme (magnetic resonance imaging, MRI) verilebilir. Radyografi, ilgilenilen bir anatomiye X-ışınlarına maruz bırakarak ve nesneden geçerken geçirdikleri zayıflamayı ölçerek iki boyutlu projeksiyon görüntüleri oluşturma sürecini tanımlar. Çok yaygın bir X-ışını görüntüleme şeklidir ve dünya çapında, kliniklerde kullanılmaktadır. Ana uygulama alanı iskelet sistemindeki kırık ve değişikliklerin incelenmesidir. Burada, çevreleyen dokuya kıyasla kemiklerin yüksek zayıflama katsayısı iyi bir kontrast sağlar ve kırıkların tespit edilmesine ve sınıflandırılmasına izin verir. Dahası, osteoporoz veya kemik kanseri gibi durumlarda bir kemiğin kıvamındaki veya yoğunluğundaki değişiklikleri tespit etmek için radyografi kullanılabilir [75].

X-ışınları elektromanyetik ışınlar grubuna aittir ve dolayısıyla elektromanyetik radyasyon kurallarına tabidirler. Elektromanyetik radyasyon, ışıyan enerji olarak da adlandırılan enerjiyi, tıpkı radyo dalgaları, görünür ışık veya mikrodalgalar gibi dalgalar ve fotonlar aracılığıyla uzayda taşır. Böylece fotonlarla veya bir dalga modeli ile temsil

edilebilir. Görünür ışık gibi X ışınları da farklı malzemelerden geçerken belli bir miktar enerji kaybeder. Enerji kaybı, malzemenin emilim davranışına bağlıdır. Örneğin, X-ışınları x birim sudan geçerse, x birim kemiğin içinden geçmesine kıyasla daha az enerji kaybeder. Enerjinin azalması, geleneksel X-ışını görüntülemenin ana prensibi olan soğrulmadan kaynaklanmaktadır. Genel olarak, X-ışını radyografisi enerji kaybı miktarını ölçer. Bu enerji kaybı farklı malzemeler için farklılık gösterdiğinden, görüntüde belirli bir kontrast görülür. Bir X-ışını görüntüsü, yumuşak doku için yüksek yoğunluk, X-ışınlarının kemiklerden geçtiği yerlerde ise daha düşük yoğunluk gösterir. Soğrulan enerji görüntüleme sırasında hastaya verilen dozla doğrudan ilişkilidir [75].

X-ışınları Almanya'nın Wurzburg kentinde Wilhelm Conrad Röntgen tarafından keşfedildi. 8 Kasım 1895'te, tipik olarak elektron akışlarını görselleştirmek için kullanılan Crookes tüplerini içeren deneyler yapıyordu. Deneyler sırasında ayrıca bir floresan ekran kullandı ve gerçek tüpü siyah kartonla kapladı. Floresan ekranı tüplerin açıklığından uzaklaştırırken, floresan ekranda hala siyah kartondan geçen radyasyonun sonucu olması gereken bir parıltı olduğunu fark etti. Kartonu kitap gibi daha yoğun malzemelerle değiştirdiği ek deneyler de aynı gözleme yol açtı. Bundan sonra, X ışınları adını verdiği yeni radyasyonun sistematik bir incelemesine başladı. Röntgen, 28 Aralık 1895'te, ilk keşiften yaklaşık altı hafta sonra, farklı malzemelerin soğurulma özelliklerine ilişkin ilk raporları içeren X-ışınları hakkında bilinen ilk makalesini "Über eine neue Art von Strahlen" (Yeni bir ışın türü üzerine) başlığıyla yayımladı. Çığır açan keşfiyle Röntgen, 1901'de ilk Nobel Fizik Ödülü'nü aldı. Röntgen, keşfini insanlığa ithaf ederek ne bir patent başvurusu yaptı ne de kar amaçlı bir ticari girişimde bulundu.

Günümüzde, X-ışınları rutin olarak tanıda ve aynı zamanda tüm dünyada girişimsel tıbbi görüntülemelerde kullanılmaktadır. Tıbbi görüntülemelerde, basit radyografik görüntülemenin çok ötesine geçen çeşitli uygulamalar geliştirilmiştir. Fluros kopi, minimal invazif müdahalelerde gerçek zamanlı X-ışını sekanslarına izin verir. Ayrıca, sayısal çıkarımlı anjiyografi (DSA), küçük damar yapılarını bile görselleştirmek için etkili bir araç sağlar. 1970'lerde, şimdi tüm insan vücudunu üç boyutlu olarak görselleştirmeye izin veren CT adınının atılması X-ışınlarının kullanımı sayesinde. X-ışınlarının da zararlı olabileceğinin kanıtlanması, tıbbi görüntüleme tekniklerindeki madalyonun diğer yüzünü oluşturmaktadır. Bir X-ışını görüntülenmesi sırasında vücuda yayılan yüksek enerji iyonlaşmaya neden olabilir. Radyasyon, dokunun atomik yapısını bozabilir ve bu durumda kanser riski ortaya çıkabilir. Deoksiribonükleik asit (DNA) radyasyondan zarar görmektedir. Çoğu durumda, DNA hücrenin kendisi tarafından onarılacaktır. Yine de onarım süreci bazen

başarısız olur ve bazı durumlarda kansere yol açabilecek düzensiz hücre bölünmesine yol açar. Günümüzde insanların çoğu X-ışınlarının oluşturduğu risk hakkında bilinçlidir ve X-ışını görüntüleme sırasında hastaya verilen doz önemli ölçüde düşürülmüştür [75].

1.6. Tez Çalışmasının Genel Katkıları

Tez çalışmasının genel katkıları üç ana maddede sunulabilir. İlki, proksimal femur boyun görüntülerinden kırık tespiti yapan çalışmalarda hazır CNN mimarilerinin kullanılmasına odaklanılmıştır. Bu mimariler başka problemler için oluşturulmuş ve optimize edilmiştir. Dolayısıyla girdi boyutu, katman sayısı, öznitelik haritası sayısı ve evrimsel katmanlarda kullanılacak filtre boyutu gibi parametreler de ilgili problemler için optimize edilmiştir. Yapılan çalışmalarda girdi boyutu, kullanılan hazır mimarinin girdi boyutuna göre düzenlenerek diğer girdi boyutlarının sonucu nasıl etkileyeceği göz ardı edilmiştir. Bu çalışmalar daha önceden eğitilmiş ağırları kullandığı için katmanlardaki ağırlıklar da ilgili problemin verilerine göre oluşmuştur. Bu bağlamda yeni bir CNN mimarisi oluşturularak farklı girdi boyutlarının başarımlar ölçütleri üzerinden sistemin performansını nasıl etkilediği araştırılmıştır. Girdi boyutu seçildikten sonra sistemin başarımlar performansını artırmak için her evrimsel katmandaki öznitelik harita sayısının ve filtre boyutlarının optimize edilmesi için çalışmalar gerçekleştirilmiştir. Optimizasyon için genetik algoritma (GA) ve parçacık sürü optimizasyonu (PSO) olmak üzere iki üst-sezgisel algoritma kullanılmıştır. Bu tez çalışması, proksimal femur boyun kırıklarının tespitinde yeni bir CNN mimarisinin başarımlar performansını artırmak için GA ve PSO üst-sezgisel algoritmalarını uygulayan ilk çalışmadır.

Tezin ikinci genel katkısı ise proksimal femur boyun kırıklarının tespiti için dengeli ve dengesiz olmak üzere iki farklı veri kümesi üzerinde çalışmalar yapılmasıdır. Dengesiz veri kümesinin kullanılmasıyla elde edilen başarımlar performansı dengeli veri kümesinin kullanılmasıyla elde edilen başarımlar performansı ile karşılaştırılarak farklı başarımlar ölçütleri üzerindeki etkisi incelenmiştir. Bir veri kümesinin dengesiz olarak kabul edilmesi için veri kümesinde bulunan farklı sınıflara ait verilerin arasındaki oranın çok yüksek olması gerekmektedir. Çalışmamızda dengesiz veri kümesinin oranı (femur boyun kırığına sahip PXR görüntülerinin normal PXR görüntülerine oranı) düşük olmakla beraber dengesizliğin kanonik makine öğrenme algoritmaları ve derin öğrenme algoritmaları üzerindeki etkisi başarımlar ölçütleri üzerinden ortaya konmuştur.

Tez çalışmasının son katkısı ise proksimal femur kırıklarının (boyun ve intertrokanterik) sınıflandırılmasında hazır CNN mimarilerinin karşılaştırılması alanındadır. Literatürde hazır mimarilerin hangi kritere göre seçildiği üzerine bir çalışma bulunmamakla beraber genellikle iki veya daha fazla hazır mimarinin sınıflandırma performansı üzerindeki etkisi incelenmiştir. Çalışmamızda on bir farklı hazır mimari, üç sınıftan oluşan (femur boyun kırığı, intertrokanterik kırık ve normal) dengeli bir veri kümesi üzerinde test edilerek başarımları karşılaştırılmıştır. CNN mimarisi girdi olarak verilen görüntülerden otomatik olarak öznitelikleri çıkarmaktadır. Bu öznitelikler kanonik makine öğrenme algoritmalarıyla da kullanılarak proksimal femur kırığı sınıflandırma problemindeki başarımları karşılaştırılmıştır.

Genel olarak bakıldığında CNN ile yapılan çalışmalarda çok fazla medikal görüntüye sahip veri kümeleri kullanılmaktadır. Veri toplama ve etiketleme süreci özellikle sağlık alanında çok maliyetli ve zaman alıcıdır. Bu bağlamda tez çalışmasında, daha az örneklem sayısına sahip veri kümelerinin kullanımıyla ve mevcut örneklemelerden sentetik örneklemeler elde edilmek suretiyle veri çoğaltma gerçekleştirilerek modeller oluşturulmuştur. Böylelikle geniş imkanlara sahip olmayan sağlık kuruluşları da ellerindeki az sayıdaki örneklem ile yapacakları çalışmalarla modeller oluşturabileceklerdir. Özellikle doktorun teşhis ve tedavi planlama süreçlerinde iş yükünün azaltılmasında, yanlış tedavinin önüne geçilerek masrafların azaltılmasında ve hastanın yaşam kalitesini korumasına yardımcı olacak bir sistemin geliştirilmesine imkan sağlaması tez çalışmasının ek katkısı olarak görülmektedir.

1.7. Tez Planı

Tezin ikinci bölümünde kemik kırığı tespiti ve sınıflandırması üzerine yapılan geçmiş çalışmalara yer verilmiştir. Üçüncü bölümde femur boyun kırığı tespiti çalışmasında kullanılan dengeli ve dengesiz veri kümelerine ait bilgiler ile femur kırığı sınıflandırması çalışmasında kullanılan veri kümesine ait bilgiler sunulmuştur. Dördüncü bölüm, kırık tespiti çalışmasında önerilen CNN mimarisi hakkında bilgileri, bu mimarinin performansını artırmak için kullanılan üst-sezgisel optimizasyon yöntemlerini, CNN ve diğer derin öğrenme yöntemleri olan LSTM, BiLSTM ve AE hakkında bilgileri, kanonik makine öğrenme yöntemlerini ve kanonik sınıflandırıcıları beslemek için kullanılan özniteliklerin nasıl çıkarıldığını ve önerilen üç kanallı görüntü yöntemini; kırık sınıflandırması çalışmasında ise kullanılan hazır CNN mimarileri hakkında bilgileri ve eğitim aşamasında geri yayılım için kullanılan eniyileyicileri içermektedir. Beşinci bölümde deneysel sonuçlar

ana başlığı altında deneysel kuruluma, kullanılan başarıml ölçütlerine ve kırık tespiti ile sınıflandırması çalışmaları için detaylı analiz sonuçlarına yer verilmiştir. Altıncı ve son bölümde ise deneylerden elde edilen sonuçlar yorumlanarak elde edilen kazanım ve yapılan katkılar belirtmeye çalışılmış ve gelecek çalışmalardan bahsedilmiştir. Tez çalışması kapsamında yayımlanan makalelerin ve sunulan bildirilerin künyeleri ekler bölümünde verilmiştir.



2. KIRIK TESPİTİ VE SINIFLANDIRMASI İLE İLGİLİ ÇALIŞMALAR

Literatürde kemik türüne bağlı olarak çeşitli çalışmalar bulunmaktadır. Bu çalışmaları kanonik makine öğrenme ve derin öğrenme yöntemleri kullanan çalışmalar olmak üzere ikiye ayırmak mümkündür. Kanonik makine öğrenme yöntemleri kullanan çalışmalar ön işleme ve sınıflandırma adımlarını temel almaktadır. Ön işleme adımında, görüntülerdeki gürültüyü gidermek için çeşitli görüntü işleme teknikleri kullanılır. Sınıflandırma adımında ise kullanılacak sınıflandırıcıyı beslemek için görüntülerden özniteliklerin çıkarılması gerekmektedir. Destek vektör makinesi (SVM), Naïve Bayes (NB), yapay sinir ağları (ANN veya NN), karar ağaçları (DT) ve rastgele orman (RF) kırık tespiti ve sınıflandırmasında yaygın olarak kullanılan sınıflandırıcılardır. Kanonik makine öğrenmede kullanılan sınıflandırıcıların değerlendirme performansı görüntülerden manuel olarak çıkarılan özniteliklere sıkı sıkıya bağlıdır.

Kanonik makine öğrenme yöntemlerinin aksine derin öğrenme mimarilerinde öznitelik çıkarma ön aşamasına gerek kalmamaktadır. Bu mimariler ön aşamayı atlayarak öznitelikleri otomatik olarak çıkarır. Kırık tespiti ve sınıflandırması probleminde derin öğrenme yaklaşımlarından faydalanan çeşitli kırık türlerine göre çalışmalar mevcuttur. Bu kırık türlerine kalça özelinde femur boyun bölgesi, topuk kemiği, kafatası, humerus ve kol bileği örnek olarak verilebilir. Mevcut çalışmalar ResNet, VGG, AlexNet, GoogleNet ve türevleri gibi hazır mimarileri kullanmaktadır. Bu mimariler yeni girdilerle tekrar eğitilerek model oluşturulmakta ve test işlemleri bu model üzerinden yapılmaktadır. Hazır mimarilerin bazı katmanları probleme uyacak şekilde değiştirilerek eğitim aşaması gerçekleştirilmektedir. Çalışmalarda kullanılan veri kümelerinin boyutu onlarca medikal görüntüden on binlerce görüntüye kadar değişmektedir.

Tian [76] kalça X-ışını görüntülerinden kollodiafizer açığı ölçerek bu değeri sağlıklı femur ve kırık femur arasında ayırım yapmak için kullanmıştır. Bu yüksek lisans tezi çalışması kollodiafizer (femur boyun-şaft) açığı ölçerek kullanan ilk algoritmaya sahip olmakla bilinmektedir. Sınıflandırma için bir eşik veya eşikleme değeri seçilmiş, kırık tespiti de bu değere göre yapılmıştır. Çalışmada önerilen sistemi oluşturan iki modül vardır. İlk modül, görüntüdeki femurun konturunu (dış hatlarını) belirlemeden sorumludur. Bu aşamada yılan algoritması olarak da bilinen aktif konturlar yöntemi kullanılmıştır. İkinci modül kırık tespit modülüdür. Femurdan elde edilen kontur kollodiafizer açığı hesaplamak

için kullanılır. Olağandışı kollodiyafizer açığa sahip herhangi bir femur kırık olarak sınıflandırılır. Veri kümesinde 64 X-ışını görüntüsü bulunmaktadır. 64 adet görüntüden 19 adedi kırık içermektedir. Her görüntüde en fazla bir kırık bulunmaktadır. Kalça görüntülerindeki sağ ve sol femurun kollodiyafizer açıları ve aralarındaki açı farkı görüntü bilgilerinden elde edilmiştir. Bu bilgilerden hareketle herhangi bir femurdaki kırığı tespit edebilmek için belirlenen eşik değeri 116 derece olduğunda genel doğruluk başarımları ölçütü üzerinden en iyi performansa ulaşılmıştır. Sağ ve sol femur arasındaki açı farkı ise 11 derece olarak belirlenmiştir. Deney sonuçlarına göre sol femurda %95,3, sağ femurda %93,8, sağ ve sol femurda %94,5 performans elde edilmiştir. Sağ ve sol femur arasındaki açı farkı kullanıldığında ise %85,9 performansa ulaşılmıştır.

Lim et al., [77] femur ve radius içeren X-ışını görüntüleri üzerinde bir kırık tespiti çalışması yapmışlardır. Deneyler, NB ve SVM sınıflandırıcıları kullanılarak yapılmıştır. Boyun-şaft açısı, Gabor deseni, Markov Random Field (MRF) deseni ve parlaklık gradyanı (IGD) sınıflandırıcıları beslemek için çıkarılan özniteliklerdir. Çalışma sonucunda iki sınıflandırıcının birbirinin eksikliklerini kapattığı ortaya çıkarılmıştır. Veri kümesi femur için 432 X-ışını görüntüsünden ve radius için 145 görüntüden oluşmaktadır. Femur kırık tespitinde veri kümesi, eğitim için 324 ve test için 108 adet görüntü olmak üzere ayrılmıştır. Eğitim kümesinde 39 adet kırık içeren görüntü bulunurken test kümesinde 13 adet kırık içeren görüntü bulunmaktadır. Genel doğruluk başarımları ölçütü üzerinden Gabor öznitelikleri girdi olarak kullanıldığında NB %94,4 performans ile, IGD öznitelikleri girdi olarak kullanıldığında ise SVM %93,5 performans ile üstün gelmiştir. Radius kırık tespitinde veri kümesi 71 görüntü içeren eğitim kümesine ve 74 görüntü içeren test kümesine bölünmüştür. Eğitim kümesinde 21 adet kırık içeren görüntü bulunurken test kümesinde 23 adet kırık içeren görüntü bulunmaktadır. MRF öznitelikleriyle beslenen SVM sınıflandırıcısı genel doğruluk başarımları ölçütü üzerinden %77 performans sergilemiştir.

Lum et al., [78] ayrıca femur ve radius içeren X-ışını görüntüleri üzerinde bir kırık saptama çalışması yapmışlardır. Farklı öznitelik vektörleri ile beslenen Gauss çekirdeğine sahip SVM sınıflandırıcıları çoğunluk oylaması, maksimum, minimum, çarpım ve toplama kuralları üzerinden birleştirilerek sonuçlar elde edilmiştir. Sınıflandırıcı, Gabor oryantasyonu (GO), MRF ve IGD dahil olmak üzere üç farklı öznitelikle beslenmiştir. Genel doğruluk ve duyarlılık başarımları ölçütleri açısından en yüksek performans MRF özniteliklerinin çıkarılmasıyla femur kırıklarında sırasıyla %98,1 ve %100 olarak elde edilirken, doğruluk ve kesinlik başarımları ölçütleri açısından en yüksek performans sırasıyla IGD ve MRF özniteliklerinin çıkarılmasıyla radius kırıklarında %96 ve %91,3 olarak elde

edilmiştir. Femur görüntüleri için en yüksek genel doğruluk performansı farklı özneliliklerle beslenen sınıflandırıcıların sonuçları maksimum ve minimum kuralları uygulandığında %98,1 olarak elde edilmiştir. En yüksek duyarlılık performansı ise çarpım, toplama ve üç sınıflandırıcıdan en az biri kuralları uygulandığında %100 olarak tespit edilmiştir. Genel doğruluk ve duyarlılık başarımleri ölçütleri üzerinden kayıplar göz önüne alındığında en yüksek performans üç sınıflandırıcıdan en az biri kuralıyla %97,2 ve %100 olarak ortaya konmuştur. Radius görüntülerinde en yüksek genel doğruluk performansı maksimum, minimum, çoğunluk oylaması ve üç sınıflandırıcıdan en az ikisi kuralları uygulanarak %95,9 olarak bulunmuştur. Duyarlılık başarımleri ölçütü üzerinden en yüksek performans ise çarpım ve üç sınıflandırıcıdan en az biri kuralları uygulanarak %100 olarak tespit edilmiştir. Genel doğruluk ve duyarlılık başarımleri ölçütleri üzerinden kayıplar göz önünde bulundurulduğunda en yüksek performans, sınıflandırıcıların sonuçları üzerinde maksimum ve minimum kuralları uygulandığında genel doğruluk için %95,9 ve duyarlılık için %95,7 ile ulaşıldığı belirtilmiştir. 432 adet femur X-ışını görüntüsü 324 adedi eğitim kümesinde ve 108 adedi de test kümesinde olmak üzere ayrılmıştır. Eğitim kümesinde 39 adet kırık görüntüsü bulunurken eğitim kümesinde 12 adet kırık görüntüsü bulunmaktadır. 145 adet radius X-ışını görüntüsünden 71'i eğitim kümesinde 74'ü de test kümesinde olacak şekilde ayrılmıştır. Eğitim kümesinde 21 adet kırık görüntüsü bulunurken test kümesinde 23 adet kırık görüntüsü bulunmaktadır.

He et al., [79] femur X-ışını görüntüsü içeren bir veri kümesi üzerinde hiyerarşik SVM sınıflandırıcısı kullanarak kırık tespiti üzerine çalışmışlardır. Böl ve fethet yaklaşımı kullanılan çalışmada mevcut sınıflandırma problemi SVM'nin çekirdek uzayında daha küçük alt problemlere bölünerek her bir alt problemin çözümünde uzmanlaşan bir SVM eğitilir. Alt problemlerin çözülmesi tüm problemin çözülmesine nazaran daha kolay olduğundan hiyerarşik SVM mimarisi tüm problemi çözmeye çalışan tek SVM'nin performansına üstün gelmektedir. Hiyerarşik SVM mimarisi çalışma prensibini üç ilke belirler. Birinci ilkeye göre daha yüksek seviyeli bir SVM tarafından güvenilir bir şekilde sınıflandırılabilen örneklem, onun tarafından işlenir. İkinci ilkeye göre daha yüksek seviyeli bir SVM tarafından güvenilir bir şekilde sınıflandırılmayan örneklem, daha düşük seviyeli bir SVM'ye (yüksek seviyeli SVM'nin çocuğu) aktarılır. Üçüncü ilkeye göre daha düşük seviyeli bir SVM'nin kendisine geçirilen örneklem üzerindeki performansı, bu örneklem üzerindeki ebeveyninin performansından daha iyi olmalıdır. Çalışmadaki veri kümesi 420 adet görüntüden oluşmaktadır. Bunların 200 adedi eğitim için 160 adedi geçerleme için ve 60 adedi de test için ayrılmıştır. Her kümede kırık içeren görüntülerin

oranı %12 olarak tutulmuştur. Sınıflandırıcıyı beslemek için Gabor ve IG öznitelikleri görüntülerden çıkarılmıştır. Önerilen sistemin performansı genel doğruluk ve duyarlılık başarımları ölçütleri üzerinden belirlenmiştir. Hiyerarşik SVM mimarisi kullanılarak yapılan deneylerde Gabor öznitelikleri için üç seviye, IG öznitelikleri için ise dört seviyeli bir mimari oluşmuştur. Birinci seviye SVM'ler test örneklemelerinin %70'inden fazlasını sınıflandırabilmiş, geri kalanını düşük seviyeli SVM'lere geçirmiştir. Normal görüntülerin çoğunluğunu sınıflandırabildikleri için düşük seviyeli SVM'lere göre daha yüksek genel doğruluk performansına ve daha düşük duyarlılık performansına sahiptir. Hiyerarşik SVM mimarisi Gabor öznitelikleriyle beslendiğinde %91,67 genel doğruluk ve %57,14 duyarlılık performansı sergilemiştir. IG öznitelikleriyle beslendiğinde ise %93,33 genel doğruluk ve %85,71 duyarlılık performansına erişmiştir. Bu çalışmanın katkısı femur kırıklarının tespitinde hiyerarşik SVM mimarisinin performansı artırabildiğinin ortaya konmasıdır.

Mahendran and Baboo, [80] uzun bacak kemiklerinden tibia'yı içeren X-ışını görüntüleri üzerinde kırık tespiti üzerine çalışmışlardır. Ön işleme aşamasında kontrast ayarlaması, kenar iyileştirme ve gürültü giderimi işlemleri yapılarak görüntüler tespit aşamasına hazır hale getirilmeye başlanmıştır. Segmentasyon aşamasında X-ışını görüntüsünden kemik yapısının ayrılması gerçekleştirilir ve elde edilen kemik yapısında diafiz bölgesi belirlenir. Son aşama ise özniteliklerin çıkarılarak sınıflandırıcıların kullanıldığı tespit aşamasıdır. NB, NN ve SVM sınıflandırıcıları kullanarak yaptıkları deneylerde yazarlar tespit oranında kayda değer gelişme olduğunu göstermişlerdir. Üç sınıflandırıcının tek bir sonuç almak üzere birleştirildiği durumda kırık ve normal kemiklerde en yüksek tespit (doğruluk) oranının elde edildiği gösterilmiştir. 3 sınıflandırıcıdan 2'sinin aynı yönde oy kullanması sonucu (kırık veya normal) oluşturmaktadır (çoğunluk oylaması). GLCM ortalama, GLCM varyans, enerji, entropi, homojenlik, GO, MRF ve IGD olmak üzere 8 farklı öznitelik çıkarılmış ve sınıflandırıcılar beslenmiştir. Veri kümesinde 650 görüntü eğitim için 350 görüntü de test için kullanılmıştır. Eğitim kümesinde 400 adet kırık içeren ve 250 adet normal görüntü bulunurken test kümesinde ise 200 adet kırık içeren ve 150 adet normal görüntü bulunmaktadır. Kırıkların ve normal kemiklerin tespitinde NN sınıflandırıcısı sırasıyla %83,12 ve %92,96; SVM sınıflandırıcısı %85,71 ve %94,55; NB sınıflandırıcısı ise %86,08 ve %95,91 tespit oranı performansı sergilemiştir. Üç sınıflandırıcının da birleştirildiği çoğunluk oylaması senaryosunda ise performans %91,27 ve %98,43'e yükselmiştir.

Al-Ayyoub and Al-Zghool, [81] uzun kemikleri içeren X-ışını görüntülerinde kırığın türünü tespit etmeye yarayan bir çalışma yapmışlardır. Ön işleme aşamasında görüntüleri

yumuşatmak ve bulanıklık, karanlık, parlaklık, Poisson ve Gaussian gürültülerini gidermek için bir dizi filtreleme algoritması kullanılır. Daha sonra kenar tespiti, köşe tespiti, paralel ve kesik çizgilerin tespiti, dokuların çıkarılması ve tepe noktası tespiti gibi yöntemler kullanılarak sınıflandırıcıları besleyecek öznitelikler elde edilir. SVM, DT, NB ve NN sınıflandırıcılarını kullanarak yaptıkları deneylerde SVM'nin en yüksek performansa eriştiğini göstermişlerdir. Deneyler 5, 10 ve 15 kat çapraz doğrulama için tekrarlanmıştır. Çalışmalarındaki veri kümesinde 300 X-ışını görüntüsü bulunmaktadır. Bunlardan 200 adedi normal kemiklere aitken geri kalanı dört farklı kırık türü içeren kemiklere aittir. Sistemin performansı keskinlik, duyarlılık, F_1 skoru ve AUC skoru başarımlar ölçütleri üzerinden ölçülmüştür. Kırık tespiti için SVM sınıflandırıcısı 10-kat çapraz geçerleme sonuçlarına göre 0,893 AUC skoru performansı ile diğer sınıflandırıcılara üstün gelmiştir. Kırık türünün sınıflandırılmasında da SVM sınıflandırıcısı 10-kat geçerleme sonuçlarına göre 0,893 AUC skoru performansı ile diğer sınıflandırıcıları geride bırakmıştır.

Al-Helo et al., [82] CT görüntüleri kullanarak omurlarda kama tipi kompresyon kırığı tespiti için tam otomatik bir bilgisayar destekli tanı (CAD) sistemi önermişlerdir. Önerilen sistem başlangıçta beş bel omurunu tespit eder, etiketler, bölütlere ayırır ve kama tipi kırığı tespit eder. K-ortalama (gözetimsiz öğrenme) ve NN (gözetimli öğrenme) algoritmaları kullanılarak yapılan çalışmalarda sınıflandırıcıları beslemek için 4 öznitelik kullanılmıştır. Veri kümesi 250 adet omur görüntüsünden oluşmaktadır. K-ortalama için elde edilen genel doğruluk performansı %98 iken NN için yapılan 10-kat çapraz geçerleme testleri sonucunda %93,2 olarak bulunmuştur. Özgüllük ve duyarlılık başarımlar ölçütleri üzerinden performans K-ortalama için sırasıyla %99,1 ve %87,1 olarak tespit edilmiştir.

Avinash et al., [83] humerus, ulna, femur, tibia ve fibula X-ışını görüntüleri üzerinde kırık tipi tespiti çalışması yapmışlardır. Kırık tipi olarak transversal ve oblik kırıklar tespit edilmeye çalışılmıştır. Ön işleme aşamasında görüntüler üzerinde Canny kenar tespiti ve Harris köşe tespiti algoritmaları uygulanmıştır. Öznitelik çıkarma aşamasında ise metin sınıflandırma probleminde kullanılan kelime torbası (BoW) modeli seçilmiştir. Burada görüntüdeki öznitelikler kelimeler olarak düşünülmüştür. BoW, bir görüntüdeki yerel bölgelerde çıkarılan özniteliklerin frekanslarının vektörü olarak düşünülebilir. Her görüntüdeki yerel bölgelere SIFT algoritması uygulanarak 128 boyutlu bir vektöre dönüştürülmüştür. Böylelikle sınıflandırıcıyı besleyecek girdilerin boyutu eşitlenmiştir. Çalışmada sınıflandırıcı olarak SVM kullanılmıştır. Veri kümesini oluşturmak için 3900 X-ışını görüntüsü toplanmıştır. 380 adet humerus, 1309 adet radius ve ulna, 225 adet femur ve 1986 adet tibia ve fibula görüntüsü veri kümesini oluşturmaktadır. Görüntülerdeki kırık

tipleri doktorlar tarafından etiketlenmiştir. 10-kat çapraz geçerleme yönteminin uygulandığı tespit sonuçlarına göre sistemin performansı genel doğruluk başarımları ölçütü üzerinden %78 olarak hesaplanmıştır.

Bayram and Çakıroğlu, [84] X-ışını görüntüleri kullanarak diafizyal femur kırıklarını sınıflandırma çalışması yapmışlardır. Sınıflandırma işlemi AO sınıflandırma sistemindeki 9 kırık tipini belirlemektedir. Önerilen yöntem görüntüler üzerinde Niblack yerel eşikleme yöntemini kullanarak segmentasyon yapar ve görüntüye gürültü giderme işlemi uygulanarak görüntü iyileştirilir. Çalışmada SVM, kNN, NN ve doğrusal ayırıcı analizi (LDA) sınıflandırıcıları kullanılmıştır. Sınıfları beslemek için görüntülerden 8 adet öznitelik çıkarılmıştır. Veri kümesi 196 adet femur görüntüsü içermektedir. 10-kat çapraz geçerleme testleri kullanılarak genel doğruluk başarımları ölçütü üzerinden yapılan performans değerlendirmelerinde SVM sınıflandırıcısının %89,87 ile diğer sınıflandırıcılara üstün geldiği gösterilmiştir.

Yao et al., [85] CT görüntüleri kullanarak torasik (göğüs ile ilgili) ve lomber vertebra (bel omurgası) kırıklarını tespit çalışması yürütmüşlerdir. Görüntülerde öncelikle spinal kolon tespit edilerek omurlara ayrılır. Bir sonraki işlem, omur gövdesinin kortikal kabuğunun deforme olabilen çift yüzeyli modeller kullanılarak bölümlere ayrılmasını içerir. Kortikal kabuk 2 boyutlu bir düzleme açılarak anormallikleri tespit etmek için görüntü tanıma teknikleri uygulanır. Anormalliklerin bulunduğu bölgeler 3 boyutlu düzleme tekrar yansıtılarak öznitelikler çıkarılır. Oluşturulan öznitelik vektörleri SVM sınıflandırıcısını beslemek için kullanılır. Çıkarılan öznitelikler; morfolojik, dokusal, fizyolojik ve konumsal başlıkları altında toplam 28 adettir. Veri kümesinde 40 hastadan elde edilen görüntüler bulunmaktadır. Eğitim kümesinde 20 ve bağımsız test kümesinde 20 hastadan elde edilen görüntüler olacak şekilde veri kümesi ikiye bölünmüştür. Önerilen CAD sistemi duyarlılık başarımları ölçütü üzerinden %93,6 performans ve hasta başına 3,2 yanlış pozitif oranı ile çalışmıştır.

Tripathi et al., [86] femur X-ışını görüntüleri üzerinde kırık tespiti için bir çalışma yapmışlardır. Ön işleme aşamasında öncelikle görüntüler üzerinde ortalama filtre ve ortanca filtre yöntemleriyle gürültü giderme işlemi uygulanmıştır. Görüntünün kontrastını artırmak için ise logaritmik operatör kullanılmıştır. Kemiklerin sınırlarının daha net görüntüsünün elde edilebilmesi için ilk olarak aşındırma ve genişleme morfolojik operatörleri uygulanmış sonrasında ise Canny, Gaussian ve Sobel kenar tespiti algoritmaları test edilmiştir. Yapılan deneyler sonucunda en iyi sonucun Sobel algoritması ile elde edildiği belirtilmiştir. Veri kümesi, eğitim kümesinde 30, test kümesinde ise 24 adet görüntü olacak şekilde ayrılmıştır.

Kırık içeren ve normal görüntü sayıları belirtilmemiştir. SVM sınıflandırıcısının kullanıldığı çalışmada, genel doğruluk başarımları ölçütü üzerinden sistemin performansı %87,5 olarak ölçülmüştür.

Basha et al., [87] X-ışını görüntüleri kullanarak uzun kemikler üzerinde kırık tespiti çalışması yapmışlardır. Uzun kemiklerden ne kastettikleri ise makalelerinde kullandıkları şekillerden distal femur olarak anlaşılmaktadır. İlk olarak, Hough dönüşümü tabanlı kırık tespiti (HTBFD) adını verdikleri gözetimsiz öğrenme yöntemiyle kırık tespiti deneyleri yapmışlardır. Bu yöntem ilgili kemiğin sınırlarını bulmak için bulanık c-ortalama eşikleme ve gürültü giderme filtreleri kullanılmaktadır. Kırığın tespiti ise Hough dönüşümü ile yapılmaktadır. Çalışmalarının ikinci bölümünde, görüntülerden gradyan özniteliklerini çıkarıp bunlarla sınıflandırıcıları beslemişlerdir. Gradyan öznitelikleri (şiddet ve yön) görüntü üzerinde 20x20'lik bir pencere gezdirilerek elde edilmektedir. Sınıflandırıcı olarak kNN ve radyal tabanlı fonksiyon kullanan NN (RBFNN) kullanılmıştır. Veri kümesinde 180 X-ışını görüntüsü bulunmaktadır. Bunların 100 tanesi normal iken 80 tanesi kırık içermektedir. 100 normal görüntünün 80 tanesi eğitim 20 tanesi de test için ayrılmıştır. Kırık içeren 80 görüntünün 60 tanesi eğitim 20 tanesi de test için ayrılmıştır. RBFNN sınıflandırıcısının genel doğruluk başarımları ölçütü üzerinden %88 performans ile HTBFD ve kNN sınıflandırıcısının performanslarını geçtiği raporlanmıştır.

Dimililer, [88] yaptığı çalışmada çeşitli kemikleri içeren X-ışını görüntüleri üzerinde kırık tespiti problemini ele almıştır. Çalışmada hangi kemikler üzerinde çalışıldığı belirtilmemiştir. Ön işleme aşamasında Haar dalgacık dönüşümü uygulanarak görüntünün iyileştirilmesi sağlanmıştır. Ölçekle değişmeyen öznitelik dönüşümü (SIFT) algoritması ile de görüntüden öznitelikler çıkarılmıştır. Bu öznitelikler 3 katmanlı (giriş, gizli, çıkış) bir NN'ye girdi olarak verilerek model oluşturulmuştur. Veri kümesinde 100 görüntü bulunmaktadır. Bunlardan 30'u eğitim, 70'i ise test aşamasında kullanılmıştır. Genel doğruluk başarımları ölçütü üzerinden performans %94,3 olarak bulunmuştur.

Mall et al., [89] X-ışını görüntüleri üzerinde çeşitli kemik kırıklarının tespiti üzerine bir çalışma yapmışlardır. Veri kümesi olarak hazır Musculoskeletal Radiographs (MURA) veri kümesi kullanılmıştır. Bahsi geçen veri kümesinde 20828 normal (%56,64) ve 15942 kırık içeren (%43,36) görüntü bulunmaktadır. Görüntülerin %67'si eğitim aşamasında %33'ü ise test aşamasında kullanılmıştır. Çalışma görüntü ön işleme, öznitelik çıkarma ve tespit (ikili sınıflandırma) aşamalarından oluşmaktadır. Öncelikle RGB görüntüler gri seviyeli görüntülere indirgenmiştir. Gürültü giderimi için kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE) yöntemi uygulanarak görüntüler iyileştirilmiştir. Öznitelik

çıkarımı aşamasında ise GLCM yöntemi ile her bir görüntü için 12 adet öznitelik elde edilmiştir. Çalışmada radyal tabanlı SVM, lineer SVM, lojistik regresyon (LR) ve karar ağacı (DT) olmak üzere dört farklı sınıflandırıcı kullanılarak duyarlılık, özgüllük, kesinlik, genel doğruluk ve F_1 skoru başarımlar ölçütleri üzerinden performans karşılaştırılması yapılmıştır. Duyarlılık ölçütü üzerinden DT %54,48 ile, özgüllük ölçütü ve kesinlik ölçütü üzerinden lineer SVM %87,42 ile, genel doğruluk ölçütü üzerinden radyal tabanlı SVM %62 ile ve F_1 skoru üzerinden ise DT %53,85 ile en yüksek performansa ulaşmıştır.

Cao et al., [90] çeşitli kemiklerde kırığın konumunu tespit etmeye yarayan geliştirilmiş bir yöntem sunmuşlardır. Ayak, diz, bilek, el ve kol kemiklerini içeren ve çeşitli çekim açıları kullanılarak elde edilmiş X-ışını görüntüleri üzerinde çalışmışlardır. Görüntülerden çıkarılan öznitelikler üç grupta toplanmıştır. Birinci grupta 13 adet öznitelik ile Schmid doku öznitelikleri bulunmaktadır. Schmid öznitelikleri, parçalı kırıkların rastgele örüntüsünü tanımlayan, yönelimle değişmeyen dokuları temsil eder. İkinci grupta 40 adet öznitelik ile Gabor doku öznitelikleri bulunmaktadır. Gabor öznitelikleri, memeli görsel korteksinin işlevselliği taklit edilerek elde edilir. Açık ve çapraz kırıklar gibi kenar veya çıkıntı yapıları temsil eder. Üçüncü grupta 120 adet öznitelik ile bağlamsal-yoğunluk (CI) öznitelikleri bulunmaktadır. CI öznitelikleri, görüntüdeki kenar ve doku hakkında ek bilgi sunması için kullanılmıştır. Çalışmada sınıflandırıcıları eğitmek için kullanılan toplam öznitelik sayısı 173'tür. Yığılı rastgele orman (SRF) algoritması ilk katmanda her bir öznitelik tipi için bir rastgele orman (RF) kullanır. İlk katmanda RF'leri oluşturan ağaçların yaprak düğümlerinden elde edilen dağılımlar birleştirilerek yeni bir öznitelik vektörü oluşturulur ve bir sonraki katmana verilir. Bu işlemler tekrarlanarak son katmanda nihai karar verilir. Sistemin eğitilmesi için görüntülerdeki kırıklar uzman bir radyolog tarafından işaretlenerek sınırlayıcı kutular tarafından kapsanmaktadır. Test aşamasında, eğitilmiş SRF görüntüde yerel bölgeler için güven puanı haritaları üretir. Bu haritalar bir yerel bölgenin kırık içerme olasılığını belirtir. Güven puanı haritaları temel alınarak büyük olasılıkla kırık içeren bölgeleri tespit etmek için etkili alt pencere araması (ESS) algoritması kullanılır. Çalışmada kullanılan veri kümesinde 145 X-ışını görüntüsü bulunmaktadır. Her görüntüde en az bir kırık vardır. Görüntülerin %80'i eğitim, %20'si ise test aşamasında kullanılmıştır. Çapraz geçerleme için veri kümesinin ayrılması 10 kere tekrar edilmiştir. Sistemin performansını ölçmede uzman radyoloğun çizdiği sınırlayıcı kutu ile sistemin öngördüğü sınırlayıcı kutu arasında merkez sapma (CD) uzaklık ölçütü kullanılmıştır. CD değeri 0,12 değerinden küçük ise sistemin öngörüsü doğru kabul edilmiştir. 4 katmanlı SRF'nin hem 1 ve 2 katmanlı SRF'ye hem de farklı öznitelik grupları ile beslenen SRF'lere üstün geldiği

tespit edilmiştir. Ek olarak farklı öznetelik gruplarını girdi olarak kullanan SVM'ler ile de deneyler yapılmış ve SRF'nin SVM'ye üstün geldiği gösterilmiştir. Önerilen sistem test için verilen bir görüntüdeki kırığın konumunu tespit etmek için 20 tane sınırlayıcı kutu üretir. Çalışmada, en yüksek puanı alan 7 adet sınırlayıcı kutunun ortalama olarak kırıkların %81,2'sini içerdiği ortaya konmuştur.

Chung et al., [20] düz anteroposterior (ön arka eksenli) omuz X-ışını görüntüleri üzerinde hem proksimal humerus kırık tespiti hem de kırık sınıflandırması çalışması yapmışlardır. Proksimal humerus kırığı sınıflandırmasında 4 kırık tipi kullanılmıştır. CNN hazır mimarisi olarak ResNet-152, ellerindeki veri kümesi ile tekrar eğitilerek mevcut probleme uygun hale getirilmiştir. Veri kümesinde 1891 X-ışını görüntüsü bulunmaktadır. Bunlardan 1376 tanesi proksimal humerus kırığı görüntüsüyken 515 tanesi de normal omuz görüntüsüdür. Her görüntü bir kişiden elde edilmiştir. Hastaların yaş ortalaması 65'tir (24-90). CNN'in başarımları, 28 hekimin (ameliyata girmeyen), 11 ortopedistin ve omuz üzerinde uzmanlaşmış 19 ortopedistin başarımlarıyla karşılaştırılmıştır. Başarımlar ölçütleri olarak genel doğruluk, duyarlılık, özgüllük, Youden indeksi ve alıcı işletim karakteristik eğrisi (ROC) altında kalan alan (AUC) seçilmiştir. Veri kümesi üzerinde 10-kat çapraz geçişleme uygulanarak eğitim ve test işlemleri gerçekleştirilmiştir. Çalışmanın sonuçlarına göre önerilen model, kırık tespiti probleminde genel doğruluk başarımları ölçütü üzerinden %96, AUC skoru olarak 1 (%100), duyarlılık başarımları ölçütü üzerinden %99, özgüllük başarımları ölçütü üzerinden %97 ve Youden indeksi başarımları ölçütü üzerinden %97 performansına sahiptir. Proksimal humerus kırığı sınıflandırmasında ise birinci kırık türünden dördüncü kırık türüne doğru %65-86 arası genel doğruluk, 0,90-0,98 arası AUC skoru, %88-97 arası duyarlılık, %83-94 arası özgüllük ve %71-90 arası Youden indeksi başarımları elde edilmiştir. Önerilen model insanların başarımlarıyla karşılaştırıldığında CNN, 28 hekime ve 11 ortopediste üstün gelirken omuz üzerinde uzmanlaşmış 19 ortopedistin başarımlarıyla benzer performans göstermiştir.

Kim and MacKinnon, [91] yan (lateral) el bileği X-ışını görüntülerini kullanarak distal radiusta ve ulnada kırık tespiti üzerine çalışmışlardır. Çalışmada hazır CNN mimarisi olarak Inception v3 ağı kullanılmıştır. Bu ağın en üst katmanı eldeki veri kümesi ile tekrar eğitilerek deneyler yapılmıştır. Veri kümesinde 695 adet kırık ve 694 tane normal el bileği içeren toplam 1389 tane X-ışını görüntüsü bulunmaktadır. Görüntü sayısı veri çoğaltma yöntemleri uygulanarak 8 kat artırılmış ve 11112 görüntü sayısına ulaşılmıştır. Veri kümesinin %80'si eğitim için, %10'u geçişleme için, kalan %10'u da bağımsız testler için ayrılmıştır. Buna ek olarak 50 adet kırık ve 50 adet de normal el bileği X-ışını görüntüsü içeren toplam 100 adet

görüntü üzerinde de testler yapılmıştır. Modelin performansını ölçmek için başarımlar ölçütleri olarak AUC, duyarlılık ve özgüllük seçilmiştir. AUC skoru üzerinden 0,954, duyarlılık üzerinden %90 ve özgüllük üzerinden %88 performansları elde edilmiştir.

Olczak et al., [14] çeşitli vücut bölümlerini içeren X-ışını görüntüleri üzerinde kırık tespiti çalışması yapmışlardır. Görüntüler ayak bileği, el bileği ve el bölgelerini içermektedir. Bahsi geçen bölgelerin X-ışını görüntüsü elde edilirken anteroposterior, lateral ve oblik çekim yöntemleri kullanılmıştır. Çalışmada beş tane hazır CNN mimarisi denenmiştir. Bunlar BVLC Reference CaffeNet, VGG-8, VGG-16, VGG-19 ve Network-in-network mimarileridir. Kullanılan veri kümesi 256458 görüntüden oluşmaktadır. Bu görüntülerin %56'sı kırık içeren görüntülerdir. Veri kümesinin %70'i eğitim, %20'si geçerleme ve %20'si de test için ayrılmıştır. Genel doğruluk başarımlar ölçütü üzerinden en yüksek performans VGG-16 mimarisinin kullanımı ile %83 olarak elde edilmiştir. İki uzman ortopedik cerrahın kırık tespitindeki performansları ise ikisi için de %82 olarak ölçülmüştür. Kırık tespiti haricinde vücut bölgesi sınıflandırması, çekim yöntemi sınıflandırması ve görüntüde sağ-sol tespiti deneyleri de yapılmıştır. Bu deneylere göre genel doğruluk başarımlar ölçütü üzerinden VGG-16 hazır mimarisi, yukarıda bahsi geçen ikincil sınıflandırma ve tespit problemleri için sırasıyla %99, %95 ve %90 performansına ulaşmıştır.

Urakawa et al., [92] yaptıkları çalışmada anteroposterior proksimal femur X-ışını görüntülerinden intertrokanterik kalça kırıklarının tespitinde ortopedik cerrahlar ile CNN'nin performanslarını karşılaştırmışlardır. Deneylerde hazır CNN mimarisi olarak VGG-16 kullanılmıştır. Veri kümesinde 1773 tane kırık ve 1573 tane normal, toplamda 3346 tane kalça görüntüsü bulunmaktadır. Eğitim kümesi 2678 (1408 kırık ve 1270 normal), geçerleme kümesi 334 (185 kırık ve 149 normal), test kümesi ise 334 (180 kırık ve 154 normal) görüntü içermektedir. Başarımlar ölçütü olarak genel doğruluk, duyarlılık, özgüllük ve AUC skoru seçilmiştir. Oluşturulan modelin performansı başarımlar ölçütleri üzerinden 5 ortopedik cerrahın performansları ile karşılaştırılmıştır. Modelin performansı genel doğruluk üzerinden %95,5 ile duyarlılık üzerinden %93,9 ile özgüllük üzerinden %97,4 ile AUC skoru üzerinden ise 0,984 ile ortopedik cerrahların performanslarına (başarımlar ölçütleri üzerinden sırasıyla %92,2, %88,3, %96,8 ve 0,969) üstün gelmiştir.

Adams et al., [93] anteroposterior pelvik X-ışını görüntülerinde femur boyun kırıklarının tespiti üzerine bir çalışma yapmışlardır. AlexNet ve GoogLeNet hazır mimarilerinin kullanıldığı çalışmada oluşturulan modellerin performansı ile daha önceden radyoloji alanında bilgisi olmayan tıp öğrencilerinin performansı karşılaştırılmıştır. Deneylerde görüntü sayıları farklı olan üç veri kümesi kullanılmıştır. 200, 320 ve 640

görüntüye sahip olan veri kümelerinin %80'i eğitimde ve %20'si geçerlemede kullanılmak üzere ayrılmıştır. Bağımsız test kümesinde ise 160 görüntü bulunmaktadır. Bütün görüntülerin sağ taraflı olarak sisteme girdi olarak verilmesi kararlaştırıldığından, sol kalça görüntülerinin ayna görüntüleri elde edilerek sağ taraflı hale getirilmiştir. Başarım ölçütleri olarak genel doğruluk ve AUC skoru seçilmiştir. Farklı görüntü sayılarına sahip bütün veri kümelerinde GoogLeNet (%90,6) ortalama genel doğruluk üzerinden AlexNet'e (%85,3) üstün gelmiştir. 640 görüntüyle yapılan eğitim ile 200 görüntüyle yapılan eğitimin test sonuçlarının performansı sırasıyla %90,9 ve %85,5 olarak ortaya konmuştur. Veri kümesindeki örneklem sayısının genel doğruluk başarım ölçütü üzerinden performansı artırdığı belirtilmiştir. Eğitim sırasında ezberlemenin önüne geçmek için uygulanan veri çoğaltma (görüntünün rastgele bir açıyla döndürülmesi, ayna görüntüsünün elde edilmesi) işleminin istatistiksel olarak anlamlı bir farklılık yaratmadığı da deneyler ile ortaya konmuştur. Tıp öğrencileri ise 200 görüntü üzerinde %87,6 performans sergilerken bu oran 640 görüntü üzerinde %90,5'e yükselmiştir. AUC skoru baz alındığında ise GoogLeNet'in performansı her veri kümesi için AlexNet'in performansına üstün gelmiştir.

Pranata et al., [18] calcaneus (topuk kemiği) kırıklarını içeren CT görüntülerinin yorumlanmasında fikir birliği olmamasından yola çıkarak kırık tespiti ve kırık bölgesinin belirlenmesi üzerine çalışmışlardır. CT görüntüleri koronal, sagittal ve transversal görünüm ile elde edilmiştir. Çalışmada ResNet-50 ve VGG-16 hazır CNN mimarileri kullanılmıştır. ResNet'ten elde edilen sonuçlar kırığın konumunu ve tipini bulmak için SURF algoritmasına girdi olarak verilmiştir. Konum tespitinde, referans görüntüler ResNet-50 kullanılarak yapılan kırık tespiti sonuçlarına dayandırılarak üretilmiştir. Bir kırmızı kare belirteç, CT görüntülerindeki kırık bölgeleri kapsayacak şekilde manuel olarak eklenmiştir. Bu belirtecin kapsadığı alan SURF algoritmasının eşleşme için kullanacağı referans görüntü olarak görev yapmaktadır. Veri kümesinde 1931 CT görüntüsü bulunmaktadır. 683 görüntü kırık içerirken 1248 tanesi normal calcaneus görüntüsüdür. Eğitim aşaması için görüntülerin %80'i kullanılırken geçerleme için %20'si kullanılmıştır. Önerilen bilgisayar destekli karar destek sisteminin performansını ölçmek için başarım ölçütü olarak genel doğruluk seçilmiştir. Kırık tespitinde her iki mimari de %98'lik bir performans sergilemiştir. VGG-16'nın eğitimi ve geçerleme aşaması için geçen süre 1120 saniye iken ResNet-50 için bu süre 1575 saniye olarak ölçülmüştür. Yazarlar kırığın konumunu ve tipini SURF algoritması ile tespit ederken ResNet-50 mimarisini seçmişler ve bu seçimlerinin nedenini de bu mimarinin daha fazla katmana sahip olmasından kaynaklandığını belirtmişlerdir.

Cheng et al., [94] PXR'ler üzerinde kalça kırıklarının tespiti ve konumlarının belirlenmesi için bir çalışma gerçekleştirmişlerdir. Hazır CNN mimarisi olarak DenseNet-121 kullanılmıştır. Bu mimari daha önce 25505 adet ayak, diz, el bileği, ayak bileği ve dirsek içeren X-ışını görüntüsü ile eğitilmiştir. Çalışma sırasında, önceden eğitilmiş bu model 3605 PXR ile tekrar eğitilmiştir. Önceden eğitilmiş modelin ağırlıkları tekrar eğitim için korunmuştur. 3605 PXR'nin %80'i eğitim aşamasında %20'si ise geçerleme aşamasında kullanılmıştır. Eğitim aşamasında modelin veriye aşırı uyum sağlamasını engellemek için veri çoğaltma yöntemleri kullanılmıştır. Başarım ölçütü olarak genel doğruluk, duyarlılık, özgüllük, yanlış negatif (FP) oranı, F_1 skoru ve AUC skoru seçilmiştir. Performans 100 PXR'den oluşan bağımsız test kümesi kullanılarak ölçülmüştür. Modelin geçerliliği yazarlardan tarafından gradyan-ağırlıklı sınıf aktivasyon eşlemesi (Grad-CAM) isimli görselleştirme algoritması kullanılarak kuvvetlendirilmiştir. Grad-CAM, PXR'ler üzerinde kullanılarak her görüntü için bir ısı haritası elde edilmiştir. Bu ısı haritaları modelin kırık tespiti sonuçları ile karşılaştırıldığında, ısı haritalarındaki aktivasyon bölgelerinin modelin tespit ettiği kalça kırığı tarafında %95,9 doğrulukla bulunduğu gözlemlenmiştir. Önerilen model yukarıda bahsi geçen başarım ölçütleri üzerinden sırasıyla %91, %98, %84, %2, 0,916 ve 0,98 performansına ulaşmıştır. İki radyolog ve dört ortopedik cerrahın duyarlılık ve özgüllük üzerinden ortalama performansları %99,3 ve %87,7 ile oluşturulan modele üstün gelmiştir. On beş pratisyen hekimin ortalama duyarlılık ve özgüllük performansları ise sırasıyla %95,6 ve %82,2 olarak ölçülmüş ve modelin performansını geçememişlerdir.

Tomita et al., [95] CT görüntüleri üzerinde osteoporotik omurga kırıklarının (OVF) tespiti için bir çalışma yapmışlardır. Önerilen tespit sistemi iki ana bileşenden meydana gelmektedir. Bunlar CNN tabanlı öznitelik çıkarım modülü ve otomatik olarak çıkarılan öznitelikleri son teşhis için kullanan LSTM modülüdür. Hazır CNN mimarisi olarak ResNet-34 kullanılmıştır. Çalışmaya dahil edilen LSTM mimarisi, 256 gizli birimden oluşan tek katmanlı bir yapıya sahiptir. CNN'nin tam bağlantılı (FC) katmanlarından elden edilen 32 boyutlu öznitelik vektörleri LSTM'yi beslemek için kullanılmıştır. Veri kümesinde 713 kırık içeren ve 719 normal görüntü olmak üzere toplam 1432 CT görüntüsü bulunmaktadır. Görüntülerin %80'i eğitim, %10'u geçerleme ve kalan %10'u ise test aşamalarında kullanılmıştır. Genel doğruluk, duyarlılık ve F_1 skoru başarım ölçütleri üzerinden sistemin performansı (sırasıyla %89,2, %85,2 ve %90,8) bir radyoloğun performansını (sırasıyla %88,4, %81,5 ve %89,8) geride bırakmıştır.

Guan et al., [96] X-ışını görüntüleri üzerinde femur kırığının konumunun tespiti için bir çalışma sunmuşlardır. Yazarlar, nesne tanıma probleminde yaygın olarak kullanılan

öznitelik piramit ağı (FPN) yönteminin omurgasını değiştirerek genişletilmiş evrişimsel öznitelik piramit ağı (DCFPN) adını verdikleri yeni bir derin öğrenme yöntemi önermişlerdir. Bir CNN'nin evrişimsel katmanlarında kullanılan konvolüsyon işlemi yerine genişletilmiş konvolüsyon olarak adlandırdıkları basitçe delikli bir konvolüsyon olarak düşünülebilecek bir yöntem denemişlerdir. Önerilen konvolüsyon, parametre sayısını artırmadan konvolüsyon çekirdeğinin (kernelinin) alanını genişletmektedir. Böylelikle görüntü (ve öznitelik haritaları) üzerinde daha fazla bilgi elde edinebilmekte ve daha fazla kırık bilgisi çıkarılabilmektedir. Sistemde 5 farklı ölçekte öznitelik haritası çıkarılabilmektedir. Bu öznitelik haritalarındaki her bir piksel farklı en boy oranına sahip referanslar olarak katkı sunmaktadır. Referanslar bağlantı kutularını (ilgi bölgesi) oluşturur. Eğitim aşamasında bağlantı kutuları ile kesin referans (uzamanlar tarafından işaretlenmiş bölge) arasında birlik üzerinde kesişim (IoU) değeri 0,7'nin üzerindeyse bağlantı kutusu görüntüde ön plan adayı (kırığa ait) olmaktadır. IoU değeri 0,1'in altındaysa bağlantı kutusu arka plan görüntüsü olarak kabul edilmektedir. Bağlantı kutuları seçildikten sonra her bağlantı kutusu için 14x14'lük bir öznitelik vektörü oluşturulmaktadır. Öznitelik vektörleri tam bağlantılı katmanlar kullanılarak 4096 boyutlu öznitelik vektörlerine dönüştürülmektedir. Bu vektörler nihayetinde kırıkları içeren sınırlayıcı kutuları tahmin etmek için kullanılacaktır. Önerilen DCFPN mimarisinin arkasında ResNet mimarisi yatmaktadır. Veri kümesinde 3842 adet kırık içeren görüntü bulunmaktadır. 3484 görüntü eğitim için 358 görüntü ise test için kullanılmıştır. Görüntülerdeki kırıklar üç uzman radyolog tarafından etiketlenmiştir (kırığın olduğu bölge sınırlayıcı kutu ile çevrelenmiştir). Test aşamasında sistemin sınırlayıcı kutu ile çevreleyerek öngördüğü alanın güven skoru 0,5'ten büyükse bahsi geçen alanın kırık içerdiği kabul edilmiştir. Sistemin performansının ölçülmesinde başarımlı ölçütü olarak ortalama kesinlik (average precision) seçilmiştir. Elde edilen sonuçlara göre DCFPN %82,1 ile FPN'nin %78,2'lik performansını geçmiştir.

Guan et al., [97] X-ışını görüntülerinden kol kırıklarının konumunu tespit etmeye çalışmışlardır. Bir önceki çalışmalarındaki [96] CNN mimarisini değiştirerek kol kırığı içeren X-ışını görüntülerine uygulamışlardır. Genişletilmiş konvolüsyon bu çalışmada yerini normal konvolüsyon işlemine bırakmıştır. Bütün görüntülere gürültü giderme için açılma ve parlaklığı artırmak için piksel transformasyonu ön işlemleri uygulanmıştır. Öznitelik piramit mimarisi temel alınarak ön işlemeden geçirilmiş görüntülerin özniteliklerini çıkaracak yeni bir mimari hazırlanmıştır. 5 farklı ölçekteki öznitelik haritaları, her bir pikselin ait olduğu ilgi bölgesini bulmakta kullanılmıştır. 256 adet ilgi bölgesi yaratılarak sınıflandırıcıya kırıkları nerelerde bulabileceği bilgisi öğretilmeye çalışılmıştır. Çok küçük kırıkların tespiti

için de algı alanı genişletilmiştir. İlgili bölgelerinde 7x7'lik bir öznitelik vektörü oluşturulur ve tam bağlantılı katmanlar kullanılarak 1024 boyutlu bir öznitelik vektörü elde edilir. Bu öznitelik vektörleri kullanılarak kırıkları içeren sınırlayıcı kutular kestirilmeye çalışılır. Veri kümesi, hazır MURA veri kümesinden 4004 tane X-ışını görüntüsü seçilerek oluşturulmuştur. Bu görüntüler humerus, dirsek ve ön kol kırıklarını içermektedir. Eğitim kümesinde 3392, test kümesinde ise 612 adet görüntü bulunmaktadır. Görüntüler üzerinde kırıkları içeren sınırlayıcı kutuları çizmek için 20 yıldan fazla tecrübeye sahip uzman radyologlar görev almışlardır. Ortalama kesinlik başarımleri ölçütü üzerinden önerilen sistemin performansı %62,04 olarak ölçülmüştür.

Gan et al., [98] yaptıkları çalışmada anteroposterior el bileği X-ışını görüntülerinde distal radiusun konumunun tespiti ve bulunan konumu kullanarak kırık tespiti üzerine eğilmişlerdir. Konum tespitinde bölge tabanlı hazır bir Faster R-CNN mimarisi, kırık tespitinde ise Inception-v4 hazır CNN mimarisi kullanılmıştır. İlk önce R-CNN mimarisi el bileği görüntüleri üzerinde distal radiusun ilgi alanı (ROI) olarak belirlenmesi için eğitilmiştir. Görüntülerde distal radius ortopedistler tarafından sınırlayıcı kutular kullanılarak etiketlenmiştir. Sistemin ilgi alanı olarak tespit ettiği sınırlayıcı kutular görüntülerden kesilerek kırık tespiti aşamasında kullanılmak üzere Inception-v4 mimarisine girdi olarak verilmiştir. Diğer bir deyişle Faster R-CNN mimarisi, Inception-v4 mimarisine son teşhiste yardımcı bir algoritma olarak kullanılmıştır. Veri kümesi 1491 kırık içeren görüntü ve 849 normal görüntü olmak üzere toplam 2340 el bileği X-ışını görüntüsünden oluşmaktadır. Eğitim kümesinde 2040 (1341 kırık içeren, 699 normal) adet görüntü bulunurken test kümesinde 300 (150 kırık içeren, 150 normal) adet görüntü bulunmaktadır. Önerilen sistemde yardımcı algoritma olarak kullanılan Faster R-CNN mimarisinin performansı IoU başarımleri ölçütü üzerinden değerlendirilmiştir. Buna göre performans 0,87 olarak ölçülmüş ve her görüntü için 0,5'in üzerinde çıkmıştır. Son teşhiste kullanılan Inception-v4 mimarisinin performansı ise sırasıyla genel doğruluk, duyarlılık, özgüllük, Youden indeksi ve AUC skoru başarımleri ölçütleri ile değerlendirilmiştir. Sınıflandırıcı performansı bahsi geçen başarımleri ölçütleri için sırasıyla %93, %90, %96, 0,86 ve 0,96 olarak hesaplanmıştır. Önerilen sistemin performansı ortopedistlerle ve radyologlarla da karşılaştırılmıştır. Sistemin performansı radyologların performansına her başarımleri ölçütü üzerinden üstün gelirken, ortopedistlerin performansını sadece özgüllük başarımleri ölçütü üzerinden geçebilmiş, diğer başarımleri ölçütleri üzerinden ise yakın bir performans sergilemiştir.

3. VERİ KÜMELERİ

Tez çalışması kapsamında kullanılan veri kümelerini femur boyun kırığının tespitinde kullanılanlar ve femur kırığı sınıflandırmasında kullanılanlar olmak üzere ikiye ayırmak mümkündür.


3.1. Femur Boyun Kırığı Tespitinde Kullanılan Veri Kümeleri

Femur boyun kırığı tespitinde kullanılan veri kümeleri ikiye ayrılmaktadır. Birincisi femur boyun kırıklarına sahip X-ışını görüntülerinin kırık bulunmayan normal X-ışını görüntülerine oranla daha fazla bulunduğu dengesiz veri kümesidir. İkincisi femur boyun kırıklarına sahip X-ışını görüntülerinin sayısının normal X-ışını görüntülerinin sayısına eşit olduğu dengeli veri kümesidir.

3.1.1. Dengesiz veri kümesi


Dengesiz verilerden öğrenme, farklı araştırma alanlarında hala zorlu bir çalışmadır. Sınıfları arasında orantısızlık olan veri kümeleri dengesiz veri kümeleri olarak bilinir. Diğer bir deyişle, eşit sınıf dağılımına sahip olmayan bir veri kümesinin teknik olarak dengesiz olduğu söylenir [99]. Bununla birlikte, her bir sınıfın örnek sayısı arasındaki orantısızlık önemli ölçüde aşırı ise, bir veri kümesi dengesiz bir veri kümesi olarak kabul edilebilir. Dengesiz sınıf dağılımı üzerine yapılan çalışmaların çoğu 1:4 ile 1:100 arasında değişen oranlara odaklanmaktadır [100]. 1:35'lik dengesiz bir oran iyi bir model oluşturmayı engelleyebilirken, 1:10'luk bir oranın üstesinden gelmek zor olabilir [101]. Bu nedenle dengesizlik oranı, dengesiz verilerden yetersiz öğrenmenin tek kaynağı değildir. Düşük performans, azınlık sınıfındaki zor örneklerden kaynaklanabilir [102]. Dengesiz oran sorununun üstesinden gelmek için veri düzeyinde bazı yöntemler önerilmiştir. Yüksek hızda örnekleme yöntemi (oversampling), veri kümesini dengelemek için azınlık sınıfları için yeni örnekler üretir. Ancak bu süreç, yeni oluşturulan örneklerin ilgili sınıfı iyi temsil etmeye uygun olmayabileceği bir soruna yol açabilir. Az örnekleme yöntemi (undersampling), çoğunluk sınıfındaki örnekleri rastgele seçer ve kaldırır. Ne var ki, kaldırma işlemi önemli örnekler olabilir. Diğer bir yaklaşım, mümkün olduğu kadar çok numune toplamaktır, ancak bu zaman alıcı bir süreçtir ve aşırı derecede dengesiz veri kümeleri için uygulanabilir değildir.

Başkent Üniversitesi Adana Turgut Noyan Eğitim ve Araştırma Merkezi'nde toplanan veri kümesi Ocak 2013 ile Ocak 2018 tarihleri arasında çekilen anteroposterior düz proksimal PXR görüntülerini içermektedir. 32'si kadın ve 33'ü erkek olmak üzere 65 hastadan toplam 234 PXR görüntüsü toplanmıştır. Görüntülerden elde edilebilen verilere göre hastaların yaş ortalaması 74,9 olup hastalar 33 ve 89 yaş aralığında bulunmaktadır. 234 görüntünün 149'unda femur boyun kırığı mevcutken geriye kalan 85 görüntüde herhangi bir kırık bulunmamaktadır. Elde edilen veri kümesi 1:1,75 (4:7) oranında dengesizliğe sahip olmakla birlikte aşırı dengesiz bir veri kümesi değildir. Şekil 3.1.'te femur boyun kırığı içeren ve femur boyun kırığı içermeyen PXR görüntüleri gösterilmiştir.



Şekil 3.1. Kırık ve kırık olmayan PXR görüntüleri

Dengesiz veri kümesindeki görüntü sayısını artırmak üzere veri çoğaltma yöntemleri kullanılarak sentetik görüntüler elde edilmiştir. Orijinal görüntüler saat yönünde ve saat yönünün tersinde 10°, 20° ve 30° derece döndürülmüştür. Ayrıca, Gauss gürültüsü eklenerek orijinal görüntülerden sentetik görüntüler elde edilmiştir. Son olarak her bir görüntünün ayna görüntüsü elde edilerek sentetik yeni görüntü üretme aşaması sonlandırılmıştır. Böylelikle veri kümesindeki görüntü sayısı 1341'i kırık ve 765'i normal olmak üzere toplam 2106'ya yükseltilmiştir. Elde edilen sentetik görüntülere Şekil 3.2.'de yer verilmiştir.



Şekil 3.2. Elde edilen sentetik görüntülerden bazı örnekler [103]

3.1.2. Dengeli veri kümesi

Dengeli bir veri kümesi elde etmek için 64 adet femur boyun kırığı içermeyen anteroposterior düz PXR görüntüsü daha toplanmıştır. Bu görüntüler 27 erkek ve 28 kadın olmak üzere toplam 55 hastadan elde edilmiştir. Bu hastaların yaş ortalaması 48,5 olup hastalar 36-70 yaş aralığında bulunmaktadır. Oluşturulan dengeli veri kümesi son tahlilde 59 erkek ve 61 kadın olmak üzere toplam 120 hastanın PXR görüntülerinden oluşmaktadır. Yaş ortalaması 63,4 olup yaş aralığı 33'ten 89'a kadardır. Dengeli veri kümesinin örneklem sayısını artırmak için Bölüm 3.1.1.'de açıklanan veri çoğaltma yöntemleri uygulanmıştır. Böylelikle dengeli veri kümesinde 1341'i femur boyun kırığına sahip ve kalan 1341'i femur boyun kırığı içermeyen olmak üzere toplam 2682 PXR görüntüsü bulunmaktadır.


3.1.3. Bağımsız veri kümesi

Bağımsız testlerde (blind test) kullanılmak üzere 100 adet daha anteroposterior PXR görüntüsü toplanmıştır. Bunların 50 tanesi femur boyun kırığı barındırırken kalan 50 tanesi ise normal femur boynu içermektedir. Femur boyun kırığına sahip görüntüler 30 kişiden toplanmıştır. Bahsi geçen 30 kişinin 19'u kadın 11'i ise erkektir. Yaş aralığı 41 ile 93 arasında bulunmakta, yaş ortalaması ise 71,3'tür. Normal femur boynuna sahip görüntüler ise 50 kişiden toplanmıştır. 50 kişinin cinsiyet dağılımı 26 kadın ve 24 erkek şeklindedir. Yaş aralığı 18 ile 80 arasında olup yaş ortalaması 58,9'tur. Sonuç olarak bağımsız testlerde kullanılmak üzere oluşturulan veri kümesi için 80 kişinin anteroposterior PXR görüntüleri

toplanmıştır. Veri kümesinin cinsiyet dağılımı 45 kadın ve 35 erkek şeklindedir. Yaş aralığı 18 ile 93 arasında bulunmakta, yaş ortalaması ise 63,6'tır.

3.2. Femur Kırığı Sınıflandırmasında Kullanılan Veri Kümesi

Femur kırığının türünün sınıflandırılmasında üç sınıf bulunmaktadır. Bunlar femur boyun, intertrokanterik ve normal sınıflarıdır. Şekil 3.3.'te femur boyun kırığı, intertrokanterik kırık ve normal femur gösterilmiştir.



Şekil 3.3. Sınıflandırmada kullanılan femur kırık türleri

Sınıflandırma işleminde kullanılan dengeli veri kümesinde 100 adet femur boyun kırığına sahip, 100 adet intertrokanterik kırığa sahip ve 100 adet de normal olmak üzere toplam 300 adet anteroposterior düz proksimal PXR görüntüsü bulunmaktadır. Femur boyun kırığına sahip görüntüler 23'ü erkek ve 32'si kadın olmak üzere toplam 55 hastadan elde edilmiştir. Görüntülerin elde edildiği hastaların yaş ortalaması 71,5 olup yaş aralığı 23 ile 93'tür. İntertrokanterik kırığa sahip görüntüler 21'i erkek ve 36'sı kadın olmak üzere toplam 57 hastadan elde edilmiştir. Hastaların yaş ortalaması 75,4 olup yaş aralığı 31 ile 92'dir. Normal görüntüler 50'si kadın ve 50'si erkek olmak üzere toplam 100 hastadan elde edilmiştir. Hastaların yaş ortalaması 54,2 olup yaş aralığı 18 ile 80'dir. Son tahlilde veri kümesindeki PXR görüntüleri 94'ü erkek ve 118'i kadın olmak üzere toplam 212 hastadan elde edilmiştir. Yaş ortalaması 64,4 olup yaş aralığı 18-93 aralığına tekabül etmektedir. Tablo 3.1'de sınıflandırma çalışmasında kullanılan veri kümesinin dağılımı gösterilmiştir.


Tablo 3.1. Sınıflandırma çalışmasında kullanılan veri kümesi

	Femur Boyun	İntertrokanterik	Normal
Yaş Ortalaması	71,5	75,4	54,2
Minimum Yaş	23	31	18
Maksimum Yaş	93	92	80
Erkek Sayısı	23	21	50
Kadın Sayısı	32	36	50

4. YÖNTEMLER


4.1. Kırık Tespiti İçin Önerilen Yapı

Femur boyun kırığı tespiti için tez kapsamında önerilen yapının ilk aşamasında X-ışını görüntülerinden kırık ve normal femur boyun bölgeleri manuel olarak kesilmiştir. Kesme ve etiketleme (kırık veya normal) işlemi on yıllık deneyime sahip bir ortopedist tarafından yapılmıştır. Kesilen bu bölgeler daha sonra belirli boyutlara yeniden ölçeklendirilerek kanonik makine ve derin öğrenme yöntemlerine girdi olarak verilmek için hazır hale getirilmiştir. Yeniden ölçeklendirilen görüntülerden eğitim aşamasında kullanılmak üzere sentetik görüntüler elde edilmiş diğer bir ifade ile veri artırma işlemi uygulanmıştır. Buradaki amaç derin öğrenme yöntemlerinden CNN mimarisinin eğitimi sırasında hem çeşitliliği sağlamak hem de ezberlemenin önüne geçmektir. Eğitim aşamasında CNN mimarisinde bulunan evrimsel katmanlardaki filtrelerin boyutunu ve oluşacak öznetelik haritası sayısını diğer bir deyişle hiper parametreleri optimize etmek için GA ve PSO olmak üzere üst-sezgisel optimizasyon yöntemleri kullanılmıştır. Eğitim aşaması sonrası oluşturulan modele test görüntüleri verilerek bu görüntülerin kırık veya normal olarak sınıflandırılması sağlanmıştır. Femur boyun kırığı tespiti için önerilen yapının genel çerçevesi Şekil 4.1.'de gösterilmiştir.




Şekil 4.1. Kırık tespiti için genel çerçeve [103]

Tez çalışması kapsamında önerilen CNN mimarisi; girdi, evrişimsel, toplu normalizasyon, ReLU, maksimum havuzlama, seyreltme, tam bağlantılı, soft-max ve sınıflandırma katmanlarından oluşmaktadır. Belirli bir boyuta getirilmiş X-ışını görüntüleri (femur boyun kırığı içeren ve içermeyen) girdi katmanına verildikten sonra dört farklı katmandan oluşan bir blok tarafından işlenmeye başlanır. Bahsi geçen blok önerilen CNN mimarisinde beş kere tekrarlanır. Bir blokta sırasıyla evrişimsel, toplu normalizasyon, ReLU ve maksimum havuzlama katmanları bulunmaktadır. Son bloktan sonra seyreltme katmanına sahip bir tam bağlantılı katman, soft-max katmanı ve sınıflandırma katmanı bulunur. Önerilen CNN mimarisi eğitildikten sonra test görüntüsü modele verilerek kırık veya normal olarak sınıflandırılır. Evrişimsel katmanlardaki filtre boyutu ve bu katmanlarda üretilen öznitelik haritası sayısı GA ve PSO üst-sezgisel optimizasyon algoritmalarıyla belirlenir. Şekil 4.2.'de önerilen CNN mimarisi gösterilmektedir.




Şekil 4.2. Kırık tespiti için önerilen CNN mimarisi [103]

Derin öğrenme mimarilerinin aksine kanonik makine öğrenme yöntemleri öznitelikleri otomatik olarak çıkaramaz. Bu yüzden sınıflandırma işlemi öncesi özniteliklerin ön işlem aşamasında manuel olarak çıkarılması gerekir. Kanonik makine öğrenme yöntemlerinde başarımlar ölçütleri üzerinden elde edilecek performans manuel olarak çıkarılan özniteliklere sıkı sıkıya bağlıdır. Tez çalışması kapsamında kanonik makine öğrenme yöntemleri için önerilen yapı Şekil 4.3.'te gösterilmiştir.



Şekil 4.3. Kanonik makine öğrenme için genel çerçeve


LSTM ve BILSTM mimarileri için önerilen yapıda, CNN mimarisinin evrişimsel ve havuzlama katmanlarında otomatik olarak çıkarılan öznitelikler girdi olarak kullanılmıştır. Bahsi geçen RNN mimarilerinde kullanılan katman sayısının başarımlarını nasıl etkilediği de araştırılmıştır. Şekil 4.4.'te önerilen derin öğrenme hibrit yapısı gösterilmiştir.




Şekil 4.4. Önerilen derin öğrenme hibrit yapısı

AE mimarisi için önerilen yapıda öncelikle X-ışını görüntüleriyle bir AE eğitilmiştir. Eğitilen AE'den X-ışını görüntülerinin öznitelikleri elde edilmiştir. İkinci aşamada, elde edilen ilk öznitelikler ile ikinci bir AE eğitilmiştir. Eğitilen ikinci AE'den ilk öznitelikler kullanılarak ikinci öznitelikler elde edilmiştir. Üçüncü aşamada, ikinci öznitelikler

kullanılarak bir soft-max katmanı eğitilmiştir. Son aşamada, birinci AE, ikinci AE ve soft-max ağı birleştirilerek yığılı bir sinir ağı elde edilmiştir. Yığılı sinir ağı X-ışını görüntüleriyle tekrar eğitilerek test görüntüleriyle de ağı performansı ölçülmüştür. Önerilen AE mimarisi için özniteliklerin elde edilmesi Şekil 4.5.'de, yığılı sinir ağı ise Şekil 4.6.'da gösterilmiştir.



Şekil 4.5. AE mimarisi ile özniteliklerin elde edilmesi



Şekil 4.6. Yığılı sinir ağı

4.1.1. Öznitelik çıkarımı

Medikal görüntüleme alanı başta olmak üzere geleneksel makine öğrenme yöntemlerinde sınıflandırma işlemi için manuel olarak elde edilen özniteliklere ihtiyaç vardır. Bu durum CNN gibi öznitelikleri otomatik olarak üreten mimarilerin karşısında konumlanmaktadır. Derin öğrenme mimarilerinin sonuçları ile karşılaştırılması ve referans noktası teşkil etmesi bakımından tez kapsamında çeşitli öznitelikler çıkarılmış ve kanonik makine öğrenme yöntemlerinde kullanılan sınıflandırıcılar ile eğitilmiştir. Görüntülerden manuel olarak elde edilen geleneksel öznitelikler aşağıda açıklanmıştır [104], [105], [106]:

Ortalama (Mean):

Görüntüdeki değerlerin ortalamasını verir (4.1). $\bar{x}$ ortalama değeri, $m \times n$ boyutundaki görüntünün veya matrisin bir satırındaki piksel sayısını, n görüntünün bir sütunundaki piksel

sayısını, i ve j görüntünün x ve y eksenlerindeki indislerini, $p(i, j)$ ise görüntünün ilgili konumunda bulunan pikselin değerini belirtmektedir:

$$\bar{x} = \frac{1}{m*n} \sum_{i=1, j=1}^{m, n} p(i, j) \quad (4.1)$$

Çarpıklık (Skewness):

Görüntüde hesaplanan ortalama ($\bar{x}$) etrafındaki verinin asimetrisinin ölçüsüdür (4.2). s çarpıklığı, σ ise standart sapmayı temsil eder:

$$s = \frac{\sum_{i=1, j=1}^{m, n} (p(i, j) - \bar{x})^3 / m*n}{\sigma^3} \quad (4.2)$$

Basıklık (Kurtosis):

Görüntüdeki dağılımın ne kadar aykırı olduğunu gösteren bir ölçüdür (4.3). k basıklığı, σ ise standart sapmayı temsil eder:

$$k = \frac{\sum_{i=1, j=1}^{m, n} (p(i, j) - \bar{x})^4 / m*n}{\sigma^4} \quad (4.3)$$

Standart sapma (Standard deviation):

Görüntüdeki piksellerin değerlerinin, aritmetik ortalamadan ($\bar{x}$) farkının karelerinin toplamının toplam piksel sayısının bir eksiğine bölünmesi ve karekökünün alınmasıyla hesaplanır (4.4). Standart sapma ne kadar büyükse piksel değerleri o kadar ortalamadan uzak olacaktır. Standart sapma, varyansın kare kökü olarak da bilinmektedir:

$$\sigma = \sqrt{\frac{\sum_{i=1, j=1}^{m, n} (p(i, j) - \bar{x})^2}{m*n - 1}} \quad (4.4)$$

Varyans (Variance):

Görüntüdeki piksellerin değerlerinin, aritmetik ortalamadan ($\bar{x}$) farkının karelerinin toplamının toplam piksel sayısının bir eksiğine bölünmesiyle hesaplanır (4.5):

$$v = \sigma^2 = \frac{\sum_{i=1, j=1}^{m, n} (p(i, j) - \bar{x})^2}{m*n - 1} \quad (4.5)$$

Entropi (Entropy):

Görüntüdeki ortalama bilgi olarak da kabul edilir ve rastgelelik derecesinin istatistiksel bir ölçüsüdür (4.6). Görüntünün dokusunu karakterize etmek için kullanılabilir. H entropiyi, a_k görüntüde bulunan her farklı piksel değerini, $P(a_k)$ her farklı piksel değerinin görülme olasılığını, K ise görüntüde bulunan farklı piksel değerlerinin sayısını ifade eder:

$$H = - \sum_{k=1}^K P(a_k) \log_2 P(a_k) \quad (4.6)$$

Medyan (Median):

Görüntüdeki piksel değerlerin sıralanmasıyla elde edilen ortanca değerdir. Başka bir ifade ile Eşitlik 4.7 ile belirtilen minimizasyon probleminin çözümünü sağlayan u değeridir. u görüntüdeki her pikselin değerini, $\min_u$ ise toplamı en küçük değerine ulaştıran u değerini temsil etmektedir:

$$m = \arg \min_u \sum_{i=1, j=1}^{m, n} |p(i, j) - u| \quad (4.7)$$

Minimum:

Görüntüdeki piksel değerleri arasındaki en düşük değerdir (4.8):

$$u_{i,j} = \min_{i \in m, j \in n} p(i, j) \quad (4.8)$$

Maksimum:

Görüntüdeki piksel değerleri arasındaki en yüksek değerdir (4.9):

$$u_{i,j} = \max_{i \in m, j \in n} p(i, j) \quad (4.9)$$

Mod (Mode):

Görüntüde her satırdaki ($i=1, \dots, m$) ve her sütundaki ($j=1, \dots, n$) en sık geçen değeri bulmak için kullanılır. Başka bir ifade ile, her satır ve her sütun için sırasıyla Eşitlik 4.10 ve Eşitlik 4.11 ile belirtilen minimizasyon problemlerinin çözümünü sağlayan u_i ve u_j değerleridir. u_i , i . satırdaki piksel değerlerini, u_j ise j . sütundaki piksel değerlerini ifade etmektedir. $\min_{u_i}$ ve $\min_{u_j}$ ise toplamı en küçük değerine ulaştıran u_i ve u_j değerlerini temsil etmektedir. f fonksiyonu bir gösterge fonksiyonu olup eşitlik sağlanmadığı takdirde 1 değerini sağlandığı takdirde ise 0 değerini üretmektedir:

$$mod = \arg \min_{u_i \in m} \sum_{j=1}^n f(p(i, j) \neq u_i) \quad (4.10)$$


$$mod = \arg \min_{u_j \in n} \sum_{i=1}^m f(p(i, j) \neq u_j) \quad (4.11)$$

Gri Seviye Ortak Oluşum Matrisi (GLCM):

GLCM, komşuluk ilişkilerine bağlı olduğundan gri seviye uzamsal bağımlılık matrisi olarak da adlandırılmaktadır. GLCM, gri seviye i değerine sahip bir pikselin gri seviye j değerine sahip bir pikselle yatay olarak ne sıklıkla komşu olduğu hesaplanarak oluşturulur. Oluşturulan GLCM'deki her elaman, $G(i, j)$, i değerine sahip pikselin, j değerine sahip bir

piksele yatay olarak bitişik kaç kez görüldüğünü belirtir. GLCM sadece yatay komşuluk için değil bütün yönler için oluşturulabilir. Ek olarak sadece 1 piksel uzaklık için değil görüntünün boyutunun elverdiği her uzaklık için oluşturulma imkânı vardır. Şekil 4.7.’de GLCM’nin oluşturulması gösterilmektedir.

Gri seviye imgelerde her bir gri seviye değer için GLCM oluşturulmak istenildiğinde 256x256’lık bir matris elde edilecektir. Bu da elde edilecek öznitelik sayısını artıracaktır. Süre ve hafıza kısıtları göz önüne alındığında bu istenmeyen bir durumdur. Bu yüzden gri seviye değer aralığı [0-255] için bir N değeri belirlenir. Böylelikle değer aralığı N tane yeni seviyeye bölünmüş olur. Eski gri seviye değerler, yeni seviyelerine atanarak oluşturulacak GLCM’nin boyutu küçültülmüş olur.



Şekil 4.7. GLCM’nin oluşturulması

Oluşturulan GLCM’den ek olarak enerji, kontrast, korelasyon ve homojenlik öznitelikleri de elde edilebilir. Bahsi geçen öznitelikler aşağıda anlatılmaktadır.

Enerji (Energy):

GLCM’deki her bir piksel değerinin karelerinin toplamıdır (4.12):

$$enerji = \sum_{i=1, j=1}^{m, n} p(i, j)^2 \quad (4.12)$$

Kontrast (Contrast):

Tüm GLCM üzerinde bir piksel ve komşusu arasındaki yoğunluk zıtlığının bir ölçüsüdür (4.13):

$$kontrast = \sum_{i=1, j=1}^{m, n} |i - j|^2 p(i, j) \quad (4.13)$$

Korelasyon (Correlation):

Tüm GLCM üzerinde bir pikselin komşusu ile ne kadar ilişkili olduğunu gösteren bir ölçüdür (4.14). μ , GLCM ortalamasını (4.15), σ^2 ise GLCM'deki ilişki içindeki tüm piksellerin değerlerinin varyansını (4.16) ifade etmektedir:

$$korelasyon = \sum_{i=1, j=1}^{m,n} p(i, j) \frac{(i-\mu)(j-\mu)}{\sigma^2} \quad (4.14)$$

$$\mu = \sum_{i=1, j=1}^{m,n} i * p(i, j) \quad (4.15)$$

$$\sigma^2 = \sum_{i=1, j=1}^{m,n} p(i, j)(i - \mu)^2 \quad (4.16)$$

Homojenlik (Homogeneity):


GLCM'deki elemanların dağılımının GLCM diyagonaline yakınlığını hesaplayan bir ölçüdür (4.17):

$$homojenlik = \sum_{i=1, j=1}^{m,n} \frac{p(i, j)}{1+|i-j|} \quad (4.17)$$

Yerel ikili örüntüler (LBP) bilgisayarla görme ve imge analizi alanlarında tespit ve sınıflandırma için kullanılan bir tür görsel tanımlayıcıdır. Özellikle doku veya desen sınıflandırma için güçlü bir öznitelik çıkarma yöntemidir [107]. LBP özniteliklerini çıkarmak için kullanılan algoritmanın sözde kodu aşağıda verilmiştir:

- Görüntünün incelenen bölgesi (window) veya görüntünün tamamı hücrelere bölünür.
- Bir hücredeki her piksel için, ilgili piksel sekiz komşusunun her biri ile karşılaştırılır (sol üst, sol, sol alt, sağ üst, sağ, sağ alt, üst ve alt).
- Pikseller daire boyunca, yani saat yönünde veya saat yönünün tersinde takip edilir.
- Merkez pikselin değeri komşunun değerinden büyükse 0, değilse 1 yazılır. Bu işlem sekiz basamaklı bir ikili sayı üretir.
- Oluşan her sayının frekansının histogramı hücre üzerinde hesaplanır.
- Histogram isteğe bağlı olarak normalize edilebilir.
- Tüm hücrelerin histogramları birleştirilir.
- Böylelikle görüntünün tamamı veya ilgili bölgesi için bir öznitelik vektörü elde edilir.

Elde edilen LBP öznitelik vektörü görüntülerin sınıflandırılması için bir makine öğrenme algoritması kullanılarak işlenebilir. Böylelikle sınıflandırıcılar yüz tanıma veya doku analizi için kullanılabilir. Şekil 4.8.'de LBP özniteliklerinin elde edilmesini gösteren bir örnek verilmektedir.



Şekil 4.8. LBP özniteliklerinin çıkarılması

Ojala et al., [107]'un yerel görüntü dokusunun uzamsal yapısını karakterize etmek için önerdikleri LBP kodlama yöntemi bir pikselin komşularıyla karşılaştırılmasıyla başlar (4.18):

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p, s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4.18)$$


Burada g_c merkez pikseli, g_p ($p=0, \dots, P-1$) olmak üzere R yarı çaplı bir çember üzerinde merkez pikselin komşularını, P ise merkez pikselin toplam komşu sayısını temsil etmektedir. $s(x)$ fonksiyonu herhangi bir komşu piksel ile merkez piksel arasındaki farka bakarak, eğer komşu pikselin g_p değeri merkez pikselden g_c büyük ise 1 küçük ise 0 değerlerini üretir. 2^p ifadesi ise komşu pikselin ağırlığını belirtir.

Her piksel için LBP kodu tanımlandıktan sonra desen görüntüsünü temsil etmek için bir histogram oluşturulur. Histogram oluşturulurken elde edilecek öznitelik vektörünün boyutunu azaltmak için tekdüze (uniform) örüntüler kullanılır. Bir yerel ikili örüntü, eğer ikili örüntü dairesel olarak üzerinden geçildiğinde en fazla iki bit değişimle (0→1 veya 1→0) tekrar aynı örüntüyü veriyorsa tekdüze olarak adlandırılır. 00000000 (0 değişim), 01110000

(2 deęişim), 11001111 (2 deęişim) örüntüleri tekdüze iken 11001001 (4 deęişim) ve 01010010 (6 deęişim) örüntüleri tekdüze deęildir. Tekdüze örüntülerin her biri için farklı bir etiket kullanılırken (her tekdüze örüntü farklı bir etiketle etiketlenirken) tekdüze olmayan örüntüler için aynı etiket kullanılır. Sekiz komşuluk (8, R) kullanıldığında toplamda 256 örüntü bulunurken bunların 58'i tekdüze olduğundan toplamda 59 ($P(P-1)+3$) farklı etiket kullanılarak, oluşturulacak öznitelik vektörünün boyutu azaltılmış olur. Oluşturulan her LBP kodu (örüntü), bin veya mikro-tekston olarak da adlandırılabilir. Ojala et al., [107] yaptıkları deneylerde (8, 1) komşuluęu kullandıklarında tekdüze örüntülerin bütün örüntülerin yaklaşık %90'ını oluşturduęunu, (16, 2) komşuluęu kullandıklarında ise tekdüze örüntülerin bütün örüntülerin yaklaşık %70'ini oluşturduęunu belirtmişlerdir. Her hücrede LBP histogramları elde edildikten sonra histogramlar birleştirilerek tüm görüntünün LBP histogramı da oluşturulur (Şekil 4.9). Her hücrede oluşturulacak LBP histogramı aşağıdaki denklem ile ifade edilmektedir (4.19):

$$H_i = \sum_{x,y} I\{f_l(x,y) = i\}, i = 0, \dots, n - 1 \quad (4.19)$$

Burada $f_l(x,y)$ etiketlenmiş görüntüyü, n LBP işleminin sonucunda üretilen farklı etiketlerin sayısını, $I\{f_l(x,y) = i\}$ ise ilgili etiketten kaç tane bulunduęunu yani frekansı temsil etmektedir.



Şekil 4.9. LBP histogram öznitelik vektörünün oluşturulması

Yönlü gradyanların histogramı (HOG), nesne tanıma amaçlı bilgisayarla görme ve imge işleme alanlarında kullanılan bir öznitelik çıkarma yöntemidir. Bu teknik, bir görüntünün yerel kısımlarındaki gradyan yönelim oluşumlarını sayar. HOG'un ardındaki temel düşünce, bir görüntüdeki yerel nesne görünümünün ve şeklinin yoğunluk gradyanlarının dağılımı ile veya kenar yönleriyle tanımlanabilmesidir. Görüntü, hücreler

olarak adlandırılan küçük bağılı bölgelere bölünür ve her hücre içindeki pikseller için, gradyan yönlerinin bir histogramı derlenir. Bir görüntüyü tanımlayan HOG öznitelik vektörü bu histogramların birleşimidir. Doğruluk performansını geliştirmek için yerel histogramlara, görüntünün blok adı verilen daha büyük bir bölgesinde yoğunluk ölçüsü hesaplanarak ve daha sonra bu değeri blok içindeki tüm hücreleri normalleştirmek için kullanarak, kontrast normalizasyonu (normalleştirme) uygulanabilir. Bu normalleştirme, aydınlatmadaki ve gölgelendirmedeki değişikliklerden etkilenmemeyle sonuçlanır. HOG özniteliklerinin diğer özniteliklere göre birkaç önemli avantajı vardır. Lokal hücreler üzerinde çalıştığı için, nesnenin yönelimi hariç geometrik ve fotometrik dönüşümlerden bağımsızdır yani etkilenmez. Bu tür değişiklikler sadece daha büyük uzamsal bölgelerde görülür [108]. Bir görüntünün HOG öznitelikleri elde edildikten sonra herhangi bir sınıflandırıcıyla eğitilip ilgili problemin çözümünde kullanılmak üzere matematiksel bir model yaratılabilir. Şekil 4.10.'da bir görüntünün HOG öznitelikleri çıkarılmış hali gösterilmektedir.



Şekil 4.10. HOG öznitelikleri elde edilmiş bir görüntü

Gradyanlar, bir görüntüdeki kenarları ve köşeleri tespit edebilmek için oldukça önemlidirler çünkü bahsi geçen bu bölgelerden, keskin renk değişimleri yüzünden, düz bölgelere göre daha fazla bilgi toplanabilir. HOG öznitelik vektörünü oluşturmak için yatay ve dikey gradyanların hesaplanması gerekmektedir. Bahsi geçen gradyanlar daha sonra histogramın oluşturulmasında kullanılacaktır. Hesaplama işlemi için görüntü üzerinde yatay ve dikey filtreler (kerneller) gezdirilerek görüntü filtrelenir (4.20):


$$g_x = I * h_x \text{ ve } g_y = I * h_y \quad (4.20)$$

Burada, I orijinal görüntüyü, $*$ konvolüsyon işlemini, $h_x = [-1, 0, 1]$ olmak üzere görüntünün x ekseninde uygulanan filtreyi, $h_y = [-1, 0, 1]^T$ olmak üzere görüntünün y ekseninde uygulanan filtreyi, T ise transpoz işlemini temsil etmektedir. Filtrelenmiş görüntü elde edildikten sonra her piksel için gradyanların büyüklüğü $G(i, j)$ ve yönü $\theta(i, j)$ sırasıyla aşağıdaki iki eşitlikte verilen denklemler ile hesaplanır (4.21) (4.22):


$$G(i, j) = \sqrt{g_x(i, j)^2 + g_y(i, j)^2} \quad (4.21)$$

$$\theta(i, j) = \tan^{-1} \left[\frac{g_y(i, j)}{g_x(i, j)} \right] \quad (4.22)$$

Yukarıda verilen iki eşitlikten de anlaşılacağı üzere renkler arasında keskin geçişler varsa gradyanın büyüklüğü de artacaktır. Gradyan büyüklüğünün ve yönünün hesaplanmasıyla görüntü üzerindeki önemli bilgiler tespit edilecek ve gereksiz bölümler göz ardı edilecektir. Histogramın dolayısıyla HOG özniteliklerinin elde edilebilmesi için $n \times n$ boyutundaki hücrelerde gradyan büyüklüklerinin ve yönlerinin histogramda nasıl ve nereye yerleştirileceği önem kazanmaktadır. $n \times n$ boyutundaki bir hücrede toplam $n \times n \times 2$ değer bulunmaktadır. n piksel sayısını, 2 ise gradyan büyüklüğünü ve yönünü temsil etmektedir. Oluşturulacak histogramda 9 ayrı “bin” veya aralık bulunmaktadır. Her bir aralık 20 derece artım değerine sahiptir ve aralıklar 0, 20, ..., 140 ve 160 derecelerini kapsar. Öncelikle herhangi bir hücredeki ilgili pikselin gradyan yönüne yani açı derecesi değerine bakılır. Daha sonra gradyan büyüklüğünün değerine göre ilgili bine yerleştirilir. Eğer gradyan yönü açı değeri iki binin ortasındaysa bu iki bine olan uzaklığı oranında büyüklük değeri binlere paylaşılır. HOG öznitelik vektörünün elde edilmesi Şekil 4.11.’de ve Şekil 4.12.’de gösterilmektedir.



Şekil 4.11. Bir hücre için elde edilen gradyan değerleri [109]



Şekil 4.12. HOG öznelik vektörünün oluşturulması [109]

4.1.2. Kanonik makine öğrenme yöntemleri

kNN, k değerine göre n boyutlu bir vektörün veya test örnekleminin en yakın komşularını bulmaya çalışır ve ona bir sınıf atar. Algoritma önce bir mesafe ölçüsü kullanarak k -en yakın komşuyu bulur ve ardından sınıflarını öğrenir. En yakın komşuların sınıfları sayılır ve çoğunluğa sahip olan sınıf, test örneğinin sınıfı olarak kabul edilir. k değeri genellikle tek sayı olarak seçilir. kNN parametrik olmayan bir sınıflandırma yöntemidir [110]. kNN yönteminde aslında bir eğitim aşaması yoktur. Eğitim kümesi ile sınıflandırılmak istenen örneklemin karşılaştırılacağı örnekler kümesi kastedilmektedir. Test örnekleminin en yakın k tane örneklem genellikle Öklid, Manhattan, Chebychev veya Minkowski uzaklık ölçütleri kullanılarak bulunur. Bahsi geçen uzaklık ölçütleri sırasıyla Eşitlik 4.23, 4.24, 4.25 ve 4.26 ile gösterilen denklemlerle ifade edilmektedir:

$$d(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (4.23)$$

$$d(X_1, X_2) = \sum_{i=1}^n |x_{1i} - x_{2i}| \quad (4.24)$$

$$d(X_1, X_2) = \max_i |x_{1i} - x_{2i}| \quad (4.25)$$

$$d(X_1, X_2) = \sqrt[p]{\sum_{i=1}^n |x_{1i} - x_{2i}|^p} \quad (4.26)$$

Burada X_1 ve X_2 n boyutlu iki vektörü, $d(X_1, X_2)$ iki vektör arasındaki uzaklığı, x_{1i} ve x_{2i} ise ilgili vektörlerin n boyutlu uzaydaki i . bileşenlerini, başka bir deyişle özniteliklerini temsil etmektedir. Denklemlerden de anlaşılacağı üzere p değeri (4.4) 1 olarak seçildiğinde Manhattan uzaklığı (4.2), 2 olarak seçildiğinde Öklid uzaklığı (4.1), ∞ olarak seçildiğinde ise Chebychev uzaklığı (4.3) elde edilmektedir. Manhattan, Öklid ve Chebychev uzaklık ölçütleri Minkowski uzaklık ölçütündeki p değeri için özel durumlardır [111].

SVM, farklı sınıflara ait verileri ayıran en iyi hiper düzlemi bulmaya çalışır. Bir SVM için, hiper düzlemi tanımlamanın en iyi yolu, iki sınıf arasındaki en büyük marjı (mesafe, tolerans) hesaplamaktır. Kenar boşluğunda (marj), herhangi bir sınıfa ait hiçbir veri noktası yoktur ve iki sınıfın sınırları arasındaki maksimum genişliği belirtir. Destek vektörleri, sınıfları ayıran hiper düzleme en yakın veri noktalarıdır. SVM genellikle doğrusal olarak ayrılabilen veri kümeleri için tercih edilir. Bir veri kümesinin doğrusal olarak ayrılamayan bir dağılımı yoksa, SVM, öznitelik uzayının boyutunu daha yüksek bir boyuta taşıyarak sınıflandırma problemini çözmeye çalışır. Bunu yaparken çekirdek işlevlerini kullanır [112].

Uygun bir lineer olmayan eşleme fonksiyonu $\varphi()$ kullanılarak daha yüksek boyutlu bir uzayda iki sınıfa ait olan veri her zaman bir hiper düzlem ile ayrılabilir. x_k vektörünün daha yüksek boyutlu bir uzayda $y_k = \varphi(x_k)$ temsil edildiğini varsayarsak fonksiyonun nasıl seçileceği önemli hale gelir. $k = 1, 2, \dots, n$ olmak üzere her n örnekleme için ait olduğu sınıf (ω_1 veya ω_2) $z_k = \pm 1$ ile gösterilir. Yüksek boyutlu y uzayında bir doğrusal ayırıcı aşağıdaki denklem ile ifade edilebilir:

$$g(y) = a^t y \quad (4.27)$$

Burada hem ağırlık vektörü a^t hem de daha yüksek boyutlu bir uzaya taşınan y örnekleme $a_0 = \omega_0$ ve $y_0 = 1$ ile büyütülmüştür. Böylelikle ayırıcı bir hiper düzlem aşağıdaki şekilde ifade edilebilir hale gelir:

$$z_k g(y_k) \geq 1, k = 1, \dots, n \quad (4.28)$$

Marj, karar hiper düzleminden olan herhangi bir pozitif uzaklıktır. Bir SVM'nin eğitilmesindeki hedef en geniş marja sahip ayırıcı hiper düzlemi bulmaktır. Böylece sınıflandırıcının genelleştirmesi daha iyi olacaktır. Herhangi bir hiper düzlemde daha yüksek boyutlu bir uzaya taşınmış y örnekleme arasındaki uzaklık $|g(y)|/\|a\|$ olduğundan ve pozitif bir b marjının var olduğu düşünüldüğünde amacımız b 'yi maksimize eden bir a ağırlık vektörünü Eşitlik 4.29 ile gösterildiği gibi bulmak olacaktır.

$$\frac{z_k g(y_k)}{\|a\|} \geq b, k = 1, \dots, n \quad (4.29)$$

Çözüm vektöründe hiper düzlemi korumak ve benzersizliği sağlamak için $b\|a\| = 1$ kısıtlamasından yararlanılır. Böylelikle $\|a\|^2$ ifadesinin de minimize edilmesi sağlanır.

Destek vektörleri, hiper düzleme eşit olarak yakın uzaklıkta bulunan daha yüksek boyutlu bir uzaya taşınmış eğitim örneklemeleridir (4.28). Sınıflandırmada optimal ayırıcı hiper düzlemi tanımlayan ve en zor sınıflandırılan örneklerdir. Diğer bir deyişle sınıflandırma işlemi için en çok bilgiyi taşıyan veya bilgilendirici örneklemelerdir [113].

Toplam destek vektörlerinin sayısını N_s ile tanımlarsak n adet eğitim örnekleme için genelleştirme hata oranının beklenen değeri $\varepsilon_n[\text{error rate}]$, aşağıdaki denklem ile sınırlandırılmış olur:

$$\varepsilon_n[\text{error rate}] \leq \frac{\varepsilon_n[N_s]}{n} \quad (4.30)$$

Burada beklenen değer ε_n , sınıfları veya kategorileri tanımlayan sabit dağılımlardan alınan n büyüklüğündeki tüm eğitim kümeleri üzerinde beklenen değeri gösterir. Bahsi geçen sınır, $\varphi()$ ile belirlenen daha yüksek boyutlu bir uzaya taşınan vektörlerin içinde bulunduğu uzay boyutundan bağımsızdır. Diğer bir deyişle hata, destek vektörü sayısına bağlıdır.

Eğitim kümesinde n adet noktamız olduğunu düşünelim ve $n-1$ adedi üzerinde bir SVM eğitip geriye kalan tek nokta ile oluşan modeli test edelim. Eğer geriye kalan nokta tam n örneklem durumu için bir destek vektörü ise bir hata oluşacak aksi durumda oluşmayacaktır.

SVM'nin eğitilmesinde girdiyi daha yüksek boyutlu bir uzaya taşıyan doğrusal olmayan φ fonksiyonlarının seçimi ilk adımdır. Bu fonksiyonlara örnek olarak polinomiyal (çok terimli), Gaussian veya diğer temel fonksiyonlar örnek olarak verilebilir. Girdinin taşındığı yeni uzayın boyutu oldukça yüksek olabilir fakat pratikte kaynakların yeterliliği ile sınırlıdır.

Ağırlık vektörünün büyüklüğünün minimize edilmesi problemi, Lagrange belirsiz çarpanları yöntemiyle kısıtlanmamış bir probleme indirgenebilir. (4.29) eşitliğinden yola çıkılarak ağırlık vektörünün minimize edilmesi aşağıdaki denklem ile sağlanabilir:

$$L(a, \alpha) = \frac{1}{2} \|a\|^2 - \sum_{k=1}^n \alpha_k [z_k a^t y_k - 1] \quad (4.31)$$

Burada, a ağırlık vektörüne göre $L()$ fonksiyonunun minimize edilmesi ve Lagrange belirsiz çarpanlarına, $\alpha_k \geq 0$, göre maksimize edilmesi gereklidir. (4.31) eşitliği tekrar formüle edilerek optimizasyon aşağıdaki denklem ile tekrar yazılabilir:

$$L(\alpha) = \sum_{k=1}^n \alpha_k - \frac{1}{2} \sum_{k,j} \alpha_k \alpha_j z_k z_j y_j^t y_k$$

$$\sum_{k=1}^n z_k \alpha_k = 0 \text{ ve } \alpha_k \geq 0, k = 1, \dots, n \text{ olmak üzere.} \quad (4.32)$$

Elimizde x^t ve x^s girdileri olduğunu varsayarsak bu girdileri önce daha yüksek boyutlu bir uzaya taşıyıp orada iç çarpım yapmak yerine çekirdek (kernel) işlevini doğrudan orijinal uzaydaki gösterimlere uygulayabiliriz. Bu uygulama için kullanılan polinomial ve Gauss (dairesel tabanlı) çekirdek fonksiyonları sırasıyla Eşitlik 4.33 ve 4.34 ile gösterilen aşağıdaki denklemlerle ifade edilmektedir:

$$K(x^t, x) = (x^T x^t + 1)^q \quad (4.33)$$

$$K(x^t, x) = \exp \left[-\frac{\|x^t - x\|^2}{2s^2} \right] \quad (4.34)$$

Burada x^t ile t dizini 1 ile N arasında değişen x^t örneklemeleri, x^T ile vektörün transpozu, q ile polinomun derecesi, s ile yarıçap, $\exp$ ile de üstel fonksiyon belirtilmektedir.

NB, verilere yoğunluk tahmini uygulayan bir sınıflandırma algoritmasıdır. Algoritma, Bayes teoremini kullanır ve belirli bir sınıfa ait verilerin özniteliklerinin koşullu olarak bağımsız olduğunu varsayar. Başka bir deyişle, NB sınıflandırıcısı, bağımsızlık önermesiyle Bayes teoreminin basitleştirilmiş bir versiyonudur. NB sınıflandırıcıları, test örneğini en olası sınıfa atar [113], [114]. İlk olarak, her bir sınıf için özniteliklerin olasılık yoğunluk fonksiyonu tahmin edilir. İkinci olarak, Bayes'in teoremi kullanılarak sonsal olasılıklar modellenir (4.35):

$$P(C_i|x) = \frac{p(x|C_i)P(C_i)}{p(x)}$$

$$P(C_i|x) = \frac{p(x|C_i)P(C_i)}{\sum_{k=1}^K p(x|C_k)P(C_k)} \quad (4.35)$$

$i=1..K$ ve $k=1..K$ olmak üzere K tane sınıfın (C_i) olduğu bir durumda sınıfların önsel olasılıklarının toplamı her zaman birdir (4.36):

$$P(C_i) \geq 0 \text{ ve } \sum_{i=1}^K P(C_i) = 1 \quad (4.36)$$

$p(x|C_i)$ ile C_i sınıfındaki örneklem arasında girdisi x (öznitelik vektörü) olan bir örneklem görme olasılığı belirtilmektedir. Diğer bir ifade ile $p(x|C_i)$ sınıf olabilirliği. $P(C_i)$ ile önsel olasılıklar ifade edilmektedir ve x örneklemi gözlemlenmeden önce C_i sınıfı hakkında bilgimizi temsil etmektedir. Son olarak, bir örneklem için, her bir sınıfın sonsal olasılığı hesaplanır ve ardından örneklem en az hata için maksimum sonsal olasılığa sahip sınıfa atanır (4.37):

$$P(C_i|x) = \max_k P(C_k|x) \quad (4.37)$$

RF, eğitim sürecinde birden fazla karar ağacı oluşturur. Her ağaç, test örneği için bir sınıf atar. RF, sonuçlara çoğunluk oylamasını uygulayarak bir sonuç üretir ve test örneğinin sınıfını belirler. Veri kümesindeki özniteliklerin rastgele alt kümeleri alınarak, her karar ağacı bu alt kümeler üzerinde büyütülür. Bunun yapılmasındaki amaç, karar ağaçları arasında korelasyonun sağlanmasıdır. Bir veya daha fazla öznitelik, örneğin sınıfını tahmin etmede önemli öngörücülerse, bu öznitelikler, ormanı oluşturan karar ağaçlarının çoğunda rastgele seçilebilir ve karar ağaçları arasında korelasyon sağlanır. Bu nedenle RF, karar ağaçlarının eğitim kümelerine aşırı uymasını önler [115]. RF algoritması aslında torbalama (bagging) ile rastgele öznitelik alt kümesi seçimini birleştirmektedir. Torbalama işleminde her bir ağaç, veri kümesinden rastgele örnekleme kullanılarak bağımsız olarak oluşturulur. RF torbalama işlemine ek bir rastgelelik katmanı ekler. Her ağacın farklı bir rastgele örnekleme ile oluşturulmasına ek olarak RF, sınıflandırma ağaçlarının nasıl oluşturulacağı kuralını da değiştirmiştir. Standart karar ağaçlarında her karar düğümü tüm öznitelikler içinden en iyisi aranarak belirlenir. RF algoritmasında bunun yerine her karar düğümü, ilgili düğümde rastgele seçilen bir öznitelik alt kümesi içinden en iyisi aranarak belirlenir [116].

Verilen bir eğitim kümesini $\chi_t = \{(x_m, y_m), m = 1, \dots, M\}$ ile gösterdiğimiz kabul edersek x_m bir öznitelik vektörü yani örneklem y_m ise çıktı yani örneğin ait olduğu sınıf olacaktır. Zayıf bir sınıflandırıcı χ_t eğitim kümesi kullanılarak yaratılabilir. Zayıf bir sınıflandırıcı düşük bir yanlılığa (bias) ve yüksek bir varyansa sahip $f(x, \chi)$ ile temsil edilen bir öngörücüdür. χ_t eğitim kümesinden rastgele örnekleme ile $f(x, \chi_t, \theta_k)$ zayıf sınıflandırıcılar derlemi yaratılabilir. k derlemdeki zayıf sınıflandırıcının sırasını θ_k ise k . zayıf sınıflandırıcı için veri noktalarını belirleyen rastgele vektördür. Rastgele vektörü oluşturmak için rastgele örnekleme uygulanarak veri noktalarının büyük bir bölümü her zayıf sınıflandırıcı tarafından kullanılır. Geriye kalan kısım rastgele örneklemin dışında

veya torba dışındadır (out-of-bag, OOB). RF de hem sınıflandırma hem de regresyon problemlerini çözmek için kullanılan zayıf sınıflandırıcılardan oluşan bir komitedir. RF’de her ağaç bir zayıf sınıflandırıcı olarak kullanılmaktadır. Ağaç sayısı arttıkça test kümesindeki hata oranı bir sınıra doğru yakınsar. Bu durum da geniş RF’lerde veri kümesine uyum sağlamanın yani ezberlemenin önüne geçilmesi demektir. Aşağıda RF algoritması kısa olarak verilmiştir [117]:


- i. RF’deki her ağaç eğitim kümesinden rastgele örnekleme ile büyütülür.
- ii. Bir ağaç büyütülürken her karar düğümünde herhangi bir örnekleme temsil eden ve öznitelik vektörünü oluşturan N adet öznitelikten n adet öznitelik rastgele seçilir.
- iii. Genellikle n , N ’den çok küçüktür. n değerine başlangıçta $\lfloor \log_2 N + 1 \rfloor$ veya $\sqrt{N}$ atanması ve daha sonra OOB veri kümesi için minimum hata elde edilene kadar azaltılması ve artırılması önerilmektedir. Her karar düğümünde, seçilen n adet öznitelikten en iyi ayrımı sağlayan sadece bir öznitelik kullanılır.

4.1.3. Derin öğrenme yöntemleri

CNN mimarisi nesne tanıma alanında yaygın olarak kullanılan bir derin öğrenme yaklaşımıdır. İlk defa 1988’de Fukushima [118] tarafından önerilen yöntem, ağı eğitilmesi aşamasında mevcut donanımların hesaplamalarda yetersiz kalmalarından dolayı beklenen ilgiyi görememiş ve yaygınlaşamamıştır. Günümüzde ise ekran kartlarının hesaplama kapasitelerinin artması ve fiyatlarının düşmesiyle beraber CNN mimarisi yaygın olarak çeşitli alanlarda kullanılmaya başlanmıştır. 1990’larda LeCun et al., [119] CNN mimarisi kullanarak el ile yazılmış rakamları sınıflandırmayı başarmışlardır. Bu çalışmadan sonra CNN mimarisi kullanılarak birçok alanda araştırmacılar en gelişkin sonuçları elde etmişlerdir.

CNN mimarisi genel olarak evrişimsel (convolutional), havuzlama (pooling) ve tam bağlantılı (fully connected) katmanlardan oluşur. CNN’deki evrişimsel ve havuzlama katmanları görsel sinirbilimdeki basit hücreler ve karmaşık hücreler gibi klasik kavramlardan esinlenilerek oluşturulmuştur. Genel CNN mimarisi ise görsel korteks ventral yolundaki LGN (Lateral Geniculate Nucleus) - V1 (Primary Visual Cortex) - V2 (Secondary Visual Cortex) - V4 (Quaternary Visual Cortex) – IT (Inferotemporal) hiyerarşisini andırmaktadır [120], [121]. Bu katmanlara ek olarak; toplu normalizasyon (batch

normalization), ReLU (rectified-linear unit layer) ve seyreltme (dropout) gibi katmanlar da kullanılabilir. Örnek bir CNN mimarisi aşağıdaki şekilde verilmiştir (Şekil 4.13.).




Şekil 4.13. Örnek bir CNN mimarisi

CNN mimarisinin kullanımının bir faydası da öznitelik çıkarma aşamasının otomatikleştirilmesidir. Öznitelik çıkarma işlemi sistemin çalışmasından önce yapılan bir ön işleme aşaması olmaktan çıkıp sistemin bir parçası haline gelmektedir. Böylece araştırmacılar tarafından çeşitli algoritmalar kullanılarak elde edilen özniteliklere (her bir girdi veya örneklem için oluşturulan öznitelik vektörü) gerek kalmamaktadır. CNN mimarisindeki her bir katmanın görevi ve özniteliklerin nasıl oluşturulduğu aşağıda açıklanmıştır.

Evrişimsel katman:

Evrişimsel katmanda filtreler girdi matrisi (imge, röntgen görüntüsü vb.) üzerinde çarpma ve toplama işlemleri (konvolüsyon) uygulayarak filtre sayısı kadar öznitelik haritası (feature map) oluşturur. Bu katmanda filtrelerin boyutu ve girdi matrisi üzerinde kaç pikselde bir işlem yapılacağını belirten adım (stride) parametresi, oluşturulacak öznitelik haritaları üzerinde önemli bir rol oynar. Filtrelerdeki ağırlıklar (weights) rastgele atanarak eğitim aşamasında iteratif olarak güncellenir. Böylece imgelerdeki öznitelikler eğitim aşaması sonucunda ortaya çıkar. Kullanılan evrişimsel katman sayısına göre temel öznitelikler (kenarlar vb.), temel örüntüler (kemiğin sınırları) ve gelişmiş örüntüler (kemik, kırık kemik vb.) elde edilebilir. Kullanılan her bir filtre imge üzerindeki en yüksek tepkileri veren farklı bölgeleri açığa çıkarır. Böylece imgedeki aranan nesne yönünden ve büyüklüğünden bağımsız olarak tespit edilebilir. Aşağıdaki şekilde evrişimsel katmanda girdi imgesi üzerinde yapılan işlemler görülmektedir (Şekil 4.14.).



Şekil 4.14. Evrişimsel katmanda 3x3'lük bir filtrenin uygulanması

Evrişimsel katmanda her bir filtre imgenin üzerinde gezdirilir. Filtrenin değerleri ile filtrenin imge üzerinde kapladığı alandaki değerler çarpılır ve sonuçlar toplanır (konvolüsyon). İmgenin filtre boyutundaki bölgesinin merkezindeki yeni değer bu şekilde hesaplanır. Bir sonraki aşamada filtre, imge üzerinde bir veya daha fazla sayıda piksel kadar kaydırılır. Bu kaydırma değerine adım denir. İmgedeki bütün piksellerin yeni değerleri yukarıda anlatıldığı gibi hesaplanarak öznitelik haritaları elde edilir. İmgenin ilk ve son satır ve sütunlarında bulunan piksellerin işlenebilmesi için imgenin boyutu büyütülür. Bu piksel ekleme işlemine doldurma (padding) denir. Bu sayede imgedeki bütün piksellerin yeni değeri hesaplanır. Eğitim kümesindeki bütün girdi imgeleri için her bir filtredeki değerler imge için istenilen gerçek değer ve elde edilen değer arasındaki fark kullanılarak geri yayılım yoluyla güncellenir ve ağ eğitilmiş olur. Eğitilen ağın her bir evrişimsel katmanından da oluşturulan öznitelikler çıkartılabilir.

Evrişimsel katmandan çıkacak matrislerin veya öznitelik haritalarının boyutunu ayarlamak için aşağıdaki formül kullanılır (4.38):

$$O = \frac{I-f+2 \cdot P}{S} + 1 \quad (4.38)$$

O , öznitelik haritasının boyutunu (yükseklik, genişlik); I , girdi matrisinin boyutunu; f , filtrenin boyutunu, P , doldurma yani girdi matrisinin boyutuna eklenecek satır ve sütun sayısını; S ise adım değerini yani filtrenin kaç pikselde bir işlem yapacağını temsil etmektedir. Evrişimsel katmanda girdi üzerinde konvolüsyon işlemi uygulayan bir veya daha fazla evrişimsel filtre veya kernel bulunmaktadır. Eğer filtre simetrik ise konvolüsyon işlemi bir korelasyon işlemi haline dönüşmektedir. Evrişimsel filtre, girdiyi reseptif alanlar olarak

bilinen küçük parçalara bölerek çalışır. Girdinin küçük bloklara bölünmesi sayesinde öznitelik motifleri elde edilir. Filtre kendi spesifik ağırlıklarını reseptif alandaki karşılık gelen değerlerle çarparak konvolüsyon işlemi uygular [122]. Konvolüsyon işlemi aşağıdaki denklem ile ifade edilir (4.39):

$$f_l^k(p, q) = \sum_c \sum_{x,y} i_c(x, y) \cdot e_l^k(u, v) \quad (4.39)$$

Burada, $i_c(x, y)$, I_c girdisinin veya imgesinin c kanalındaki bir piksel değerini, $e_l^k(u, v)$ l . katmandaki k . filtrenin değerini temsil etmektedir. Konvolüsyon işlemi sonucunda elde edilen öznitelik haritası F_l^k ise her bir işlem sonucu elde edilen $f_l^k(p, q)$ öznitelik matris değerleri bir araya getirilerek elde edilmektedir. p ve q sırasıyla öznitelik matrisindeki satır ve sütun değerlerini temsil etmektedir.


Havuzlama katmanı:

Havuzlama katmanı ise evrimsel katman tarafından oluşturulan öznitelik haritalarının boyutunu küçültür (dimension reduction). Bunu yapmasının iki amacı vardır. Birincisi; öznitelik haritalarının boyutu azalacağı için sistemin eğitim aşamasında harcadığı süre azalacaktır. İkincisi, $n \times m$ boyutundaki bölgelerde ortalama alma (average-pooling) veya maksimum değer alma (max-pooling) gibi işlemler yapılacağından sistemin veriye tamamen uymasının yani ezberlemenin (overfitting) önüne geçilecektir.

Havuzlama katmanında bir filtre öznitelik haritaları üzerinde gezdirilerek filtrenin boyutu kadar bir alandaki piksellerin maksimum değere sahip olanı korunur. Bu katmanda da adım parametresine göre filtrenin kaç pikselde bir işlem yapacağı belirlenir. Şekil 4.15.'de bir maksimum havuzlama katmanının nasıl çalıştığı gösterilmektedir. Diğer bir ifade ile havuzlama katmanında, reseptif alanın komşuluğundaki benzer bilgiler toplanarak yerel bölge içindeki en baskın tepki elde edilmeye çalışılır [123]. Havuzlama işlemi Eşitlik 4.40 ile gösterilmektedir:

$$Z_l^k = g_p(F_l^k) \quad (4.40)$$


Burada F_l^k l . katmandaki k . girdi öznitelik haritasını, Z_l^k havuzlanmış çıktı öznitelik haritasını, $g_p(.)$ ise havuzlama işleminin türünü (maksimum, ortalama vb.) temsil etmektedir.



Şekil 4.15. 2x2'lik filtre boyutuna ve 2 adım sayısına sahip havuzlama katmanı

Tam bağlantılı katman:

Tam bağlantılı katmanlar, elde edilen öznelik haritaları bir piksel vektörüne çevrildikten (düzleştirildikten) sonra girdi matrisini sınıflandırmaya hazır hale getirir. Aşağıdaki şekilde katmanın yaptığı işlem gösterilmektedir (Şekil 4.16.).



Şekil 4.16. Tam bağlantılı katmanın işlevi [124]

Tam bağlantılı katmandan sonra soft-max ve sınıflandırma katmanları gelir. Soft-max, girdi vektörünün mevcut sınıflara ait olma olasılığını hesaplar. Sınıflandırma katmanı ise girdi vektörünün sınıfını belirler. Tam bağlantılı katmandan önce seyreltme katmanı da


kullanılabilir. Bu sayede her bir ağırlık (nöron) belirlenen bir olasılık değerine göre sıfırlanır veya elenir. Böylece ezberleme probleminin önüne geçilmeye çalışılır.

ReLU katmanı:

ReLU katmanı girdi matrisinin her bir elemanını bir eşik değerine tabi tutar. Bu katman girdinin boyutunu değiştirmez. Evrişimsel katmanlardan sonra genellikle bir doğrusal olmayan aktivasyon fonksiyonu kullanılır. Aktivasyon fonksiyonunun formülü (4.41) ve şekli aşağıda verilmiştir (Şekil 4.17.):

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \text{ veya } f(x) = \max(0, x) \quad (4.41)$$

Burada girdi matrisi üzerindeki herhangi bir x değeri 0'dan küçükse 0 değerine çekilir, 0'dan büyükse değeri değiştirilmez.



Şekil 4.17. ReLU katmanının işlevi


Toplu normalizasyon katmanı:

Evrişimsel katman ve doğrusal olmayan aktivasyon fonksiyonları (ReLU) arasında kullanılır. Eğitim sürecinin hızlandırılmasına katkı sunar. Evrişimsel katman tarafından oluşturulan öznitelik haritaları bu katmanda normalize edilir. Uygulamada her katmanın aktivasyonlarını (her bir filtreye karşılık gelen aktivasyon/öznitelik haritası) 0 ortalama ve 1 varyans değerlerine sahip olacak şekilde sınırlandırmak eğitilen ağı'nı gücünü baltalayabilir. Bu nedenle toplu normalleştirme, ağı'nı ortalamayı ve varyansı ağı'nı arzu ettiği herhangi bir değere dönüştürebilen beta ve gama parametrelerini öğrenmesini sağlar. Eğitim aşamasında ağırlıklar güncellenirken bütün ağırlıkların yerine sadece bu iki ağırlık (beta ve gama) değiştirilir. Diğer öğrenilmiş ağırlıklar korunarak değer aralığı beta ve gama parametreleri sayesinde değiştirilebilir. Toplu normalleştirme sırasında belirlenen minimum toplu iş

boyutu (mini-batch size) sayısı kadar imge için oluşturulan aktivasyon haritaları üzerinde işlemler yapılır [125].

Seyreltme katmanı:


Seyreltme, belirli bir olasılıkla bazı nöronları veya bağlantıları rastgele atlayarak son tahlilde genelleştirmeyi (regularization) geliştirerek ağ içinde bir düzenlilik sağlar. Sinir ağlarında doğrusal olmayan bir ilişkiyi öğrenen birden fazla bağlantı bazen birlikte adapte olarak aşırı uyuma yani ezberlemeye neden olabilir. Bazı nöronların veya bağlantıların rastgele atlanması sayesinde inceltilmiş bir ağ mimarisi oluşturularak küçük ağırlıklara sahip bir ağ elde edilebilir [126]. Böylelikle ezberleme probleminin önüne geçilmeye çalışılır. Şekil 4.18.'de iki adet tam bağlantılı katman için seyreltme katmanının nasıl çalıştığı gösterilmektedir.



Şekil 4.18. Seyreltme katmanının işlevi [124]

LSTM ve BILSTM mimarileri tekrarlı sinir ağları (RNN) yapısı altında bulunan iki benzer mimaridir. Sıralı verilerin işlenmesi söz konusu olduğunda diğer derin öğrenme yaklaşımlarını geride bırakmaktadırlar. Bunun sebebi RNN'leri diğer modellerden ayıran süreç yani farklı zaman adımlarındaki parametrelerin paylaşılmasıdır. Gizli katmandaki her gizli nöron (t) kendinden önce işlem yapan nöronun (t-1) çıktısına bağımlıdır [127]. Diğer derin öğrenme mimarilerine benzer şekilde, RNN'ler de geri yayılım yöntemini kullanarak eğitilebilir. Her iki mimarinin gücü sekans verisinin zaman adımları arasındaki uzun vadeli bağımlılıkları öğrenebilmesinden kaynaklanmaktadır. BILSTM'nin farkı bağımlılıkları iki yönlü olarak (pozitif zaman yönü ve negatif zaman yönü) öğrenebilmesidir [128], [129].


Diğer bir deyişle nöron (t) kendinden sonraki nöronun ($t+1$) bilgisine erişebilir. LSTM mimarisi Şekil 4.19.'da gösterilmiştir.



Şekil 4.19. LSTM mimarisi

C sayıda kanala sahip, her kanal için S uzunluğundaki x sekansı bir LSTM katmanı boyunca işlenmektedir. h_t ve c_t sırasıyla t zaman dilimindeki çıktıyı (gizli durum) ve hücre durumunu temsil etmektedir. İlk LSTM bloğu ağın başlangıç durumunu ve sekansın ilk zaman dilimini (adımını) kullanarak ilk gizli durumu yani çıktıyı ve güncellenmiş hücre durumunu hesaplar. t zaman adımında ilgili blok ağın mevcut durumunu (c_{t-1} , h_{t-1}) ve sekansın bir sonraki zaman adımını kullanarak çıktıyı ve güncellenmiş c_t hücre durumunu hesaplar. LSTM katmanının durumu gizli durum ve hücre durumu olmak üzere iki durumdan oluşur. t zaman adımındaki gizli durum LSTM katmanındaki t zaman adımı için çıktıyı içerir. Hücre durumu ise önceki zaman adımlarından öğrenilen bilgiyi tutar. Her zaman adımında katman hücre durumuna bilgi ekler veya hücre durumundan bilgi çıkarır.

LSTM katmanı güncelleme işlemlerini çeşitli kapıları kullanarak yapar [130]. Girdi kapısı (i), hücre durumunun güncellenmesinin seviyesini kontrol eder. Unutma kapısı (f), hücre durumunun sıfırlanma (reset) seviyesini kontrol eder. Hücre aday kapısı (g), hücre durumuna bilgi ekler. Çıkış kapısı (o) ise gizli duruma eklenecek hücre durumunun seviyesini kontrol eder. Şekil 4.20.'de t zaman adımı için veri akışı ve kapılar gösterilmektedir.



Şekil 4.20. LSTM bloğundaki kapılar

Bir LSTM katmanındaki öğrenilebilir ağırlıklar girdi ağırlıkları W , tekrarlı ağırlıklar R ve bias (yanlılık) b 'den oluşur. Bu ağırlık matrisleri her kapı bileşeninin (i, f, g, o) birbirine eklenmesiyle elde edilir (4.42):

$$W = \begin{pmatrix} w_i \\ w_f \\ w_g \\ w_o \end{pmatrix}, R = \begin{pmatrix} R_i \\ R_f \\ R_g \\ R_o \end{pmatrix}, b = \begin{pmatrix} b_i \\ b_f \\ b_g \\ b_o \end{pmatrix} \quad (4.42)$$

t zaman adımında hücre durumu ise aşağıdaki formül ile elde edilir (4.43):

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (4.43)$$

$\odot$ işlemi Hadamard çarpımı olarak da bilinir ve vektörlerin eleman tabanlı çarpımıdır. t zaman adımındaki gizli durum ise aşağıdaki denklemde belirtilen formül ile elde edilir (4.44):

$$h_t = o_t \odot \sigma_c(c_t) \quad (4.44)$$

σ_c durum aktivasyon fonksiyonunu belirtir. Aktivasyon fonksiyonuna hiperbolik tanjant fonksiyonu örnek olarak verilebilir. t zaman adımındaki kapıların çıktıları aşağıdaki denklemlerle verilen formüller ile hesaplanır (4.45, 4.46, 4.47, 4.48):

$$i_t = \sigma_g(W_i x_t + R_i h_{t-1} + b_i) \quad (4.45)$$

$$f_t = \sigma_g(W_f x_t + R_f h_{t-1} + b_f) \quad (4.46)$$

$$g_t = \sigma_c(W_g x_t + R_g h_{t-1} + b_g) \quad (4.47)$$

$$o_t = \sigma_g(W_o x_t + R_o h_{t-1} + b_o) \quad (4.48)$$

σ_g kapı aktivasyon fonksiyonunu ifade etmek için kullanılır. Kapı aktivasyon fonksiyonuna sigmoid fonksiyon örnek olarak verilebilir (4.49):

$$\sigma(x) = (1 + e^{-x})^{-1} \quad (4.49)$$


Bir otomatik kodlayıcı veya otokodlayıcı (AE), girişini çıkışında tekrar üretmek için eğitilmiş bir sinir ağıdır. Bu yüzden etiketlenmiş veriye ihtiyaç duymaz. Yöntemdeki asıl amaç verilerin bilgilendirici bir temsilini gözetimsiz bir şekilde öğrenmektir. Girdi sıkıştırılarak anlamlı bir temsil elde edilmeye çalışılır diğer bir deyişle kodlanır. Daha sonra oluşturulan temsilin, orijinal girdiye mümkün olduğu kadar benzer olmasını sağlayacak şekilde kod çözülür [131]. Eğitim aşaması bir maliyet fonksiyonunun optimizasyonuna bağlıdır [132], [133]. Maliyet fonksiyonu x girdisi ile tekrar üretilmeye çalışılan x' çıktısı arasındaki hatayı ölçer. AE, bir kodlayıcı (encoder) ve bir kod çözücünden (decoder) oluşur. Kodlayıcıyı besleyen x girdi vektörü kodlayıcı tarafından z vektörüne eşlenir (4.50):

$$z = h^{(1)}(W^{(1)}x + b^{(1)}) \quad (4.50)$$

(1) kodlayıcı katmanını temsil ederken h kodlayıcı için bir transfer fonksiyonu görevini yerini getirir. W ağırlık matrisini, b ise bias (yanlılık) vektörünü temsil eder. Kod çözücü, kodlanmış z temsili (gösterimini) orijinal x girdi vektörünün bir tahminine x' eşler (4.51):

$$x' = h^{(2)}(W^{(2)}z + b^{(2)}) \quad (4.51)$$

(2) kod çözücü katmanını temsil ederken h kod çözücü için bir transfer fonksiyonu görevini yerini getirir. W ağırlık matrisini, b ise bias (yanlılık) vektörünü temsil eder. Şekil 4.21.'de bir AE mimarisi gösterilmektedir.



Şekil 4.21. Örnek bir AE mimarisi

AE'lerin kodlayıcı katmanları girdi vektörünün boyutunu azaltarak (gizli birim/nöron sayısına bağlı olarak) onun yeni bir temsilini oluştururlar. Diğer bir deyişle öznetelik üretirler. Dolayısıyla AE'lerin kodlayıcı katmanları CNN'deki evrişimsel ve havuzlama katmanları gibi düşünülebilir. Kodlayıcı katmanından veya katmanlarından sonra soft-max katmanı eklenerek otomatik olarak üretilen öznetelikler ile sınıflandırma yapılabilir. İkinci bir strateji ise kodlayıcıların ürettiği öznetelikleri kanonik makine öğrenme algoritmaları ile sınıflandırmaktır.

4.1.4. Üst-sezgisel optimizasyon yöntemleri

Genetik algoritmanın (GA) amacı, evrimsel süreci taklit ederek bir optimizasyon problemine yeterince iyi bir çözüm sağlamaktır. GA'da, aday çözümler veya bireyler popülasyonu oluşturur. Bireyler, optimize edilmek istenen parametrelerden diğer bir deyişle genlerden meydana gelir ve arama uzayına göre rastgele oluşturulur. Arama uzayı ise bu parametrelerin alacağı değerlerin sınırlarını belirler. Her birey, problemle ilgili amaç fonksiyonu (objective function) tarafından hesaplanan bir uygunluk değerine (fitness value) sahiptir. Yeni nesli oluşturmak için, daha yüksek uygunluk değerine sahip bireyler doğrudan seçilirken, diğerlerine çapraz geçiş (crossover) ve mutasyon işlemleri uygulanır. Bu yinelemeli bir süreçtir ve GA, belirli sayıda nesil veya belirlenmiş bir uygunluk değerine ulaşıldığında sona erer [134]. Genetik algoritmanın sözde kodu aşağıda verilmiştir:

1. Popülasyondaki her birey (kromozom) için objektif fonksiyonu değerini hesapla
2. Durma kriteri sağlanmıyorsa döngüye başla
 - 2.1 Yeni jenerasyona aktarmak için bireyleri seç
 - 2.2 Bireyleri çaprazlayarak yeni bireyler yarat
 - 2.3 Bazı bireyleri mutasyona uğrat
 - 2.4 Yeni jenerasyonu oluştur ve objektif fonksiyonu değerini hesapla

3. Bitir

Sözde koddan da anlaşılacağı üzere bir jenerasyondan diğerine geçiş sırasında temel bileşenler seçim, çaprazlama, mutasyon ve yeni popülasyonun yaratılmasıdır. Seçim aşamasında objektif fonksiyonu değerine (uyum sağlama/fitness) göre bireyler seçilmektedir. Seçilen bireyler çaprazlanarak yeni bireyler oluşturulmaktadır. Buradaki amaç ortama uyum sağlama derecesi yüksek olan iki bireyin oluşturacağı çocukların da ortama uyum sağlama derecesinin yüksek olacağı beklentisinden yola çıkılarak yüksek uyum derecesine sahip çocukların elde edilmesidir. Mutasyonda ise belirli bir olasılıkla bireylerin genlerinde rasgele değişiklikler oluşur. Buradaki amaç ise çeşitliliğin korunarak en iyi çözüme ulaşılmasını sağlamaktır. Yeni popülasyon oluştuktan sonra durma kriteri sağlanana kadar anlatılan süreçler tekrar tekrar uygulanmaktadır.

Çözülme istenen probleme göre kromozomun gen sayısına karar verilmelidir. Optimize edilmek istenen parametre sayısı kromozomun büyüklüğünü belirleyecektir. Yeni bir jenerasyon oluşurken kaç kromozomun bu jenerasyona direkt olarak aktarılacağı (seçkin/elite sayısı), çaprazlama ve mutasyon uygulanacak birey sayısı, popülasyonun başlangıçta sahip olacağı kromozom/birey sayısı, kaç jenerasyon yaratılacağı ve objektif fonksiyonunun ne olacağı gibi sorulara cevap verilerek genetik algoritma, optimizasyon problemlerine uygulanabilir.

Parçacık Sürü Optimizasyonu (PSO), kuş sürülerinin davranışından esinlenen popülasyon tabanlı bir optimizasyon algoritmasıdır. Parçacıklar aday çözümlerdir ve popülasyonu veya sürüyü oluşturur. Parçacıklar, konumlarına ve hızlarına göre arama uzayında hareket eder. Algoritma, ilk parçacıkları oluşturarak başlar ve daha sonra başlangıç hızları parçacıklara atanır. Optimizasyon problemiyle ilgili amaç fonksiyonu, her parçacık konumu için değerlendirilir. Sonrasında en iyi değer ve en iyi konum belirlenir. Yeni hızlar, mevcut hıza, parçacıkların en iyi konumlarına ve komşularının en iyi konumlarına göre seçilir. Parçacık konumları, hızları ve komşular yinelemeli olarak güncellenir. Algoritma, bir durdurma kriterine ulaşıldığında sona erer [135]. PSO algoritmasının sözde kodu aşağıda verilmiştir:

1. Arama uzayında D boyutlu rastgele konumlara ve hızlara sahip parçacıkların popülasyonu dizisini oluştur
2. Döngüye başla
 - 2.1 Her parçacık için D değişkenlerini kullanarak uygunluk fonksiyonunu hesapla

2.2 Parçacığın uygunluk değerini bir önceki pozisyonu ($pbest_i$) ile karşılaştır. Eğer mevcut değer $pbest_i$ 'den iyi ise $pbest_i$ 'ye mevcut değeri ata ve D boyutlu uzayda $\vec{p}_i$ 'ye mevcut $\vec{x}_i$ konumunu ata

2.3 Şimdiye kadarki en başarılı parçacığı belirle ve indeksini g değişkenine ata

2.4 Parçacığın hızını ve konumunu aşağıdaki denkleme (4.52) göre değiştir:

$$\begin{aligned}\vec{v}_i &\leftarrow \vec{v}_i + \vec{U}(0, \phi_1) \otimes (\vec{p}_i - \vec{x}_i) + \vec{U}(0, \phi_2) \otimes (\vec{p}_g - \vec{x}_i), \\ \vec{x}_i &\leftarrow \vec{x}_i + \vec{v}_i\end{aligned}\tag{4.52}$$

2.5 Herhangi bir kriter sağlanırsa (uygunluk değeri veya iterasyon sayısı) döngüden çık

3. Bitir

Sözde koddan da anlaşılacağı üzere her birey üç adet D boyutlu vektörden oluşmaktadır. $\vec{x}_i$ mevcut konumu, $\vec{p}_i$ bir önceki iterasyondaki en iyi konumu, $\vec{v}_i$ ise hızı temsil etmektedir. Mevcut $\vec{x}_i$ konumu uzaydaki bir noktayı tanımlayan koordinatlar kümesi olarak düşünülebilir. Algoritmadaki her iterasyonda mevcut konum problemin bir çözümü olarak değerlendirilir. Eğer mevcut konum o zamana kadar bulunanlardan daha iyi ise koordinatlar ikinci bir $\vec{p}_i$ vektöründe saklanır. En iyi fonksiyon sonucunun değeri ise $pbest_i$ (bir önceki en iyi) isimli bir değişkende muhafaza edilerek sonraki iterasyonlarda karşılaştırma için kullanılır. Buradaki amaç daha iyi konumlar bulmayı sürdürerek $\vec{p}_i$ ve $pbest_i$ değişkenlerini güncellemektir. Yeni noktalar, $\vec{v}_i$ koordinatlarının $\vec{x}_i$ 'ye eklenmesiyle seçilir ve algoritma, adım boyutu olarak görülebilen $\vec{v}_i$ değişkenini ayarlayarak çalışır. $\vec{U}(0, \phi_i)$, her bir parça için her iterasyonda rastgele olarak yaratılan, $[0, \phi_i]$ aralığında tekdüze dağılıma sahip rastgele sayıların bir vektörünü temsil ederken $\otimes$ işlemi bileşen-bazlı çarpımı göstermektedir.

Parçacık sürüsü parçacıkların toplamından daha fazlasıdır. Tek bir parçacık herhangi bir problemi çözmek için tek başına neredeyse hiçbir güce sahip değildir. Problemin çözümünde ilerleme sadece parçacıklar birbirleri ile etkileştiklerinde meydana gelir. Problem çözme, parçacıkların etkileşimleri sayesinde bireysel davranışlarından ortaya çıkan, popülasyon çapında bir olgudur. Herhangi bir durumda popülasyonlar sıklıkla bir sosyal ağ gibi düşünülen bir çeşit iletişim yapısına veya topolojiye göre örgütlenir. Topoloji genellikle parçacık çiftlerini birbirine bağlayan çift yönlü kenarlardan oluşur öyle ki i parçacığı j 'nin

komşuluğundaysa j de i 'nin komşuluğunda olacaktır. Her parçacık diğer bazı parçacıklarla iletişim halindedir ve topolojik komşuluğunda bulunan herhangi bir parçacık tarafından bulunan en iyi noktadan etkilenir. Komşuluktaki bu en iyi noktayı bulan parçacığın $\vec{p}_i$ vektörü $\vec{p}_g$ ile gösterilir. Parçacık sürü optimizasyon işleminde her bir parçacığın hızı iteratif olarak ayarlanır. Böylece parçacık stokastik olarak $\vec{p}_i$ ve $\vec{p}_g$ konumları etrafında salınır [136].

4.1.5. Yeni yöntem - üç kanallı görüntü


Tek kanallı gri seviye bir görüntünün dolayısıyla iki boyutlu bir matrisin Fourier dönüşümü (Fourier Transformation/FT) ile yeni bir görüntü elde edilebilir. Bu görüntü uzamsal alanda ifade edilen orijinal görüntünün frekans alanındaki yeni ifade biçimidir. Aşağıda $m \times n$ boyutundaki bir X matrisinin FT uygulanarak frekans alanına (uzayına) taşınması gösterilmektedir (4.53). Y frekans uzayındaki sonucu, ω_m (4.54) ve ω_n (4.55) karmaşık kökleri, i sanal kısmı, p ve j 0'dan $m-1$ 'e kadar olan indeksleri q ve k ise 0'dan $n-1$ 'e kadar olan indeksleri temsil eder:

$$Y_{p+1,q+1} = \sum_{j=0}^{m-1} \sum_{k=0}^{n-1} \omega_m^{jp} \omega_n^{kq} X_{j+1,k+1} \quad (4.53)$$

$$\omega_m = e^{-2\pi i/m} \quad (4.54)$$

$$\omega_n = e^{-2\pi i/n} \quad (4.55)$$


Orijinal görüntü, orijinal görüntüden yerel ikili örüntüler kullanılarak elde edilen LBP görüntüsü ve Fourier dönüşümü ile frekans uzayında elde edilen FT görüntüsü üç kanallı bir görüntü elde edilmek üzere birleştirilir. Oluşan üç kanallı yeni görüntünün öznelilikleri CNN kullanılarak otomatik olarak elde edilir ve tespit (ikili sınıflandırma) işleminde kullanılır. Yeni yöntemin genel yapısı Şekil 4.22.'de gösterilmektedir.



Şekil 4.22. Üç kanallı görüntünün elde edilmesi

4.1.6. Çoğunluk oylaması


Bir sınıflandırma probleminde farklı sınıflandırıcıların avantajlarından yararlanmak için kullanılan bir yöntemdir. Birden çok sınıflandırıcı eğitim kümesindeki veriler ile eğitilip matematiksel modeller oluşturulur. Yeni bir test verisi bu modeller ile sınanarak her bir sınıflandırıcı için bir çıktı (sınıf) elde edilir. Çıktılar üzerinde çoğunluk oylaması yöntemine başvurulur. Buna göre çıktılarda hangi sınıfın sayısı fazla ise test verisinin sınıfı o sınıf olarak belirlenir [137]. Bu yöntemin avantajı hatalı sınıflandırmanın, birden çok sınıflandırıcının sonuçlarını ortaya koyarak, oylama ile giderilebilmesi olasılığında yatar. Şekil 4.23.'de çoğunluk oylamasının işleyişi gösterilmektedir.



Şekil 4.23. Çoğunluk oylaması

4.1.7. CNN ve LSTM/BILSTM hibrit mimarileri

Derin öğrenme hibrit mimarileri özellikle aktivite tanıma (Human Activity Recognition, HAR) alanında yaygın olarak kullanılan mimarilerdir. CNN mimarileri, RNN ve türevi mimarilerle (LSTM ve BILSTM) birleştirildiğinde genel doğruluk ve kayıp değeri başarımlar ölçütleri üzerinden daha iyi sonuçlar elde edildiği ortaya konmaktadır [138]. Hibrit mimarilerde, CNN mimarilerinin öznelik çıkarma gücünden, LSTM ve BILSTM mimarilerinin ise sekans verileri arasındaki uzun vadeli bağımlılıkları ortaya çıkarma gücünden faydalanılır. CNN'nin özellikle evrimsel ve havuzlama katmanlarından otomatik olarak elde edilen öznelikler LSTM ve BILSTM mimarilerine girdi olarak verilerek mevcut problem sonuçlandırılabilir veya sadece bir mimari kullanılarak elde edilen sonuçlara göre iyileştirme sağlanabilir. CNN'nin evrimsel katmanlarında mevcut görüntüden öznelik haritaları üretilmektedir. Üretilen öznelik haritalarının sayısı mevcut görüntüyü çok kanallı bir görüntü haline getirerek LSTM veya BILSTM mimarilerinin farklı zaman adımları arasındaki uzun vadeli bağımlılıkları bulmasına olanak tanır. Şekil 4.24.'de bir CNN/RNN hibrit mimarisi gösterilmektedir.




Şekil 4.24. Örnek bir CNN/RNN hibrit mimarisi [138]

4.2. Kırık Sınıflandırması İçin Önerilen Yapı

Femur kırığı sınıflandırması çalışmasında X-ışını görüntülerinden femur boyun kırığı ile intertrokanterik kırık içeren ve kırık içermeyen normal bölgeler manuel olarak kesilmiştir. Kesme ve etiketleme (femur boyun kırığı, intertrokanterik kırık veya normal) işlemi kırık tespiti çalışmasında olduğu gibi on yıllık deneyime sahip bir ortopedist

tarafından yapılmıştır. Kesilen bölgeler, hazır CNN mimarilerinin girdi katmanlardaki boyutlara göre tekrar ölçeklendirilerek hazır CNN mimarilerinin eğitilmesi sağlanmıştır. Eğitilen hazır CNN mimarilerinin evrişimsel katmanlarından otomatik olarak elde edilen öznitelikler ise kanonik makine öğrenme sınıflandırıcılarını beslemek için kullanılmıştır. Eğitim aşaması sonrasında oluşturulan modeller test görüntüleriyle sınanarak görüntülerin femur boyun kırığı, intertrokanterik kırık veya normal olarak sınıflandırılması sağlanmıştır. Femur kırığı sınıflandırması için önerilen yapının genel çerçevesi Şekil 4.25.'te gösterilmiştir. Şekildeki siyah oklar hazır bir CNN mimarisinin eğitim ve test aşamalarını ifade etmektedir. Eğitim kümesi ile hazır CNN mimarisinin eğitilmesi sağlanarak bir model oluşturulur. Oluşturulan model test kümesindeki görüntüler ile sınanarak ilgili test görüntüsünün sınıfı belirlenir. Kırmızı oklar ise hazır bir CNN mimarisi kullanılarak oluşturulan modelden çıkarılan öznitelikler ile kanonik sınıflandırıcıların nasıl eğitildiğini ve test edildiğini ifade etmektedir. Eğitim kümesindeki görüntüler oluşturulan modele verilerek belirli bir evrişimsel katmandaki öznitelikleri elde edilir. Bu sayede elde edilen öznitelikler kanonik sınıflandırıcılara girdi olarak verilip sınıflandırıcıların eğitilmesi sağlanır ve her sınıflandırıcı için model oluşturulur. Test kümesindeki görüntülerin, hazır CNN mimarisi ile oluşturulan model kullanılarak öznitelikleri elde edilir. Test kümesindeki her bir görüntüyü temsil eden bu öznitelikler her kanonik sınıflandırıcı ile oluşturulan modellerle sınanarak bir sınıfa atanır.



Şekil 4.25. Kırık sınıflandırması için genel çerçeve


4.2.1. Hazır CNN mimarileri

Önceden eğitilmiş bir ağı alınıp yeni bir görev öğrenmek için başlangıç noktası olarak kullanılmasına transfer öğrenimi (transfer learning) denilmektedir. Transfer öğrenimi yaygın olarak derin öğrenme uygulamalarında kullanılmaktadır. Bir ağda transfer öğrenimi ile ince ayar yapmak, genellikle sıfırdan rastgele başlatılan ağırlıklara sahip bir ağı eğitmekten çok daha hızlı ve kolaydır. Transfer öğreniminin bir diğer avantajı da az sayıda görüntünün eğitim aşamasında kullanılmasıyla daha önceden başka bir alanda öğrenilmiş özniteliklerin yeni bir probleme hızlı bir şekilde aktarılabilmesidir. Herhangi bir CNN mimarisinin ilk evrimsel katmanları düşük seviye öznitelikler olarak kabul edilen kenar, renk vb. öznitelikleri öğrenir. Son evrimsel katmanlar ise probleme özgü öznitelikleri ortaya çıkarır. Bu yüzden transfer öğreniminde hazır mimarinin probleme özgü öznitelikleri üreten son evrimsel katmanları yeni probleme göre değiştirilebilir. Bir diğer yöntem ise yeni problemdeki sınıf sayısına göre sınıflandırma katmanının güncellenmesidir.

Kırık sınıflandırması kapsamında AlexNet, VGG, GoogLeNet, ResNet, DenseNet, SqueezeNet, Inception-v3 ve InceptionResNet-v2 mimarileri kullanılmıştır. Bahsi geçen hazır CNN mimarileri aşağıda kısaca anlatılmıştır.

AlexNet:


AlexNet mimarisi adını 2012 yılında düzenlenen ve görsel nesne tanıma alanında en zor yarışma olarak kabul edilen ImageNet Large Scale Visual Recognition Challenge (ILSVRC) isimli yarışmada mevcut bütün geleneksel makine öğrenim algoritmalarını ve bilgisayarla görme yaklaşımlarını geride bırakarak duyurmuştur [139]. Bu andan sonra derin öğrenmeye olan ilgi kısa sürede artmaya başlamıştır. AlexNet mimarisinde ilk evrimsel katmanda 11×11 boyutlarındaki filtreler ile 96 öznitelik haritası üretilmektedir. Takip eden maksimum havuzlama katmanında 3×3 'lük bir filtre 2 artım değeri ile işlem yapmaktadır. İkinci evrimsel katmanda 5×5 boyutlarındaki filtreler ile 256 öznitelik haritası üretilmektedir. Üçüncü, dördüncü ve beşinci evrimsel katmanlarda ise 3×3 boyutlarındaki filtreler ile sırasıyla 384, 384 ve 256 tane öznitelik haritası üretilmektedir. Son evrimsel katmandan sonra iki adet 4096 nörona sahip tam bağlantılı katman (seyreltilmiş) gelmektedir. Tam bağlantılı katmanları ise soft-max katmanı takip etmektedir. AlexNet mimarisi $224 \times 224 \times 3$ boyutundaki görüntüler için çalışmaktadır. Mimarinin yapısı Şekil 4.26.'da gösterilmiştir.



Şekil 4.26. AlexNet mimarisi

The Visual Geometry Group (VGG):


VGG mimarisi, 2014 yılında düzenlenen ILSVRC yarışmasında ikinci sırayı almıştır. VGG mimarisi, CNN mimarilerinde daha yüksek sınıflandırma doğruluğu elde etmek için ağın derinliğinin önemli bir bileşen olduğunu ortaya koymuştur [140]. VGG mimarisinde ilk olarak ReLU katmanlarına sahip iki adet evrişimsel katman bulunmaktadır. Sonrasında ise maksimum havuzlama katmanı gelmektedir. Bahsi geçen katmanlar VGG mimarisinin temel bloğunu oluşturmaktadır. Evrişimsel katman sayısı VGG-11, VGG-16 ve VGG-19 mimarileri için sırasıyla 8, 13 ve 16'dır. Son havuzlama katmanından diğer bir deyişle son temel bloktan sonra ise sırasıyla 4096, 4096 ve 1000 nörona sahip 3 adet tam bağlantılı katman ve softmax katmanı gelmektedir. Üretilen öznetelik haritası sayısı her bloktaki evrişimsel katmanlar için değişiklik göstermektedir. İlk bloktaki evrişimsel katmanlarda 64 adet öznetelik haritası üretilirken takip eden bloklardaki evrişimsel katmanlar için bu sayısı iki katına çıkmaktadır. Evrişimsel katmanlarda 3x3 boyutundaki filtreler 2 artım ile işlem yapmaktadır. VGG mimarisi 224x224x3 boyutundaki görüntüler için çalışmaktadır. Mimarinin yapısı Şekil 4.27.'de gösterilmiştir.



Şekil 4.27. VGG mimarisi

GoogLeNet:

GoogLeNet mimarisi 2014 yılında düzenlenen ILSVRC yarışmasında birinciliği kazanmıştır. Geleneksel CNN mimarilerine göre hesaplama karmaşıklığını azaltan yapısıyla öne çıkmaktadır. Önerilen yöntem farklı boyutlara sahip filtreler tarafından yaratılan çeşitli alıcı alanlara sahip başlangıç katmanlarını (inception layer) CNN mimarisine dahil etmiştir (Şekil 4.28.). Alıcı alanlar, oluşturulan öznitelik haritası yığınınında seyrek korelasyon örüntülerini yakalayabilmektedir [141]. GoogLeNet toplamda 22 katmandan oluşmaktadır ve bu sayı kendisinden önceki mimarilerinin katman sayısından fazladır. Fakat ağda bulunan parametre sayısı, AlexNet'teki ve VGG'deki ağ parametre sayısından çok daha azdır. İlk evrimsel ağ 7x7 boyutunda 2 artımla işlem yapan filtreler kullanmaktadır ve 64 adet öznitelik haritası üretmektedir. Bu katmanı 3x3 boyunda 2 artımla işlem yapan filtre kullanan maksimum havuzlama takip etmektedir. Bu katmanlardan sonra tekrar evrimsel ve maksimum havuzlama katmanları gelmektedir. İkinci evrimsel katman 3x3 boyutunda 1 artımla işlem yapan filtreler kullanarak 192 adet öznitelik haritası üretmektedir. Bundan sonra sırasıyla 256 ve 480 adet öznitelik haritası üreten iki başlangıç katmanı, maksimum havuzlama katmanı, ilk üçü 512 kalan ikisi sırasıyla 528 ve 832 adet öznitelik haritası üreten 5 adet başlangıç katmanı, maksimum havuzlama katmanı, sırasıyla 832 ve 1024 adet öznitelik haritası üreten iki adet başlangıç katmanı, 7x7 boyutunda ve 1 artımla işlem yapan bir ortalama havuzlama katmanı, %40 olasılıkla çalışan seyreltme katmanı, 1024 nörona sahip tam bağlantılı katman ve soft-max katmanı yer almaktadır. GoogLeNet mimarisi 224x224x3 boyutundaki görüntüler için çalışmaktadır.




Şekil 4.28. Başlangıç katmanı [141]

Residual Network (ResNet):

ResNet mimarisi 2015 yılında düzenlenen ILSVRC yarışmasında birinciliği kazanmıştır. ResNet mimarisi seleflerinin sahip olduğu kaybolan gradyan probleminden


etkilenmeyecek derin ağların tasarlanabilmesi için geliştirilmiştir [142]. Eğitim aşamasında çıktı katmanında elde edilen değer geri dağılım yöntemiyle gerideki katmanlardaki ağırlıkları güncellemek için kullanılırken baştaki katmanlara doğru sıfıra yakınsamaya başlar ve ağ öğrenemez hale gelebilir. Bunu önlemek için ReLU aktivasyon fonksiyonunu içeren bir yapı önerilmiştir. ResNet mimarisinin 34, 50, 101, 152 ve 1202 katmana sahip versiyonları bulunmaktadır. Bunlardan ResNet50 mimarisinin 49 evrişimsel katmanı ve 1 tam bağlantılı katmanı bulunmaktadır. ResNet'teki temel blok yapısına artık blok denmektedir (Şekil 4.29.). Artık blokta yapılan işlemler versiyonlara göre farklılık göstermektedir. ResNet mimarisi 224x224x3 boyutundaki görüntüler için çalışmaktadır.



Şekil 4.29. ResNet artık blok yapısı [142]

Densely Connected Network (DenseNet):

Huang et al., [143] her bir katmanın çıktısının kendisinden sonraki bütün katmanlara bağlandığı bir CNN mimarisi önermişlerdir. Katmanlar arasındaki bu yoğun bağlantılardan dolayı mimariye DenseNet ismi verilmiştir. DenseNet mimarisinde yoğun ve geçiş olmak üzere iki temel blok bulunmaktadır (Şekil 4.30.). Geçiş bloğu, evrişimsel ve havuzlama katmanlarından oluşmaktadır. Evrişimsel katmandan kasıt ise sırasıyla toplu normalleştirme, ReLU ve evrişimsel katman sıralamasıdır. DenseNet mimarisinde toplam 4 adet yoğun blok bulunmaktadır. Yoğun bloklardaki evrişimsel katman sayısı versiyona göre farklılık gösterebilmektedir. Geçiş blokları iki yoğun blok arasında bulunmaktadır. DenseNet'te eğitim aşamasında hata sinyali geriye doğru yayılırken her bir katman kendinden sonraki katmandan bilgi alabildiği gibi direkt sınıflandırma katmanından da bilgi alabilmektedir. Her bir katman kendinden önceki katmanların çıktılarını girdi olarak aldığı için de çok çeşitli öznetelikler bir araya gelmekte ve bu durum da daha zengin örüntülerin elde edilmesine olanak sağlamaktadır. DenseNet mimarisi 224x224x3 boyutundaki görüntüler için çalışmaktadır.




Şekil 4.30. Yoğun blok ve geçiş bloğu [143]

SqueezeNet:

Iandola et al., [144] doğruluk performansından ödün vermeden daha az parametreye sahip bir CNN mimarisi geliştirmek için yola çıkmışlardır. Bu yolda üç ana strateji önermişlerdir. Birinci strateji 3x3 boyutundaki filtrelerin 1x1 boyutuna getirilmesidir. Böylelikle parametre sayısı 9 kat azalacaktır. İkinci strateji girdideki kanal sayısının 3x3 boyutundaki filtreler göre kontrol edilmesidir. Parametre sayısının düşürülmesi için sadece filtre boyutunun azaltılması yeterli değildir. Bunun yanında girdideki kanal sayısının veya öz nitelik boyutunun da kontrol edilmesi gerekmektedir. Bu işlem de squeeze katmanı adı verilen katmanlar vasıtasıyla yapılmaktadır. Üçüncü strateji ise girdinin boyutunun ne zaman küçültüleceğine odaklanmaktadır. CNN mimarisinin son katmanlarında boyut küçültme işlemi yapıldığı takdirde evrimsel katmanlar daha büyük öz nitelik haritalarına sahip olacaktır. Bu duruma ilk katmanlardaki artım değerinin 1 olarak seçilmesiyle ulaşılabilir. Birinci ve ikinci stratejiler parametre sayısının azaltılmasıyla ilgiliyken üçüncü strateji doğruluk performansının artırılması ile ilgilidir. SqueezeNet mimarisinde temel blok ateşleme modülüdür. Bir ateşleme modülü, sadece 1x1 boyutundaki filtreler sahip evrimsel squeeze katmanından ve bu katmanın beslediği 1x1 ve 3x3 boyutlarındaki evrimsel filtrelerin karışımına sahip bir genişletme katmanından oluşmaktadır (Şekil 4.31.). Ateşleme modülünde 3 önemli hiper parametre bulunmaktadır. Birincisi squeeze katmanındaki 1x1 boyutundaki filtrelerin sayısı (s_1), ikincisi genişletme katmanındaki 1x1 boyutundaki filtrelerin sayısı (e_1), üçüncüsü ise genişletme katmanındaki 3x3 boyutundaki filtrelerin sayısıdır (e_3). s_1 'in değeri e_1+e_3 'ün değerinden küçük tutularak girdideki kanal


sayısının 3x3 boyutundaki filtreler göre sınırlandırılması sağlanır. SqueezeNet mimarisi 227x227x3 boyutundaki görüntüler için çalışmaktadır.



Şekil 4.31. Ateşleme modülü [144]

Inception-v3:


Inception-v3 mimarisi, GoogLeNet mimarisi için geliştirilen bir modül olarak hayat bulmuş sonrasında GoogLeNet'i ILSVRC 2012 sınıflandırma veri kümesi üzerinde yapılan testlerde geride bırakmıştır [145]. Önerilen mimaride geleneksel 7x7 boyutundaki evrişimsel filtre 3 adet 3x3 boyutundaki filtreye dönüştürülmüştür. İlk üç başlangıç modülünde 5x5 boyutundaki her evrişimsel filtre iki adet 3x3 evrişimsel filtreye çevrilmiştir (Şekil 4.32.a.). İşlemler sonucunda her biri 17x17 boyutunda 768 adet öznitelik haritası üretilmektedir. Takip eden beş başlangıç modülünde ise 7x7 boyutundaki evrişimsel filtreler yerine 1x7 ve 7x7 boyutlarındaki asimetrik evrişimsel filtreler kullanılmıştır (Şekil 4.32.b.). İşlemler sonucunda 8x8 boyutunda 1280 adet öznitelik haritası elde edilmektedir. Son iki başlangıç modülünde ise 3x3 boyutundaki evrişimsel filtre 1x3 ve 3x1 boyutundaki evrişimsel filtrelerle, 1x1 boyutundaki evrişimsel filtre ise 1x3 ve 3x1 boyutlarındaki evrişimsel filtrelerle genişletilmiştir (Şekil 4.32.c.). İşlemler sonucunda 8x8 boyutunda 2048 adet öznitelik haritası üretilmektedir. Mimaride 2048 nöronlu oluşan tam bağlantılı bir katman softmax sınıflandırma katmanından önce yer almaktadır. Inception-v3 mimarisi 299x299x3 boyutundaki görüntüler için çalışmaktadır.



Şekil 4.32. Farklı başlangıç modülleri [145]

InceptionResNet-v2:

Artık bağlantıların geleneksel CNN mimarileri içinde kullanılmasının önerilmesiyle ResNet mimarisi 2015 yılında düzenlenen ILSVRC yarışmasında birinciliği kazanmıştır. Bu mimarinin performansı Inception-v3 mimarisiyle benzerlik göstermektedir. Szegedy et al., [146] Inception mimarisi ile ResNet mimarisinde kullanılan artık bağlantıların birleştirilmesi üzerinde durmuşlar ve artık bağlantıların Inception mimarisinde eğitim aşamasını hızlandırdığını ortaya koymuşlardır. Buna ek olarak artık bağlantıları kullanan Inception mimarisinin artık bağlantıları kullanmayan Inception mimarilerini performans olarak geride bıraktığı da raporlanmıştır. InceptionResNet-v2 mimarisinin genel yapısı Şekil 4.33.a.'da gösterilmiştir. Mimaride 5 adet Inception-ResNet A modülü bulunmaktadır (Şekil 4.33.b.). Burada artık blok yapısına Inception mimarisindeki başlangıç katmanları eklenmiştir. Aynı şekilde 10 adet Inception-ResNet B (Şekil 4.33.c.) ve 5 adet Inception-ResNet C (Şekil 4.33.d.) modüllerinde de artık blok yapısı başlangıç katmanları ile birleştirilerek InceptionResNet-v2 mimarisi elde edilmiştir. InceptionResNet-v2 mimarisi 299x299x3 boyutundaki görüntüler için çalışmaktadır.



Şekil 4.33. InceptionResNet-v2 mimarisi [146]

4.2.2. Eğitim aşamasında geri yayılım

CNN mimarilerinde eğitim aşamasında katmanlardaki ağırlıkların güncellenmesi için elde edilen kayıp veya hata değerinin geri yayılım yöntemiyle katmanlara ulaştırılması gerekmektedir. Femur kırığı sınıflandırmasında geri yayılım yönteminde kullanılan sgdm (stochastic gradient descent with momentum, momentumlu stokastik gradyan inişi) ve adam (adaptive moment estimation, uyarlanır moment kestirimi) eniyileyici algoritmaları aşağıda kısaca anlatılmıştır.

Sgdm:

Standart gradyan inişi algoritmasında ağırlıklardan ve yanlılıklardan oluşan ağ parametreleri güncellenirken kayıp fonksiyonu minimize edilir. Minimizasyon işlemi her iterasyonda kaybın negatif gradyanı yönünde küçük adımlar atılarak sağlanır:

$$\theta_{\ell+1} = \theta_{\ell} - \alpha \nabla E(\theta_{\ell}) \quad (4.56)$$

Eşitlik 4.56'da ℓ iterasyon numarasını, $\alpha > 0$ olmak üzere öğrenme oranını, θ parametre (ağırlık ve yanlılık) vektörünü, $E(\theta)$ ise kayıp fonksiyonunu temsil eder. Kayıp fonksiyonunun gradyanı, $\nabla E(\theta)$, bütün eğitim kümesinin kullanılmasıyla hesaplanır ve standart gradyan inişi algoritması veri kümesini aynı anda kullanır. Stokastik gradyan inişi

algoritmasında ise gradyanın hesaplanması ve parametrelerin güncellenmesi eğitim kümesinin bir alt kümesinin kullanılmasıyla yapılır. Bu alt küme mini-batch olarak adlandırılır ve her iterasyonda kullanılır. Stokastik gradyan inişi algoritmasının stokastik olma sebebi, bir mini-batch kullanılarak hesaplanan parametre güncellemelerinin, tüm veri kümesinin kullanılmasından kaynaklanacak parametre güncellemesinin gürültülü bir tahmini olmasından ötürüdür.

Stokastik gradyan inişi algoritması, optimuma doğru en dik iniş yolu boyunca salınabilir. Parametre güncellemesine bir momentum terimi eklemek, bu salınımı azaltmanın bir yoludur [147]. Momentumlu stokastik gradyan inişi eniyileyici algoritması Eşitlik 4.57 ile verilen denklemde gösterilmektedir:

$$\theta_{\ell+1} = \theta_{\ell} - \alpha \nabla E(\theta_{\ell}) + \gamma(\theta_{\ell} - \theta_{\ell-1}) \quad (4.57)$$

Eşitlik 4.57’de γ bir önceki gradyan adımının mevcut iterasyona olan katkısını belirler. Adam:

Sgdm eniyileyici algoritması bütün parametreler için tek bir öğrenme oranı kullanmaktadır. Adam eniyileyici algoritması ise parametreye göre farklılık gösteren ve optimize edilmekte olan kayıp fonksiyonuna otomatik olarak uyarlanabilen öğrenme oranlarını kullanarak ağ eğitimini iyileştirmeye çalışır. İyileştirme, eleman bazında parametre gradyanlarının ve karelerinin hareket etme ortalaması tutularak gerçekleştirilir. Hareket etme ortalamaları da ağdaki parametrelerin güncellenmesinde kullanılır:

$$\begin{aligned} m_{\ell} &= \beta_1 m_{\ell-1} + (1 - \beta_1) \nabla E(\theta_{\ell}) \\ v_{\ell} &= \beta_2 v_{\ell-1} + (1 - \beta_2) [\nabla E(\theta_{\ell})]^2 \\ \theta_{\ell+1} &= \theta_{\ell} - \frac{\alpha m_{\ell}}{\sqrt{v_{\ell} + \epsilon}} \end{aligned} \quad (4.58)$$

Eşitlik 4.58’de m parametre gradyanlarını, v parametre gradyanlarının karesini, β_1 ve β_2 hareket etme ortalamalarının çürüme oranını, ϵ ise sıfıra bölünmeyi engellemek için eklenen küçük bir sabit değeri temsil etmektedir. Eğer birçok iterasyondaki gradyanlar benzerse, gradyanın hareket etme ortalamasının kullanılması parametre güncellemelerinin belirli bir yönde momentum almasını sağlar. Eğer gradyanlar çoğunlukla gürültü içeriyorsa, gradyanın hareket etme ortalaması küçülür ve bu da parametre güncellemelerinin küçülmesine yol açar [148].

5. DENEYSEL SONUÇLAR

5.1. Deneyisel Kurulum

Tespit aşamasında bir X-ışını görüntüsünün kırık bir femur boynu içerip içermediğini bulmak için orijinal görüntülerden kesilerek elde edilen femur boyun görüntüleri 50x50, 100x100, 200x200 ve 400x400 piksel olmak üzere dört farklı çözünürlükte yeniden ölçeklendirilmiştir. Bu görüntüler CNN'i beslemek için kullanılmış ve başarımlar ölçütları üzerinden en yüksek performansa sahip çözünürlük ile diğer mimariler eğitilerek karşılaştırmalar yapılmıştır. Çalışmada kullanılan CNN mimarisi, her biri bir evrişimsel katmana, bir toplu normalleştirme katmanına, bir doğrultulmuş (rektifiye) doğrusal birimine (ReLU) ve bir maksimum havuzlama katmanına sahip olan beş blok içermektedir. Aşırı uyumu (ezberlemeyi) önlemek için son bloktan sonra 0.5 olasılığa sahip bir seyreltici (dropout) katman da eklenmiştir. Tam bağlantılı (fully connected) bir katman, bir soft-max katmanı ve çapraz entropi kaybını hesaplayan bir sınıflandırma katmanı, seyreltici katmandan sonra gelmektedir. Her bir evrişimsel katman 3x3 boyutunda bir filtreye sahiptir ve beş evrişimsel katman sırasıyla 8, 16, 32, 32 ve 32 tane olmak üzere öznitelik haritası üretmektedir. Maksimum havuzlama katmanları üretilen öznitelik haritalarının boyutunu, 2 artırımla ilerleyen 2x2 boyutundaki filtreler ile azaltmaktadır.

Aşırı uyumu azaltmak için kayıp fonksiyonunun ağırlıklarına düzenleme terimi (L2 regularization, 0.0005) eklenmiştir. Eğitim sürecinin tamamlanması 50 devir (epoch) sürmektedir. Toplu iş büyüklüğü (mini batch size) 64 olarak seçildiğinden 1 devir 33 iterasyon sürmektedir. Böylelikle eğitim süreci 1650 iterasyondan oluşmaktadır. Başlangıç öğrenme oranı 0.001 olarak seçilmiştir. Bu sayede eğitim aşamasında sistemin yerel minimuma takılmasının önüne geçilmeye çalışılmıştır. Her beş devirde bir, öğrenme oranı 0,5 kat azaltılmıştır. Ayrıca her devir için eğitim aşamasında kullanılan görseller karıştırılarak sistemin görüntüleri ezberlememesi sağlanmıştır. Eğitim sürecinde Adam eniyileştiricisi (optimizer) kullanılmıştır.

Önerilen CNN mimarisinde evrişimsel katmanlardaki filtre boyutu ve öznitelik haritası sayısı GA ve PSO üst-sezgisel optimizasyon yöntemleri ile optimize edilmeye çalışılmıştır. Bunun için GA'da ve PSO'da her bir olası çözüm (kromozom veya birey) ilk beş filtre sayısı ve kalan beş tanesi de öznitelik haritası sayısı olmak üzere toplam 10 gen veya değişkenden oluşmaktadır. GA'da çaprazlama (crossover) için ebeveynlerin seçimi sırasında stokastik tekdüze seçim (stochastic uniform selection) algoritması kullanılmıştır. Seçim algoritması,

her aday ebeveyni bir parametreye göre bir çizgi üzerinde düzenler. Bu parametre, uygunluk (fitness) değerinin tüm uygunluk değerlerinin toplamına bölünmesiyle hesaplanır. Böylelikle her aday çizgi üzerindeki seçilebilme olasılığına göre bir yer kaplar. Seçimin başlatılması için rastgele bir sayı ve adım boyu oluşturulur. Algoritma, ilk ebeveyni seçmek için rastgele sayıyı kullanır ve ardından diğer ebeveynleri seçmek için adım boyuna göre çizgi boyunca hareket eder. Ebeveynlerin seçiminden sonra, rastgele bir ikili vektör çaprazlama işlemi için oluşturulur. Oluşturulan rastgele ikili vektör yalnızca sıfırları ve birleri içerdiğinden, bit değerleri bir çocuk oluşturmak için genlerin hangi ebeveyninden alınacağını temsil eder. Eğer vektörün ilgili elemanındaki bit değeri 1 ise birinci ebeveynin geni, bit değeri 0 ise ikinci ebeveynin geni alınarak çocuk yani yeni olası çözüm üretilir. Bu algoritma saçılmış çaprazlama (scattered crossover) olarak bilinir ve Şekil 5.1.'de gösterilmektedir. Mutasyon işleminde ise basitçe kromozomlardaki genler rastgele değiştirilir. Elit sayısı yani direkt olarak yeni nesle aktarılacak kromozom sayısı 2, çaprazlama oranı (çaprazlanarak elde edilecek ve yeni nesle aktarılacak kromozom sayısı) %80 ve mutasyon oranı (mutasyona uğratarak yeni nesle aktarılacak kromozom sayısı) %20 olarak belirlenmiştir.

Parent 1	a	b	c	d	e	f	g	h	i	j
Parent 2	k	l	m	n	o	p	q	r	s	t
Random binary vector	1	1	0	0	1	0	0	1	0	0
Child	a	b	m	n	e	p	q	h	s	t

Şekil 5.1. Saçılmış çaprazlama [103]

GA ve PSO üst-sezgisel optimizasyon algoritmalarında 10, 50 ve 100 kromozomdan oluşmak üzere üç farklı popülasyon büyüklüğü parametresi kullanılmıştır. Algoritmalar 10 kuşak (jenerasyon) boyu devam ettirilmiş ve en düşük hata oranına (1-doğruluk ile hesaplanır) sahip kromozom optimal çözüm olarak belirlenmiştir.

LSTM, BILSTM ve AE mimarilerinde, CNN mimarisinde kullanılan eğitim parametreleri seçilmiştir. LSTM ve BILSTM mimarilerinde CNN'nin evrimsel ve maksimum havuzlama katmanlarından otomatik olarak elde edilen öznitelikler girdi olarak kullanılmış, LSTM ve BILSTM katmanlarındaki gizli birim sayısı CNN'den elde edilen öznitelik haritalarındaki diğer bir deyişle kanallardaki piksel sayısına göre belirlenmiştir. LSTM, BILSTM ve AE mimarilerinde kullanılan katman sayısı 1'den 5'e kadar seçilmiştir. AE mimarisinde her katmanda girdi boyutu yarıya düşürülerek elde edilen yığılı sinir ağının

başarım ölçütleri üzerinden performansı elde edilmiş ve hem katman sayısına göre hem de diğer mimariler ile karşılaştırma yapılmıştır.

Kanonik makine öğrenme algoritmalarını beslemek için 50x50 piksel çözünürlükteki her bir görüntüden toplam 653 adet geleneksel öznitelik çıkarılmıştır. Geleneksel özniteliklerde ilk grup 9 adet öznitelikten oluşmaktadır. Bunlar ortalama, çarpıklık, basıklık, standart sapma, varyans, entropi, medyan, minimum ve maksimumdur. İkinci grup, görüntüdeki (matristeki) her satır ve her sütun için mod özniteliklerini içerir. Satır bazında 50 ve sütun bazında 50 olmak üzere toplam 100 öznitelik barındırır. Üçüncü grup GLCM özniteliklerini içerir. Bir pikselin 8 farklı komşuluğu olduğundan bir görüntü için 512 öznitelik elde edilir. Ayrıca her GLCM için enerji, kontrast, korelasyon ve homojenlik olmak üzere 4 adet daha öznitelik çıkarıldığından bir görüntü toplamda 544 adet geleneksel GLCM özniteliği ile temsil edilmektedir.

Geleneksel öznitelikler dışında kanonik makine öğrenme algoritmalarını beslemek için kullanılan diğer öznitelikler HOG ve LBP öznitelikleridir. Bir görüntüden elde edilen HOG özniteliklerinin sayısı 900 iken LBP özniteliklerinin sayısı 59'dur.

Kanonik makine öğrenme algoritmalarında SVM, NB, kNN ve RF sınıflandırıcıları kullanılmıştır. SVM algoritmasında lineer, radyal temel ve polinomiyal çekirdek fonksiyonları kullanılmıştır. Polinomiyal çekirdek fonksiyonu için 2'den 10'a kadar olan dereceler ile daha fazla artış sağlanmayana kadar deneyler yapılmıştır. NB algoritmasında kernel (KDE) ve normal dağılımlar için deneyler yürütülmüştür. RF algoritmasında ağaç sayısı 50'den başlatılarak 50 artımla 550 ağaca kadar çalışmalar yapılmış ve sonuçlar alınmıştır. kNN algoritmasında ise 1'den 19'a kadar olan tek sayılar için en yakın komşu parametresi belirlenerek deneyler yapılmıştır.

Çoğunluk oylaması için; genetik algoritma ile optimize edilmiş CNN ve HOG öznitelikleri ile eğitilmiş SVM, NB, kNN ve RF algoritmaları kullanılmıştır. Her bir algoritmanın bulduğu sonuç (sınıf) oylamaya sokularak esas sonuca ulaşılmıştır. Çoğunluk oylamasında her bir sınıflandırıcının veya mimarinin ağırlığı eşit olarak kabul edilmiştir. Bu nedenle beşli ve üçlü sınıflandırıcı kombinasyonları ile deneyler yapılmıştır.

Tespit çalışmasında deneyler 5-kat çapraz geçerleme yöntemi kullanılarak yürütülmüştür. Bu yöntemde veri kümesi (dengesiz ve dengeli) 5 farklı alt kümeye bölünür. Dengesiz veri kümesinde iki sınıfın örneklemeleri arasındaki oran her alt kümede korunur. Dengeli veri kümesinde ise iki sınıfın örneklem sayıları her alt kümede eşit olarak bulundurulur. Birinci aşamada ilk alt küme geçerleme kümesi olarak seçilerek eğitim aşaması dışında bırakılır. Kalan dört alt küme ile eğitim süreci başlatılır ve eğitim süreci

sonunda elde edilen model geerleme kmesi ile test edilir. Bu iřlem her alt kme eēitim ařaması dıřında bırakılıp geerleme kmesi olarak oluřturulan modelin test edilmesinde kullanılabilece kadar devam eder. Her geerleme kmesi ile elde edilen hata matrisleri birleřtirilerek modelin bařarım ltleri zerinden genel performansı hesaplanır. řekil 5.2.'de 5-kat apraz geerleme gsterilmiřtir.

5-KAT APRAZ GEERLEME					
1. İterasyon	GEERLEME	EēİTİM	EēİTİM	EēİTİM	EēİTİM
2. İterasyon	EēİTİM	GEERLEME	EēİTİM	EēİTİM	EēİTİM
3. İterasyon	EēİTİM	EēİTİM	GEERLEME	EēİTİM	EēİTİM
4. İterasyon	EēİTİM	EēİTİM	EēİTİM	GEERLEME	EēİTİM
5. İterasyon	EēİTİM	EēİTİM	EēİTİM	EēİTİM	GEERLEME

řekil 5.2. 5-kat apraz geerleme

Kırık sınıflandırması alıřmasında veri kmesi %60'ı eēitim, %20'si geerleme ve %20'si baēımsız test kmesi olarak e blnmüřtür. Her kmede e sınıf iin de rneklem sayısı eēit tutulmuřtur. Hazır CNN mimarilerinin girdi olarak kabul ettiēi boyuta gre grntler ilgili boyuta tekrar leklendirilmiřtir. Tespit alıřmasında nerilen CNN mimarisinde kullanılan eēitim parametreleri kırık sınıflandırmasında da kullanılmıřtır. Geerleme testleri hem Sgdm hem de Adam eniyileyicileri ile yrtlmř, bařarım ltleri zerinden elde edilen performansa gre modelin hangi eniyileyici ile oluřturulacağına karar verilerek model zerinde baēımsız testler yapılmıřtır.

Hazır CNN mimarilerinin kullanımında transfer ērenme yntemi uygulanmıř, bařka bir problem uzayından elde edilen aē parametreleri (aēırlıklar ve yanlılıklar) tekrar eēitim sırasında bařlangı parametreleri olarak kullanılmıřtır. Aēın tekrar eēitimi sırasında ilk 10 katmanının parametre gncellemesi yapması dondurma (freezing) yntemi ile engellenmiř ve bylelikle ezberlemenin nne geilmeye alıřılmıř ve aēın eēitim sresi kısaltılmıřtır. Baēımsız testlerde bařarım ltleri zerinden performansı en yksek olan hazır CNN mimarisinin dondurulan ilk 10 katmanından sonraki birinci ve sonuncu evriřimsel katmanlarından otomatik olarak oluřturulan znitelikler alınarak SVM, NB, kNN ve RF sınıflandırıcıları eēitilmė ve baēımsız testler ile performansları karřılařtırılmıřtır.

RF sınıflandırıcısında aēa sayısı iin 50'den bařlayarak 50 artımla 600'e kadar aēa ile deneyler yrtlmřtir. Ek olarak 1000, 2000 ve 5000 aēa ile de sonular alınmıřtır.

kNN sınıflandırıcısında en yakın komşu değeri olarak 1'den 19'a kadar olan aralıktaki değerler 2 artımla seçilmiştir. NB sınıflandırıcısında kernel ve normal dağılımlar için deneyler yapılmıştır. SVM sınıflandırıcısında ise lineer, radyal temel ve polinomiyal çekirdek (ikinci derece ve onuncu derece aralığı) fonksiyonları kullanılmıştır.

5.2. Başarım Ölçütleri

Yöntemlerin başarımlarını değerlendirmek için tez çalışmasının tespit bölümünde kullanılan ölçütler Cohen'in Kappa katsayısı (Kappa), doğruluk (accuracy, Acc), duyarlılık (sensitivity, Sn), özgüllük (specificity, Sp), F_1 skoru (F_1 score, F_1) ve alıcı işletim karakteristik eğrisi (Receiver Operating Characteristic curve, ROC) altında kalan alandır (Area Under Curve, AUC). Tespit çalışmasında TP, TN, FP ve FN sırasıyla, gerçek pozitif (doğru şekilde kırık femur boynu olarak sınıflandırılmış), gerçek negatif (doğru şekilde kırık olmayan femur boynu olarak sınıflandırılmış), yanlış pozitif (hatalı şekilde kırık femur boynu olarak sınıflandırılmış) ve yanlış negatif (hatalı şekilde kırık olmayan femur boynu olarak sınıflandırılmış) anlamına gelmektedir. Tespit performansını değerlendirmek için kullanılan tüm ölçütler aşağıda verilmiştir.

Kappa, anlaşmanın şans faktörünü dikkate alarak kategorik maddeler için değerlendiriciler arası anlaşmayı ölçer (5.1):

$$p_e = \frac{(TN+FP)*(TN+FN)*(TP+FN)*(TP+FP)}{(TN+TP+FN+FP)^2}$$

$$Kappa = \frac{Acc - p_e}{1 - p_e} \quad (5.1)$$

Doğruluk, doğru olarak sınıflandırılmış kırık femur boynu sayısı ile toplam kırık femur boynu sayısı arasındaki orandır (5.2):

$$Acc = \frac{TP+TN}{TP+FP+TN+FN} \quad (5.2)$$

Duyarlılık, doğru olarak sınıflandırılmış kırık femur boynu sayısı ile toplam kırık femur boynu sayısı arasındaki orandır (5.3):

$$Sn = \frac{TP}{TP+FN} \quad (5.3)$$

Özgüllük, doğru olarak sınıflandırılmış kırık olmayan femur boynu sayısı ile toplam kırık olmayan femur boynu sayısı arasındaki orandır (5.4):

$$Sp = \frac{TN}{TN+FP} \quad (5.4)$$


F_1 skoru, kesinlik (precision) ve geri çağırmanın (recall, duyarlılık) harmonik ortalamasıdır. Ancak, gerçek negatifleri hesaba katmaz (5.5):

$$Precision = \frac{TP}{TP+FP}$$

$$F_1 = 2 * \frac{Precision*Recall}{Precision+Recall} \text{ veya } F_1 = \frac{TP}{TP+\frac{1}{2}(FP+FN)} \quad (5.5)$$

Günümüzde en yaygın olarak kullanılan performans ölçütlerinden birisi de AUC-ROC eğrisidir. Tipik bir ROC eğrisinde x ekseninde Yanlış Pozitif Oran (FPR) ve y ekseninde Doğru Pozitif Oran (TPR) bulunmaktadır. AUC, “ROC eğrisi altındaki alan” anlamına gelir. Bahsi geçen alan ne kadar büyükse ilgili model verilen sınıfları ayırt etmede o kadar başarılıdır. AUC için ideal değer 1’dir. AUC değerinin 0,5 olması oluşturulan model için sınıflandırma işleminde rastgeleliğin ön plana çıktığını göstermektedir (Şekil 5.3.).

ROC eğrisi, farklı eşik değerlerinde duyarlılık başarımlarının (5.3) diğer bir adı olan TPR’ye karşı, özgüllük başarımlarının (5.4) kullanılmasıyla (1-Sp) elde edilen FPR’yi işaretleyerek sinyali gürültüden ayıran bir olasılık eğrisidir. AUC de bu olasılık eğrisinin altında kalan alanın hesaplanması ile bir sınıflandırıcının sınıflar arasında ayırım yapabilme kabiliyetinin ölçülmesinde devreye girer.



Şekil 5.3. ROC eğrisi [149]

Yöntemlerin başarımlarını değerlendirmek için tez çalışmasının sınıflandırma bölümünde kullanılan ölçütler Kappa, doğruluk, Makro F_1 (Macro F_1),

Matthews korelasyon katsayısı (Matthews correlation coefficient, MCC) ve her sınıf için (femur boyun kırığı, intertrokanterik kırık ve normal femur) kesinlik, duyarlılık ve F_1 skorudur. Ayrıca her sınıf için AUC değeri bire karşı bir (1 vs 1) ve bire karşı hepsi (1 vs All) yöntemleriyle elde edilmiştir.

Tespit yani ikili sınıflandırmanın aksine çok sınıflı sınıflandırmada pozitif veya negatif sınıflar bulunmamaktadır. Başarım ölçütlerinin değerlerini hesaplamak için her bir sınıf için TP, TN, FP ve FN değerleri belirlenmelidir. Tablo 5.1.'de tez çalışmasının sınıflandırma bölümünde kullanılan hata (karmaşıklık) matrisi (confusion matrix) gösterilmiştir.

Tablo 5.1. Sınıflandırma hata matrisi

		Gerçek Sınıf		
Öngörülen Sınıf		Boyun Kırığı	İntertrokanterik Kırık	Normal
	Boyun Kırığı	a	b	c
	İntertrokanterik Kırık	d	e	f
	Normal	g	h	i

Tablo 5.1.'e göre femur boyun kırığı için $TP = a$, $TN = e + f + h + i$, $FP = b + c$ ve $FN = d + g$ olmaktadır. Buradan yola çıkarak her sınıf için duyarlılık (geri çağırma), kesinlik ve F_1 skoru Eşitlik 5.3 ve Eşitlik 5.5 kullanılarak hesaplanabilir.

Doğruluk, sınıfı doğru olarak tespit edilen örneklerin sayısının bir başka ifade ile diyagonal üzerinde bulunan değerlerin toplamının toplam örneklem sayısına bölünmesiyle elde edilir (5.6):

$$Acc = \frac{a+e+i}{a+b+c+d+e+f+g+h+i} \quad (5.6)$$

Makro F_1 skoru ise her sınıf için hesaplanan F_1 skorunun sınıf sayısına bölünmesiyle elde edilir (5.7). n sınıf sayısı olmak üzere $F_1^{C_i}$ i . sınıfın F_1 skorunu temsil etmektedir:

$$Macro F_1 = \frac{\sum_{i=1}^n F_1^{C_i}}{n} \quad (5.7)$$

MCC ölçütü sınıflandırmanın kalitesinin belirlenmesinde kullanılan bir ölçüttür. c doğru olarak sınıflandırılan örneklem sayısını, s toplam örneklem sayısını, p_k k . sınıfın kaç kere tahmin edildiğini, t_k ise k . sınıfın örneklem sayısını belirtmektedir (5.8):

$$MCC = \frac{c*s - \sum_{k=1}^K p_k*t_k}{\sqrt{(s^2 - \sum_{k=1}^K p_k^2)(s^2 - \sum_{k=1}^K t_k^2)}} \quad (5.8)$$

Kappa ölçütü tıpkı ikili sınıflandırmada olduğu gibi tahmin edilen sınıflar (örneklem etiketi) ve gerçek sınıflar arasındaki uyumu belirlemek için kullanılır. c doğru olarak sınıflandırılan örneklem sayısını, s toplam örneklem sayısını, p_k k . sınıfın kaç kere tahmin edildiğini, t_k ise k . sınıfın örneklem sayısını belirtmektedir (5.9):

$$Kappa = \frac{c*s - \sum_{k=1}^K p_k*t_k}{c^2 - \sum_{k=1}^K p_k*t_k} \quad (5.9)$$

5.3. Analiz Sonuçları

5.3.1. Femur boyun kırığı tespiti için analiz sonuçları

Genetik algoritma kullanılmadan önerilen CNN mimarisi ile elde edilen 5-kat çapraz geçişleme deneylerinin sonuçları Tablo 5.2.'de verilmiştir.

Tablo 5.2. Farklı görüntü boyutları için performans karşılaştırması

Görüntü boyutu (piksel)	Acc	Kappa	F ₁	Sn	Sp
50x50	0.777	0.518	0.825	0.825	0.693
100x100	0.770	0.497	0.823	0.837	0.654
200x200	0.729	0.394	0.796	0.830	0.552
400x400	0.712	0.389	0.780	0.803	0.552

Tablo 5.2.'ye göre doğruluk, Kappa, F_1 skoru ve özgüllük açısından en iyi performans kesilen görüntülerin 50x50 piksel boyutuna tekrar ölçeklendirilmesiyle elde edilmiştir. En yüksek duyarlılık değerinin ise 100x100'lük görüntülerin kullanılmasıyla elde edildiği

görülmektedir. Öte yandan, Kappa ölçütü, CNN'yi beslemek için 50x50 piksel görüntü boyutu kullanıldığında, tespit performansının diğer görüntü boyutlarına göre daha güvenilir olduğunu göstermiştir.

Genetik algoritma kullanılarak 50x50 piksel boyutundaki görüntüler üzerinde yapılan geçişleme testlerinin sonuçları Tablo 5.3.'te gösterilmiştir.

Tablo 5.3. GA ile elde edilen sonuçlar

Popülasyon büyüklüğü	Hiper parametreler	Acc	Kappa	F ₁	Sn	Sp
10	4 10 4 9 23 88 54 81 69 118	0.767	0.497	0.817	0.817	0.681
50	3 4 10 10 15 18 122 117 80 79	0.793	0.554	0.836	0.829	0.729
100	3 10 24 9 24 111 123 114 56 73	0.793	0.552	0.838	0.838	0.714

Tablo 5.3.'e göre en yüksek doğruluk sonucu popülasyondaki kromozom sayısının 50 ve 100 olarak seçildiği durumlarda alınmıştır. Popülasyon büyüklüğünün 10 olarak seçilmesi 50x50 piksel boyutundaki görüntülerde ilk elde edilen 0.777 doğruluk değerinin gerisine düşülmesine sebep olmuştur. Hiper parametreler sütunundaki 10 tamsayıdan ilk 5'i filtre boyutunu son 5'i ise öznitelik haritası sayısını vermektedir. Kappa katsayısına baktığımızda ise popülasyon büyüklüğünün 50 veya 100 seçildiğinde tespit performansının iki durum için de güvenilir olduğunu göstermektedir.

Önerilen CNN mimarisinin performansı ile karşılaştırılması ve referans teşkil etmesi bakımından tespit çalışması HOG, LBP ve geleneksel öznitelikler ile SVM, kNN, NB ve RF sınıflandırıcıları da kullanılarak yapılmıştır. HOG öznitelikleri kullanılarak yapılan SVM deneylerinin sonuçları Tablo 5.4.'te verilmiştir.

Tablo 5.4. HOG özniteliklerinin SVM ile sınıflandırılması


SVM çekirdek	Kappa	Acc	Sn	Sp	F ₁
lineer	0.41	0.728	0.789	0.619	0.787
RBF	0.111	0.669	0.998	0.091	0.794
polinomiyal					
2. derece	0.49	0.764	0.815	0.674	0.815
3. derece	0.502	0.771	0.827	0.671	0.822
4. derece	0.518	0.778	0.832	0.684	0.827
5. derece	0.483	0.76	0.808	0.677	0.811
6. derece	0.0278	0.613	0.881	0.143	0.744
7. derece	0.0105	0.633	0.973	0.035	0.771

Tablo 5.4.'e göre 4. dereceden bir polinomiyal çekirdek fonksiyonu kullanıldığında sınıflandırıcının güvenilirliğini temsil eden Kappa ölçütü açısından en yüksek sonuç olan 0.518 elde edilmiştir. Yine genel doğruluğa bakıldığında 0.778 ile aynı çekirdek fonksiyonunun diğer çekirdek fonksiyonlarına üstün geldiği görülmektedir.

HOG özniteliklerinin Öklid uzaklığını kullanan kNN sınıflandırıcısını beslemesiyle elde edilen deney sonuçları Tablo 5.5.'te ve k parametresi ile Kappa ilişkisi Şekil 5.4.'te verilmiştir.

Tablo 5.5. HOG özniteliklerinin kNN ile sınıflandırılması

k-en yakın komşu	Kappa	Acc	Sn	Sp	F1
1	0.461	0.747	0.785	0.682	0.798
3	0.493	0.763	0.797	0.702	0.811
5	0.499	0.766	0.805	0.698	0.815
7	0.505	0.77	0.813	0.694	0.818
9	0.528	0.782	0.832	0.694	0.829
11	0.538	0.788	0.842	0.693	0.835
13	0.521	0.78	0.837	0.681	0.829
15	0.52	0.78	0.84	0.676	0.829
17	0.525	0.783	0.843	0.677	0.831
19	0.507	0.775	0.845	0.654	0.827



Şekil 5.4. k parametresi ve Kappa ilişkisi

Tablo 5.5.'e göre en yakın komşu sayısı olan k parametresi 11 seçildiğinde Kappa ve doğruluk ölçütleri sırasıyla 0.538 ve 0.788 ile en yüksek değerlere ulaşmaktadır. Böyle bir sonucun ortaya çıkmasının aynı sınıftan örneklemelerin HOG öznitelikleri uzayında birbirlerine yakın olarak kümeleneşine bağlı olduğu düşünülmektedir.

NB sınıflandırıcısının HOG öznitelikleri ile beslenmesi sonucu elde edilen deney sonuçları Tablo 5.6.'da gösterilmiştir.

Tablo 5.6. HOG özniteliklerinin NB ile sınıflandırılması

Dağılım	Kappa	Acc	Sn	Sp	F ₁
kernel (KDE)	0.211	0.63	0.692	0.522	0.704
normal (Gaussian)	0.129	0.565	0.553	0.587	0.618

Tablo 5.6.'ya göre kernel yoğunluk tahmini kullanan NB sınıflandırıcısı özgüllük dışında bütün başarımlar ölçütleri üzerinden normal dağılım kullanan NB sınıflandırıcısına üstün gelmiştir. Fakat her iki dağılım için de sonuçlar sınıflandırıcı güvenilirliği açısından başarısız olarak yorumlanabilir. Böyle bir sonucun ortaya çıkmasının nedeninin NB'nin örneklemeleri temsil eden HOG öznitelik vektörlerindeki her bir özneliğin diğer özniteliklerden bağımsız olarak kabul etmesi olduğu düşünülmektedir.

HOG öznitelikleri son sınıflandırıcı olan RF'yi beslemek için kullanıldığında elde edilen sonuçlar Tablo 5.7.'de verilmiştir. Buna göre ağaç sayısı 500 olarak seçildiğinde duyarlılık ölçütü hariç bütün ölçütler açısından en yüksek değerler elde edilmektedir. Böyle bir sonucun ortaya çıkmasının etkili HOG özniteliklerinin farklı ağaçlarda bulunma olasılığının ağaç sayısının çoğalmasıyla birlikte artmasına bağlı olduğu düşünülmektedir.

Tablo 5.7. HOG özniteliklerinin RF ile sınıflandırılması

Ağaç Sayısı	Kappa	Acc	Sn	Sp	F ₁
50	0.338	0.724	0.916	0.388	0.809
100	0.351	0.731	0.926	0.388	0.814
150	0.376	0.741	0.931	0.407	0.821
200	0.388	0.744	0.927	0.424	0.822
250	0.38	0.743	0.934	0.408	0.822
300	0.389	0.746	0.935	0.414	0.824
350	0.379	0.742	0.931	0.409	0.821
400	0.392	0.747	0.934	0.42	0.824
450	0.397	0.749	0.937	0.421	0.826
500	0.401	0.75	0.935	0.426	0.827
550	0.399	0.749	0.934	0.426	0.826

LBP öznitelikleri kullanılarak yapılan SVM deneylerinin sonuçları Tablo 5.8.'de verilmiştir.

Tablo 5.8. LBP özniteliklerinin SVM ile sınıflandırılması

SVM çekirdek	Kappa	Acc	Sn	Sp	F ₁
Lineer	0	0.637	1	0	0.778
RBF	0.029	0.637	0.97	0.054	0.773
polinomial					
2. derece	0.046	0.64	0.963	0.075	0.773
3. derece	0.179	0.671	0.921	0.234	0.781
4. derece	0.184	0.658	0.857	0.31	0.761
5. derece	0.248	0.67	0.808	0.427	0.757
6. derece	0.276	0.673	0.776	0.494	0.751
7. derece	0.285	0.674	0.761	0.52	0.748
8. derece	0.269	0.665	0.75	0.516	0.741
9. derece	0.252	0.657	0.741	0.508	0.733
10. derece	0.254	0.655	0.729	0.524	0.729

Tablo 5.8.'e göre 7. dereceden bir polinomial çekirdek fonksiyonu kullanıldığında sınıflandırıcının güvenilirliğini temsil eden Kappa ölçütü açısından en yüksek sonuç olan 0.285 elde edilmiştir. Yine genel doğruluğa bakıldığında 0.674 ile aynı çekirdek fonksiyonunun diğer çekirdek fonksiyonlarına üstün geldiği görülmektedir. Kappa değerinin 0.4'ten düşük olması LBP öznitelikleriyle beslenen SVM'nin sınıflandırıcı güvenilirliği açısından başarısız olduğu şeklinde yorumlanabilir.


LBP özniteliklerinin Öklid uzaklığını kullanan kNN sınıflandırıcısını beslemesiyle elde edilen deney sonuçları Tablo 5.9.'da ve k parametresi ile Kappa ilişkisi Şekil 5.5.'te verilmiştir.

Tablo 5.9. LBP özniteliklerinin kNN ile sınıflandırılması

k-en yakın komşu	Kappa	Acc	Sn	Sp	F ₁
1	0.157	0.604	0.67	0.489	0.683
3	0.197	0.626	0.696	0.502	0.703
5	0.196	0.629	0.712	0.484	0.71
7	0.201	0.633	0.723	0.476	0.715
9	0.213	0.639	0.729	0.482	0.72
11	0.212	0.64	0.732	0.478	0.721

Tablo 5.9. devam ediyor

13	0.228	0.648	0.743	0.481	0.729
15	0.214	0.645	0.753	0.456	0.73
17	0.203	0.639	0.745	0.454	0.724
19	0.195	0.64	0.761	0.427	0.729



Şekil 5.5. k parametresi Kappa ilişkisi

Tablo 5.9.'a göre en yakın komşu sayısı olan k parametresi 13 seçildiğinde Kappa ve doğruluk ölçütleri sırasıyla 0.228 ve 0.648 ile en yüksek değerlere ulaşmaktadır. Kappa değerinin 0.4'ten düşük olması LBP öznitelikleriyle beslenen kNN'nin sınıflandırıcı güvenilirliği açısından başarısız olduğu şeklinde yorumlanabilir. Böyle bir sonucun ortaya çıkmasının aynı sınıftan örneklemelerin LBP öznitelik uzayında birbirlerine yakın olarak kümelenmediğine bağlı olduğu düşünülmektedir.

NB sınıflandırıcısının LBP öznitelikleri ile beslenmesi ile elde edilen deney sonuçları Tablo 5.10.'da gösterilmiştir. Her iki dağılım için de sonuçlar sınıflandırıcı güvenilirliği açısından başarısız olarak yorumlanabilir. Başka bir deyişle Kappa değerinin 0.4'ten düşük olması LBP öznitelikleriyle beslenen NB'nin sınıflandırıcı güvenilirliği açısından başarısız olduğunu göstermektedir. LBP öznitelik vektörlerindeki özniteliklerin NB tarafından birbirinden bağımsız olarak kabul edilmesinin böyle bir sonucu ortaya çıkardığı düşünülmektedir.

Tablo 5.10. LBP özniteliklerinin NB ile sınıflandırılması

Dağılım	Kappa	Acc	Sn	Sp	F ₁
kernel (KDE)	0.141	0.585	0.617	0.531	0.655
normal (Gaussian)	0.104	0.541	0.497	0.618	0.579

LBP öznitelikleri kullanılarak deneylerin yapıldığı son sınıflandırıcı olan RF ile elde edilen sonuçlar Tablo 5.11.'de verilmiştir.

Tablo 5.11. LBP özniteliklerinin RF ile sınıflandırılması

Ağaç Sayısı	Kappa	Acc	Sn	Sp	F ₁
50	0.168	0.652	0.855	0.297	0.758
100	0.163	0.657	0.881	0.263	0.776
150	0.167	0.658	0.88	0.268	0.766
200	0.18	0.663	0.883	0.277	0.769
250	0.186	0.667	0.893	0.272	0.774
300	0.201	0.674	0.902	0.276	0.779
350	0.191	0.67	0.898	0.271	0.776
400	0.19	0.669	0.895	0.273	0.775
450	0.19	0.669	0.895	0.273	0.775
500	0.194	0.67	0.895	0.277	0.776
550	0.191	0.669	0.893	0.276	0.775

Tablo 5.11.'e göre ağaç sayısı 300 olarak seçildiğinde özgüllük hariç diğer tüm başarımlar ölçütleri açısından en yüksek değerler elde edilmektedir. Kappa değerinin 0.4'ün altında olması LBP öznitelikleriyle beslenen RF'nin sınıflandırıcı güvenilirliği açısından başarısız olduğunu göstermektedir. Ormanı oluşturan ağaçlarda, etkili LBP özniteliklerinin seçilemeyerek ve dolayısıyla sonuca etki etme olasılığının azalmasıyla böyle bir sonucun ortaya çıkmasına sebep olduğu düşünülmektedir.

Geleneksel öznitelikler ile beslenen SVM sınıflandırıcısı ile elde edilen deney sonuçları Tablo 5.12'de gösterilmiştir. Tablo 5.12.'ye göre 7. dereceden bir polinomiyal çekirdek fonksiyonu kullanıldığında Kappa katsayısı başarımlar ölçütü üzerinden en yüksek değer elde edilmiştir. 5. derece polinomiyal çekirdek fonksiyonu kullanan SVM sınıflandırıcısı özgüllük başarımlar ölçütü hariç bütün başarımlar ölçütlerinde en düşük değerleri vermiştir. Genel doğruluk başarımlar ölçütü için en yüksek değer radyal temel fonksiyon (RBF) kullanan SVM sınıflandırıcısı tarafından verilmiştir. Duyarlılık ve F₁ skoru başarımlar ölçütleri açısından yine en yüksek değerler radyal temel çekirdek fonksiyonuna sahip SVM tarafından

elde edilmiştir. Özgüllük başarımlar ölçütü için en yüksek değer 7. derece polinomiyal çekirdek fonksiyonu kullanan SVM ile elde edilmişken en düşük değer RBF kullanan SVM ile elde edilmiştir. Kappa katsayısının değeri tüm SVM mimarileri için 0.4'ün altında kaldığı için geleneksel öznitelikler ile beslenen SVM'nin sınıflandırıcı güvenilirliği açısından başarısız olduğunu görülmektedir.

Tablo 5.12. Geleneksel özniteliklerin SVM ile sınıflandırılması

SVM çekirdek	Kappa	Acc	Sn	Sp	F1
lineer	0.029	0.632	0.953	0.071	0.768
RBF	0	0.636	0.999	0.001	0.778
polinomiyal					
2. derece	0.075	0.547	0.569	0.51	0.616
3. derece	0.072	0.547	0.57	0.506	0.616
4. derece	0.058	0.546	0.588	0.473	0.622
5. derece	-0.091	0.406	0.298	0.595	0.389
6. derece	0.035	0.507	0.473	0.566	0.55
7. derece	0.096	0.491	0.312	0.805	0.438
8. derece	0.059	0.506	0.433	0.634	0.527
9. derece	0.04	0.562	0.673	0.366	0.662
10. derece	-0.014	0.506	0.541	0.444	0.582

Geleneksel öznitelikler ile beslenen kNN sınıflandırıcısı ile elde edilen deney sonuçları Tablo 5.13'te gösterilmiştir.

Tablo 5.13. Geleneksel özniteliklerin kNN ile sınıflandırılması

k-en yakın komşu	Kappa	Acc	Sn	Sp	F1
1	0.084	0.566	0.626	0.46	0.647
3	0.094	0.574	0.644	0.452	0.658
5	0.119	0.591	0.673	0.446	0.677
7	0.101	0.585	0.677	0.424	0.675
9	0.098	0.585	0.682	0.416	0.677
11	0.102	0.588	0.686	0.416	0.679
13	0.099	0.586	0.686	0.412	0.679
15	0.103	0.59	0.695	0.407	0.684
17	0.096	0.587	0.694	0.4	0.682
19	0.114	0.597	0.707	0.405	0.691

Tablo 5.13.'e göre Kappa katsayısı başarımlar ölçütü açısından en yüksek değere en yakın 5 komşu seçildiğinde ulaşıldığı görülmüştür. En yakın komşu ile sınıflandırma yapıldığında Kappa katsayısının en düşük değere sahip olduğu tespit edilmiştir. Buna ek

olarak en yakın komşunun kullanıldığı durumda özgüllük hariç bütün başarımlar ölçütleri açısından en düşük değerlerin elde edildiği gözlemlenmiştir. Buna rağmen özgüllük başarımlar ölçütünün en yüksek değeri en yakın komşunun kullanıldığı durumda elde edilmiştir. Genel doğruluk, hassasiyet ve F_1 skoru başarımlar ölçütlerinin en yüksek değerlerine en yakın 19 komşunun kullanıldığı durumda ulaşıldığı görülmüştür. Kappa katsayısının değeri tüm kNN mimarileri için 0.4'ün altında kaldığı için geleneksel öznitelikler ile beslenen kNN'nin sınıflandırıcı güvenilirliği açısından başarısız olduğu görülmektedir. Böyle bir sonucun ortaya çıkmasının aynı sınıftaki örneklemelerin geleneksel öznitelikler uzayında birbirlerinden uzak olarak kümelenmesine bağlı olduğu düşünülmektedir.

Geleneksel öznitelikler ile beslenen NB sınıflandırıcısı ile elde edilen deney sonuçları Tablo 5.14'te gösterilmiştir. Buna göre sonuç sadece kernel (KDE) dağılımı kullanıldığında alınabilmektedir. Normal dağılım kullanılarak sonuç alınamamıştır. Bunun sebebi, kırık değil veya normal sınıfı için 117. özniteliğin verilerde 0 varyansa sahip olmasıdır. Kappa katsayısının değeri 0.4'ün altında kaldığı için geleneksel öznitelikler ile beslenen NB'nin sınıflandırıcı güvenilirliği açısından başarısız olduğu görülmektedir. NB'nin öznitelik vektörlerindeki özniteliklerin birbirinden bağımsız olduğu kabulünün böyle bir sonucun ortaya çıkmasında etkili olduğu düşünülmektedir.

Tablo 5.14. Geleneksel özniteliklerin NB ile sınıflandırılması

Dağılım	Kappa	Acc	Sn	Sp	F ₁
kernel (KDE)	0.157	0.563	0.498	0.677	0.592
normal (Gaussian)	N/A	N/A	N/A	N/A	N/A

Geleneksel öznitelikler ile beslenen RF sınıflandırıcısı ile elde edilen deney sonuçları Tablo 5.15'te gösterilmiştir.

Tablo 5.15. Geleneksel özniteliklerin RF ile sınıflandırılması

Ağaç sayısı	Kappa	Acc	Sn	Sp	F ₁
50	0.091	0.589	0.707	0.382	0.686
100	0.089	0.586	0.699	0.388	0.682
150	0.084	0.586	0.705	0.376	0.685
200	0.075	0.583	0.705	0.369	0.683
250	0.077	0.585	0.711	0.363	0.686
300	0.073	0.583	0.708	0.363	0.683
350	0.075	0.584	0.708	0.365	0.684
400	0.071	0.581	0.705	0.365	0.682
450	0.078	0.585	0.708	0.367	0.685

Tablo 5.15. devam ediyor

500	0.078	0.585	0.711	0.365	0.686
550	0.083	0.586	0.709	0.371	0.686

Tablo 5.15.'e göre Kappa katsayısı başarımlı ölçütü açısından en yüksek değere ağaç sayısı parametresi 50 olarak seçildiğinde ulaşıldığı görülmüştür. Bu ölçütün ağaç sayısı 400 olarak seçildiğinde en düşük değerini aldığı gözlemlenmiştir. Genel doğruluk başarımlı ölçütü açısından da durumun değişmediği tespit edilmiştir. Duyarlılık başarımlı ölçütü açısından en yüksek değere 500 ağaç kullanılarak ulaşılrken en düşük değer 100 ağaç kullanıldığında elde edilmiştir. Özgüllük başarımlı ölçütü açısından en yüksek değer 100 ağaç ile elde edilirken en düşük değerlerin 250 ve 300 ağaç kullanıldığında ortaya çıktığı saptanmıştır. F₁ skorunda ise en yüksek ve en düşük değerler sırasıyla 50 ve 100 (2. olarak 400) ağaç kullanıldığında elde edilmiştir. Kappa katsayısının değeri tüm RF mimarilerinde 0.4'ün altında kaldığı için geleneksel öznitelikler ile beslenen RF'nin sınıflandırıcı güvenilirliği açısından başarısız olduğu görülmektedir. Etkili geleneksel özniteliklerin ormanı oluşturan ağaçlarda seçilemeyerek ve sonuca etki etme olasılığının azalmasına bağlı olarak böyle bir sonucun ortaya çıktığı düşünülmektedir.

Kanonik sınıflandırıcıları beslemek için kullanılan farklı öznitelikler üzerinde düşünüldüğünde HOG özniteliklerinin başarımlı ölçütleri üzerinden LBP özniteliklerine ve geleneksel özniteliklere üstün geldiği görülmektedir. Kırık görüntülerinin öznitelik vektörleriyle temsil edilebilmesi için görüntüdeki kenarların ve özellikle köşelerin tespit edilebilmesi gerekmektedir. Çünkü kırıklar kemikteki devamlılığı bozan başka bir deyişle görüntüdeki kenarlarda kopmaya neden olan ve çıkıntı-girinti oluşturan dolayısıyla köşelerle temsil edilen bir örüntüye sahiptir. HOG özniteliklerinin diğer özniteliklere göre daha yüksek sonuçlar vermesinin kenar ve köşe tespitinde daha başarılı olmasına bağlı olduğu düşünülmektedir.

Önerilen CNN/GA mimarisinin performansını artırmak için bahsi geçen mimarinin sonuçları ile HOG öznitelikleri tarafından beslenerek en yüksek Kappa değerine ulaşan kanonik makine öğrenme sınıflandırıcılarının sonuçları çoğunluk oylamasına tabi tutulmuştur. Tablo 5.16.'da çoğunluk oylaması deney sonuçları gösterilmiştir.

Tablo 5.16. oęunluk oylaması

Sınıflandırıcılar	Kappa	Acc	Sn	Sp	F ₁
CNN/GA+SVM+KNN+NB+RF	0.564	0.806	0.902	0.639	0.856
CNN/GA+SVM+KNN	0.436	0.766	0.954	0.437	0.838
CNN/GA+SVM+RF	0.33	0.73	0.961	0.327	0.819
CNN/GA+KNN+RF	0.347	0.737	0.963	0.34	0.823
CNN/GA+KNN+NB	0.362	0.741	0.958	0.36	0.825
CNN/GA+NB+RF	0.286	0.716	0.964	0.281	0.812
CNN/GA+SVM+NB	0.331	0.73	0.956	0.333	0.818
SVM+KNN+RF	0.356	0.738	0.953	0.361	0.822
SVM+KNN+NB	0.36	0.738	0.947	0.371	0.822
SVM+NB+RF	0.306	0.722	0.961	0.305	0.815
KNN+NB+RF	0.317	0.726	0.958	0.318	0.816

Tablo 5.16.'ya g re Kappa katsayısı bařarım  l t   zerinden en y ksek deęer, CNN/GA (pop lasyon b y kl ę  50), SVM (4. derece polinomiyal  ekirdek), kNN (k=11), NB (KDE) ve RF (500 aęa ) sınıflandırıcılarının sonu larının  oęunluk oylamasına sokularak elde edilmiřtir. Buna ek olarak  zg ll k, genel doęruluk ve F₁ skoru i in de en y ksek deęerler bahsi ge en 5 sınıflandırıcının  oęunluk oylaması ile elde edilmiřtir. Duyarlılık bařarım  l t  g z  n ne alındıęında dięer sınıflandırıcı kombinasyonlarına (birleřimlerine) g re en d ř k deęerin elde edildięi g r lm řtir.  oęunluk oylamasının uygulanması i in oluřturulan farklı sınıflandırıcı birleřimlerinde Kappa katsayısı,  zg ll k, genel doęruluk ve F₁ skoru bařarım  l t leri  zerinden yapılan deęerlendirmede CNN/GA, NB ve RF sınıflandırıcılarının birleřiminin en d ř k deęerleri aldıęı buna karřılık duyarlılık bařarım  l t   zerinden ise en y ksek deęere sahip olduęu tespit edilmiřtir. CNN/GA mimarisi ve d rt kanonik sınıflandırıcının kullanıldıęı  oęunluk oylamasında ortaya  ıkan sonucun, sınıflandırıcıların hatalı sınıflandırmalarının oylama ile azaltılmasına baęlı olduęu g r lmektedir.

LBP imgeleri, FT imgeleri ve    kanallı (orijinal imge, LBP imgesi ve FT imgesi) imgeler kullanarak CNN (genetik algoritma kullanılmadan) ile yapılan deney sonu ları Tablo 5.17.'de verilmiřtir.

Tablo 5.17. Üç kanallı görüntüler için sonuçlar

Yöntem	Kappa	Acc	Sn	Sp	F ₁
CNN orijinal imgeler	0.518	0.777	0.825	0.693	0.825
CNN 3 kanallı imgeler	0.339	0.704	0.811	0.518	0.777
CNN LBP imgeleri	0.312	0.693	0.805	0.497	0.769
CNN FT imgeleri	0.171	0.637	0.787	0.374	0.734

Tablo 5.17.'ye göre Kappa katsayısı başarımlı ölçütüne göre önerilen yöntemlerin hiçbirisi orijinal resimlerin girdi olarak kullanıldığı CNN kadar başarılı olamamıştır. FT imgelerinin CNN'i beslemek için kullanıldığı yöntem bütün başarımlı ölçütlerinde en düşük sonuçları vermiştir. Orijinal imgeler ile bu imgelerden elde edilen LBP imgelerinin ve FT imgelerinin birleştirilerek üç kanallı bir imge elde edildiği yöntem ise bütün başarımlı ölçütlerine göre, orijinal imgelerin kullanıldığı CNN yöntemi hariç, en yüksek değerlere sahiptir. Fakat Kappa katsayısının değeri 0.4'ün altında kaldığı için 3 kanallı imgeler ile kullanılan CNN yöntemi sınıflandırıcı güvenilirliği açısından başarısız olarak görülmektedir. Böyle bir sonucun ortaya çıkmasının LBP ve FT imgelerinde kenar ve köşe bilgilerinin yeterince ifade edilemediğine bağlı olduğu düşünülmektedir.

CNN/GA kullanılarak çeşitli katmanlardan otomatik olarak elde edilen özneteliklerin LSTM ve BILSTM mimarileri ile sınıflandırılmasıyla elde edilen sonuçlar Tablo 5.18.'de verilmiştir.

Tablo 5.18. LSTM ve BILSTM ile sınıflandırma

Yöntem	CNN katmanı	Kappa	Acc	Sn	Sp	F ₁
CNN	-	0.518	0.777	0.825	0.693	0.825
CNN/GA	-	0.554	0.793	0.829	0.729	0.836
LSTM						
Gizli birim sayısı/katman sayısı						
100/1	1. evrişimsel	0.213	0.643	0.747	0.461	0.727
200/1	1. evrişimsel	0.181	0.633	0.755	0.42	0.724
400/1	1. evrişimsel	0.264	0.667	0.769	0.489	0.746
800/1	1. evrişimsel	0.229	0.65	0.75	0.475	0.732
625/1	1. maksimum havuzlama	0.445	0.744	0.803	0.641	0.8

Tablo 5.18. devam ediyor

144/1	2. maksimum havuzlama	0.474	0.761	0.834	0.633	0.816
144/1	3. evrimsel	0.362	0.713	0.811	0.541	0.783
36/1	3. maksimum havuzlama	0.534	0.785	0.838	0.693	0.833
36/1	4. evrimsel	0.531	0.783	0.834	0.695	0.831
9/1	4. maksimum havuzlama	0.561	0.796	0.834	0.729	0.839
9/2	4. maksimum havuzlama	0.558	0.794	0.831	0.731	0.837
9/3	4. maksimum havuzlama	0.554	0.794	0.84	0.712	0.839
9/1	5. evrimsel	0.55	0.792	0.837	0.712	0.837
1/1	5. maksimum havuzlama	0.56	0.793	0.814	0.757	0.833
1/2	5. maksimum havuzlama	0.575	0.802	0.838	0.74	0.844
1/3	5. maksimum havuzlama	0.554	0.793	0.837	0.718	0.838
1/4	5. maksimum havuzlama	0.563	0.797	0.838	0.725	0.84
1/5	5. maksimum havuzlama	0.566	0.797	0.824	0.749	0.838
9/4	4. maksimum havuzlama	0.551	0.793	0.846	0.701	0.839
9/5	4. maksimum havuzlama	0.534	0.784	0.83	0.705	0.831

Tablo 5.18. devam ediyor

BILSTM						
Gizli birim sayısı/katman sayısı						
1/1	5. maksimum havuzlama	0.564	0.795	0.82	0.753	0.836
1/2	5. maksimum havuzlama	0.549	0.79	0.828	0.724	0.834
1/3	5. maksimum havuzlama	0.566	0.799	0.839	0.728	0.841
1/4	5. maksimum havuzlama	0.556	0.795	0.843	0.711	0.84
1/5	5. maksimum havuzlama	0.552	0.796	0.858	0.686	0.843
9/1	4. maksimum havuzlama	0.554	0.792	0.83	0.727	0.836
9/2	4. maksimum havuzlama	0.564	0.798	0.837	0.729	0.84
9/3	4. maksimum havuzlama	0.558	0.794	0.832	0.728	0.838
9/4	4. maksimum havuzlama	0.561	0.797	0.842	0.719	0.841
9/5	4. maksimum havuzlama	0.561	0.797	0.84	0.72	0.84

Tablo 5.18.'e göre elde edilen sonuçların ışığında Kappa katsayısı başarımlı ölçütü açısından en yüksek değer, CNN'in 5. maksimum havuzlama katmanından elde edilen özniteliklerin 2 katmanlı LSTM mimarisinin kullanıldığı bir sınıflandırıcıyla sınıflandırılmasıyla elde edilmiştir. Şu ana kadar elde edilen Kappa katsayısı değeri dolayısıyla sınıflandırıcı güvenilirliği açısından LSTM mimarisi, CNN/GA mimarisini geçmiştir. Genel doğruluk başarımlı ölçütü açısından bakıldığında yine yukarıda bahsedilen mimari kullanılarak en yüksek değere ulaşılmıştır. Duyarlılık başarımlı ölçütü açısından en yüksek değer 5 katmanlı BILSTM mimarisiyle elde edilmiştir. Burada da CNN'in 5. maksimum havuzlama katmanından otomatik olarak elde edilen öznitelikler devrededir.

Özgüllük başarımlar ölçütü açısından en yüksek değer 1 katmanlı LSTM mimarisinin kullanıldığı durumda elde edilmiştir. LSTM'yi besleyen öznitelikler yine CNN'in 5. maksimum havuzlama katmanından otomatik olarak çıkarılan özniteliklerdir. F_1 skoru başarımlar ölçütünde en yüksek değere 2 katmanlı LSTM mimarisi ile ve CNN'in 5. maksimum havuzlama katmanından çıkarılan öznitelikler ile ulaşılmıştır. Başarımlar ölçütleri açısından en düşük değerlere tek katmanlı LSTM mimarisinin rastgele kullanılan gizli birim sayılarıyla ulaşılmıştır. Burada CNN'in 1. evrimsel katmanından otomatik olarak elde edilen öznitelikler LSTM'yi beslemek için kullanılmıştır. CNN/GA mimarisinin öznitelik çıkarıcı olarak kullanılması sayesinde son katmanlarda kırıklara özgü öznitelikler elde edilmesi, bu özniteliklerin GA ile belirlenen öznitelik haritası sayısı ile temsil edilmesi ve LSTM ve BILSTM mimarilerinin öznitelikler arasındaki ilişkiyi açığa çıkarmasıyla böyle bir sonucun elde edildiği düşünülmektedir.

Auto Encoder (AE) ile yapılan deneyler sonucunda elde edilen sınıflandırma sonuçları Tablo 5.19.'da verilmiştir. Gizli birim sayısı her katman için yarıya düşürülmüştür. Örneğin "AE1 (1250)" mimarinin 1 katmanlı olduğunu veya 1250 gizli birimden oluşan 1 kodlayıcı ile özniteliklerin çıkarıldığını ifade etmektedir.

Tablo 5.19. AE mimarisi ile sınıflandırma

Yöntem	Kappa	Acc	Sn	Sp	F ₁
CNN	0.518	0.777	0.825	0.693	0.825
CNN/GA	0.554	0.793	0.829	0.729	0.836
AE mimarisi					
AE 1 (1250)	0.294	0.691	0.829	0.448	0.774
AE 2 (1250,625)	0.225	0.659	0.795	0.42	0.748
AE 3 (1250,625,312)	0.223	0.653	0.78	0.434	0.739
AE 4 (1250,625,312,156)	0.11	0.647	0.913	0.18	0.767
AE 5 (1250,625,312,156,78)	0.265	0.682	0.838	0.409	0.771

Tablo 5.19.'a göre Kappa katsayısı başarımlar ölçütü açısından en yüksek değere tek katmanlı kodlayıcı kullanan AE mimarisiyle ulaşılmıştır. Tek katmanlı AE mimarisi duyarlılık başarımlar ölçütü hariç diğer başarımlar ölçütlerinde en yüksek değerleri vermiştir (referansımız olan CNN ve CNN/GA dahil değildir). Duyarlılık başarımlar ölçütünün en yüksek değere ulaştığı mimari 4 katmanlı AE mimarisidir. Kappa katsayısı, genel doğruluk ve özgüllük başarımlar ölçütlerinde en düşük değerler yine 4 katmanlı AE mimarisi ile elde edilmiştir. F_1 skoru başarımlar ölçütünde ise en düşük değer 3 katmanlı AE mimarisi ile tespit edilmiştir. Tüm AE mimarileri için Kappa katsayısının değeri 0.4'ün altında kaldığından

dolayı AE mimarisi sınıflandırıcı güvenilirliği açısından başarısız olarak görülmektedir. Bu sonuçların ortaya çıkmasının, katmanlardaki nöron sayısının herhangi bir optimizasyon algoritması ile belirlenmemesine bağlı olduğu düşünülmektedir.

PSO üst-sezgisel optimizasyon algoritması kullanılarak CNN ile elde edilen deney sonuçları Tablo 5.20.'de verilmiştir. CNN/PSO mimarisi kullanılarak yapılan deneylerde sonuçlar, 10 iterasyon uygulanarak alınmıştır.

Tablo 5.20. CNN/PSO ile sınıflandırma

Popülasyon büyüklüğü	Hiper parametreler	Kappa	Acc	Sn	Sp	F ₁
10	4 2 3 4 2 66 128 127 110 27	0.553	0.798	0.87	0.671	0.846
50	10 4 8 5 2 8 102 74 98 91	0.553	0.795	0.852	0.697	0.841
100	8 2 2 5 2 35 128 128 106 18	0.562	0.8	0.858	0.698	0.845

Tablo 5.20.'ye göre Kappa katsayısı başarımlı ölçütü açısından en yüksek değere popülasyon veya sürü büyüklüğünün 100 olarak seçildiği durumda ulaşılmıştır. Doğruluk ve özgüllük açısından bakıldığında popülasyon büyüklüğünün 100 olarak seçildiği kuruluma yine en yüksek değerler elde edilmiştir. Buna karşın duyarlılık ölçütü ve F₁ skoru en yüksek değerine popülasyon büyüklüğü 10 olarak seçildiğinde ulaşmaktadır. Kappa katsayısı değeri 0.4'ün üzerinde olduğu için CNN/PSO mimarisi sınıflandırıcı güvenilirliği açısından başarılıdır ve CNN/GA mimarisine üstün gelmiştir. Burada CNN mimarisinin evrimsel katmanlarındaki hiper parametreler olan evrimsel filtre boyutu ve öznitelik haritası sayısının önemi bir kez daha kanıtlanmıştır.

Dengesiz veri kümesi ile yapılan deneyler dengeli veri kümesi ile de tekrarlanmış ve başarımlı ölçütleri üzerinden performansları karşılaştırılmıştır. Bahsi geçen veri kümeleri için elde edilen deney sonuçları CNN mimarileri, HOG özniteliklerini kullanan kanonik makine öğrenme sınıflandırıcıları, LBP özniteliklerini kullanan kanonik makine öğrenme sınıflandırıcıları, geleneksel öznitelikleri kullanan kanonik makine öğrenme sınıflandırıcıları, CNN/GA mimarisinden elde edilen öznitelikleri kullanan LSTM/BILSTM mimarileri ve CNN/GA mimarisinin sonuçları ile HOG özniteliklerini kullanan kanonik makine öğrenme sınıflandırıcılarının sonuçlarının çoğunluk oylamasına tabi tutulduğu bölümler olarak sırasıyla Tablo 5.21.'de, Tablo 5.22.'de, Tablo 5.23.'te, Tablo 5.24.'te, Tablo 5.25'te ve Tablo 5.26.'da verilmiştir.

Tablo 5.21. Farklı veri kümeleri için CNN mimarileri ile sınıflandırma

Yöntem	DENGESİZ VERİ KÜMESİ					DENGELİ VERİ KÜMESİ				
	Kappa	Acc	Sn	Sp	F ₁	Kappa	Acc	Sn	Sp	F ₁
CNN BÖLÜMÜ										
CNN	0.518	0.777	0.825	0.693	0.825	0.563	0.782	0.787	0.776	0.783
CNN/GA (10 10)	0.497	0.767	0.817	0.681	0.817	0.552	0.776	0.758	0.794	0.772
CNN/GA (50 10)	0.554	0.793	0.829	0.729	0.836	0.562	0.781	0.776	0.787	0.78
CNN/GA (100 10)	0.552	0.793	0.838	0.714	0.838	0.543	0.771	0.755	0.787	0.768
CNN/PSO (10 10)	0.553	0.798	0.87	0.671	0.846	0.609	0.805	0.795	0.814	0.803
CNN/PSO (50 10)	0.553	0.795	0.852	0.697	0.841	0.585	0.792	0.783	0.802	0.79
CNN/PSO (100 10)	0.562	0.8	0.858	0.698	0.845	0.501	0.751	0.769	0.732	0.755
CNN 3C	0.339	0.704	0.811	0.518	0.777	0.172	0.586	0.609	0.564	0.595
CNN LBP	0.312	0.693	0.805	0.497	0.769	0.107	0.553	0.503	0.604	0.529
CNN FFT	0.171	0.637	0.787	0.374	0.734	0.25	0.625	0.632	0.618	0.627

Tablo 5.21.'e göre CNN mimarilerinin kullanılmasıyla dengesiz veri kümesinde Kappa başarımları ölçütü açısından en yüksek değere popülasyon büyüklüğünün 100 olduğu CNN/PSO ile ulaşılırken dengeli veri kümesinde en yüksek değere popülasyon büyüklüğünün 10 olduğu CNN/PSO ile ulaşılmıştır. Diğer başarımlar ölçütleri üzerinden bakıldığında dengesiz veri kümesinde farklı CNN mimarileri ile en yüksek değerlere ulaşılırken dengeli veri kümesinde en yüksek değerlere sadece popülasyon büyüklüğü 10 olan CNN/PSO ile ulaşılmıştır.

Tablo 5.22. Farklı veri kümeleri için HOG ile sınıflandırma

Yöntem	DENGESİZ VERİ KÜMESİ					DENGELİ VERİ KÜMESİ				
	Kappa	Acc	Sn	Sp	F ₁	Kappa	Acc	Sn	Sp	F ₁
HOG ÖZİTELİKLERİ BÖLÜMÜ										
kNN (k=11)	0.538	0.788	0.842	0.693	0.835	0.504	0.752	0.716	0.788	0.743
SVM (7. derece)	0.518	0.778	0.832	0.684	0.827	0.545	0.773	0.758	0.787	0.769
RF (500 ağaç)	0.401	0.75	0.935	0.426	0.827	0.53	0.765	0.777	0.753	0.768
NB (KDE)	0.211	0.63	0.692	0.522	0.704	0.211	0.606	0.585	0.626	0.597

Tablo 5.22.'ye göre HOG özellikleri ile beslenen kanonik makine öğrenme sınıflandırıcılarının kullanılmasıyla Kappa ve doğruluk başarımları ölçütleri açısından en yüksek değerlere, dengesiz veri kümesinde en yakın 11 komşuya göre çalışan kNN ile ulaşılırken, dengeli veri kümesinde ise 7. derece polinomial çekirdek fonksiyonu kullanan SVM ile ulaşılmıştır. Duyarlılık başarımları ölçütü açısından en yüksek değerler, her iki veri kümesi için de 500 ağaçlı RF ile elde edilmiştir. Özgüllük başarımları ölçütü için en yüksek

değerlere her iki veri kümesinde kNN ile ulaşılmıştır. F_1 skoru için dengesiz veri kümesinde kNN ile, dengeli veri kümesinde ise SVM ile en yüksek değerler elde edilmiştir.

Tablo 5.23. Farklı veri kümeleri için LBP ile sınıflandırma

	DENGESİZ VERİ KÜMESİ					DENGELİ VERİ KÜMESİ				
Yöntem	Kappa	Acc	Sn	Sp	F_1	Kappa	Acc	Sn	Sp	F_1
LBP ÖZİTELİKLERİ BÖLÜMÜ										
kNN (k=13)	0.228	0.648	0.743	0.481	0.729	0.136	0.568	0.5	0.635	0.537
SVM (7. derece)	0.285	0.674	0.761	0.52	0.748	0.242	0.621	0.619	0.623	0.62
RF (300 ağaç)	0.201	0.674	0.902	0.276	0.779	0.116	0.558	0.565	0.55	0.561
NB (KDE)	0.141	0.585	0.617	0.531	0.655	0.063	0.531	0.479	0.583	0.506

Tablo 5.23.'e göre LBP öz nitelikleri ile beslenen kanonik makine öğrenme sınıflandırıcılarının kullanılmasıyla Kappa ve doğruluk başarımları ölçütleri açısından en yüksek değerlere, her iki veri kümesi için de 7. derece polinomiyal çekirdek fonksiyonu kullanan SVM ile ulaşılmıştır. Duyarlılık ölçütü açısından bakıldığında dengesiz veri kümesinde 300 ağaç kullanan RF ile, dengeli veri kümesinde ise SVM ile en yüksek değerler elde edilmiştir. Özgüllük ölçütü için en yüksek değerlere dengesiz veri kümesinde kernel yoğunluk tahmini kullanan NB ile, dengeli veri kümesinde ise kNN ile ulaşılmıştır. F_1 skorunda en yüksek değerler dengesiz veri kümesinde RF ile, dengeli veri kümesinde ise SVM ile elde edilmiştir.

Tablo 5.24. Geleneksel öz nitelikler ile sınıflandırma

	DENGESİZ VERİ KÜMESİ					DENGELİ VERİ KÜMESİ				
Yöntem	Kappa	Acc	Sn	Sp	F_1	Kappa	Acc	Sn	Sp	F_1
GELENEKSEL ÖZİTELİKLERİ BÖLÜMÜ										
SVM (7. derece)	0.096	0.491	0.312	0.805	0.438	0.076	0.538	0.11	0.966	0.192
kNN (k=5)	0.119	0.591	0.673	0.446	0.677	0.127	0.563	0.536	0.591	0.551
NB (KDE)	0.157	0.563	0.498	0.677	0.592	0.159	0.579	0.368	0.79	0.467
RF (50 ağaç)	0.091	0.589	0.707	0.382	0.686	0.11	0.555	0.528	0.582	0.543

Tablo 5.24.'e göre geleneksel öz nitelikler ile beslenen kanonik makine öğrenme sınıflandırıcılarının kullanılmasıyla Kappa başarımları ölçütü açısından en yüksek değerlere, her iki veri kümesi için de kernel yoğunluk tahmini kullanan NB ile ulaşılmıştır. Dengesiz ve dengeli veri kümeleri için doğruluk ölçütü açısından en yüksek değerlere en yakın 5 komşu kullanan kNN ve KDE ile, duyarlılık ölçütü açısından en yüksek değerlere 50 ağaç kullanan RF ve kNN ile, özgüllük ölçütü açısından en yüksek değerlere 7. derece

polinomiyal çekirdek fonksiyonu kullanan SVM ile, F_1 skoru açısından en yüksek değerlere ise RF ve kNN ile ulaşılmıştır.

Tablo 5.25. LSTM/BILSTM ile sınıflandırma

Yöntem	DENGESİZ VERİ KÜMESİ					DENGELİ VERİ KÜMESİ				
	Kappa	Acc	Sn	Sp	F_1	Kappa	Acc	Sn	Sp	F_1
CNN/GA LSTM/BILSTM BÖLÜMÜ										
LSTM (2 katman)	0.575	0.802	0.838	0.74	0.844	0.562	0.781	0.777	0.785	0.78
BILSTM (3 katman)	0.566	0.799	0.839	0.728	0.841	0.562	0.781	0.787	0.774	0.782

Tablo 5.25.'te verilen deney sonuçları, 50 popülasyon büyüklüğüne sahip CNN/GA mimarisinin 5. havuzlama katmanından otomatik olarak elde edilen öz nitelikler ile alınmıştır. 5. havuzlama katmanından çıkarılan öz nitelikler ile beslenen LSTM ve BILSTM mimarilerinin kullanılmasıyla Kappa, doğruluk ve özgüllük başarımları ölçütleri açısından en yüksek değerlere, her iki veri kümesi için de iki katmanlı LSTM mimarisi ile ulaşılmıştır. Duyarlılık ölçütü açısından en yüksek değerler ise her iki veri kümesi için de üç katmanlı BILSTM mimarisi ile elde edilmiştir. F_1 skoru için en yüksek değerlere dengesiz veri kümesinde LSTM ile, dengeli veri kümesinde ise BILSTM ile ulaşılmıştır.


Tablo 5.26. Farklı veri kümeleri için çoğunluk oylaması

Yöntem	DENGESİZ VERİ KÜMESİ					DENGELİ VERİ KÜMESİ				
	Kappa	Acc	Sn	Sp	F_1	Kappa	Acc	Sn	Sp	F_1
ÇOĞUNLUK OYLAMASI (CNN/GA ve HOG ÖZNİTELİKLERİ) BÖLÜMÜ										
CNN/GA (10 10) + SVM+kNN +NB+RF	0.555	0.803	0.903	0.628	0.854	0.575	0.787	0.782	0.793	0.786
CNN/GA (50 10) + SVM+kNN +NB+RF	0.564	0.806	0.902	0.639	0.856	0.581	0.79	0.782	0.799	0.789
CNN/GA (100 10) + SVM+kNN +NB+RF	0.556	0.804	0.907	0.624	0.855	0.573	0.786	0.775	0.798	0.784

Tablo 5.26.'da farklı popülasyon büyüklüğüne sahip CNN/GA mimarilerinin sonuçları ile HOG öz nitelikleri tarafından beslenen kanonik makine öğrenme sınıflandırıcılarının sonuçlarının çoğunluk oylamasına sokularak elde edilen performans değerleri gösterilmektedir. Çoğunluk oylamasında kullanılan sınıflandırıcılar en yakın 11 komşuya göre çalışan kNN, 7. derece polinomiyal çekirdek fonksiyonu kullanan SVM, 500 ağaçlı RF ve kernel yoğunluk tahmini kullanan NB'dir. Buna göre Kappa, doğruluk, özgüllük ve F_1 skoru başarımları ölçütleri üzerinden en yüksek değerlere her iki veri kümesi için de 50


popülasyon büyüklüğüne sahip CNN/GA ile SVM, kNN, NB ve RF sınıflandırıcılarının sonuçlarının çoğunluk oylamasına katılmasıyla ulaşılmıştır. Duyarlılık başarımlarını ölçütü açısından en yüksek değerler dengesiz veri kümesinde 100 popülasyon büyüklüğüne sahip CNN/GA mimarisi ve kanonik sınıflandırıcılarla, dengeli veri kümesinde ise 10 ve 50 popülasyon büyüklüğüne sahip CNN/GA mimarileri ve kanonik sınıflandırıcılarla elde edilmiştir.

Duyarlılık başarımlarını ölçütü açısından hem dengeli hem de dengesiz veri kümelerinde CNN mimarileri için en yüksek sonuçlar Şekil 5.6.'da gösterilmektedir. Sonuçlar, dengesiz veri kümesinde, PSO kullanılarak optimize edilen CNN'nin (CNN/PSO) GA kullanılarak optimize edilen CNN'den (CNN/GA) üstün olduğunu göstermektedir. Dengeli veri kümesinde ise CNN/PSO, optimize edilmemiş CNN mimarisine üstün gelmiştir. CNN/GA, optimize edilmemiş CNN mimarisinin gerisine düşmüştür. Her iki veri kümesinde de PSO, popülasyon büyüklüğü için 10 ve jenerasyon/iterasyon sayısı için 10 değerleri ile çalıştırılmıştır.




Şekil 5.6. CNN mimarilerinde duyarlılık ölçütü [150]

Şekil 5.7.'de farklı kanonik sınıflandırıcılara girdi olarak verilen HOG ve LBP öznitelikleri arasındaki karşılaştırma duyarlılık başarımlarını ölçütü üzerinden gösterilmektedir. Dengeli veri kümesinde HOG öznitelikleri ile eğitilen RF sınıflandırıcısı, LBP öznitelikleri ile eğitilen SVM sınıflandırıcısından daha yüksek performans göstermiştir. Dengesiz veri kümesinde HOG öznitelikleri ile eğitilen 500 ağaçlı RF sınıflandırıcısı, LBP öznitelikleri ile eğitilen 300 ağaçlı RF sınıflandırıcısına üstün gelmiştir. RF sınıflandırıcısı hem HOG hem de LBP öznitelikleri ile başarılı bir performans sergilemiştir. Ayrıca, her iki veri kümesi senaryosu için, 500 ağaçtan oluşan RF sınıflandırıcısı diğer sınıflandırıcılara göre üstün gelmiştir.



Şekil 5.7. HOG ve LBP ile duyarlılık ölçütü [150]

Şekil 5.8.'te farklı yöntem bölümleri için duyarlılık başarımlarını ölçütü açısından en yüksek performanslar gösterilmektedir.




Şekil 5.8. Farklı yöntem bölümleri için duyarlılık ölçütü [150]

Şekil 5.8.'deki bahsi geçen bölümler sırasıyla CNN mimarileri (optimize edilmemiş CNN, CNN/GA ve CNN/PSO), HOG öz nitelikleri ile beslenen kanonik sınıflandırıcılar, LBP HOG öz nitelikleri ile beslenen kanonik sınıflandırıcılar, geleneksel öz nitelikler ile beslenen kanonik sınıflandırıcılar, CNN/GA mimarisinden elde edilen öz niteliklerle beslenen LSTM/BILSTM mimarileri ve CNN/GA mimarilerinin ve kanonik sınıflandırıcıların kullanıldığı çoğunluk oylaması bölümleridir. Dengeli veri kümesinde CNN/PSO (10 popülasyon büyüklüğü ve 10 iterasyon ile), diğer öz nitelik çıkarma yöntemlerinden ve sınıflandırıcılardan daha yüksek performans göstermiştir. En düşük performans, geleneksel öz niteliklerin kNN ($k = 5$) sınıflandırılmasıyla elde edilmiştir.

Dengesiz veri kümesinde en yüksek performans, HOG öznitelikleri kullanılarak 500 ağaçlı RF sınıflandırıcısıyla elde edilmiştir. Öte yandan, geleneksel özniteliklerle beslenen 50 ağaca sahip bir RF sınıflandırıcısı en düşük performansı vermiştir. Her iki veri kümesi için, farklı sınıflandırıcılara girdi olarak verilen geleneksel öznitelikler, diğer öznitelik çıkarma yöntemleriyle rekabet edememiştir. RF sınıflandırıcısı, dengesiz veri kümesinde duyarlılık ölçütü açısından HOG öznitelikleri üzerinde başarılı bir performans göstermiştir. Dengesiz veri kümesinde, CNN/GA (100 popülasyon büyüklüğü ve 10 jenerasyon) ile HOG öznitelikleriyle beslenen SVM (4. derece polinomiyal çekirdek fonksiyonu), kNN (k=11), RF (500 ağaç) ve NB (kernel dağılımı) sınıflandırıcıları üzerinde yapılan çoğunluk oylaması yöntemi duyarlılık ölçütüne göre ikinci sırada yer almıştır. CNN/GA'nın (50 popülasyon büyüklüğü ve 10 jenerasyon ile) beşinci maksimum havuzlama katmanı tarafından üretilen öznitelikleri kullanan BILSTM mimarisi, optimize edilmemiş CNN mimarisi ile birlikte dengeli veri kümesinde ikinci sırada yer almıştır. Son olarak, veri kümesi dengeli hale getirildiğinde tüm öznitelik çıkarma yöntemleri ve sınıflandırıcılar için duyarlılık performansı azalmıştır.

Farklı yöntem bölümleri için ortalama Kappa performansı Şekil 5.9'da gösterilmektedir.



Şekil 5.9. Farklı yöntem bölümleri için ortalama Kappa değeri [150]

Şekil 5.9.'a göre dengeli veri kümesinde en yüksek performans çoğunluk oylama bölümü ile elde edilmiştir ve performans dengesiz veri kümesinden daha yüksektir. Aynı durum CNN/PSO, CNN/GA, HOG öznitelikleri ve geleneksel öznitelikler için de geçerlidir.

Öte yandan, dengesiz veri kümesinde LBP öznitelikleri ve LSTM / BILSTM mimarileri için elde edilen performans, dengeli veri kümesinde elde edilen performansa göre daha yüksek çıkmıştır.

Önerilen CNN mimarisinin hiper parametreleri olan beş evrimsel katmandaki filtre boyutu ve evrimsel katmanlarda üretilen öznitelik haritası sayısı kullanılan GA ve PSO üst-sezgisel optimizasyon algoritmaları için Tablo 5.27.'de verilmiştir.

Bağımsız testler (blind test) 50 tane femur boyun kırığına sahip ve 50 tane de normal femur içeren toplam 100 adet anteroposterior PXR görüntüsü üzerinde yapılmıştır. Dengeli ve dengesiz veri kümeleriyle eğitilip oluşturulan modeller (CNN/GA (50 10)), (CNN/PSO (10 10)) ve (CNN/GA (50 10)+LSTM) üzerinde bağımsız test kümesi denenerek AUC başarımlar ölçütü üzerinden performansları elde edilmiştir. Sonuçlar Tablo 5.28.'de verilmiştir.

Tablo 5.27. GA ve PSO ile elde edilen CNN hiper parametreleri

Yöntem	Popülasyon büyüklüğü	Dengesiz veri kümesi	Dengeli veri kümesi
		Filtre boyutu	Filtre boyutu
		Öznitelik haritası sayısı	Öznitelik haritası sayısı
GA	10	4 10 4 9 23	3 5 16 7 5
		88 54 81 69 118	95 124 50 15 13
GA	50	3 4 10 10 15	4 3 18 17 14
		18 122 117 80 79	55 110 55 34 58
GA	100	3 10 24 9 24	3 4 16 7 24
		111 123 114 56 73	36 97 28 127 115
PSO	10	4 2 3 4 2	4 6 2 6 2
		66 128 127 110 27	9 51 128 84 83
PSO	50	10 4 8 5 2	3 2 7 4 2
		8 102 74 98 91	32 107 97 124 33
PSO	100	8 2 2 5 2	2 8 9 6 2
		35 128 128 106 18	8 8 61 128 8

Tablo 5.28. Bağımsız testler için AUC performansları

Yöntem	AUC skoru	
	Dengesiz veri kümesi	Dengeli veri kümesi
CNN/GA (50 10)	0.661	0.708
CNN/PSO (10 10)	0.756	0.749
CNN/GA (50 10) + LSTM	0.652	0.708

Tablo 5.28.'den de görülebileceği üzere, dengesiz ve dengeli veri kümeleri ile eğitilip oluşturulan modeller üzerinde en yüksek AUC skoru CNN/PSO mimarisi ile elde edilmiştir. CNN/GA ve CNN/GA+LSTM mimarilerinde dengeli veri kümesi ile oluşturulan modeller üzerinde AUC skoru, dengesiz veri kümesi ile oluşturulan modellerden daha yüksek çıkmıştır. Bu durumun aksine CNN/PSO mimarisinde, dengeli veri kümesi ile oluşturulan model üzerinde elde edilen AUC skoru dengesiz veri kümesi ile oluşturulan model üzerinde elde edilen AUC skorundan daha düşüktür. CNN/GA mimarisine LSTM mimarisinin eklenmesi bağımsız testlerde dengesiz veri kümesi için AUC skorunda azalmaya neden olurken dengeli veri kümesi için bir iyileştirme sağlanmadığı görülmüştür.

5.3.2. Femur kırığı sınıflandırması için analiz sonuçları

Femur kırığı sınıflandırması çalışmasında hazır CNN mimarileri ile deneyler yürütülmüştür. Geçerleme testleri ile bağımsız testlerde kullanılacak eniyileycilerin belirlenmesi sağlanmıştır. Bağımsız testlerde Kappa başarımları ölçütü üzerinden en yüksek değere sahip hazır CNN mimarisinin iki farklı evrimsel katmanından elde edilen öznelilikler kanonik makine öğrenme sınıflandırıcılarını beslemek için kullanılmıştır. Geçerleme testleri ile belirlenen eniyileyciler ve elde edilen sonuçlar Tablo 5.29.'da verilmiştir.

Tablo 5.29. Sınıflandırma için geçerleme testleri

Mimari	Eniyileyici	Eğitim süresi	Kappa	Acc	MCC	Macro F ₁
GoogLeNet	Sgdm	1 dak. 30 sn.	0.85	0.9	0.851	0.732
ResNet18	Adam	1 dak. 5 sn.	0.85	0.9	0.851	0.735
ResNet50	Sgdm	2 dak. 4 sn.	0.825	0.883	0.835	0.712
ResNet101	Sgdm	6 dak. 57 sn.	0.8	0.867	0.801	0.655
DenseNet201	Adam	32 dak. 27 sn.	0.825	0.883	0.825	0.691
VGG16	Sgdm	2 dak. 6 sn.	0.775	0.85	0.77	0.62
VGG19	Sgdm	2 dak. 38 sn.	0.85	0.9	0.853	0.736

Tablo 5.29. devam ediyor

Inceptionv3	Sgdm	5 dak. 40 sn.	0.8	0.867	0.801	0.657
Inception ResNetv2	Adam	28 dak. 42 sn.	0.8	0.867	0.802	0.661
AlexNet	Sgdm	25 sn.	0.725	0.817	0.738	0.572
SqueezeNet	Adam	53 sn.	0.7	0.8	0.705	0.513

Tablo 5.29.'a göre eğitim süresi en kısa olan hazır mimari 25 saniye ile AlexNet'tir. Bunun sebebi AlexNet mimarisinin diğer mimarilere göre katman sayısının az olmasıdır. Kappa katsayısı ve doğruluk başarımları ölçütleri üzerinden en yüksek performansa GoogLeNet, ResNet18 ve VGG19 mimarileri ile ulaşılmıştır. Sonuçlara göre Kappa değeri bütün hazır CNN mimarileri için 0.4'ün üzerinde çıktığından her mimari, sınıflandırıcı güvenilirliği açısından başarılıdır. MCC ve Macro F₁ başarımları ölçütleri açısından en yüksek değer VGG19 mimarisi kullanılarak elde edilmiştir.

Geçerleme testleri sonucunda üç farklı sınıf (normal, femur boyun kırığı ve femur intertrokanterik kırık) için elde edilen hem bire karşı hepsi (1 vs All) hem de bire karşı bir (1 vs 1) yöntemleri kullanılarak hesaplanmış AUC skoru performansları Tablo 5.30.'da verilmiştir.

Tablo 5.30. Geçerleme testleri AUC skorları

Yöntem	AUC (1 vs All)			AUC (1 vs 1)		
	Normal	Boyun	İnter.	Normal vs Boyun	Normal vs İnter.	Boyun vs İnter.
GoogLeNet	0.971	0.96	0.969	0.965	0.998	0.968
ResNet18	0.999	0.979	0.983	0.988	1	0.975
ResNet50	0.981	0.916	0.953	0.975	0.995	0.912
ResNet101	0.954	0.965	0.991	0.965	1	0.988
DenseNet201	0.972	0.952	0.951	0.965	0.988	0.95
VGG16	0.955	0.958	0.978	0.953	0.978	0.978
VGG19	0.98	0.986	0.97	0.993	0.985	0.978
Inceptionv3	0.971	0.946	0.968	0.97	0.998	0.953
Inception ResNetv2	0.961	0.958	0.951	0.97	0.985	0.95
AlexNet	0.989	0.907	0.975	0.98	0.998	0.912
SqueezeNet	0.963	0.908	0.93	0.975	0.962	0.887

Tablo 5.30.'a göre bire karşı hepsi yöntemi kullanılarak elde edilen en yüksek AUC skoru performansları, normal sınıfı için ResNet18 mimarisi ile, femur boyun kırığı sınıfı için VGG19 mimarisi ile, femur intertrokanterik kırık için ise ResNet101 mimarisi ile elde

edilmiştir. Bire karşı bir yöntemi ile elde edilen en yüksek AUC skoru performanslarına normal ve boyun kırığı karşılaştırmasında VGG19 mimarisi ile, normal ve intertrokanterik kırık karşılaştırmasında ResNet18 ve ResNet101 mimarileri ile, boyun kırığı ve intertrokanterik kırık karşılaştırmasında ise ResNet101 mimarisi ile ulaşılmıştır.

Geçerleme testleri sonucunda üç farklı sınıf için elde edilen kesinlik, duyarlılık ve F_1 skoru başarımlar ölçütleri performansları tüm hazır CNN mimarileri için Tablo 5.31.'de verilmiştir.

Tablo 5.31. Geçerleme testleri kesinlik, duyarlılık ve F_1 skorları

Yöntem	Normal			Boyun			İntertrokanterik		
	Kes.	Duy.	F_1	Kes.	Duy.	F_1	Kes.	Duy.	F_1
GoogLeNet	0.944	0.85	0.895	0.857	0.9	0.878	0.905	0.95	0.927
ResNet18	1	0.9	0.947	0.85	0.85	0.85	0.864	0.95	0.905
ResNet50	1	0.9	0.947	0.938	0.75	0.833	0.769	1	0.87
ResNet101	0.944	0.85	0.895	0.81	0.85	0.829	0.857	0.9	0.878
DenseNet201	0.85	0.85	0.85	0.857	0.9	0.878	0.947	0.9	0.923
VGG16	0.783	0.9	0.837	0.889	0.8	0.842	0.895	0.85	0.872
VGG19	0.826	0.95	0.884	0.944	0.85	0.895	0.947	0.9	0.923
Inceptionv3	0.9	0.9	0.9	0.773	0.85	0.81	0.944	0.85	0.895
Inception ResNetv2	0.81	0.85	0.829	0.818	0.9	0.857	1	0.85	0.919
AlexNet	0.769	1	0.87	0.762	0.8	0.781	1	0.65	0.788
SqueezeNet	0.792	0.95	0.864	0.813	0.65	0.722	0.8	0.8	0.8

Tablo 5.31.'e göre normal sınıfı için en yüksek kesinlik ve F_1 skoru performansları ResNet18 ve ResNet50 mimarileri ile, en yüksek duyarlılık performansı ise AlexNet mimarisi ile elde edilmiştir. Boyun sınıfı için en yüksek kesinlik performansı VGG19 mimarisi ile, en yüksek duyarlılık performansı GoogLeNet, DenseNet201 ve InceptionResNetv2 mimarileri ile, en yüksek F_1 skoru performansı ise VGG19 mimarisi ile elde edilmiştir. İntertrokanterik sınıfı için en yüksek kesinlik performansı InceptionResNetv2 ve AlexNet mimarileri ile, en yüksek duyarlılık performansı ResNet50 ile, en yüksek F_1 skoru performansı ise GoogLeNet mimarisi ile elde edilmiştir.

Tüm hazır mimariler kullanılarak yapılan bağımsız testlerin Kappa, doğruluk, MCC ve Macro F_1 başarımlar ölçütleri üzerinden performansları Tablo 5.32'de verilmiştir.

Tablo 5.32. Sınıflandırma için bağımsız testler

Mimari	Kappa	Acc	MCC	Macro F_1
GoogLeNet	0.8	0.867	0.811	0.675
ResNet18	0.75	0.833	0.754	0.595
ResNet50	0.775	0.85	0.776	0.616
ResNet101	0.775	0.85	0.784	0.63

Tablo 5.32. devam ediyor

DenseNet201	0.8	0.867	0.804	0.664
VGG16	0.775	0.85	0.779	0.621
VGG19	0.775	0.85	0.777	0.621
Inceptionv3	0.7	0.8	0.711	0.519
Inception ResNetv2	0.8	0.867	0.804	0.664
AlexNet	0.8	0.867	0.81	0.67
SqueezeNet	0.825	0.883	0.828	0.696

Tablo 5.32.'ye göre bağımsız testlerde Kappa, doğruluk, MCC ve Macro F₁ başarımları ölçütleri üzerinden en yüksek performansı SqueezeNet mimarisi sergilemiştir. SqueezeNet'in geçerleme testlerinde düşük bağımsız testlerde yüksek performans sergilemesinin eğitim aşamasında diğer hazır mimarilere göre daha az ezberleme yaptığını göstermektedir.

Bağımsız testler sonucunda üç farklı sınıf (normal, femur boyun kırığı ve femur intertrokanterik kırık) için elde edilen hem bire karşı hepsi (1 vs All) hem de bire karşı bir (1 vs 1) yöntemleri kullanılarak hesaplanmış AUC skoru performansları Tablo 5.33.'de verilmiştir.

Tablo 5.33. Bağımsız testler için AUC skorları

Yöntem	AUC (1 vs All)			AUC (1 vs 1)		
	Normal	Boyun	İnter.	Normal vs Boyun	Normal vs İnter.	Boyun vs İnter.
GoogLeNet	0.979	0.963	0.961	0.978	0.98	0.97
ResNet18	0.978	0.969	0.972	0.97	0.985	0.98
ResNet50	0.986	0.928	0.956	0.975	0.958	0.915
ResNet101	0.978	0.933	0.958	0.965	0.99	0.955
DenseNet201	0.971	0.95	0.975	0.97	0.99	0.97
VGG16	0.98	0.954	0.962	0.97	0.985	0.953
VGG19	0.972	0.959	0.969	0.96	0.988	0.968
Inceptionv3	0.983	0.853	0.924	0.955	0.998	0.86
Inception ResNetv2	0.99	0.96	0.989	0.982	0.998	0.968
AlexNet	0.978	0.931	0.972	0.958	0.998	0.965
SqueezeNet	0.948	0.923	0.944	0.944	0.955	0.965

Tablo 5.33.'e göre bire karşı hepsi yöntemi kullanılarak elde edilen en yüksek AUC skoru performansları, normal ve intertrokanterik kırık sınıfları için InceptionResNetv2 mimarisi ile, boyun sınıfı için ise ResNet18 mimarisi ile elde edilmiştir. Bire karşı bir

yöntemi ile elde edilen en yüksek AUC skoru performanslarına, normal ve boyun kırığı karşılaştırmasında InceptionResNetv2 mimarisi ile, normal ve intertrokanterik kırık karşılaştırmasında Inceptionv3, InceptionResNetv2 ve AlexNet mimarileri ile, boyun kırığı ve intertrokanterik kırık karşılaştırmasında ise ResNet18 mimarisi ile ulaşılmıştır.

Bağımsız testler sonucunda üç farklı sınıf için elde edilen kesinlik, duyarlılık ve F_1 skoru başarımların ölçütleri performansları tüm hazır CNN mimarileri için Tablo 5.34.'te verilmiştir.

Tablo 5.34. Bağımsız testler için kesinlik, duyarlılık ve F_1 skorları

Yöntem	Normal			Boyun			İntertrokanterik		
	Kes.	Duy.	F_1	Kes.	Duy.	F_1	Kes.	Duy.	F_1
GoogLeNet	0.769	1	0.87	1	0.75	0.857	0.895	0.85	0.872
ResNet18	0.773	0.85	0.81	0.773	0.85	0.81	1	0.8	0.889
ResNet50	0.95	0.95	0.95	0.773	0.85	0.81	0.833	0.75	0.79
ResNet101	0.769	1	0.87	0.882	0.75	0.811	0.941	0.8	0.865
DenseNet201	0.826	0.95	0.884	0.81	0.85	0.829	1	0.8	0.889
VGG16	0.792	0.95	0.864	0.882	0.75	0.811	0.895	0.85	0.872
VGG19	0.783	0.9	0.837	0.842	0.8	0.821	0.944	0.85	0.895
Inceptionv3	0.826	0.95	0.884	0.846	0.55	0.667	0.75	0.9	0.818
Inception ResNetv2	0.792	0.95	0.864	0.842	0.8	0.821	1	0.85	0.919
AlexNet	0.769	1	0.87	0.938	0.75	0.833	0.944	0.85	0.895
SqueezeNet	0.826	0.95	0.884	0.941	0.8	0.865	0.9	0.9	0.9

Tablo 5.34.'e göre normal sınıfı için en yüksek kesinlik ve F_1 skoru performansları ResNet50 mimarisi ile, en yüksek duyarlılık performansı ise GoogLeNet, ResNet101 ve AlexNet mimarileri ile elde edilmiştir. Boyun sınıfı için en yüksek kesinlik performansı GoogLeNet mimarisi ile, en yüksek duyarlılık performansı ResNet18, ResNet50 ve DenseNet201 mimarileri ile, en yüksek F_1 skoru performansı ise SqueezeNet mimarisi ile elde edilmiştir. İntertrokanterik sınıf için en yüksek kesinlik performansı ResNet18, DenseNet201 ve InceptionResNetv2 mimarileri ile, en yüksek duyarlılık performansı Inceptionv3 ve SqueezeNet mimarileri ile, en yüksek F_1 skoru performansı ise InceptionResNetv2 mimarisi ile elde edilmiştir.

Bağımsız testlerde Kappa, doğruluk, MCC ve Macro F_1 başarımların ölçütleri üzerinden en yüksek değerlere ulaşan SqueezeNet mimarisinin ağ parametre güncellemesi yapmayan (dondurulan) ilk on katmanından sonraki ilk ve son evrimsel katmanlarından otomatik olarak elde edilen öz nitelikler ile RF, kNN, NB ve SVM kanonik sınıflandırıcıları beslenerek eğitilmiş ve oluşturulan modeller üzerinde bağımsız testler gerçekleştirilmiştir. Geçerleme

testlerinde ve bağımsız testlerde Kappa katsayısı başarımlar ölçütü üzerinden elde edilen sonuçlar Tablo 5.35.'te verilmiştir. Geçerleme testlerinde sadece Kappa değerini maksimize eden parametreye sahip kanonik sınıflandırıcılar gösterilmiştir.

Tablo 5.35. Kanonik sınıflandırıcıların performansı

Yöntem	SqueezeNet katmanı	Kappa	
		Geçerleme testi	Bağımsız test
RF (150 ağaç)	İlk	0.45	0.25
RF (100 ağaç)	Son	0.975	0.775
kNN (k=3)	İlk	0.35	0.1
kNN (k=3)	Son	0.925	0.675
NB (Normal)	İlk	0.375	-0.025
NB (KDE)	Son	0.875	0.775
SVM (lineer)	İlk	0.575	0.375
SVM (5. derece)	Son	1	0.75

Tablo 5.35.'e göre SqueezeNet mimarisinin ilk on katmanı dışında kalan katmanlar içerisindeki son evrimsel katmandan elde edilen öznelikler kanonik sınıflandırıcılara girdi olarak sağlandığında, ilk evrimsel katmana göre daha yüksek değerler elde edilmiştir. Geçerleme testlerinde en yüksek değere 5. derece polinomial çekirdek fonksiyonu kullanan SVM mimarisi ile ulaşılrken, bağımsız testlerde en yüksek değere 100 ağaçtan oluşan RF ve kernel yoğunluk tahmini kullanan NB sınıflandırıcıları ile ulaşılmıştır.

Bağımsız test sonuçlarında en yüksek Kappa katsayısı değerine ulaşan RF ve NB sınıflandırıcılarının diğer başarımlar ölçütleri üzerinden performansları ile SqueezeNet mimarisi ile edilen performans karşılaştırmalı olarak Tablo 5.36.'da verilmiştir.

Tablo 5.36. Kanonik sınıflandırıcılar ile SqueezeNet karşılaştırması (1)

Mimari	Kappa	Acc	MCC	Macro F ₁
SqueezeNet	0.825	0.883	0.828	0.696
RF	0.775	0.85	0.776	0.613
NB	0.775	0.85	0.779	0.623

Tablo 5.36.'ya göre tüm başarımlar ölçütleri üzerinden en yüksek performansa SqueezeNet mimarisi ile erişilmiştir. Kappa ölçütünün temsil ettiği sınıflandırıcı güvenilirliği açısından kanonik mimariler başarılı sayılsa da SqueezeNet mimarisinden %5 daha düşük bir performans sergilemiştir.

Kanonik sınıflandırıcılar ile bağımsız testler sonucunda üç farklı sınıf (normal, femur boyun kırığı ve femur intertrokanterik kırık) için elde edilen, hem bire karşı hepsi (1 vs All) hem de bire karşı bir (1 vs 1) yöntemleri kullanılarak hesaplanmış AUC skoru performansları SqueezeNet mimarisinin performansı ile karşılaştırmalı olarak Tablo 5.37.'de verilmiştir.

Tablo 5.37. Kanonik sınıflandırıcılar ile SqueezeNet karşılaştırması (2)

Yöntem	AUC (1 vs All)			AUC (1 vs 1)		
	Normal	Boyun	İnter.	Normal vs Boyun	Normal vs İnter.	Boyun vs İnter.
SqueezeNet	0.948	0.923	0.944	0.944	0.955	0.965
RF	0.955	0.895	0.962	0.925	0.985	0.938
NB	0.925	0.875	0.863	0.921	0.945	0.881

Tablo 5.37.'ye göre bire karşı hepsi yöntemi kullanılarak elde edilen en yüksek AUC skoru performansları normal ve femur intertrokanterik kırık sınıfları için RF sınıflandırıcısı ile, femur boyun kırığı sınıfı için ise SqueezeNet mimarisi ile elde edilmiştir. Bire karşı bir yöntemi ile elde edilen en yüksek AUC skoru performanslarına, normal ve boyun kırığı karşılaştırmasında SqueezeNet mimarisi ile, normal ve intertrokanterik kırık karşılaştırmasında RF sınıflandırıcısı ile, boyun kırığı ve intertrokanterik kırık karşılaştırmasında ise yine SqueezeNet mimarisi ile ulaşılmıştır.

Kanonik sınıflandırıcılar ile bağımsız testler sonucunda üç farklı sınıf için elde edilen kesinlik, duyarlılık ve F1 skoru başarımlar ölçütleri performansları SqueezeNet mimarisinin performansı ile karşılaştırmalı olarak Tablo 5.38.'de verilmiştir

Tablo 5.38. Kanonik sınıflandırıcılar ile SqueezeNet karşılaştırması (3)

Yöntem	Normal			Boyun			İntertrokanterik		
	Kes.	Duy.	F ₁	Kes.	Duy.	F ₁	Kes.	Duy.	F ₁
SqueezeNet	0.826	0.95	0.884	0.941	0.8	0.865	0.9	0.9	0.9
RF	0.864	0.95	0.905	0.833	0.75	0.789	0.85	0.85	0.85
NB	0.826	0.95	0.884	0.81	0.85	0.829	0.938	0.75	0.833

Tablo 5.38.'e göre normal sınıfı için en yüksek kesinlik ve F₁ skoru değerlerine RF sınıflandırıcısı ile, en yüksek duyarlılık değerine ise SqueezeNet mimarisi ve her iki kanonik

sınıflandırıcı ile ulaşılmıştır. Femur boyun kırığı sınıfı için en yüksek kesinlik ve F_1 skoru değerleri SqueezeNet mimarisi ile, en yüksek duyarlılık değeri ise NB sınıflandırıcısı ile elde edilmiştir. Femur intertrokanterik sınıfı için en yüksek kesinlik değerine NB sınıflandırıcısı ile, en yüksek duyarlılık ve F_1 skoru değerlerine ise SqueezeNet mimarisi ile ulaşılmıştır.



6. SONUÇ

Bu çalışmada derin öğrenme ve kanonik makine öğrenme yöntemleri kullanılarak femur boyun kırığı tespiti ve femur kırığı sınıflandırması problemlerine çözüm aranmıştır. Femur boyun kırığı tespiti çalışmasında sıfırdan bir CNN mimarisi tasarlanarak kanonik makine öğrenme yöntemlerinin sonuçlarıyla karşılaştırmalar yapılmıştır. Kanonik sınıflandırıcıları beslemek için geleneksel öznitelikler, HOG ve LBP öznitelikleri kullanılmıştır. Önerilen CNN mimarisinin hiper parametrelerini optimize etmek için GA ve PSO üst-sezgisel optimizasyon algoritmaları mimariye dahil edilmiştir. Femur kırığı sınıflandırması çalışmasında on bir hazır CNN mimarisi mevcut veri kümesi ile eğitilerek karşılaştırılmış, en yüksek performansın elde edildiği mimarinin ürettiği öznitelikler kanonik sınıflandırıcı beslemek için kullanılmıştır.

Femur boyun kırığı tespiti üzerine yapılan önceki çalışmalar hazır CNN mimarilerini kullanmışlar dolayısıyla sıfırdan bir mimari önermemişlerdir. Bunun sebebi başka bir problem uzayında oluşturulan mimarilerin yeni bir problem uzayına transfer öğrenme yöntemiyle uyarlanabilmesidir. Ayrıca transfer öğrenme yöntemi ile eğitim süreci sonunda modelin oluşturulmasında kullanılacak olan veri kümesinin boyutunun binlerce örneklemden oluşmasına da gerek kalmamaktadır. Hazır mimarilerin kullanılmasıyla CNN'leri besleyecek medikal görüntülerin de mimarilerin girdi katmanının kabul ettiği spesifik boyutlarda hazırlanması gerekmektedir. Dolayısıyla medikal görüntülerin boyutlarının performansı nasıl etkileyeceğine dair bir araştırma fırsatı kalmamaktadır. Buna ek olarak hazır mimarilerde evrimsel katmanlardaki filtre boyutları ve buralarda oluşturulan öznitelik haritası sayısı da kabul edilip direkt kullanıldığı için bu hiper parametrelerin modelin performansına nasıl katkı sunacağı bilinmemektedir.

Femur boyun kırığı tespiti çalışmasında literatüre üç ana başlık altında katkı yapıldığı düşünülmektedir. Birinci katkı sıfırdan tasarlanan CNN mimarisinin başarımlı ölçütleri üzerinden performansının veri kümesindeki görüntü boyutlarına göre nasıl değiştiğinin ortaya konmasıdır. Tez çalışması kapsamında dört farklı girdi boyutu için önerilen CNN mimarisi ile deneyler yapılmış ve sınıflandırıcı güvenilirliği açısından en yüksek değere 50x50 piksel çözünürlükteki X-ışını görüntüleriyle ulaşıldığı ortaya konmuştur. İkinci ve en önemli katkı ise önerilen CNN mimarisinde kullanılacak olan evrimsel katman sayısı ve evrimsel katmanlarda üretilecek öznitelik haritası sayısının optimize edilmesidir. Çalışmamız femur boyun kırığı tespitinde üst-sezgisel optimizasyon yöntemleri

kullanılarak, önerilen bir CNN mimarisinin hiper parametrelerini optimize etmek için yapılan ilk çalışmadır. Üst-sezgisel optimizasyon yöntemlerinin optimal çözümün bulunmasını garanti etmediği bilinmektedir. Tez çalışmasında üst-sezgisel optimizasyon yöntemleri olarak GA ve PSO kullanılmıştır. Dengesiz veri kümesinde geçerleme testleri ile elde edilen sonuçlara göre GA ve PSO yöntemlerinin kullanılması sınıflandırıcı güvenilirliği açısından sırasıyla %3,6 ve %4,4 performans artışı sağlamıştır. Dengeli veri kümesinde ise PSO yönteminin uygulanması ile sınıflandırıcı güvenilirliği açısından %4,6 performans artışı sağlanırken GA yönteminin uygulanması ile herhangi bir performans artışı elde edilememiştir. GA ile optimize edilen CNN mimarisinin çeşitli evrimsel katmanlarında otomatik olarak üretilen öznitelikler LSTM mimarisine girdi olarak verilmiş ve dengesiz veri kümesinde sınıflandırıcı güvenilirliği açısından, önerilen orijinal CNN mimarisine göre %5,7; CNN/GA mimarisine göre ise %1,3 performans artışı sağlanmıştır. Dengeli veri kümesi ile yapılan deneylerde LSTM ve BILSTM mimarileri herhangi bir performans artışı sağlayamamıştır. Bütün deneylerin sonuçları ışığında dengesiz veri kümesi için sınıflandırıcı güvenilirliği açısından en yüksek performansa CNN/GA ve LSTM mimarileri ile, dengeli veri kümesi için ise CNN/PSO mimarisi ile ulaşılmıştır. Dikkat çekici bir nokta da dengeli ve dengesiz veri kümeleri kullanılarak CNN mimarisi GA ve PSO ile optimize edildiğinde duyarlılık ve özgüllük başarımları ölçütleri üzerinden her ikisinin performansından da ödün verilmeden artış sağlanmasıdır. Ters bir duruma, kanonik makine öğrenme sınıflandırıcılarından RF ile dengesiz veri kümesinde en yüksek duyarlılık performansına özgüllük performansından ödün verilip erişilmesi örnek gösterilebilir. Bu durum da CNN mimarisinde evrimsel filtre boyutu ve öznitelik haritası sayısının iki önemli hiper parametre olduğunu kanıtlamaktadır. GA ve PSO yöntemleri arasında bir karşılaştırma yapılması gerekirse PSO yönteminin çalışmak için GA yöntemine göre daha az parametreye ihtiyaç duyduğu söylenebilir. Üçüncü katkı, X-ışını görüntülerinden manuel olarak elde edilen HOG ve LBP özniteliklerinin kanonik sınıflandırıcıları beslemek için kullanılmasıdır. Dengesiz ve dengeli veri kümeleri kullanılarak yürütülen deneylerde sınıflandırıcı güvenilirliği açısından başarılı olarak sayılabilecek sınıflandırıcılar HOG özniteliklerini girdi olarak alan kNN, SVM ve RF'dir. NB'nin başarısız olmasının nedeni bu sınıflandırıcının ön kabul olarak öznitelik vektöründeki her elemanın birbirinden bağımsız olduğunu varsaymasına bağlanabilir. Dengesiz veri kümesinde SVM orijinal CNN mimarisi ile aynı performansa sahip iken kNN orijinal CNN mimarisinden %2 daha fazla performansa sahiptir. Fakat bu durum üst-sezgisel optimizasyon yöntemleri kullanılarak aşılmıştır. Dengeli veri kümesinde ise hiçbir kanonik sınıflandırıcı orijinal CNN mimarisinin

performansını yakalayamamıştır. HOG dışında manuel olarak elde edilen LBP ve geleneksel öznitelikler ile yürütülen deneyler sonucunda bu öznitelikler ile beslenen kanonik sınıflandırıcıların sınıflandırıcı güvenilirliği açısından başarısız olduğu ortaya konmuştur. HOG özniteliklerinin kullanılmasıyla başarılı sonuçlar elde edilmesinin nedeni geometrik ve fotometrik dönüşümlerden etkilenmemesine ve görüntülerdeki kenar ve köşe gibi düşük seviye öznitelikleri çıkarabilme başarısına bağlanabilir.

CNN mimarileri ile kanonik sınıflandırıcıların sonuçlarının çoğunluk oylamasına tabi tutulmasıyla performans artışı sağlayıp sağlamayacağından yola çıkılarak dengesiz ve dengeli veri kümeleri üzerinde deneyler yürütülmüştür. Deney sonuçlarına göre dengesiz ve dengeli veri kümelerinde, CNN/GA ve kanonik sınıflandırıcıların yer aldığı çoğunluk oylaması yöntemi CNN/GA mimarisinin performansını sırasıyla %1 ve %1,9 artırmıştır. Elde edilen sonuçlara göre derin öğrenme mimarileri ile kanonik sınıflandırıcıların beraber kullanıldığında performansı artırabileceği ortaya konmuştur.

Dengesiz ve dengeli veri kümeleriyle oluşturulan modeller üzerinde bağımsız veri kümesi ile deneyler yürütülmüştür. Bağımsız testlerde AUC skoru başarımlı ölçütü üzerinden en yüksek performansa CNN/PSO mimarisi ile ulaşılmıştır. CNN/GA ve LSTM mimarilerinin de AUC skoru performansları rastgele sınıflandırıcı performansından yüksek çıkmıştır. Başta CNN/PSO mimarisi olmak üzere yukarıda bahsi geçen diğer mimariler de femur boyun kırığı tespitinde kullanılabilir durumdadır.

Femur kırığı sınıflandırması çalışmasında hazır CNN mimarileri kullanılmıştır. Farklı problem uzayları için eğitilen bu mimariler transfer öğrenme yöntemi ile femur kırığının sınıflandırılması problemine uyarlanarak, hazır CNN mimarilerinin eğitim aşamasında kullanılan on binlerce görüntüye göre oldukça az, üç yüz X-ışını görüntüsü ile tekrar eğitilmiştir. On bir farklı hazır CNN mimarisi ile yapılan geçerleme testleri ile modelin oluşturulmasında kullanılacak eniyileyci belirlenmiştir. Geçerleme testlerinde bütün hazır CNN mimarileri sınıflandırıcı güvenilirliği açısından yüksek performans sergilemiştir. Geçerleme testleriyle belirlenen eniyileyciler ile birlikte hazır CNN mimarileri tekrar eğitilerek modeller oluşturulmuştur. Bağımsız testlerin sonucunda sınıflandırıcı güvenilirliği, doğruluk, MCC ve Makro F_1 başarımlı ölçütleri üzerinden en yüksek performansa SqueezeNet mimarisi ile ulaşılmıştır. SqueezeNet mimarisinin ağ parametresi güncellemesi yapmayan ilk on katmanı dışında kalan katmanlardaki ilk ve son evrimsel katmanlardan elde edilen öznitelikler kanonik sınıflandırıcıları beslemek için kullanılmıştır. Elde edilen deney sonuçlarına göre sınıflandırıcı güvenilirliği açısından en yüksek performansı RF ve NB sınıflandırıcıları gösterirken SqueezeNet mimarisinin performansının

%5 gerisinde kalmıştır. Buna karşın kanonik sınıflandırıcıların hazır bir CNN mimarisinin evrışimsel katmanlarından elde edilen öznitelikler ile beslendiğinde sınıflandırıcı güvenilirliği ve AUC skoru performansları bazında başarılı olabileceği ortaya konmuştur. SqueezeNet mimarisi son evrışimsel katmanında yüksek seviye öznitelikleri diğer bir deyişle femur kırığını temsil edebilecek öznitelikleri ortaya çıkararak kanonik sınıflandırıcıların da yüksek performans gösterebilmelerini sağlamıştır.

Tez çalışmasında ortaya konan yöntemler özellikle küçük yerleşimlerdeki uzman hekime sahip olmayan sağlık kuruluşlarında hastanın röntgeni hemen çekildikten sonra ön bilgi vermesi açısından faydalı olacaktır. Hasta tam teşekküllü bir sağlık kuruluşuna sevk edilirken uzman hekime hastadan önce ulaştırılacak yapay zekanın ön teşhisi sayesinde uzman hekim son teşhisi koyabilecek ve yapılacak müdahaleyi planlayabilecektir. Doğru teşhisin konması hem uzman hekimin iş yükünü azaltacak hem de yapay zeka tarafından konulan ön teşhis sayesinde ikinci bir görüşe sahip olacağı için yanlış teşhis koyma olasılığını azaltacaktır. Doğru teşhisin konulması sayesinde doğru bir tedavi yöntemi izlenecektir. Yanlış teşhisin yol açacağı tedavi masrafları ve geçen zaman azalacak ve hastanın yaşam kalitesi korunabilecektir.

Gelecek çalışmalarda, bu tez kapsamında kullanılan gözetimli makine öğrenme yöntemlerinin başarımlarını ölçütleri üzerinden performanslarıyla karşılaştırılması için gözetimsiz ve pekiştirmeli öğrenme yöntemlerinin kullanılması düşünülmektedir. Hazır CNN mimarilerinin evrışimsel katmanlarındaki filtre boyutunun ve öznitelik haritası sayısının da hangi kriterlere göre seçildiği bilinmemektedir. Bu tez kapsamında filtre boyutu ve öznitelik haritası sayısı hiper parametrelerinin seçilmesi için kullanılan GA ve PSO başta olmak üzere diğer üst-sezgisel optimizasyon yöntemlerinin de kullanılarak hazır CNN mimarileri ile elde edilen performansın artırılması planlanmaktadır. Benzer şekilde RNN ve AE gibi derin öğrenme mimarilerinin hiper parametrelerinin sonuçları nasıl etkilediği ve hangi kriterlere ve kabullere göre seçildiği üzerine kırık tespiti ve sınıflandırması alanında bir çalışma bulunmamaktadır. Yapılacak çalışmalar ile literatürdeki bu boşluğun doldurulması düşünülmektedir. Mevcut çalışmalar eldeki PXR, MRI veya CT görüntüleri üzerinden kırık veya kırık değil tahminine, kırık var ise kırığın tipinin tahminine odaklanmıştır. Görüntü üzerinden kırığa yatkınlık değeri hesaplayan bir çalışma bulunmamaktadır. Bu nedenle verilen görüntüyü kullanarak ilgili kemiğin kırılma olasılığını hesaplayacak bir regresyon çalışmasının yürütülmesi planlanmaktadır.

KAYNAKLAR

- [1] O. Ş. Atik, “There is an association between sarcopenia, osteoporosis, and the risk of hip fracture,” *Eklem Hastalik Cerrahisi*, vol.30, no.1, pp. 1, 2019, doi: 10.5606/ehc.2019.001.
- [2] H. H. Bozkurt, M. A. Tokgöz, A. Yapar, and O. Ş. Atik, “What is the importance of canal-to-diaphysis ratio on osteoporosisrelated hip fractures?,” *Eklem Hastalik Cerrahisi*, vol.30, no.3, pp. 296-300, 2019.
- [3] W. D. Leslie, S. O'Donnell, S. Jean, C. Lagacé, P. Walsh, C. Bancej, S. Morin, D. A. Hanley, and A. Papaioannou, “Trends in hip fracture rates in Canada,” *JAMA*, vol. 302, no. 8, pp. 883-889, 2009.
- [4] E. M. Lewiecki, N. C. Wright, J. R. Curtis, E. Siris, R. F. Gagel, K. G. Saag, A. J. Singer, P. M. Steven, and R. A. Adler, “Hip fracture trends in the United States, 2002 to 2015.” *Osteoporos Int.*, vol. 29, no. 3, pp. 717-722, 2018.
- [5] H. H. Bozkurt, O. Ş. Atik, M. A. Tokgöz, “Can distal radius or vertebra fractures due to low-energy trauma be a harbinger of a hip fracture?,” *Eklem Hastalik Cerrahisi*, vol. 29, no. 2, pp. 100-103, 2018.
- [6] J. P. Grimes, P. M. Gregory, H. Noveck, M. S. Butler, and J. L. Carson, “The effects of time-to-surgery on mortality and morbidity in patients following hip fracture,” *Am J Med*, vol. 112, no. 9, pp. 702-709, 2002.
- [7] S. Dominguez, P. Liu, C. Roberts, M. Mandell, and P. B. Richman, “Prevalence of traumatic hip and pelvic fractures in patients with suspected hip fracture and negative initial standard radiographs--a study of emergency department patients,” *Acad Emerg Med*, vol. 12, no. 4, pp. 366-369, 2005.
- [8] A. D. Perron, M. D. Miller, and W. J. Brady, “Orthopedic pitfalls in the ED: radiographically occult hip fracture,” *Am J Emerg Med*, vol. 20, no.3, pp. 234-237, 2002.

- [9] H. Rehman, R. G. Clement, F. Perks, and T. O. White, "Imaging of occult hip fractures: CT or MRI?," *Injury*, vol. 47, no. 6, pp. 1297-1301, 2016.
- [10] S. Beyaz, "A brief history of artificial intelligence and robotic surgery in orthopedics & traumatology and future expectations," *Jt Dis Relat Surg.*, vol. 31, no. 3, pp. 653-655, 2020.
- [11] A. Esteva, B. Kuprel, R. A. Novoa, J. Ko, S. M. Swetter, H. M. Blau, and S. Thrun, "Dermatologist level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, pp. 115-118, 2017.
- [12] N. Habib, M. Hasan, M. Reza, and M. M. Rahman, "Ensemble of CheXNet and VGG-19 feature extractor with random forest classifier for pediatric pneumonia detection," *SN Computer Science*, vol. 1, no. 359, 2020, doi: 10.1007/s42979-020-00373-y.
- [13] J. -G. Le, S. Jun, Y.-W. Cho, H. Lee, G. B. Kim, J. B. Seo, and N. Kim, "Deep learning in medical imaging: general overview," *Korean J Radiol.*, vol. 18, no. 4, pp. 570-584, 2017.
- [14] J. Olczak, N. Fahlberg, A. Maki, A. S. Razavian, A. Jilert, A. Stark, O. Sköldenberg, and M. Gordon, "Artificial intelligence for analyzing orthopedic trauma radiographs," *Acta Orthop.*, vol. 88, no. 6, pp. 581-586, 2017.
- [15] V. Gulshan, L. Peng, M. Coram, M. C. Stumpe, et al., "Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs," *JAMA*, vol. 316, no. 22, pp. 2402-2410, 2016.
- [16] A. Tang, R. Tam, A. Cadrin-Chenevert, W. Guest, et al., "Canadian association of radiologists white paper on artificial intelligence in radiology," *Can Assoc Radiol J.*, vol. 69, no. 2, pp. 120-135, 2018.
- [17] P. Lakhani and B. Sundaram, "Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks," *Radiology*, vol. 284, no. 2, pp. 574-582, 2017.
- [18] Y. D. Pranata, K. -C. Wang, J. -C. Wang, I. Idram, J. -Y. Lai, J. -W. Liu, and I. -H. Hsieh, "Deep learning and SURF for automated classification and detection of

calcaneus fractures in CT images,” *Comput Methods Programs Biomed.*, vol. 171, pp. 27-37, 2019, doi: 10.1016/j.cmpb.2019.02.006.

- [19] Q. Li, L. Zhong, H. Huang, H. Liu, et al., “Auxiliary diagnosis of developmental dysplasia of the hip by automated detection of Sharp's angle on standardized anteroposterior pelvic radiographs,” *Medicine (Baltimore)*, vol. 98, no. 52, 2019, doi: 10.1097/MD.00000000000018500.
- [20] S. W. Chung, S. S. Han, J. W. Lee, K. -S. Oh, N. R. Kim, J. P. Yoon, J. Y. Kim, S. H. Moon, J. Kwon, H. -J. Lee, Y. -M. Noh, and Y. Kim, “Automated detection and classification of the proximal humerus fracture by using deep learning algorithm,” *Acta Orthop.*, vol. 89, no.4, pp. 468-473, 2018.
- [21] A. Borjali, A. F. Chen, O. K. Muratoğlu, M. A. Morid, and K. M. Varadarajan, “Detecting total hip replacement prosthesis design on plain radiographs using deep convolutional neural network,” *J Orthop Res.*, vol. 38, no. 7, pp. 1465-1471, 2020.
- [22] D. G. Steele and C. A. Bramblett, *The Anatomy and Biology of the Human Skeleton*. College Station, TX, USA: Texas A&M University Press, 1988.
- [23] M. E. Müller, P. Koch, S. Nazarian, and J. Schatzker, *The Comprehensive Classification of Fractures of Long Bones*. Berlin, Germany: Springer-Verlag Berlin Heidelberg, 1990.
- [24] Gökhan Özkazanlı, “*Femur Kırıklarında LISS Uygulamaları ve sonuçlarımız*,” Uzmanlık tezi, T.C. Sağlık Bakanlığı Taksim Eğitim ve Araştırma Hastanesi Ortopedi ve Travmatoloji Kliniği, İstanbul, Türkiye, 2008.
- [25] R. Mittal and S. Banerjee, “Proximal femoral fractures: Principles of management and review of literature,” *J Clin Orthop Trauma.*, vol. 3, no. 1, pp. 15-23, 2012, doi: 10.1016/j.jcot.2012.04.001.
- [26] K. M. Fox, J. Magaziner, J. R. Hebel, J. E. Kenzora, and T. M. Kashner, “Intertrochanteric versus femoral neck fractures: differential characteristics, treatment, and sequelae,” *J Gerontol A Biol Sci Med Sci.*, vol. 54, no. 12, pp. 635-640, 1999, doi: 10.1093/gerona/54.12.m635.

- [27] J. L. Guyton, "Fractures of hip, acetabulum, and pelvis," in *Campbell's Operative Orthopaedics*, S. T. Canale and J. H. Beaty, Eds., Philadelphia, PA, USA: Mosby/Elsevier, 2008.
- [28] M. Bhandari, P. J. Devereaux, P. Tornetta, M. F. Swiontkowski, et al., "Operative management of displaced femoral neck fractures in elderly patients. An international survey," *J Bone Jt Surg.*, vol. 87, no. 9, pp. 2122-2130, 2005.
- [29] M. J. Goldacre, S. E. Roberts, and D. Yeates, "Mortality after admission to hospital with fractured neck of femur: database study," *BMJ.*, vol. 325, no. 7369, pp. 868-869, 2002.
- [30] M. Bhandari, P. Tornetta, B. Hanson, and M. F. Swiontkowski, "Optimal internal fixation for femoral neck fractures: multiple screws or sliding hip screws?," *J Orthop Trauma.*, vol. 23, no. 6, pp. 403-407, 2009.
- [31] M. J. Heetveld, C. Rogmark, F. Frihagen, and J. Keating, "Internal fixation versus arthroplasty for displaced femoral neck fractures: what is the evidence?," *J Orthop Trauma.*, vol. 23, no. 6, pp. 395-402, 2009.
- [32] C. Grimsrud, R. J. Monzon, J. Richman, and M. D. Ries, "Cemented hip arthroplasty with a novel circlage technique for unstable intertrochanteric hip fractures," *J Arthroplasty.*, vol. 20, no. 3, pp. 337-343, 2005.
- [33] K. J. Koval and J. D. Zuckerman, "Hip fractures: II. evaluation and treatment of intertrochanteric fractures," *J Am Aca Orthop Surg.*, vol. 2, no. 3, pp. 150-156, 1994.
- [34] O. Johnell and J. Kanis J, "Epidemiology of osteoporotic fractures," *Osteoporos Int.*, vol. 16, no. Suppl. 2, pp. 3-7, 2005, doi: 10.1007/s00198-004-1702-6.
- [35] P. Sambrook and C. Cooper, "Osteoporosis," *Lancet*, vol. 367, no. 9527, pp. 2010-2018, 2006.
- [36] J. C. Gallagher, L. J. Melton, B. L. Riggs, and E. Bergstrath, "Epidemiology of fractures of the proximal femur in Rochester, Minnesota," *Clin Orthop Relat Res.*, vol. 150, pp. 163-71, 1980.

- [37] M. R. Karagas, G. L. Lu-Yao, J. A. Barrett, M. L. Beach, and J. A. Baron, "Heterogeneity of hip fracture: age, race, sex, and geographic patterns of femoral neck and trochanteric fractures among the US elderly," *Am J Epidemiol.*, vol. 143, no. 7, pp. 677-82, 1996.
- [38] C. L. Loizou and M. J. Parker, "Avascular necrosis after internal fixation of intracapsular hip fractures; a study of the outcome for 1023 patients," *Injury*, vol. 40, no. 11, pp. 1143-1146, 2009.
- [39] O. Filipov, "Epidemiology and social burden of the femoral neck fractures," *J IMAB.*, vol. 20, no.4, pp. 516-518, 2014.
- [40] M. Berglund-Röden M, B. A. Swierstra, H. Wingstrand, and K. G. Thorngren, "Prospective comparison of hip fracture treatment. 856 cases followed for 4 months in The Netherlands and Sweden," *Acta Orthop Scand.*, vol. 65, no. 3, pp. 287-294, 1994.
- [41] K. Y. Chiu, T. P. Ng, S. P. Chow, "Seasonal variation of fractures of the hip in elderly persons," *Injury*, vol. 27, no. 5, pp. 333-336, 1996.
- [42] [J. R. Crawford and M. J. Parker, "Seasonal variation of proximal femoral fractures in the United Kingdom," *Injury*, vol. 34, no. 3, pp. 223-225, 2003.
- [43] J. A. Kanis, O. Johnell, A. Oden, I. Sembo, I. Redlund-Johnell, A. Dawson, C. De Laet, and B. Jonsson, "Long-term risk of osteoporotic fracture in Malmö," *Osteoporosis Int.*, vol. 11, no. 8, pp. 669-674, 2000.
- [44] P. A. Allfram, "An epidemiological study of cervical and trochanteric fractures of the femur in an urban population. Analysis of 1,664 cases with special reference to etiologic factors," *Acta Orthop Scand Suppl.*, vol. 65, pp. 1-109, 1964.
- [45] E. S. Fisher, J. A. Baron, D. J. Malenka, J. A. Barrett, W. D. Kniffin, F. S. Whaley, T. A. Bubolz, "Hip fracture incidence and mortality in New England", *Epidemiology*, vol. 2, no. 2, pp. 116-122, 1991.
- [46] S. C. Gallannaugh, A. Martin, and P. H. Millard, "Regional survey of femoral neck fractures", *Br Med J.*, vol. 2, no. 6050, pp. 1496-1497, 1976.

- [47] D. K. Dhanwal, E. M. Dennison, N. C. Harvey, and C. Cooper, "Epidemiology of hip fracture: worldwide geographic variation," *Indian J Orthop.*, vol. 45, no. 1, pp. 15-22, 2011.
- [48] L. J. Melton, C. S. Crowson, and W. M. O'Fallon, "Fracture incidence in Olmsted County, Minnesota: comparison of urban with rural rates and changes in urban rates over time," *Osteoporos Int.*, vol. 9, no. 1, pp. 29-37, 1999.
- [49] B. Abrahamsen and P. Vestergaard, "Declining incidence of hip fractures and the extent of use of anti-osteoporotic therapy in Denmark 1997-2006," *Osteoporos Int.*, vol. 21, no. 3, pp. 373-380, 2010.
- [50] E. Lonnroos, H. Kautiainen, P. Karppi, T. Huusko, S. Hartikainen, S. I. Kiviranta, and R. Sulkava, "Increased incidence of hip fractures. A population-based study in Finland," *Bone*, vol. 39, no. 3, pp. 623-627, 2006.
- [51] U. Bergstrom, H. Jonsson, Y. Gustafson, U. Pettersson, H. Stenlund, and O. Svensson, "The hip fracture incidence curve is shifting to the right," *Acta Orthop.*, vol. 80, no. 5, pp. 520-524, 2009.
- [52] B. -H. Yoon, Y. -K. Lee, S. -C. Kim, S. -H. Kim, Y. -C. Ha, and K. -H. Koo, "Epidemiology of proximal femoral fractures in South Korea," *Arch Osteoporos.*, vol. 8, 2013, doi: 10.1007/s11657-013-0157-9.
- [53] B. Unim, G. Minelli, R. Da Cas, V. Manno, F. Trotta, L. Palmieri, L. Galluzzo, S. Maggi, and G. Onder, "Trends in hip and distal femoral fracture rates in Italy from 2007 to 2017," *Bone*, vol. 142, 2021, doi: 10.1016/j.bone.2020.115752.
- [54] S. Tüzün, N. Eskiuyurt, U. Akarırnak, M. Sarıdoğan, M. Şenocak, H. Johansson, and J. A. Kanis, "Incidence of hip fracture and prevalence of osteoporosis in Turkey: the FRACTURK study," *Osteoporos Int.*, vol. 23, no. 3, pp. 949-955, 2012.
- [55] M. Butier, R. Norton, T. Lee-Joe, A. Cheng, and A. J. Campbell, "The risk of hip fracture in older people from private homes and institutions," *Age Ageing*, vol. 25, no. 5, pp. 381-385, 1996.

- [56] L. I. Hansson, L. Ceder, K. Svensson, and K. G. Thorngren, "Incidence of fractures of the distal radius and proximal femur: comparison of patients in a mental hospital and the general population," *Acta Orthop Scand.*, vol. 53, no. 5, pp. 721-726, 1982.
- [57] R. Ganz, J. Parvizi, M. Beck, M. Leunig, H. Nötzli, and K. A. Siebenrock, "Femoroacetabular impingement: a cause for osteoarthritis of the hip," *Clin Orthop Relat Res.*, vol. 417, pp. 112-120, 2003, doi: 10.1097/01.blo.0000096804.78689.c2.
- [58] M. Beck, M. Leunig, E. Clarke, and R. Ganz, "Femoroacetabular impingement as a factor in the development of nonunion of the femoral neck: a report of three cases," *J Orthop Trauma.*, vol. 18, no. 7, pp. 425-430, 2004.
- [59] M. Goldin, C. N. Anderson, M. Fredericson, M. R. Safran, and K. J. Stevens, "Femoral neck stress fractures and imaging features of femoroacetabular impingement," *PM R.*, vol. 7, no. 6, pp. 584-592, 2015, doi: 10.1016/j.pmrj.2014.12.008.
- [60] P. Kannus, J. Parkkari, H. Sievanen, A. Heinonen, I. Vuori, and M. Järvinen, "Epidemiology of hip fractures," *Bone*, vol. 18, no. 1 Suppl., pp. 57-63, 1996.
- [61] N. Shi, K. Foley, G. Lenhart, and E. Badamgarav, "Direct healthcare costs of hip, vertebral, and non-hip, non-vertebral fractures," *Bone*, vol. 45, no. 6, pp. 1084-1090, 2009.
- [62] O. Johnell, "The socioeconomic burden of fractures: today and in the 21st century," *Am J Med.*, vol. 103, no. 2A, pp. 20-26, 1997.
- [63] R. Burge, B. Dawson-Hughes, D. H. Solomon, J. B. Wong, A. King, and A. Tosteson, "Incidence and economic burden of osteoporosis-related fractures in the United States 2005-2025," *J Bone Miner Res.*, vol. 22, no. 3, pp. 465-475, 2007.
- [64] N. Zhu, D. Zhang, W. Wang, X. Li, et al., "A novel coronavirus from patients with pneumonia in China, 2019," *N Engl J Med.*, vol. 382, no. 8, pp. 727-733, 2020.
- [65] World Health Organization. Coronavirus disease 2019 (COVID-19) situation report-51, Mar. 11, 2020. Accessed: Apr. 21, 2020. [Online]. Available: https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200311-sitrep-51-covid19.pdf?sfvrsn=1ba62e57_10

- [66] Q. Li, X. Guan, P. Wu, X. Wang, et al., “Early transmission dynamics in Wuhan, China, of novel coronavirus-infected pneumonia,” *N Engl J Med.*, vol. 382, no. 13, pp. 1199-1207, 2020.
- [67] J. M. M. Vives, M. Jornet-Gibert, J. Cámara-Cabrera, P. L. Esteban, L. Brunet, L. Delgado-Flores, P. Camacho-Carrasco, P. Torner, F. Marcano-Fernández, and Spanish HIP-COVID Investigation Group, “Mortality rates of patients with proximal femoral fracture in a worldwide pandemic: Preliminary results of the Spanish HIP-COVID observational study,” *J Bone Joint Surg Am.*, vol. 102, no. 13 – p. e69, 2020, doi: 10.2106/JBJS.20.00686.
- [68] C. Vannabouathong, T. Devji, S. Ekhtiari, Y. Chang, S. A. Phillips, M. Zhu, Z. Chagla, C. Main, and M. Bhandari, “Novel coronavirus COVID-19: current evidence and evolving strategies,” *J Bone Joint Surg Am.*, vol. 102, no. 9, pp. 734-744, 2020.
- [69] D. Giannoulis, G. M. Calori, and P. V. Giannoudis, “Thirty-day mortality after hip fractures: has anything changed?,” *Eur J Orthop Surg Traumatol.*, vol. 26, no. 4, pp. 365-370, 2016.
- [70] M. -J. Pueyo-Sánchez, M. Larrosa, X. Suris, E. Casado, J. Auleda, J. Fusté and V. Ortún, “Secular trend in the incidence of hip fracture in Catalonia, Spain, 2003-2014,” *Age Ageing*, vol. 46, no. 2, pp. 324-328, 2017.
- [71] L. Mattisson, A. Bojan, and A. Enocson, “Epidemiology, treatment and mortality of trochanteric and subtrochanteric hip fractures: data from the Swedish Fracture Register,” *BMC Musculoskelet Disord.*, vol. 19, no. 1, 2018, doi: 10.1186/s12891-018-2276-3.
- [72] J. D. Chlebeck, C. E. Birch, M. Blankstein, T. Kristiansen, C. S. Bartlett, and P. C. Schottel, “Nonoperative geriatric hip fracture treatment is associated with increased mortality: a matched cohort study,” *J Orthop Trauma.*, vol. 33, no. 7, pp. 346-350, 2019.
- [73] W. -J. Guan, Z. -Y. Ni, Y. Hu, W. -H. Liang, et al., and China Medical Treatment Expert Group for Covid-19, “Clinical characteristics of coronavirus disease 2019 in China,” *N Engl J Med.*, vol. 382, no. 18, pp. 1708-1720, 2020.

- [74] F. Zhou, T. Yu, R. Du, G. Fan, Y. Liu, Z. Liu, J. Xiang, Y. Wang, B. Song, X. Gu, L. Guan, Y. Wei, H. Li, X. Wu, J. Xu, S. Tu, Y. Zhang, H. Chen, and B. Cao, "Clinical course and risk factors for mortality of adult inpatients with COVID-19 in Wuhan, China: a retrospective cohort study," *Lancet*, vol. 395, no. 10229, pp. 1054-1062, 2020.
- [75] A. Maier, S. Steidl, V. Christlein, and J. Hornegger, *Medical Imaging Systems: An Introductory Guide*. Cham, Switzerland: Springer International Publishing, 2018.
- [76] T. P. Tian, "Detection of femur fractures in X-ray images," Master's thesis, National University of Singapore, Singapore, 2002.
- [77] S. E. Lim, Y. Xing, Y. Chen, W. K. Leow, T. S. Howe, and M. A. Png, "Detection of femur and radius fractures in X-ray images," in *Proc. 2nd Int. Conf. on Advances in Medical Signal and Information Processing*, Malta, Sept. 5-8, 2004, pp. 249-56.
- [78] V. L. F. Lum, W. K. Leow, Y. Chen, T. S. Howe, and M. A. Png, "Combining classifiers for bone fracture detection in X-ray images," in *IEEE International Conference on Image Processing*, Genova, Italy, 2005, pp. 1149-52.
- [79] J. C. He, W. K. Leow, and T. S. Howe, "Hierarchical classifiers for detection of fractures in X-ray images," in *Computer Analysis of Images and Patterns*, W. G. Kropatsch, M. Kampel, and A. Hanbury, Eds., Berlin, Germany: Springer-Verlag Berlin Heidelberg, 2007, pp. 962-969.
- [80] S. Mahendran and S. S. Baboo, "An enhanced tibia fracture detection tool using image processing and classification fusion techniques in X-ray images," *Global Journal of Computer Science and Technology*, vol. 11, no. 14, pp. 23-28, 2011.
- [81] M. Al-Ayyoub and D. Al-Zghool, "Determining the type of long bone fractures in X-ray images," *WSEAS Transactions on Information Science and Applications*, vol. 10, no. 8, pp. 261-270, 2013.
- [82] S. Al-Helo, R. S. Alomari, S. Ghosh, V. Chaudhary, Gu. Dhillon, M. B. Al-Zoubi, H. Hiary, and T. M. Hamtini, "Compression fracture diagnosis in lumbar: a clinical CAD system," *Int J Comput Assist Radiol Surg.*, vol. 8, no. 3, pp. 461-469, 2013.

- [83] V. V. Avinash, J. D. Prakash, R. Swathika, and T. S. Sree, "Detection and Classification of Long Bone Fractures," *International Journal of Applied Engineering Research*, vol. 10, no. 20, pp. 18315-18320, 2015.
- [84] Fatih Bayram and Murat Çakıroğlu, "DIFFRACT: DIaphyseal Femur FRActure Classifier SysTem", *Biocybernetics and Biomedical Engineering*, vol. 36, no. 1, pp. 157-171, 2016.
- [85] J. Yao, J. E. Burns, H. Muñoz, and R. M. Summers, "Cortical shell unwrapping for vertebral body abnormality detection on computed tomography," *Computerized Medical Imaging and Graphics*, vol. 38, no. 7, pp. 628-638, 2014.
- [86] A. M. Tripathi, A. Upadhyay, A. S. Rajput, A. P. Singh, and B. Kumar, "Automatic detection of fracture in femur bones using image processing," in *2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS)*, Coimbatore, India, Mar. 17-18, 2017, pp. 1-5.
- [87] C. M. A. K. Z. Basha, M. Padmaja, and G. N. Balaji, "Computer aided fracture detection system," *J Med Imaging Health Inform.*, vol. 8, no. 1, pp. 526-531, 2018.
- [88] K. Dimililer, "IBFDS: Intelligent bone fracture detection system," *Procedia Computer Science*, vol. 120, pp. 260-267, 2017.
- [89] P. K. Mall, P. K. Singh, and D. Yadav, "GLCM based feature extraction and medical X-ray image classification using machine Learning techniques," in *2019 IEEE Conference on Information and Communication Technology*, Allahabad, India, 2019, pp. 1-6.
- [90] Y. Cao, H. Wang, M. Moradi, P. Prasanna, and T. F. Syeda-Mahmood, "Fracture detection in x-ray images through stacked random forests feature fusion," in *2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI)*, Brooklyn, NY, USA, 2015, pp. 801-805.
- [91] R. Lindsey, A. Daluiski, S. Chopra, A. Lachapelle, M. Mozer, S. Sicular, D. Hanel, M. Gardner, A. Gupta, R. Hotchkiss, and H. Potter, "Deep neural network improves

- fracture detection by clinicians,” *Proc Natl Acad Sci U S A.*, vol. 115, no. 45, pp. 11591-11596, 2018.
- [92] T. Urakawa, Y. Tanaka, S. Goto, H. Matsuzawa, K. Watanabe, and N. Endo, “Detecting intertrochanteric hip fractures with orthopedist level accuracy using a deep convolutional neural network,” *Skeletal Radiol.* vol. 48, no. 2, pp. 239-244, 2018.
- [93] M. Adams, W. Chen, D. Holcldorf, M. W. McCusker, P. D. Howe, and F. Gaillard, “Computer vs human: Deep learning versus perceptual training for the detection of neck of femur fractures,” *J Med Imaging Radiat Oncol.*, vol. 63, no. 1, pp. 27-32, 2019.
- [94] C. -T. Cheng, T. -Y. Ho, T. -Y. Lee, C. -C. Chang, C. -C. Chou, C. -C. Chen, I. -F. Chung, and C. -H. Liao, “Application of a deep learning algorithm for detection and visualization of hip fractures on plain pelvic radiographs,” *Eur Radiol.*, vol. 29, no. 10, pp. 5469-5477, 2019.
- [95] N. Tomita, Y. Y. Cheung, and S. Hassanpour, “Deep neural networks for automatic detection of osteoporotic vertebral fractures on CT scans,” *Computers in Biology and Medicine*, vol. 98, pp. 8-15, 2018, doi: 10.1016/j.compbiomed.2018.05.011.
- [96] B. Guan, J. Yao, G. Zhang, and X. Wang, “Thigh fracture detection using deep learning method based on new dilated convolutional feature pyramid network,” *Pattern Recognition Letters*, vol. 125, pp. 521-526, 2019, doi: 10.1016/j.patrec.2019.06.015.
- [97] B. Guan, G. Zhang, J. Yao, X. Wang, and M. Wang, “Arm fracture detection in X-rays based on improved deep convolutional neural network,” *Computers & Electrical Engineering*, vol. 81, 2020, doi: 10.1016/j.compeleceng.2019.106530.
- [98] K. Gan, D. Xu, Y. Lin, Y. Shen, T. Zhang, K. Hu, K. Zhou, M. Bi, L. Pan, W. Wu, and Y. Liu, “Artificial intelligence detection of distal radius fractures: a comparison between the convolutional neural network and professional assessments,” *Acta Orthopaedica*, vol. 90, no. 4, pp. 394-400, 2019.

- [99] A. F. Hilario, S. G. López, M. Galar, R. C. Prati, B. Krawczyk, and F. Herrera, *Learning from Imbalanced Data Sets*. Cham, Switzerland: Springer International Publishing, 2018.
- [100] B. Krawczyk, "Learning from imbalanced data: open challenges and future directions," *Prog Artif Intell.*, vol. 5, pp. 221-232, 2016, doi: 10.1007/s13748-016-0094-0.
- [101] M. V. Joshi, "Learning classifier models for predicting rare phenomena," Ph.D. Thesis, University of Minnesota, Twin Cites, MN, USA, 2002.
- [102] M. Kubat and S. Matwin, "Addressing the curse of imbalanced training sets: One-sided selection," in *Proceedings of the 14th International Conference on Machine Learning, ICML*, Nashville, TN, USA, Jul. 08-12, 1997, pp. 179–186.
- [103] S. Beyaz, K. Açııcı, and E. Sümer, "Femur neck fracture detection in X-ray images using deep learning and genetic algorithm approaches," *Joint Diseases and Related Surgery*, vol. 31, no. 2, pp. 175-183, 2020.
- [104] M. Nixon and A. S. Aguado, *Feature Extraction & Image Processing*. 2nd ed. Orlando, FL, USA: Academic Press, Inc., 2008.
- [105] Z. F. Lai and H. F. Deng, "Medical image classification based on deep features extracted by deep model and statistic feature fusion with multilayer perceptron," *Computational Intelligence and Neuroscience*, vol. 2018, 2018, doi: 10.1155/2018/2061516.
- [106] P. Mohanaiah, P. Sathyanarayana, and L. GuruKumar, "Image texture feature extraction using GLCM approach," *International Journal of Scientific and Research Publications*, vol. 3, no. 5, pp. 1-5, 2013.
- [107] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971-987, 2002.

- [108] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, San Diego, CA, USA, Jun. 20-25, 2005, pp. 886-893.
- [109] S. Mallick. "Histogram of oriented gradients explained using openCV." LEARNOPENCV.com. <https://learnopencv.com/histogram-of-oriented-gradients/> (Accessed: May 27, 2021).
- [110] G. Dougherty, *Pattern Recognition and Classification: An Introduction*. New York, NY, USA: Springer-Verlag new York, 2013.
- [111] K. Chomboon, P. Chujai, P. Teerarassamee, K. Kerdprasop, and N. Kerdprasop, "An Empirical Study of Distance Metrics for k-Nearest Neighbor Algorithm," in *Proceedings of the 3rd International Conference on Industrial Application Engineering (ICIAE2015)*, Kitakyushu, Japan, Mar. 28-31, 2015, pp. 280-285.
- [112] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," in *Proceedings of the Fifth Annual Workshop on Computational Learning Theory (COLT'92)*, Pittsburgh, Pennsylvania, USA, Jul. 1992, pp. 144-152.
- [113] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*. 2nd ed. New York, NY, USA: Wiley, 2000.
- [114] E. Alpaydın, *Intoduction to Machine Learning*. 2nd ed. Cambridge, MA, USA: MIT Press, 2010.
- [115] L. Breiman, "Random Forests," *Machine Learning*, vol. 45, no.1, pp. 5–32, 2001.
- [116] A. Lulli, L. Oneto, and D. Anguita, "Mining big data with random forests," *Cogn Comput.*, vol. 11, pp. 294-316, 2019.
- [117] A. Verikas, A. Gelzinisi, and M. Bacauskiene, "Mining data with random forests: A survey and results of new tests," *Pattern Recognition*, vol. 44, pp.330–349, 2011.
- [118] K. Fukushima, "Neocognitron: A hierarchical neural network capable of visual pattern recognition," *Neural Networks*, vol. 1, no. 2, pp. 119–130, 1988.

- [119] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [120] D. H. Hubel and T. N. Wiesel, "Receptive fields, binocular interaction, and functional architecture in the cat's visual cortex", *J. Physiol*, vol.160, pp. 106–154, 1962.
- [121] [D. J. Felleman and D. C. V. Essen, "Distributed hierarchical processing in the primate cerebral cortex," *Cereb. Cortex*, vol. 1, pp. 1–47, 1991.
- [122] J. Bouvrie. *Notes on Convolutional Neural Networks*. (2006). Accessed: Mar. 25, 2021. [Online]. Available: http://cogprints.org/5869/1/cnn_tutorial.pdf
- [123] C. -Y. Lee, P. W. Gallagher, and Z. Tu, "Generalizing pooling functions in convolutional neural networks: mixed, gated, and tree," in *Proceedings of the 19th International Conference on Artificial Intelligence and Statistics (AISTATS) 2016*, Cadiz, Spain, May 9-11, 2016, pp. 464-472.
- [124] Y. -D. Zhang, C. Pan, J. Sun, and C. Tang, "Multiple sclerosis identification by convolutional neural network with dropout and parametric ReLU," *Journal of Computational Science*, vol. 28, pp. 1-10, 2018.
- [125] S. Ioffe and C. Szegedy, "Batch normalization: accelerating deep network training by reducing internal covariate shift," in *Proceedings of the 32nd International Conference on Machine Learning (ICML '15)*, Lille, France, Jul. 06-11, 2015, vol. 37, pp. 448-456.
- [126] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research*, vol. 15, no. 56, pp. 1929–1958, 2014.
- [127] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [128] Q. Sun, M. V. Jankovic, L. Bally, and S. G. Mougiakakou, "Predicting Blood Glucose with an LSTM and BiLSTM Based Deep Neural Network," in *14th Symposium on Neural Networks and Applications (NEUREL)*, Belgrade, Serbia, Nov. 20-21, 2018, pp. 1-5.

- [129] Ü. Budak, Z. Cömert, Z. N. Rashid, A. Şengür, and M. Çıbuk, “Computer-aided diagnosis system combining FCN and Bi-LSTM model for efficient breast cancer detection from histopathological images”, *Applied Soft Computing Journal*, vol. 85, Dec. 2019, doi: 10.1016/j.asoc.2019.105765.
- [130] J. Fagerström, M. Bång, D. Wilhelms, and M. S. Chew, “LiSep LSTM: A Machine Learning Algorithm for Early Detection of Septic Shock,” *Scientific Reports*, vol. 9, Oct. 2019, doi: 10.1038/s41598-019-51219-4.
- [131] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning internal representations by error propagation,” in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition Volume 1: Foundations*, Cambridge, MA, USA: MIT Press, 1986, pp. 318–362.
- [132] M. F. Møller, “A scaled conjugate gradient algorithm for fast supervised learning,” *Neural Networks*, vol. 6, no. 4, pp. 525-533, 1993.
- [133] B. A. Olshausen and D. J. Field, “Sparse coding with an overcomplete basis set: A strategy employed by V1?,” *Vision Research*, vol. 37, no. 23, pp. 3311-3325, 1997.
- [134] S. N. Sivanandam and S. N. Deepa, “Genetic algorithms,” in *Introduction to Genetic Algorithms*, Berlin, Germany: Springer-Verlag Berlin Heidelberg, 2008, ch. 2, pp. 15-37.
- [135] J. Kennedy and R. Eberhart, “Particle Swarm Optimization,” in *Proceedings of IEEE International Conference on Neural Networks (ICNN’95)*, Perth, WA, Australia, Nov. 27-Dec. 1, 1995, pp. 1942–1948.
- [136] R. Poli, J. Kennedy, and T. Blackwell, “Particle swarm optimization,” *Swarm Intell.*, vol. 1, pp. 33–57, 2007.
- [137] M. Kubat, *An Introduction To Machine Learning*. Cham, Switzerland: Springer International Publishing, 2015.

- [138] S. Abbaspour, F. Fotouhi, A. Sedaghatbaf, H. Fotouhi, M. Vahabi, and M. Linden, "A comparative analysis of hybrid deep learning models for human activity recognition," *Sensors*, vol. 20, no. 19:5707, 2020, doi: 10.3390/s20195707.
- [139] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," in *Advances in Neural Information Processing Systems 25*, F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, Eds. Curran Associates, Inc., 2012, pp. 1097-1105.
- [140] K. Simonyan and Andrew Zisserman, "Deep convolutional networks for large-scale image Recognition," *arXiv preprint*, arXiv:1409.1556, 2014.
- [141] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Raninovich, "Going deeper with convolutions," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, June 7-12, 2015, pp. 1-9.
- [142] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, June 27-30, 2016, pp. 770-778.
- [143] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, Jul. 21-26, 2017, pp. 2261-2269.
- [144] F. Iandola, S. Han, M. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5mb model size", *arXiv preprint*, <https://arxiv.org/abs/1602.07360>, 2016.
- [145] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception architecture for computer vision," in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, June 27-30, 2016, pp. 2818-2826.
- [146] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, "Inception-v4, Inception-ResNet and the impact of residual connections on learning," in *Proceedings of the Thirty-First*

AAAI Conference on Artificial Intelligence (AAAI'17), San Francisco, California USA, Feb. 4-9, 2017, pp. 4278-4284.

- [147] K. P. Murphy, *Machine Learning: A Probabilistic Perspective*. Cambridge, MA, USA: MIT Press, 2012.
- [148] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," in *3rd International Conference on Learning Representations, (ICLR 2015)*, San Diego, CA, USA, May 7-9, 2015.
- [149] S. H. Park, J. M. Goo, and C. -H. Jo, "Receiver operating characteristic (ROC) curve: practical review for radiologists," *Korean J Radiol.*, vol. 5, no. 1, pp. 11-18, 2004.
- [150] K. Açıcı, E. Sümer, and S. Beyaz, "Comparison of different machine learning approaches to detect femoral neck fractures in X-ray images," *Health and Technology*, vol. 11, no. 3, pp. 643-653, 2021.

EKLER



**EK 1: TEZ ÇALIŞMASI KAPSAMINDA YAYIMLANAN
MAKALELERİN VE SUNULAN BİLDİRİLERİN KÜNYELERİ**



MAKALELER

S. Beyaz , K. Açııcı, and E. Sümer, “Femur neck fracture detection in X-ray images using deep learning and genetic algorithm approaches,” *Joint Diseases and Related Surgery*, vol. 31, no. 2, pp. 175-183, 2020, (SCI-E).

K. Açııcı, E. Sümer, and S. Beyaz, “Comparison of different machine learning approaches to detect femoral neck fractures in X-ray images,” *Health and Technology*, vol. 11, pp. 643-653, 2021, (Scopus).

BİLDİRİLER

S. Beyaz, K. Açııcı, and E. Sümer, “Fracture detection in X-ray images using deep learning methods,” in *7th Congress of The Asia Pacific Trauma Society*, Bangkok, Thailand, Sep. 20-22, 2019.

S. Beyaz, K. Açııcı ve E. Sümer, “Derin öğrenme ve genetik algoritma yaklaşımları kullanılarak X-ray görüntülerinde femur boyun kırığı tespiti,” *Uluslararası Sağlıkta Yapay Zeka Kongresi*, İzmir, Türkiye, Ocak 16-18, 2020, s. 20.