



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DERİN ÖĞRENME YÖNTEMLERİ
KULLANILARAK OSTEOPOROZUN
BELİRLENMESİ

Mohamad Melad Ali ASHAMES

YÜKSEK LİSANS TEZİ

Elektrik–Elektronik Mühendisliği Anabilim Dalı

Ağustos-2020
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mohamad Melad Ali Ashames tarafından hazırlanan “Derin Öğrenme Yöntemleri Kullanılarak Osteoporozun Belirlenmesi” adlı tez çalışması 27/08/2020 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Şakir TAŞDEMİR

.....

Danışman

Doç. Dr. Murat CEYLAN

.....

Üye

Doç. Dr. Bayram AKDEMİR

.....

Yukarıdaki sonucu onaylıyorum.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Mohamad Melad Ali ASHAMES
Tarih: 27.08.2020



ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK OSTEOPOROZUN BELİRLENMESİ

Mohamad Melad Ali ASHAMES

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik - Elektronik Mühendisliği Anabilim Dalı**

Danışman: Doç. Dr. Murat CEYLAN

2020, 70 Sayfa

Jüri

**Doç. Dr. Murat CEYLAN
Prof. Dr. Şakir TAŞDEMİR
Doç. Dr. Bayram AKDEMİR**

Osteoporoz, düşük kemik mineral yoğunluğu ile karakterize edilen en yaygın kronik kemik hastalığıdır. Dual Enerji X-Işını Absorbsiyometrisi (DEXA) taraması, kemik mineral yoğunluğunu ölçmek ve osteoporoz tanısı koymak için en sık kullanılan yöntemdir. Ancak, cihazın büyüklüğü ve yüksek maliyeti gibi belirli kısıtlamaları vardır. Standart X-ışınları ve Bilgisayarlı Tomografi (BT) gibi diğer tarama yöntemleri, hastalık ortaya çıkana kadar osteoporozu belirleyemediği için teşhis amacıyla kullanılamaz. Bu çalışmada, topuk kemiğinin x-ışını görüntülerini (düz radyografiler) kullanarak osteoporoz sınıflandırması için invazif olmayan bir yöntem önerilmiştir. Evrişimsel Sinir Ağları ile Veri Arttırma teknikleri ve Transfer Öğrenme Mimarileri, sağlıklı ve osteoporotik hastaların x-ışını görüntülerini sınıflandırmak için birleştirilmiştir. Önerilen yaklaşım ile osteoporozun teşhisi yüksek doğrulukla gerçekleştirilmiştir.

Anahtar Kelimeler: Osteoporoz, Evrişimsel Sinir Ağları, Transfer Öğrenme, Veri Arttırma, X-Işını

ABSTRACT

MS THESIS

**DETERMINATION OF OSTEOPOROSIS USING DEEP LEARNING
METHODS**

Mohamad Melad Ali ASHAMES

**Konya Technical University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering**

Advisor: Doç. Dr. Murat CEYLAN

2020, 70 Pages

Jury

**Assoc. Prof. Dr. Murat CEYLAN
Prof. Dr. Şakir TAŞDEMİR
Assoc. Prof. Dr. Bayram AKDEMİR**

Osteoporosis is the most common chronic bone disease, which is characterized by low bone mineral density. Dual Energy X-Ray Absorptiometry (DEXA) scan is the most used method for measuring bone mineral density and diagnosing osteoporosis. Unfortunately, this method has certain limitations, such as the size of the device and its high cost. Other screening methods like standard X-rays and computed tomography (CT) can't detect osteoporosis until it's fully accrued. In this study, a non-invasive method for osteoporosis classification using X-ray images (plain radiographs) of the heel is proposed. Convolutional Neural Networks along with Data Augmentation techniques and Transfer Learning Architectures are combined to classify X-ray images of healthy and osteoporotic patients. With the proposed approach, diagnosis of osteoporosis has been achieved with high accuracy.

Keywords: Convolutional Neural Network, Data Augmentation, Osteoporosis, Transfer Learning, X-Ray

ÖNSÖZ

Çalışma konusunun belirlenmesinde ve çalışmanın hazırlanma sürecinin her aşamasında bilgilerini, tecrübelerini ve değerli zamanlarını esirgemeyerek bana her fırsatta yardımcı olan danışmanım Sayın Doç. Dr. Murat Ceylan'a ve manevi anlamda daima yanımda olan aileme teşekkürlerimi sunarım. Ayrıca, bu tezde kullanılan verileri paylaşan Fransa Orleans Üniversitesi Öğretim Üyesi Sayın Prof. Dr. Rachid Jennane'ye teşekkür ederim.

Mohamad Melad Ali ASHAMES
KONYA-2020



İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL VE YÖNTEM	7
3.1. Kemik Mineral Yoğunluğunu Ölçmek için Kullanılan Klinik Yöntemler	7
3.1.1. Dual X-Işını Absorbsiyometri (DEXA)	7
3.1.2. Periferik Dual X-Işını Absorbsiyometri (pDXA)	9
3.1.3. Radyografik Absorbsiyometri (RA)	9
3.1.4. Dijital X-Işını Radyogrametri (DXR)	9
3.1.5. Kantitatif Bilgisayarlı Tomografi (KBT)	10
3.1.6. Kantitatif Ultrason (KUS)	10
3.2. Kullanılan Veri	10
3.3. Önerilen Yaklaşım	11
3.4. Veri Arttırma	12
3.4.1. Geleneksel veri arttırma yöntemleri.....	14
3.4.1.1.Karşıtlık (Kontrast) İyileştirme.....	14
3.4.1.2.Parlaklık Değişirme.....	15
3.4.1.3.Keskinlik(Netlik) Değişirme	15
3.4.1.4.Döndürme	16
3.4.2.Tezde kullanılan osteoporoz verilerinin arttırılması	17
3.5. Derin Öğrenme	19
3.5.1.Evrişimsel sinir ağları	20
3.5.1.1.Evrişimsel katman.....	21
3.5.1.2.Havuzlama.....	22
3.5.1.3.Tam bağlı katmanlar	23
3.5.2.Aktivasyon fonksiyonları	24
3.5.3.Sinir ağı optimizasyonu.....	26
3.5.4.Başarım iyileştirme	27
3.5.5.Transfer öğrenme	27
3.5.5.1.Önceden eğitilmiş modelin problem göre düzenlenmesi	28
3.5.6.Transfer öğrenme mimarileri.....	29
3.5.6.1.ImageNet	30
3.5.6.2. AlexNet mimarisi.....	30
3.5.6.3. GoogleNet mimarisi	32
3.5.6.4. ResNet50 mimarisi.....	38

3.5.6.5. Inception-v3 mimarisi	41
3.5.6.6. MobileNetV2 mimarisi.....	45
3.6. Osteoporozun Sınıflandırılması için Modellerin Eğitilmesi	48
3.7. K-Katlamalı Çapraz Doğrulama	49
3.8. Performans Değerlendirmesi için Karmaşıklık Matrisi	49
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	52
4.1. Deneysel 1: Orijinal Verilerin Sınıflandırılması.....	52
4.2. Deneysel 2: AVeri Kümesinin Sınıflandırılması	53
4.3. Deneysel 3: BVeri Kümesinin Sınıflandırılması	54
4.4. Deneysel 4: CVeri Kümesinin Sınıflandırılması	54
4.5. Deneysel 5: Basit bir ESA Modelinin Sıfırdan Eğitimi	57
4.6. Deneysel 6: Maksimum (Çoğunluk) Oylama Yaklaşımı	58
4.7. Deneysel 7: 3-Katlamalı Çapraz Doğrulama.....	58
5. SONUÇLAR VE ÖNERİLER	60
5.1 Sonuçlar	60
5.2 Öneriler	62
KAYNAKLAR	64
ÖZGEÇMİŞ.....	70

SİMGELER VE KISALTMALAR

Simgeler

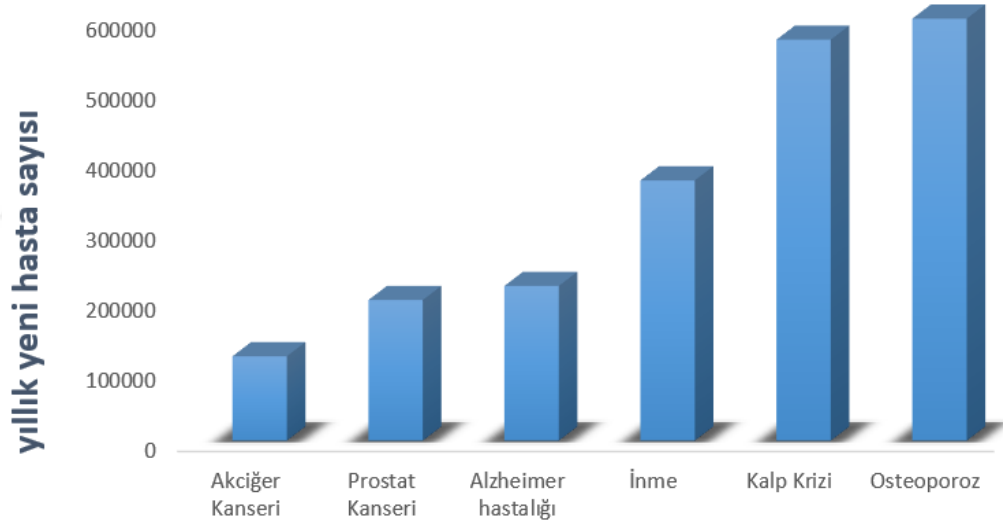
X	: Giriş
α	: Aktivasyon Fonksiyonu
σ	: Standart Sapma
Σ	: Toplama Operatörü

Kısaltmalar

1B	: 1 Boyutlu
1DLBP	: 1B Yerel İkili Desen
2B	: 2 Boyutlu
3B	: 3 Boyutlu
AF	: Aktivasyon Fonksiyonu
BT	: Bilgisayarlı Tomografi
ÇD	: Çapraz Doğrulama
ÇKA	: Çok Katmanlı Algılayıcılar
DEXA	: Dual X-Işını Absorbsiyometri
DN	: Doğru Negatif
DNO	: Doğru Negatif Oranı
Doğ	: Doğruluk
DÖ	: Derin Öğrenme
DP	: Doğru Pozitif
DPO	: Doğru Pozitif Oranı
Duy	: Duyarlılık
DVM	: Destek Vektör Makinesi
DXR	: Dijital X-ışını Radyogrametrisi
ESA	: Evrimsel Sinir Ağları
GA	: Genetik Algoritma
GİB	: Grafik İşlemci Birimi
KBT	: Kantitatif Bilgisayarlı Tomografi
KMY	: Kemik Mineral Yoğunluğu
KT	: Kontrol
KUS	: Kantitatif Ultrason
MÖ	: Makine Öğrenimi
MSGİ	: Momentum ile Stokastik Gradyan İniş
OP	: Osteoporotik
ÖEM	: Önceden Eğitilmiş Model
Özg	: Özgüllük
PDXA	: Periferik Dual X-Işını Absorbsiyometri
RA	: Radyografik Absorpsiyometri
ReLU	: Doğrultulmuş Doğrusal Ünite
Tanh	: Tanh aktivasyon fonksiyonu
TNYS	: Toplu Normalizasyon Yardımcı Sınıflandırıcı
TÖ	: Transfer Öğrenme
US	: Ultrason
YN	: Yanlış Negatif
YP	: Yanlış Pozitif

1. GİRİŞ


Osteoporoz, düşük kemik kütlesi ve kemik dokusunun mikro mimari yapısının bozulması sonucu kemik kırılabilirliğinin ve kırık olasılığının artması ile karakterize sistemik bir iskelet hastalığıdır (Christodoulou ve Cooper, 2003; Tuck ve Francis, 2002). Genellikle ilk kırık ortaya çıkana kadar hiçbir semptom ortaya çıkmamaktadır. Kemik yoğunluğundaki azalma fark edilmeyecek bir şekilde zamanla aşamalı olarak meydana gelir ve bu nedenle bazen sessiz hastalık olarak adlandırılır. Dünyada 200 milyon kişiden fazla osteoporoz hastası olduğu tahmin edilmekte, her 3 kadın ve her 5 erkekte birinde osteoporotik kırık riski bulunmaktadır (Sözen ve ark., 2017). Şekil 1.1, Amerika'da en yaygın hastalıkların arasında osteoporozun ilk sırada geldiğini göstermektedir (Binkley, 2009).



Şekil 1.1. Amerika'da karşılaşılan yaygın hastalıklar ve yıllık hasta sayısı

Osteoporoz ile ilişkili en sık görülen kırıklar kalça, omurga ve el bileğinde meydana gelmekte, özellikle kalça ve omurga kırıklarının oluşma olasılığı kadınlarda ve erkeklerde yaşla birlikte artmaktadır (Christodoulou ve Cooper, 2003; Tuck ve Francis, 2002).

Preklinik dönemde hastalık, kırık olmadan Düşük Kemik Mineral Yoğunluğu (KMY) ile karakterize edilir. Düşük kemik yoğunluğu (osteopeni), kemik yoğunluğunun normalden düşük olduğu ancak osteoporoz olarak kabul edilecek kadar düşük olmadığı durumdur. Düşük kemik yoğunluğuna sahip olan insanlar gelecekte osteoporoz hastası olabilir. Şekil 1.2'de görülebileceği gibi, kemik yoğunluğuna göre osteoporozun 3 derecesi vardır. Bunlar; osteopeni, osteoporoz ve şiddetli osteoporoz'dur (Kling ve ark., 2014; Sözen ve ark., 2017).



Şekil 1.2. Osteoporoz dereceleri (Anonymous, 2019)


Osteoporozun tanısı için düşük kemik yoğunluğu testi, Dual Enerji X-Ray Absorbsiyometri (DEXA) yöntemi ile yapılmaktadır. DEXA'nın kemik yoğunluğunu ölçmek için kullanılması Amerika'daki Ulusal Osteoporoz Vakfı (Anonymous, 2017) ve Dünya Sağlık Örgütü (DSÖ) tarafından tavsiye edilmektedir.

DEXA'nın, hastanelerde en yaygın uygulanan yöntem olmasına rağmen, cihazın büyüklüğü, yüksek maliyeti ve hastanelerde zor bulunması gibi belirli kısıtlamaları vardır. Aynı zamanda, standart X ışınları hastalık ortaya çıkana kadar osteoporozu gösteremediği için teşhis amacıyla kullanılamaz. Bununla birlikte, omurgadaki veya başka bir yerdeki kırık kemikleri tespit etmek için DEXA'ya ek olarak X ışınları kullanılabilir. Bilgisayarlı Tomografi (BT) muayenelerinde ise, BT semptomları veya belirtileri erkenden belirleyemediği için yetersiz teşhise sebep olur.

İnvaziv olmayan kemik kütlelerinde etkileyici performans gösteren Sonlu Eleman Analizi (finite element analysis FEA) kullanan fizik tabanlı modeller vardır (Allaire ve ark., 2019; Johannesdottir ve ark., 2018) Ancak bu modeller yüksek hesaplama maliyetlerinden dolayı klinik kullanım için uygun değildir.

Osteoporozun tespitindeki önemli noktalardan biri, osteoporotik ve sağlıklı bireylerin kemik mikro mimari doku görüntülerinin yüksek derecede benzerlik gösterdiği için ayırt

edilmesinin oldukça zor olmasıdır. Şekil 1.3'te, sol tarafta bir osteoporoz hastasının X-ışını görüntüsü, sağ tarafta ise sağlıklı bireyin X-ışını görüntüsü gösterilmektedir.



Şekil 1.3. (a) Osteoporotik X-ışını görüntüsü. (b) Sağlıklı X-ışını görüntüsü

Özellikle osteoartrit ve osteoporozun birlikte görüldüğü yaşlı hastalarda, bu iki ayrı hastalığın etkilediği eklemlerde (özellikle diz, kalça ve vertebral kolon bölgesi) osteoartritin ortaya konması için her bölgenin ayrı ayrı röntgeninin (osteoporozu ortaya koymak için DEXA tetkiklerinin) alınması gerekmektedir. Fakat osteoartritin genel özelliklerinden biri olan, eklem çevresinde osteofit oluşumları özellikle DEXA çekimlerinde yanlış pozitif sonuçlara sebep olmakta ve bu durum aslında osteoporotik olan bir hastanın yeterli tedaviyi alamaması ile sonuçlanmaktadır. Osteoporotik hastalarda özellikle kalça kırıkları, vertebra ve el bilek kırıkları çoğu zaman cerrahiyle tedavi edilmekte olup ileri yaşta ameliyat ve hareketsiz kalma (immobilizasyon) beraberinde akciğer embolisi gibi komplikasyonlara yol açabilmektedir.

Bu tez çalışmasının amacı, kemik mineral yoğunluğu (KMY) ölçümüne ek olarak kemik dokusunun mikro mimari yapısal özelliklerinin yapay zeka kullanılarak çıkarılması ile osteoporozun tespit edilmesidir. Buradan yola çıkarak, invasiv olmayan bir yöntem ile osteoporozun tanısını koyabilecek klinik yöntemlere destek sağlayacak sistem tasarlanabilir.

Bu tez, ilk olarak literatürdeki konu ile ilgili çalışmaların taramasının yapıldığı bölümle başlamaktadır. Sonrasında tez çalışmasında kullanılan materyal ve yöntemler detaylı bir şekilde incelenmiş ve elde edilen bulgular tartışılmıştır. Son olarak, tez çalışması sırasında elde edilen sonuçlar verilmiş ve ileride gerçekleştirilebilecek çalışmalar için öneriler sunulmuştur.

2. KAYNAK ARAŞTIRMASI

Literatürde osteoporozu tahmin etmek için farklı makine öğrenimi tekniklerini kullanan birçok çalışma vardır.

2004 yılında gerçekleştirilen bir çalışmada, kalkaneusun radyolojik görüntülerinden kemik yapısının tanımlanmasını sağlayan morfolojik bilgilerin çıkarılması için bir yöntem önerilmiştir. Bu çalışmanın ana katkısı, klasik 3D-morfolojik kemik parametrelerine yakın olan kemik tanımlayıcılarının sağlanmasına dayanmaktadır. Görüntülerde bulunan mikro-yapıların gri ölçekli iskeletin çıkarılması önerilmiştir. Uygun işlemde sonra, elde edilen iskelet osteoporotik hastalar ile kontrol hastaları arasında tanımlayıcı özellikler sağlamaktadır (Sevestre-Ghalila ve ark., 2004).

(Jennane ve ark., 2007) 2B trabeküler kemik görüntülerinden 3B benzerlik parametrelerini tahmin etmeye çalışmışlardır. Yirmi bir trabeküler kemik örneği dondurulmuş insan femur başlarından türetilmiş ve yüksek çözünürlüklü bir mikro-BT kullanılarak sayısallaştırılmıştır. Projeksiyonları, verileri üç dikey yönde toplayarak sayısal olarak simüle edilmiştir. Çalışma, basit bir projeksiyonun kemik yapısı hakkında 3B bilgi sağladığını göstermektedir. Bu bilgi, osteoporozun erken teşhisi için yardımcı olmaktadır.

Yine Jennane'nin içerisinde yer aldığı bir diğer çalışmada(Akgundogdu ve ark., 2010) artiritik ve osteoporotik kemik örneklerinin sınıflandırılması adaptif nöral bulanık girişim sistemi (ANBGS), Destek Vektör Makineleri (DVM) ve genetik algoritma (GA) ile gerçekleştirilmiştir. Sadece 18 görüntünün kullanıldığı bu çalışmada GA yöntemi en iyi performansı sunmuştur.

Çene kemiği bilgisayarlı tomografi (BT) görüntülerinin dokusal özelliklerinin curvelet dönüşümü ile çıkartıldığı ve sınıflandırıldığı bir yaklaşımda birinci dereceden istatistikî özellikler ile gerçekleştirilen sınıflama uygulaması ile bir karşılaştırma yapılmıştır (Reddy ve Kumaravel, 2010). Curvelet dönüşümü kullanıldığında sınıflama sonuçlarındaki başarının %90' lardan %95' lere çıktığı belirtilmiştir.

Osteoporozun belirlenmesi için gerçekleştirilen başka bir çalışmada ise (Jennane ve ark., 2010) görüntü işleme ve GA'yı uygulamışlardır. Trabeküler kemiğin 3B karakterizasyonu için Hibrit İskelet Grafik Analizi tekniğini kullandılar. Bu teknikte elde edilen özellikler, verilerin sınıflandırılmasına yardımcı olan önemli topolojik ve morfolojik bilgiler içermektedir.

(Houam ve ark., 2011), yüksek geçiren bantlarda dalgacık katsayıları ve bir boyutlu yerel ikili örüntüler kullanarak trabeküler kemik doku sınıflandırılması gerçekleştirmişlerdir. K-en yakın komşuluk sınıflayıcısı kullanılan çalışmada eğri altında kalan alan değeri en fazla 0.85 olarak elde edilebilmiştir.

Başka bir yaklaşımda, bilgisayarlı tomografi görüntülerinden özelliklerin çıkarılması için dalgacık dönüşümü uygulanırken, Yapay Sinir Ağları (YSA) ve DVM sınıflandırma için tercih edilmiştir. Destek Vektör Makineleri %86 doğruluk yüzdesi ile Yapay Sinir Ağları'ndan daha iyi performans göstermiştir (İstanbullu ve ark., 2012).

(Houam ve ark., 2012) kemik radiograf görüntülerine dalgacık dönüşümü ve bir boyutlu yerel ikili örüntüler kullanarak doku karakterizasyonu gerçekleştirmişlerdir. Çalışmada iki yaklaşım izlenmiştir; birincisi yerel ikili örüntüler histogramlarını karşılaştırır, ikincisi ise farklı özellik vektörleri oluşturmak için histogramlardan istatistiksel ölçümler çıkarır. Deneyler iki sınıf için gerçekleştirilmiştir; osteoporotik hasta sınıfı ve kontrol sınıfı. Sonuçlar, 2D görüntülerin 1D yansıtılan alanının iki popülasyonun sınıflandırılması için daha iyi sonuçlar elde ettiğini göstermektedir.

(Harrar ve ark., 2012) osteoporotik ve kontrol örneklerin sınıflandırılmasında Çok Katmanlı Algılayıcının (ÇKA) etkinliğini test etmiştir. Modelin doğruluğunu ve güvenilirliğini artırmak için k-katlamalı Çapraz Doğrulama (k-fold Cross Validation) kullanılmıştır. Çalışmada, topuk kemiğinin 120 X-ışını görüntüsü kullanılarak %97 doğruluğuna ulaşılmıştır

Kemik Mineral Yoğunluğu (KMY) ve mikro mimari doku analizi kombine edilerek kırılma tanımlanmasının yapıldığı bir diğer çalışma ise (Touvier ve ark., 2015) tarafından gerçekleştirilmiştir. Elde edilen sonuçlara göre eğri altında kalan alan en fazla %82 olarak belirlenmiştir. Benzer şekilde sınıflama doğruluğu da yaklaşık %70 civarındadır. Bu çalışma, kombine sistemlerin geliştirilmesine ihtiyaç duyulduğunu ortaya koymuştur.

Tafraouti ve ark., DVM tekniğinin bir sınıflandırıcı olarak kullanıldığı çalışmada X-Ray görüntülerinin fraktal analizi ile osteoporozu karakterize etmişlerdir (Tafraouti ve ark., 2014). Burada kalkaneus kemiğinin sadece 77 X-ışını görüntüsü kullanılırken, fraksiyonel Brown hareketi (fractional Brownian motion - fBm) modeli görüntülerden özellikler çıkarmak için kullanılmıştır.

(Nasser ve ark., 2017) özellik çıkarmak için bir nöral ağ modelini Yığılmış Seyrek Otoenkoder (Stacked Sparse Autoencoder - SSAE) olarak kullanırken, doğrusal bir DVM sınıflandırıcıyı osteoporoz ve kontrol olarak etiketli X-ışını görüntüleri arasında ayırım yapmak için bir sınıflandırıcı olarak kullanarak %95.5'lik bir doğruluk elde etmişlerdir.

DVM'nin en iyi performansı gösterdiği başka bir çalışmada osteoporoz / kontrol X-ışını görüntü sınıflandırıcısı olarak destek vektör makinesi (DVM), k-en yakın komşular, Naïve Bayes ve yapay sinir ağları (YSA) karşılaştırılmıştır (Singh ve ark., 2017).

(Ciuşdel ve ark., 2017) sentetik olarak üretilen süngerimsi kemik anatomilerinin geniş bir veri seti üzerinde bir evrişimli sinir ağı (ESA) modeli geliştirmişlerdir. Eğitilmiş modelin performansı, ayrı bir test veri seti üzerinde bir sonlu elemanlar analizi (FEA) modeli ile değerlendirilmiştir.

(Tomita ve ark., 2018) 1432 BT taramasında her bir dilimden radyolojik özellikleri çıkarmak için derin bir evrişimsel sinir ağının (ESA) kullanıldığı osteoporotik vertebral kırıkları tespit etmek için bir sistem geliştirirken, uzun kısa süreli bellek (UKSB) ağı ile %89.2'lik bir doğruluk elde etmişlerdir.

(Scanlan ve ark., 2018) bir hastanın tibia üzerinde test uyaranları uygulamak için bir refleks çekici ve dürtü yanıtlarını almak için elektronik stetoskop kullanmışlardır. Sinyaller katsayılar olarak işlenmiş ve tibia'nın dürtü yanıtlarından osteoporoz olasılığını belirlemek için yapay bir sinir ağına verilmiştir.

(Sela ve Pulungan, 2019), osteoporozu tanımlamak için dijital dental radyografik görüntülerdeki trabeküler alanı kullanmışlardır. %87.87 doğruluğuna ulaşan Çok Katmanlı Algılayıcı (ÇKA), istatistiksel doku analizi ile osteoporoz varlığını tahmin etmek için önerilmiştir.

X-ışını görüntülerinden osteoporozu tespit etmek için Transfer Öğrenme (TÖ) de uygulanmıştır. (Sylvia Grace ve ark., 2019) topuk kemiği verilerini sınıflandırmak için TÖ uygularken VGG16, Transfer Öğrenme Modeli olarak tercih edilmiştir. VGG16 mimarisi ile, %79.3'lik bir doğruluğa ulaşmayı başarmıştır.

VGG-16'nın dental panoramik radyografi (DPR) görüntülerinde düşük kemik yoğunluğunu tespit etmek için kullanıldığı bir başka çalışma, ince ayarlı önceden eğitilmiş VGG-16 modelinin umut verici doğruluk sonuçlarına ulaşabileceğini göstermiştir. Bu çalışmada Lee ve ark. (2020) %84 doğruluk değeri elde etmişlerdir.

3. MATERYAL VE YÖNTEM

Osteoporozun etkili bir şekilde önlenmesi için çok sayıda test uygulanması ve erken tanı yapılması gerekmektedir. Klinik olarak mevcut tanı yöntemleri temel olarak en çok X-ışınlarının ve daha sonra da ultrasonun (US) kullanımına dayanmaktadır. Tüm X-ışınını temel alan yöntemler kemik mineral yoğunluğu (KMY) ölçümü içerir. Ancak, kemiğin diğer yapısal yönlerinin, yoğunluk ölçüm tabanlı teknikler kullanılarak değerlendirilemeyen mekanik özellikler ve elastik özellikler ile kırık risklerinin belirlenmesinde önemli olduğu ifade edilmiştir (Pisani ve ark., 2013).


3.1. Kemik Mineral Yoğunluğunu Ölçmek için Kullanılan Klinik Yöntemler

Dünya Sağlık Örgütü (DSÖ), osteoporozu Dual X-Işını absorbsiyometri (DEXA) tekniği ile yapılan ölçümleri temel alarak tanımlasa da, KMY ölçümünde kullanılan başka yöntemler de mevcuttur. Bu yöntemlerin en yaygınları aşağıda verilmiştir.

3.1.1. Dual X-Işını Absorbsiyometri (DEXA)

1987'de kullanıma giren DXA veya DEXA ile KMY ölçümü osteoporozun tanımlanmasında ve değerlendirilmesinde Dünya Sağlık Örgütü (World Health Organization-WHO) tarafından altın standart olarak kabul edilmektedir ve klinik pratikte en yaygın kullanılan tekniktir.

DEXA testi sırasında, bir görüntüleme kolu hastanın vücudu üzerinde yavaşça hareket ederken düşük dozlu enerjiye sahip bir ışın demeti geçer. Şekil 3.1 DEXA cihazının çalışma mantığını göstermektedir.



Şekil 3.1. DEXA ile kemik yoğunluğu taraması (Pisani ve ark., 2013)

Kemik yoğunluğu testi sonuçları T-puanı kullanılarak teşhis edilir. T-puanı'nın hesaplanması için referans yaş, cinsiyet, ırk, iskelet bölgesi ve ölçüm birimi değerlerine karşı gelen referans KMY ve standart sapmayı (σ) gösteren bir tablo kullanılmaktadır. DEXA cihazları g/cm^2 cinsinden kemik yoğunluğunu hesaplamaktadır. T-puanı aşağıdaki formüle göre hesaplanır;

$$T\text{-puanı} = (\text{ölçülen KMY} - \text{referans KMY}) / \sigma \quad (3.1)$$

-1.0 ile -2.5 arasındaki bir T puanı, düşük kemik yoğunluğu veya osteopeni anlamına gelir. -2,5 veya daha düşük T-puanı osteoporozun varlığını gösterir. Çizelge 3.1 T-puanına göre osteoporozun teşhis edilmesini göstermektedir.

Çizelge 3.1. T-puana göre osteoporoz teşhisi

Kategori	T puanları	
	Aralık	Örnek Puan
Normal Kemik Yoğunluğu	-1 ve üstü	+0.5, 0, -1.0
Düşük kemik yoğunluğu (osteopeni)	-1 ile -2.5 arası	-1.1, -1.5, -2.4
Osteoporoz	-2.5 ve altı	-2.5, -3.0, -4.0

Diğer X-ışını tabanlı teknikler gibi, DEXA iyonlaştırıcı radyasyon kullanımı, cihazın büyük boyutu, yüksek maliyet ve hastane ve kliniklerde zor bulunması gibi belirli sınırlamalara sahiptir (Pisani ve ark., 2013). Bu sınırlamalar cihazın kullanılabilirliğini azaltır ve popülasyon taramaları için uygulanmasını engeller.

3.1.2. Periferik Dual X-ışını Absorbsiyometri (pDXA)

Periferik DXA cihazları, DXA ile aynı teknolojiyi kullanarak önkol, kalkaneus ve parmak gibi periferik bölgelerde KMY'yi ölçen aletlerdir (Sindel ve Gula, 2015). Periferik DXA ile kırık riskinin değerlendirilmesi karışık olabilir. Buna rağmen, pDXA ile ölçülmüş periferik bölgelere ait düşük T-puan değerleri artmış kırık riski ile ilişkilidir (Sindel ve Gula, 2015). Distal 1/3 yarıçap bölgesi dışında, Dünya Sağlık Örgütü (DSÖ) osteoporozun tanısı için pDXA'yı önermemektedir. Metodolojik olarak standart DXA'ya eşdeğer olan pDXA cihazlarında kullanılan ikinci enerji, değişen yumuşak doku kalınlığının düzeltilmesine izin verir (Glüer ve ark., 1997).

3.1.3. Radyografik Absorbsiyometri (RA)

Radyografik absorpsiyometri (RA), çoğunlukla el veya topuk olmak üzere periferik bölgelerin radyografilerinden kemik kütlesi ölçümü için bir tekniktir (Yates ve ark., 1995). Düşük maliyetli olması, özel ekipmana ihtiyaç duymaması, uygulanmasının kolay olması, düşük radyasyon dozu ve çocuklarda kullanılabilirliği gibi avantajları varken, kişi bağımlı olması, sadece periferik iskeleti değerlendirebilmesi ve tedaviye yanıtı değerlendirmede yetersiz oluşu gibi dezavantajları da vardır (Yates ve ark., 1995).

3.1.4. Dijital X-ışını Radyogrametri (DXR)

Dijital X-ışını radyogrametrisi (DXR), elin standart bir grafisinden kemik mineral yoğunluğunu (KMY) tahmin eden bir tekniktir. DXR, geleneksel radyogrametri tekniğinin otomatik ve dijital bir versiyonudur (Elliot ve ark., 2005; Rosholm ve ark., 2001). Elin postero-anterior grafisi dijital olarak çekilip, bilgisayarlı aktif sınırlama metodları (ASMs) ile metakarplar işaretlenir. Sistem kemiğin her santimetresinden 118 bağımsız ölçüm yaparak her alan başına kemik volümünü hesaplar (Sindel ve Gula, 2015). Kolay uygulanması, düşük maliyeti, geriye dönük filmler üzerinde değerlendirme yapabilme kapasitesi gibi avantajları vardır (Sindel ve Gula, 2015).

3.1.5. Kantitatif Bilgisayarlı Tomografi (KBT)

Kantitatif bilgisayarlı tomografi (KBT), bilgisayarlı tomografi (BT) tarayıcının, bir ped içine hastanın altına yerleştirilen katı fantomlar (kalsiyum hidroksiapatitten yapılmış, çeşitli kemik mineral yoğunluklarını temsil eden) kullanılarak kalibre edildiği bir KMY ölçüm tekniğidir. Teknik, trabeküler kemik mineral yoğunluğunu (KMY; mg / cm³) ölçmek için lomber omurgadaki 2D dilimlere yaygın olarak uygulanır. Periferik KBT (pKBT), KBT cihazının tarayıcıların periferik iskelet bölgelerinde (radyus, tibia) kemik kalitesini değerlendirmeye yönelik bir versiyonudur. KBT'nin en büyük dezavantajı, çift enerjili X-ışını absorpsiyometrisine (DEXA) kıyasla daha fazla radyasyon dozuna sahip olmasıdır (Adams, 2009).

3.1.6. Kantitatif Ultrason (KUS)

Kantitatif ultrason (KUS), yoğunluk ölçme tabanlı teknikleri kullanılarak değerlendirilemeyen kemik dokularının kemik yapısal ve elastik özelliklerini incelemek için ultrason teknolojisini kullanır. Ultrason tekniğinin zararlı radyasyon yaymamasının yanı sıra, ultrason cihazlarının DXA'ya kıyasla küçük boyut, taşınabilirlik, hızlı ve basit ölçümler, düşük maliyet ve daha kısa değerlendirme süresi gibi avantajları ilgi çekmektedir (Pisani ve ark., 2013).

3.2. Kullanılan Veri


Bu tez çalışmasında, Fransa Orleans Üniversitesi'nin I3MTO Laboratuvarında etiketlenen x-ray görüntülerinden oluşan bir veri seti kullanılmıştır. Veriler, Kasım 2004 ile Şubat 2006 tarihleri arasında Orleans Hastanesi'nde yatan 40-92 yaşları arasındaki 174 kadından kaydedilmiştir. Oluşturulmuş veritabanı, 87 osteoporotik (OP) ve 87 kontrol (KT) olarak sınıflandırılan toplam 174 görüntü içermektedir (Lespessailles ve ark., 2008).

Bu veri setinde osteoporotik olarak etiketli; kalça kırığı olan 21, bilek kırığı olan 23, ve vertebra kırığı olan 22 hasta bulunmaktadır. Geri kalan 21 hastada ise farklı kırıklar mevcuttur (Lespessailles ve ark., 2008).

Kalça ve vertebra kırıklarının görüntülerini sınıflandırmak, bu kemikleri çevreleyen yumuşak dokulardan dolayı oldukça zordur. Bu sebeple, her hastadan dijital bir X-ışını cihazı ile topuk kemiğinin (kalkaneus) görüntüleri elde edilmiştir. Topuk kemiği, sınırlı yumuşak

dokularla çevrili bir kemik olup kullanılacak modelin kararsızlığını artırabilecek yumuşak dokuların etkisini sınırlamak için seçilmiştir.


Şekil 3.2’de görüldüğü gibi, yeri belirten iki anatomik işaret kullanılarak, her grup için (osteoporotik ve kontrol) İlgi Bölgesi (ROI) tanımlanmıştır. Bir operatör, her bir görüntü üzerinde bu işaretlerin yerini belirleyerek, yazılımın ROI’yi (1,6x1,6 cm²) konumlandırmasını sağlamıştır. Görüntüler 400x400 piksel boyutundadır (Lespessailles ve ark., 2008).



Şekil 3.2. Topuk kemiğinin (kalkaneus) X-ışını görüntüsü ve ilgi bölgesi (ROI) (Jennane ve ark., 2017)

3.3. Önerilen Yaklaşım

Bu tez çalışmasında, mevcut osteoporotik (OP) / kontrol (KT) veri kümesi üzerine öznitelik çıkarmak, kullanılacak derin modellerin genelleştirilebilirliğini ve doğruluğunu arttırmak ve veri arttırmanın sınıflandırmaya etkisini gözlemlemek için farklı veri arttırma teknikleri uygulanmıştır. Elde edilen farklı veri kümeleri kullanılarak, literatürde görüntü sınıflandırmada başarılı olduğu kanıtlanmış beş farklı önceden eğitilmiş mimari ile farklı deneyler yapılarak Transfer Öğrenmenin osteoporoz sınıflandırmadaki performansı ölçülmüştür. Önerilen yaklaşım Şekil 3.3’te gösterilmektedir.



Şekil 3.3. Osteoporozun belirlenmesi için önerilen yaklaşım

3.4. Veri Arttırma

Veri arttırma, eğitim modelleri için mevcut veri çeşitliliğinin önemli ölçüde artırılmasını sağlayan bir stratejidir. Veri arttırma tekniklerinin derin sinir ağlarını eğitmek için kullanılması oldukça yaygın bir uygulamadır.

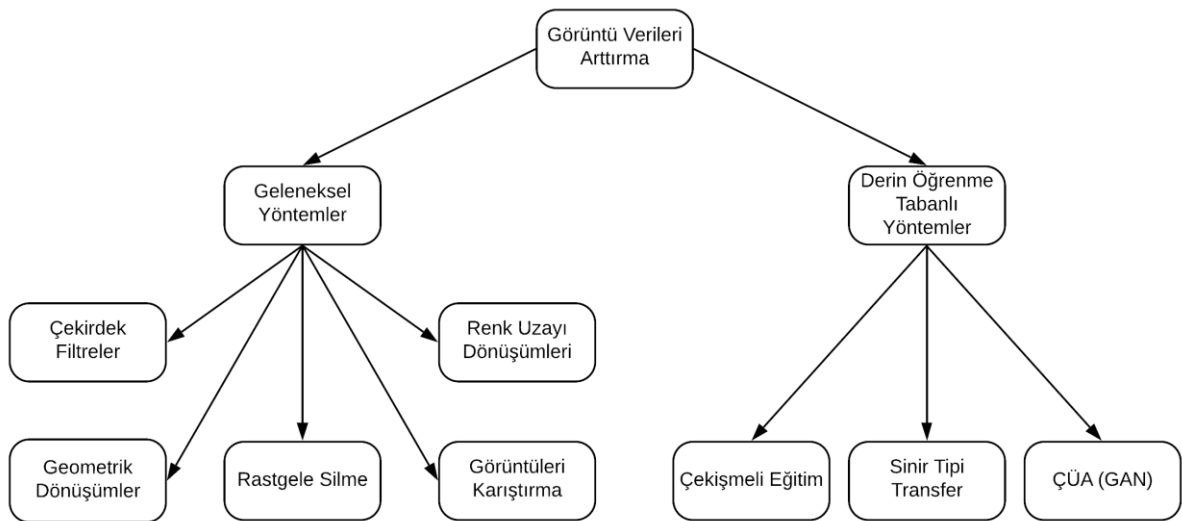
Derin öğrenme modelini uygun bir şekilde eğitmek için yüksek genelleştirilebilirliğe sahip olması gerekir. Genelleştirilebilirlik, eğitim verilerinin çeşitliliğini ve modelin kör test verilerini doğru bir şekilde sınıflandırma yeteneğini ifade etmektedir.

Görüntüden oluşan verinin arttırılması için kullanılan teknikler, orijinal görüntü eğitim verisinden, verilerin sınıf etiketlerini değiştirmeden “yeni” eğitim örnekleri üretmek için kullanılan tekniklerdir. Veri arttırmanın amacı modelin genelleştirilebilirliğini arttırmaktır. Bir görüntü sınıflandırıcısının iyi bir performans vermesi için çok sayıda görüntüye ihtiyacı var. Derin öğrenme algoritmaları, sadece bazı görüntüler test verisinde farklı yöneldiği için sınıflandırmada başarısız olabilir.

Yüksek genelleştirilebilirliğe sahip bir veri elde etmek için, örneklerin farklı açıları veya renk ölçekleri gibi farklı olasılıklarını kapsaması gerekir. Bazen, bir derin öğrenme modeli, aynı görüntünün farklı bir renk aralığına, açığa veya konuma sahip versiyonu test setinde bulunup eğitim setinde bulunmadığı için düşük sınıflama performansı gösterebilir. Ayrıca, genelleştirilebilirliği zayıf olan modeller genellikle eğitim verilerinde aşırı uyuma neden olmaktadır. Bir modelde aşırı uyum olması, test doğruluğu düşükken yüksek eğitim doğruluğuna ulaşması anlamına gelir. Etkili bir derin öğrenme modeli oluşturmak için, test doğruluğunun eğitim doğruluğu ile artmaya devam etmesi ve test hatasının eğitim hatasıyla azalmaya devam etmesi gerekmektedir. Veri arttırma, olabildiğince çok olasılığı kapsayan daha genel bir veri oluşturulmasına yardımcı olduğu için aşırı uyumu önlemede en kullanışlı tekniklerden biridir.

Veri arttırmanın Şekil 3.4'te görüldüğü gibi geleneksel ve derin öğrenme tabanlı yöntemleri vardır (Perez ve Wang, 2017; Shorten ve Khoshgoftaar, 2019). Derin öğrenme tabanlı veri arttırma yöntemleri çalışma mantığına göre 3'e ayrılır: özellik arttırmaya tabanlı veri arttırma, çekişmeli eğitim ile veri arttırma ve Çekişmeli Üretici Ağlarla (ÇÜA) veri arttırmadır (Shorten ve Khoshgoftaar, 2019). Çekişmeli Üretici Ağlarla veri arttırma bu yöntemlerin en yaygınıdır. ÇÜA, 2014 yılında Goodfellow ve ark. tarafından tanıtılmıştır. ÇÜA, iki modelin, bir üretici ve bir ayırıcı, birbirleriyle yarışırken birbirlerini aynı anda güçlendirdikleri denetlenmeyen modellerdir. Jeneratör olarak adlandırılan bir sinir ağı, yeni veri örnekleri üretirken, ayırıcı olarak adlandırılan sinir ağı jeneratörün ürettiği yeni örneklerin gerçek olup olmadıklarına karar verir.

Derin öğrenme tabanlı veri arttırma yöntemleri genelde verilerin net ve tanımlayıcı özellikler içerdiği durumlarda kullanılmaktadır. Aksi halde, üretici çekişmeli ağlar gürültü vektörlerinden ibaret olan veriyi gerçek veriye benzetmeye çalıştığı için yeni yapay veri üretmesi oldukça zordur. Geleneksel yöntemlerle ise bulanık, belirsiz ve kontrast veya keskinlik iyileştirme gibi düzeltmelere ihtiyacı olan veriler iyileştirilebilmekte ve arttırılabilmektedir. Bu tez çalışmasında, 174 X-ışını görüntüsünü içeren orijinal veri seti üzerinde farklı geleneksel teknikler uygulanmıştır.



Şekil 3.4. Veri arttırma yöntemleri


3.4.1. Geleneksel veri arttırma yöntemleri

Geleneksel veri arttırma yöntemleri temel görüntü manipülasyonlarına dayanmaktadır. Bu yöntemler geometrik dönüşümlere dayanan teknikler (tersleme, döndürme, boyutlandırma, büyütme, küçültme ve kırpm gibi) ve renk uzayında değiştirmelere dayanan teknikler (kontrast parlaklık ve keskinlik seviyelerini değiştirme gibi) içermektedir.

3.4.1.1. Karşıtlık (Kontrast) İyileştirme

Kontrast, bir görüntüdeki maksimum ve minimum piksel yoğunluğu arasındaki fark olarak açıklanabilir (Smith, 1997). Başka bir deyişle kontrast, nesnelere veya bölgeler arasındaki parlaklık farkıdır. Kontrast iyileştirme de, piksel yoğunluğu dağılımının dinamik aralığını ayarlayarak görüntü kontrastını geliştirme anlamına gelir (Cao ve ark., 2018; Gonzalez, 2006). Kontrast iyileştirme, bilgisayarlı görme, görüntü tanıma ve sayısal görüntü işleme için görsel kalitenin geliştirilmesinde önemli bir rol oynamaktadır. Kontrast iyileştirme teknikleri, uygulandıkları veri alanına göre piksel-etki alanı ve dönüştürme-etki alanı kategorilerine ayrılabilir. Birincisi piksel yoğunluğu işlemine dayanırken, ikincisi ayrık kosinüs dönüşümü (AKD), dalgacık dönüşümü ve eğricik dönüşümü gibi dönüşümler kullanarak bir görüntünün dönüşüm alanında kontrast iyileştirme uygular (Cao ve ark., 2018). Genellikle, piksel alanında uygulanan kontrast iyileştirme teknikleri daha düşük hesaplama maliyetinden dolayı gerçek uygulamalarda daha yaygın olarak kullanılır. En yaygın kullanılan piksel alanına dayanan kontrast iyileştirme yöntemi histogram eşitlemedir.


Şekil 3.5'te, iki farklı kontrast örneği yer almaktadır. (a)'da kontrol grubuna ait orijinal görüntü, (b) 'de yüksek kontrastlı görüntü, (c)'de ise düşük kontrastlı görüntü gösterilmiştir. Burada tüm pikseller gri tonludur ve detaylar kaybedilmiştir.



Şekil 3.5. (a) Kontrol grubuna ait orijinal görüntü, (b) yüksek kontrastlı görüntü ve (c) düşük kontrastlı görüntüdür

3.4.1.2. Parlaklık Değişirme

Parlaklık, karşılaştırdığımız kaynağa göre bir ışık kaynağı tarafından üretilen enerji miktarı olarak tanımlanabilir (Smith, 1997). Genel olarak görüntünün açıklığını veya koyuluğunu ifade edilen parlaklık, görüntü matrisine basit toplama veya çıkarma ile kolayca artırılabilir veya azaltılabilir. Şekil 3.6, iki farklı parlaklık örneği yer almaktadır. (a)'da kontrol grubuna ait orijinal görüntü, (b) 'de yüksek parlaklığa sahip görüntü, (c)'de ise düşük parlaklığa sahip görüntü gösterilmiştir.




Şekil 3.6. (a) KT etiketli görüntü, (b) yüksek parlaklığa sahip görüntü ve (c) düşük parlaklığa sahip görüntüdür

3.4.1.3. Keskinlik (Netlik) Değişirme

Netlik veya keskinlik, bir görüntüdeki ayrıntıların netliğini tanımlar. Görüntüleri keskinleştirmek, farklı renklerin bulunduğu kenarlar boyunca kontrastı artırır (Anonymous, 2020; Smith, 1997). Keskinleştirmenin temel amacı, bir görüntüdeki ince ayrıntıları

vurgulamak, bulanıklaştırılmış ayrıntıları geliştirmek ve kenarları daha görünür hale getirmektir. Görüntü keskinleştirmenin kullanımı, elektronik baskı, tıbbi görüntüleme, endüstriyel denetim ve askeri sistemlerde otonom yönlendirmeye kadar çeşitli uygulamaları içerir. Şekil 3.7’de Kontrol grubuna ait orijinal görüntü ve keskinliğinin artırıldığı versiyonu gösterilmektedir.




Şekil 3.7. (a) Kontrol grubuna ait orijinal görüntü, (b) keskinliğin artırıldığı görüntü

Keskinlik iyileştirme literatürde 3 farklı yöntemle uygulanmaktadır. Bunlar; yüksek geçiren filtre, yüksek kuvvetlendirilmiş filtre (alçak geçiren filtreden geçirilmiş bir görüntüyü bir kuvvetlendirme faktörü ile çarpılmış orijinal görüntüden çıkarmaya dayanan yüksek geçiren filtre) ve keskin olmayan çekirdek (görüntünün keskin olmayan veya düzleştirilmiş bir versiyonunu orijinal görüntüden çıkararak kenarları geliştiren bir operatör) (Obulesu ve Kishore, 2012).

3.4.1.4.Döndürme

Döndürme veya rotasyon, geometrik dönüşümleri temel alan bir veri artırma tekniğidir. Derin öğrenmede modellerin genel olması gerektiği için bazen veri setinde görüntülerin farklı açılardan olan versiyonlarının bulunması tercih edilmektedir. Döndürme işlemi en çok, x ekseninde, y ekseninde veya +90 ile -90 (+270) derece olarak gerçekleştirilmektedir. Şekil 3.8’de, bir görüntü döndürme örneği yer almaktadır. (a)’da kontrol grubuna ait orijinal görüntü, (b) 'de saat yönünde 90 derece döndürülmüş görüntü, (c)’de ise saat ters yönünde 90 derece (+270 derece) döndürülmüş görüntü gösterilmiştir.



Şekil 3.8. (a) Kontrol grubuna ait orijinal görüntü, (b) Saat yönünde 90 derece döndürülmüş görüntü ve (c) Saat ters yönünde 90 derece döndürülmüş görüntü

3.4.2. Tezde kullanılan osteoporoz verilerinin arttırılması


Veri arttırmanın etkisini ve kullanılan KT/OP verisinin boyutu ile sınıflandırma doğruluğu arasındaki ilişkiyi gözlemlemek için üç adımda veri arttırma uygulanarak üç farklı veri grubu elde edilmiştir.

İlk adımda, 174 görüntü (N ; orijinal verideki görüntü sayısı)'den oluşan orijinal veriler 90 derece döndürülerek yeni bir veri seti ve ardından 270 derece (saat ters yönünde 90 derece) döndürülerek ayrı bir veri seti elde edilmiştir. Rotasyon, hem veri boyutunu hem de modelin genelleştirilebilirliğini arttırmak için kullanılmıştır. Aynı adımda, orijinal verilerin kontrastı %30 oranında artırılmış iken, parlaklık %30 oranında azaltılmıştır. Ayrıca, parlaklığın azaltılmasından doğabilecek bilgi kaybını önlemek için N 'ye %20'lik parlaklık arttırma ve %20'lik kontrast azaltma gerçekleştirilmiştir. Bu adımda 696 görüntüden oluşan yeni bir veri kümesi A elde edilmiştir.

Kontrast ve parlaklık düzeltmeleri, orijinal görüntülerden daha fazla tanımlayıcı bilginin çıkarılabileceği varsayılarak uygulanmıştır. Kontrast ayarı, görüntü yoğunluğu değerlerini yeniden eşleyerek daha fazla bilginin elde edilmesine yardımcı olmaktadır. İyi kontrastlı bir görüntü, siyah ve beyaz arasında keskin farklılıklara sahip olduğundan görüntü ile ilgili tanımlayıcı nitelikler sağlamaktadır. Piksel uzayında kontrast-parlaklık iyileştirme tekniği olan histogram eşitleme, kontrast ve parlaklık ayarı için gerçekleştirilmiştir.


İkinci adımda, 696 görüntüden oluşan A veri kümesinin tamamı %50 oranında ve 3 değerindeki bir yarıçap ile keskinleştirilmiştir. Bu şekilde, 696 yeni görüntü ve toplam 1392 görüntüden oluşan B veri kümesi elde edilmiştir. Bu adımın amacı, kemik yapısındaki

çizgilerin ve özelliklerin daha net görünmesini sağlamaktır. Şekil 3.9’da, uygulanan veri arttırma prosedürü yer almaktadır.



Şekil 3.9. Uygulanan veri arttırma prosedürü

Üçüncü adımda ise, orijinal veriler (N) 1392 görüntüden oluşan B veri kümesine eklenmiş ve bize 1566 görüntüden oluşan C veri kümesi sağlamıştır. Şekil 3.10’da, kontrol (KT) etiketli bir görüntüyü ve onlara ilişkin histogramlarla beraber farklı veri arttırma yöntemlerinin uygulandığı versiyonları gösterilmektedir.



Şekil 3.10. KT etiketli bir X-ışın görüntüsü ve onlara ilişkin histogramlarla beraber iyileştirilmiş versiyonları. (a_1, a_2) KT etiketli görüntü; (b_1, b_2) kontrast %30 oranıyla arttırılmış; (c_1, c_2) parlaklık %30 oranıyla azaltılmış; (d_1, d_2) keskinlik %50 oranıyla arttırılmış

3.5. Derin Öğrenme

Yapay zeka, insanların davranışlarını taklit eden ve akıllı makinelerin geliştirilmesini vurgulayan bir bilim alanıdır. Bu bilim alanının kapsadığı en önemli kavramlardan biri Makine Öğrenimi'dir. Makine öğrenimi, sistemlere, deneyimden otomatik olarak öğrenme ve geliştirme yeteneği sağlayacak şekilde programlanmış algoritmaların bütünüdür. Bu algoritmalar, belirli bir sistemin girdileri ve çıktıları arasındaki matematiksel ilişkilerden ibarettir. Makine öğrenimi algoritmaları genellikle denetimli veya denetimsiz öğrenme olarak kategorize edilir. Ancak yarı denetimli ve pekiştirmeli öğrenme olarak adlandırılan makine öğrenme algoritmaları da mevcuttur (Alom ve ark., 2018). Bilgisayarlı görme (nesne tanıma, nesne algılama), tahmin (metin sınıflandırma, görüntü analizi, tıbbi tanı), anlambilimsel analiz, doğal dil işleme ve bilgi toplama gibi makine öğreniminin kullanımının görülebileceği çeşitli araştırma alanları vardır (Shinde ve Shah, 2018).

Yaygın olarak kullanılan makine öğrenme algoritmalarına örnek olarak; Doğrusal Regresyon, Lojistik Regresyon, Naive Bayes (NB), Bayes Ağı (BN), Destek Vektör Makineleri (SVM), Karar Ağacı, Rassal Orman (Random Forests), k-En Yakın Komşu (k-NN), K-means ve Yapay Sinir Ağları (YSA) verilebilir.

Yapay sinir ağları makine öğreniminin en yaygın yöntemlerindedir. Adındaki "sinir" kelimesinin gösterdiği gibi, yapay sinir ağları insanların düşünme yolunu taklit etmeye çalışan, beyinden ilham alan sistemlerdir (Haykin, 1996). Yapay sinir ağı (YSA), sınıflandırma, tahmin, karar verme ve görselleştirme gibi görevleri yerine getirmeyi öğrenen hesaplamalı doğrusal olmayan bir modeldir.

Yapay sinir ağı, yapay nöronlardan veya hesaplama birimlerinden oluşur ve birbirine bağlı üç ana katman halinde düzenlenir. Bunlar: giriş katmanı, gizli katman ve çıkış katmanıdır. Sinir ağındaki nöronlar diğer nöronlardan veya harici bir kaynaktan girdi alır ve bir çıktı hesaplar. Her girdinin, diğer ilişkili bir ağırlığı (w) vardır. Ağırlıklar, sinir ağını parametrelili bir sisteme dönüştüren ayarlanabilir parametrelerdir.

Makine öğrenmesinin bir alt kümesi olan Derin Öğrenme ise, derin mimariye dayanan, gizli katmanların sayısı artırılmış ve her katmanda probleme dair bir özneliğin öğrenildiği yapay sinir ağlarından oluşan yöntemler bütünüdür. Bu mimaride her katmanda öğrenilen nitelikler (özellikler) bir sonraki daha derin katman için giriş verilerini temsil eder.

Böylelikle en alt katmandan en üst katmana doğru en basitten en karmaşık niteliğin öğrenildiği bir yapı kurulmuş olur (Işık ve Artuner, 2016; Rawat ve Wang, 2017).

Derin öğrenme için kullanılan çok sayıda algoritma mevcuttur. Görüntü sınıflama uygulamalarında kullanılan bu algoritmaların çoğu Evrişimsel Sinir Ağları (ESA) olarak adlandırılan mimarilere dayanmaktadır (Işık ve Artuner, 2016; Rawat ve Wang, 2017).

3.5.1. Evrişimsel sinir ağları


Evrişimsel Sinir Ağları (ESA), birden fazla evrişim katmanından oluşan ve bu katmanlarda lineer olmayan fonksiyonların bulunduğu yapılardır. Şekil 3.11’de ESA yapısını en sade şekliyle gösteren bir blok şeması yer almaktadır.



Şekil 3.11. Bir ESA modelinin en basit yapısı

ESA’da geleneksel ileri beslemeli sinir ağlarına ek olarak, çıkışı üretmesi için giriş katmanına evrişim uygulanır. Her evrişim katmanı farklı filtreler uygular ve bunların sonuçlarını birleştirir (Rawat ve Wang, 2017).

Eğitim boyunca ESA modeli, filtrelerin içeriğini (öznitelikleri), gerçekleştirmesi istenen işleme göre kendisi otomatik olarak öğrenir. Böylece baştan sona doğru her katmanda görüntüye ilişkin, basitten karmaşığa, öznitelikler öğrenilmiş olur. Şekil 3.12’de, iki evrişimsel katman, iki maksimum havuzlama katmanı ve iki tam bağlı katmandan oluşan bir ESA örneği gösterilmiştir.




Şekil 3.12. İki evrişimsel katman, iki maksimum havuzlama katmanı ve iki tam bağlı katmandan oluşan bir ESA örneği

3.5.1.1. Evrişimsel Katman

Derin öğrenmede evrişim, genel tanımıyla matris üzerine kayan bir pencere fonksiyonunun uygulanmasıdır (Işık ve Artuner, 2016).

Şekil 3.13'deki matris siyah – beyaz bir görüntüyü göstermektedir. 0 ve 1 ile gösterilenler sırasıyla siyah ve beyaz piksellere karşılık gelmektedir. Alt alta gösterilen iki görüntü ise, bir matris üzerine iki kere evrişim işlemi yapıldığını göstermektedir. Kayan pencereye genelde kernel ya da filtre denilmektedir.


Burada kullanılan 3x3 boyutlu filtre değerleri, üzerinde bulunduğu matris ile eleman elemana çarpılır ve toplamı alınır. Bu işlem matrisin sonuna gelene kadar kaydırılarak devam etmektedir.



Şekil 3.13. Evrişim katmanları ve görüntü matrisi üzerinde kayan bir pencere fonksiyonu

3.5.1.2. Havuzlama

Evrişimsel Sinir Ağları'nda havuzlama (pooling) katmanları evrişim katmanlarından sonra gelmektedir. Havuzlama katmanları girdi olarak verilen resme alt örnekleme işlemi uygular. Böylece, özellik haritalarının uzamsal çözünürlüğünü azaltılır. Üzerinde işlem yapılan kısmın, maksimum havuzlama ile en büyüğü, minimum havuzlama ile en küçüğü ve medyan havuzlama ile medyan değeri alınarak özetlenmiş olur (Işık ve Artuner, 2016). Ayrıca, havuzlama katmanları model aşırı uyumunu azaltmada önemli bir rol oynamaktadır. Şekil 3.14, bir görüntü matrisi üzerine 2x2 filtrelerle maksimum havuzlamanın uygulanmasını göstermektedir.

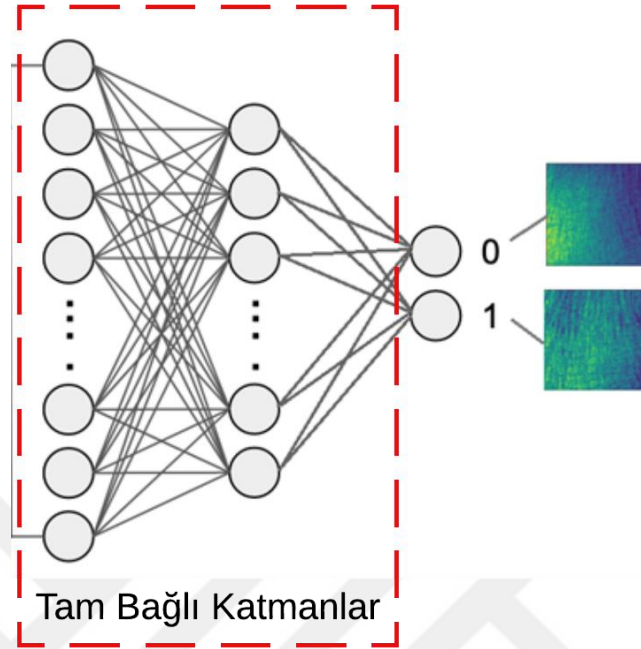


Şekil 3.14. Havuzlama katmanları ve bir matrise 2x2 filtrelerle maksimum havuzlamanın uygulanması

3.5.1.3. Tam Bağlı Katmanlar

Tam Bağlı katmanlarda, Şekil 3.15'te görüldüğü gibi, bir katmandaki her bir nöron başka bir katmandaki nörona bağlıdır. Prensip olarak, tam bağlı katmanlar çok katmanlı algılayıcılar (ÇKA) gibi davranır. Tek fark, tam bağlı katmanı besleyecek verilerin evreşimsel katmanlar tarafından oluşturulan formda olmasıdır. Çok katmanlı algılayıcılar, aslında yapay sinir ağlarıdır. Bu terim, hem tek gizli katmana hem de birden fazla gizli katmana sahip sinir ağlarını kapsamaktadır.

Evrşimsel katmanlar özellik çıkarma görevini yerine getirirken, tam bağlı katmanlar sınıflandırma görevinden sorumludur. Sınıflandırma problemlerinde, tam bağlı katmanlar Softmax fonksiyonunu varsayılan olarak kullanır, ancak softmax fonksiyonu bazen bir Destek Vektör Makinesi (DVM) ile değiştirilir (Tang, 2013). Bu tez çalışmasında, verilerin sınıflandırılması için softmax fonksiyonu kullanılmıştır.



Şekil 3.15. Tam Bağlı Katmanlar

3.5.2. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, girişlerin ve biasların ağırlıklı toplamını hesaplamak için kullanılan ve bir nöronun 0 veya 1 değerini alıp almayacağına karar veren fonksiyonların bütünüdür (Nwankpa ve ark., 2018).

Sinir ağları doğrusal sonuçlar üretir ve aktivasyon fonksiyonuna duyulan ihtiyaç burada doğmaktadır. Aktivasyon fonksiyonları, doğrusal olmayan çıkışlar elde etmek için doğrusal modellerin çıkışlarına uygulanmaktadır.


Sigmoid (lojistik fonksiyon), Tanh (Hiperbolik Tanjant fonksiyonu), Softmax ve Doğrultulmuş Doğrusal Ünite (ReLU) fonksiyonları literatürde en yaygın olarak kullanılan aktivasyon fonksiyonlarıdır.

Bu tez çalışmasında, ReLU aktivasyon fonksiyonu kullanılmıştır. Rampa Fonksiyonu olarak da bilinen ReLU (Doğrultulmuş Doğrusal Ünite) aktivasyon fonksiyonu, girişi pozitifse doğrudan onu aktarır, değilse sıfır çıkışını verir. ReLU fonksiyonu aşağıdaki şekilde gösterilebilir;

$$f(x) = \max(0, x) = \begin{cases} x_i, & \text{if } x_i \geq 0 \\ 0, & \text{if } x_i < 0 \end{cases} \quad (3.2)$$

Kaybolan gradyan problemi nedeniyle derin ağlarda Tanh ve sigmoid'in kullanımı ReLU kadar verimli değildir. Kaybolan gradyan problemi ile gradyan tabanlı öğrenme yöntemleri ve geri yayılım algoritması kullanılarak yapay sinir ağları eğitilirken karşılaşılır. Bazı durumlarda, gradyanların çok küçülüp sifıra yaklaşması (kaybolması), ağırlıkların değerini değiştirmesini önler ve ağı eğitmeyi zorlaştırır (Hochreiter, 1998).

ReLU, kaybolan gradyan probleminin üstesinden gelme kabiliyeti sayesinde özellikle görüntü sınıflandırma problemlerinde diğer aktivasyon fonksiyonlarından çok daha iyi bir performans göstermektedir. ReLU bunu modellerin daha hızlı öğrenmesine olanak tanıyan sıfırın altındaki girişlerin değerlerini sifıra zorlayarak başarmaktadır. ReLU'nun eşdeğer sigmoid veya Tanh fonksiyonlarından daha hızlı olmasının bir başka nedeni, üstel kuvvet içermemesidir, bu nedenle daha az hesaplama gücüne ihtiyaç duyarak daha hızlı işlem yapmaktadır (Nwankpa ve ark., 2018). Şekil 3.16'deki grafik Sigmoid, Tanh ve ReLU aktivasyon fonksiyonlarını göstermektedir.

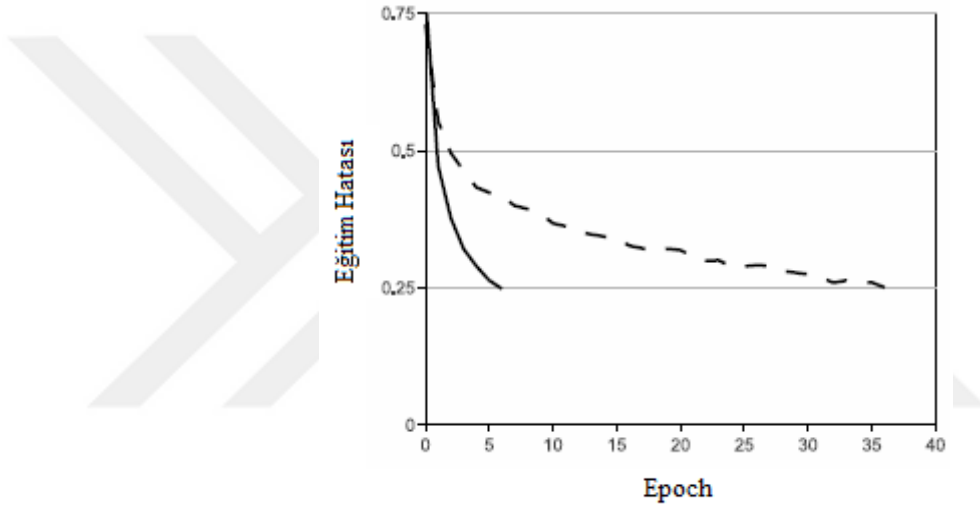


Şekil 3.16. Sigmoid, Tanh ve ReLU aktivasyon fonksiyonları

(Krizhevsky ve ark., 2012) derin bir sinir ağının ReLU kullanarak Tanh veya sigmoid gibi aktivasyon fonksiyonları kullanılarak eğitildiği zamana göre çok daha hızlı eğitilebileceğini gösterdiler. Şekil 3.17'de görüldüğü gibi, ReLU'nun kullanıldığı dört katmanlı bir evrişimli sinir ağı, tanh fonksiyonunun kullanıldığı eşdeğer bir ağdan % 25'lik bir eğitim hata oranına altı kat daha hızlı ulaştığını gösterilmiştir.

Verilerin sınıflandırılması için tez çalışmasında mimarilerin son katmanlarında softmax fonksiyonu kullanılmıştır. Softmax fonksiyonu 0 ile 1 arasında bir çıktı üretir. Her değer bir sınıfın olasılığını temsil eder ve tüm olasılıkların toplamı 1'e eşittir. Softmax fonksiyonu aşağıdaki şekilde ifade edilebilir;

$$f(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (3.3)$$



Şekil 3.17. ReLU'nun kullanıldığı (düz çizgi) dört katmanlı bir evrişimli sinir ağı, tanh fonksiyonunun kullanıldığı (kesikli çizgi) eşdeğer bir ağdan % 25'lik bir eğitim hata oranına altı kat daha hızlı ulaşmıştır (Krizhevsky ve ark., 2012)

3.5.3. Sinir ağı optimizasyonu

Sinir ağlarının en önemli amacı, tahmin edilen çıktı ile gerçek çıktı arasındaki farkı azaltmaktır. Bu fark, maliyet fonksiyonu veya kayıp fonksiyonu olarak adlandırılır. Bir yapay sinir ağının eğitiminde ilk ağırlık değerleri rastgele atılır. İlk iterasyonda çıkışta büyük bir hata (Kayıp Fonksiyonu) ile karşılaşılır. Ağırlık değerlerini güncelleyerek hatayı veya kayıp fonksiyonunu minimize etmek için optimizasyon algoritmaları kullanılır (Ruder, 2016).

Sinir ağlarının optimize edilmesi için kullanılan temel yöntem geri yayılım'dır. Geri yayılım, yapay sinir ağlarının eğitilmesi için kullanılan ve gradyan iniş (gradient descent) tekniğine dayanan bir denetimli öğrenme algoritmasıdır.

Geri yayılım algoritması, her bir nöronün kayıptan ne kadar sorumlu olduğunu bilmek için toplam kaybı sinir ağına geri yayarak daha yüksek hata oranlarına sahip düğümlerin ağırlıklarının değerlerini düşürerek kaybı en aza indirecek şekilde ağırlıkları günceller. Hatanın minimize edilmesi ile ağırlık değerlerinin optimize edilmesi ve ağıın belirli bir doğruluk seviyesine ulaşması sağlanmaktadır.

Ayrıca, sinir ağlarının optimizasyonu için kullanılan fonksiyonlar mevcuttur. MSGİ veya Momentum ile Stokastik Gradyan İniş (Stochastic Gradient Descent with Momentum) bu tez çalışmasında Geri Yayılım ile uygulanan optimizasyon fonksiyonudur.

MSGİ, klasik optimizasyon algoritması SGİ'nin (Stokastik Gradyan İniş) momentum eklendiği geliştirilmiş bir sürümüdür. Momentum, gradyan vektörlerini optimum yönde hızlandırmaya ve yanlış yerel minimum noktada sıkışıp kalmamaya yardımcı olmak için eklenmiştir (Qian, 1999).

3.5.4. Başarım iyileştirme

Son birkaç yıl içinde yapay öğrenme için önerilen farklı başarım iyileştirme (düzenleştirme) yaklaşımları vardır. Seyreltme adı verilen basit ama etkili başarım iyileştirme yaklaşımı, (Hinton ve ark., 2012) tarafından önerilmiştir. Seyreltme, önceden belirlenmiş bir oran ile bazı nöronları (örneğin %50) devre dışı alır. Bu, rastgele seçilen aktivasyonların bir katman içinde sıfıra ayarlandığı anlamına gelir (Srivastava ve ark., 2014). Böylece, her iterasyonun model parametrelerinin farklı bir örneğini kullanır ve her nöron daha sağlam ve çeşitli özelliklere sahip olur. Seyreltme modelin aşırı uyumunu önlerken, modelin yakınsaması için gereken eğitim süresini arttırır. Bu tez çalışmasında osteoporotik-kontrol verisini sınıflandırmak için kullanılan derin öğrenme mimarilerinde seyreltme tekniği uygulanmıştır.

3.5.5. Transfer öğrenme

Transfer öğrenme daha kısa sürede doğru modellerin oluşturulmasını sağladığı için derin öğrenmenin popüler yaklaşımlarından biridir (Rawat ve Wang, 2017). Derin Öğrenme'de Transfer Öğrenme kavramı, önceden eğitilmiş bir modelin kullanımını göstermektedir. Transfer Öğrenme ile öğrenme süreci baştan başlatılmak yerine farklı bir problem çözerken elde edilen ağırlıkları kullanılır.


Önceden eğitilmiş modeller büyük bir veri seti üzerinde eğitilmiş modellerdir. Bir görüntü sınıflandırma problemi için, ImageNet veri seti üzerinde önceden eğitilmiş AlexNet mimarisi kullanılabilir ve baştan eğitmek yerine öğrenilen özelliklerle beraber ağırlıklar da olduğu gibi bırakılabilir. Bu eğitim yöntemi, verinin az olduğu durumlarda yararlıdır.

Önceden eğitilmiş modelleri kullanmanın iki temel nedeni vardır. Birincisi, çok derin modelleri büyük veri ile eğitmenin fazla hesaplama gücü gerektirmesidir. İkincisi de bu çok derin modellerin eğitilmesinin uzun sürmesidir. Önceden eğitilmiş ağırlıklara sahip yeni modellerin eğitilmesi modellerin daha hızlı öğrenmesini sağlar ve ağır genelleştirilebilirliğini artırır.

3.5.5.1. Önceden eğitilmiş modelin problem göre düzenlenmesi

Önceden eğitilmiş bir modeli belirli bir problemde kullanmak için, modelin çözülmesi amaçlanan probleme göre hazırlanması gerekir. Bunu yapmak için farklı stratejiler vardır, ancak bu stratejiler temel olarak iki önemli adım içerir: Birincisi; modeldeki sınıflandırıcı söz konusu sınıflandırma problemine uygun değilse sınıflandırıcıyı değiştirmektir. Aynı sınıflandırıcı kullanılacak olsa bile, sınıf sayısının çözülmesi amaçlanan sınıflandırma problemine uyumlu olması gerekmektedir. İkinci adım ise, giriş verilerini önceden eğitilmiş modelin gereksinimlerine göre yeniden boyutlandırmaktır.

Bu çalışmada veri artırma ile elde edilen veri setlerini (orijinal veri, A , B , C) sınıflandırmak için farklı transfer öğrenme modelleri kullanılmıştır. Şekil 3.18’de, sınıflandırma probleminde önceden eğitilmiş bir modelin kullanımı göstermektedir.



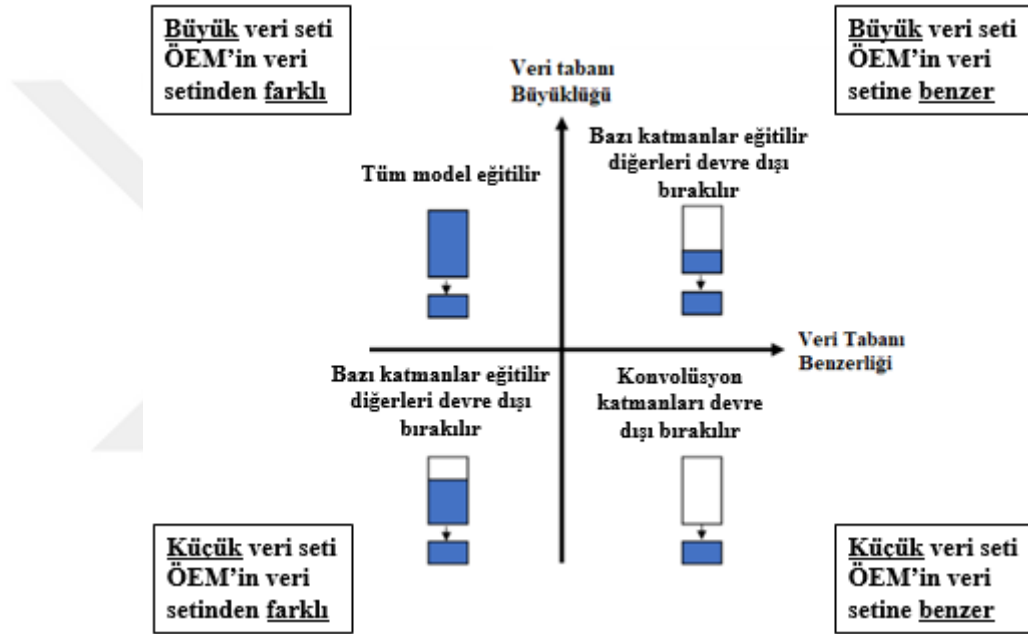
Şekil 3.18. Önceden eğitilmiş modelin kullanımı

Önceden eğitilmiş modele yeni sınıflandırma probleminde kullanılabilmesi için aşağıdaki üç stratejiden birine göre ince ayar (Fine-Tuning) uygulanması gerekmektedir:

- Önceden elde edilen ağırlıklarla ve yeni sınıf sayısı ile modelin tamamını eğitmek

- Bazı katmanları eğitip diğerlerini devre dışı (frozen) bırakmak
- Evrimsel katmanları devre dışı bırakmak

Bu stratejilerin hangisinin uygun olduğuna karar vermek için Şekil 3.19'daki boyut-benzerlik matrisi kullanılabilir. Bu matris, problemi veri setinin boyutunu ve önceden eğitilmiş modelin eğitildiği veri setine benzerliğini dikkate alarak sınıflandırır. Bu tez çalışmasında modellerin tamamı eğitilerek kullanılmışlardır.



Şekil 3.19. Boyut-benzerlik matrisi. ÖEM: Önceden Eğitilmiş Model (Marcelino, 2018)

3.5.6. Transfer öğrenme mimarileri

Çok sayıda önceden eğitilmiş model vardır. VGG (Simonyan ve Zisserman, 2014), ResNet (He ve ark., 2016), GoogleNet (Szegedy ve ark., 2015), Inception-v2 ve Inception-v3 (Szegedy ve ark., 2016), MobileNetV2 (Sandler ve ark., 2018), DenseNet (Huang ve ark., 2017), AlexNet (Krizhevsky ve ark., 2012), NASNet (Zoph ve ark., 2018) ve Xception (Chollet, 2017). Bu tez çalışmasında osteoporotik ve kontrol etiketli verileri sınıflandırmak için bu mimarilerden 5 tanesi kullanılmıştır. Bunlar; AlexNet, ResNet50, GoogleNet, Inception-v3 ve MobileNetV2'dir. Bu modellerin her biri ilerleyen bölümlerde detaylı bir şekilde anlatılmıştır.

3.5.6.1. ImageNet

Tez çalışmasında kullanılacak transfer öğrenme mimarilerinden bahsetmeden önce, ImageNet (Deng ve ark., 2009) veri kümesinin açıklanması gerekmektedir.

ImageNet, yaklaşık 22.000 sınıfa ait 15 milyondan fazla etiketli yüksek çözünürlüklü görüntüden oluşan bir görüntü veri kümesidir. Görüntüler web'den toplanarak ve Amazon'un Mechanical Turk crowd-Sourcing Tool yardımıyla veri etiketleme uzmanları tarafından etiketlenmiştir.

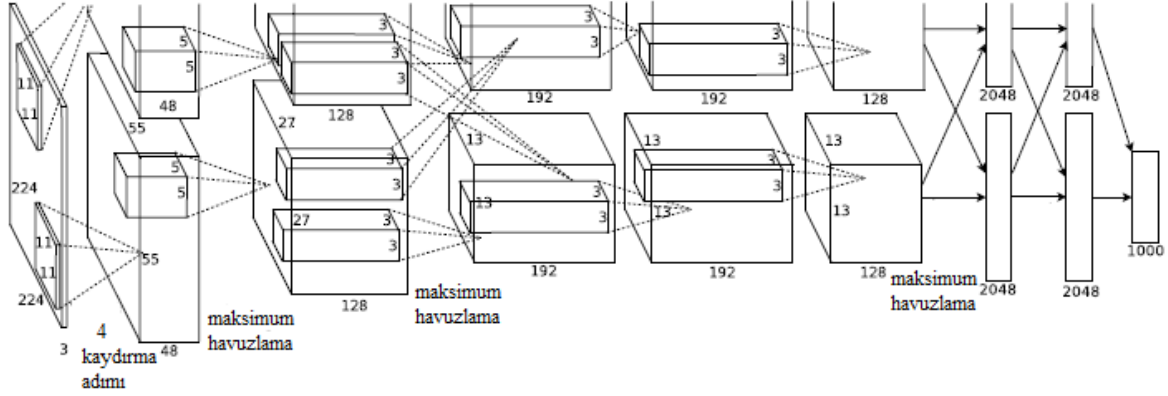
2010 yılından itibaren Pascal Görsel Nesne Yarışması (The Pascal Visual Object Challenge) kapsamında, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large-Scale Visual Recognition Challenge - ILSVRC) adı verilen bir yarışma düzenlenmiştir. ILSVRC, 22000 sınıfın sadece 1000'ini kullanan ve bu 1000 sınıfın her birinden 1000 görüntü içeren bir ImageNet alt kümesini kullanır. Bu veride yaklaşık 1,2 milyon eğitim görüntüsü, 50.000 doğrulama görüntüsü ve 150.000 test görüntüsü vardır. ImageNet, değişik boyutlara sahip görüntülerden oluşur. Bu nedenle, görüntüler 256×256 sabit boyuta yeniden boyutlandırılmıştır.

3.5.6.2. AlexNet mimarisi

Derin Öğrenme kurallarını değiştiren ImageNet sınıflandırma makalesinin ilk yazarı Alex Krizhevsky'nin adını alan AlexNet mimarisi 2012 yılında tanıtılmıştır (Krizhevsky ve ark., 2012). AlexNet, makine öğreniminde ve özellikle derin öğrenmenin makine görmesi alanındaki uygulamalarında büyük etkisi olan evrimsel sinir ağıdır.

2012 yılında ImageNet LSVRC-2012 yarışmasını büyük bir farkla kazanan AlexNet, 2. sırada gelen ağın elde ettiği hata oranını %26.2'den %15.3'e düşürmüştür.

AlexNet ağı, Yann LeCun ve arkadaşlarının LeNet (LeCun ve ark., 1990) ağına çok benzer bir mimariye sahip olsa da Alexnet katman başına daha fazla filtre ve evrimsel katmanlar içermektedir. Şekil 3.20'de görüldüğü gibi, AlexNet sekiz katman içerir; ilk beş katman evrişim katmanları ve geri kalan üçü tam bağlı katmanlardır. Son tam bağlı katmanın çıkışı, 1000 sınıf etiketlerinin üzerinde bir dağıtım oluşturan 1000 yollu bir Softmax fonksiyonuna verilir.



Şekil 3.20. AlexNet Mimarisi (Krizhevsky ve ark., 2012)

Şekil 3.20’de görüldüğü gibi, ikinci, dördüncü ve beşinci evrişimsel katmanların çekirdekleri yalnızca bir önceki katmandaki aynı GİB (Grafik İşlemci Birimi)’de bulunan çekirdeklere bağlanırken, üçüncü evrişimsel katmanın çekirdekleri her iki GİB’in ikinci katmanındaki tüm çekirdeklere bağlanmaktadır. Ayrıca, tam bağlı katmanlardaki nöronlar, önceki katmandaki tüm nöronlara bağlıdır.

AlexNet, standart olan tanh aktivasyon fonksiyonu yerine doğrultulmuş doğrusal ünite (ReLU) fonksiyonunu kullanır. ReLU’nun en büyük avantajı (Bölüm 3.5.2’de bahsedildiği gibi) eğitim süresini azaltmaktır. AlexNet’te, her evrişimsel ve tam bağlı katmandan sonra ReLU aktivasyon fonksiyonu bulunmaktadır.

AlexNet, 6 gün boyunca iki Nvidia Geforce GTX 580 Grafik İşlemci Birimi (GİB) üzerinde eş zamanlı olarak eğitilmiştir. Bu, Şekil 3.28’de görüldüğü gibi, AlexNet ağına iki ayrı kanala ayrılmasının nedenidir. Yani AlexNet, modelin nöronlarının yarısını bir GİB’te, diğer yarısını başka bir GİB’te tutarak çoklu GİB kullanarak eğitim yapabilmektedir. Çoklu GİB kullanımı, hem çok derin modellerin eğitilmesine hem de eğitim süresini azaltılmasına olanak sağlamaktadır.

AlexNet mimarisi, 62.3 milyon parametreye sahiptir ve bir ileri beslemede 1.1 milyar hesaplama birimine ihtiyaç duymaktadır. Fazla parametreye sahip olması aşırı uyuma yol açabileceğinden aşırı uyumu azaltmak için iki yöntem kullanılmıştır: 1) Geleneksel veri arttırma yöntemleri uygulanarak mevcut veri 2048 kat arttırılmış; 2) Düzenleştirme yerine seyreltme kullanılmıştır. Seyreltme tekniği birinci ve ikinci tam bağlı katmandan önce uygulanmıştır.

3.5.6.3. GoogleNet mimarisi

GoogLeNet veya diğer adıyla Inception-v1 (Szegedy ve ark., 2015), ZFNet (2013 yılında kazanan) ve AlexNet (2012 yılında kazanan) üzerinde önemli bir gelişme gösteren ve VGGNet ile karşılaştırıldığında nispeten daha düşük hata oranına sahip olan (ImageNet Büyük Ölçekli Görsel Tanıma Yarışması) ILSVRC yarışmasının 2014 yılındaki kazananıdır.

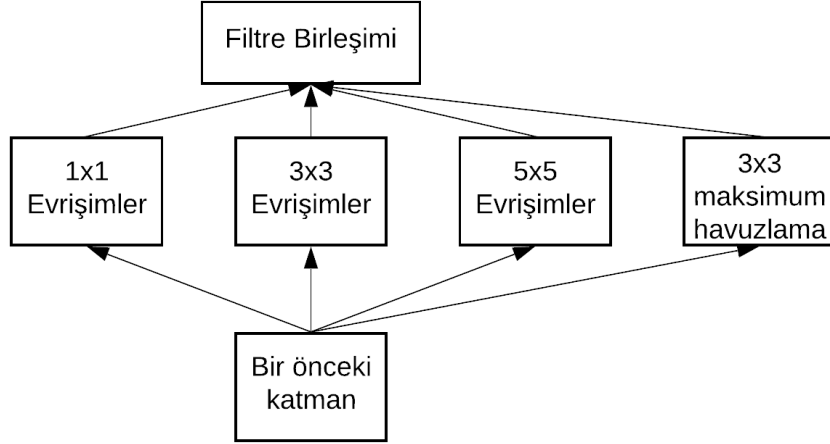
Adından da anlaşılacağı gibi, GoogleNet, Google'in bir çalışmasıdır. "GoogLeNet" adı ayrıca Prof. Yan LeCun'un LeNet'ine (LeCun ve ark., 1990) saygı göstermek için "LeNet" kelimesini de içerir.

Derin sinir ağlarının performansını artırmanın en basit yolunun boyutlarını arttırmak olduğuna inanılmaktadır. Bu, ağın derinliğini (gizli katmanların sayısını) ve genişliğini (her bir katmandaki nöronların sayısını) arttırmak demektir. Ancak, sinir ağlarının boyutlarını belli bir noktaya kadar arttırmakla birlikte iki büyük dezavantaj doğar. Birincisi, daha büyük boyut, tipik olarak daha fazla sayıda parametre anlamına gelir. Bu da, özellikle eğitim setindeki etiketli örneklerin sayısı sınırlıysa, ağda aşırı uyum olmasının olasılığını arttırmaktadır. Ağ boyutunun artmasının bir başka dezavantajı ise, ciddi bir hesaplama gücü ve donanımı gerektirmesidir.

Google'in "Going Deeper with Convolutions" adlı makalesi (Szegedy ve ark., 2015), özellikle evrimsel katmanlar içinde, tam bağlı katmanlar yerine seyrek bağlı katmanlara (sparsely connected layers) geçmeyi önermektedir. Bu yaklaşım, ağın derinliğini ve genişliğini artırırken hesaplama maliyetinin artmasını önlemektedir.

GoogleNet mimarisinin arkasındaki ana fikir, Şekil 3.21'de gösterilen ve Inception olarak adlandırılan modül veya katmandır. Inception katmanı, seyrek bağlı bir mimarinin temel konseptidir. Inception katmanı ile beraber, GoogleNet global ortalama havuzlama (global average pooling) gibi ağın daha derin olma imkanını sağlayan teknikleri kullanır.


Inception katmanı, 1×1 'lik evrişim katmanı, 3×3 'lük evrişim katmanı ve 5×5 evrişim katmanının çıkış filtreleriyle beraber bir sonraki katmanın girdisini oluşturan tek bir çıkış vektörün kombinasyonudur.



3.21. Sade Inception modülü (Szegedy ve ark., 2015)


1×1 'lik evrişim, (Lin ve ark., 2013)'nın çalışmasında tanıtılmıştır. GoogLeNet'te, hesaplama gücünü azaltmak ve neticesiyle de aşırı uyumu azaltmak için boyut küçültme modülü olarak kullanılır. Böyle bir filtre ile, hesaplama gücü artırılmadan ağın derinliği ve genişliği artırılabilir.

Şekil 3.22'de, 1×1 'lik evrişim kullanmadan 48 filtreye sahip 5×5 'lik evrişimin hesabı gerçekleştirilmiştir.



Şekil 3.22. 48 filtreye sahip 5×5 'lik evrişimin hesabı

Burada, parametre sayısı = $(14 \times 14 \times 48) \times (5 \times 5 \times 512) = 120.4$ milyondur. Şekil 3.23'te olduğu gibi 16 filtreye sahip bir 1×1 'lik hesaplama maliyeti azaltma evrişimi yardımı ile 5×5 'lik bir evrişim gerçekleştirilmiştir (Çizelge 3.2'deki Inception (4a) katmanı için hesaplama);

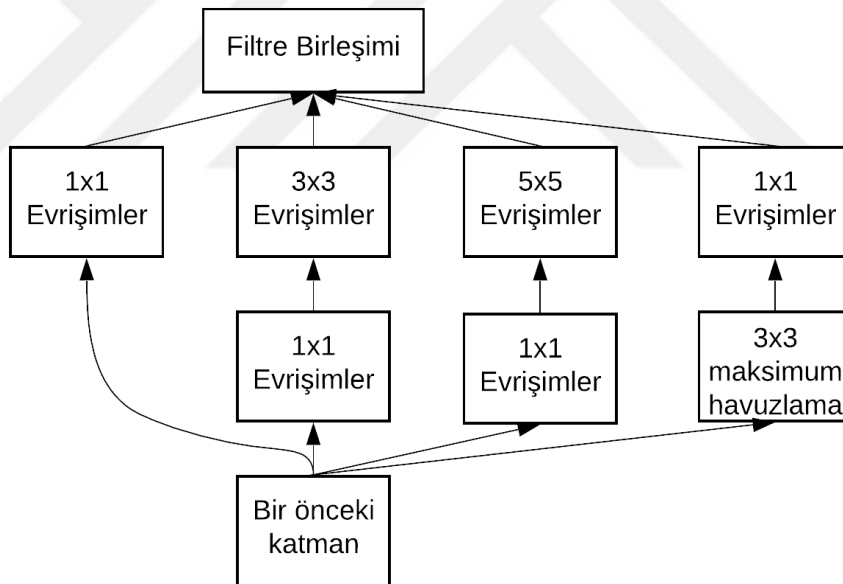


Şekil 3.23. 1x1 boyut azaltma evrişimi yardımıyla 48 filtreye sahip 5x5'lik evrişimin hesabı

1x1 için parametre sayısı = $(14 \times 14 \times 16) \times (1 \times 1 \times 512) = 1.6$ milyon.

5x5 için parametre sayısı = $(14 \times 14 \times 48) \times (5 \times 5 \times 16) = 3.8$ milyon.

Toplam parametre sayısı = 1.6 milyon + 3.8 milyon = 5.4 milyon. Bu sayı, 120.4 milyondan çok daha azdır. Şekil 3.24, 1x1'lik evrişimler yardımıyla boyut azaltmanın uygulandığı bir Inception modülünü göstermektedir.



Şekil 3.24. Boyut azaltma ile Inception modülü (Szegedy ve ark., 2015)

AlexNet gibi öncü mimarilerde, ağın sonunda tam bağlı katmanlar kullanılmaktadır. Bu tam bağlı katmanlar, hesaplama maliyetinde artışa neden olan parametrelerinin çoğunu içerir. GoogLeNet mimarisinde ağın sonunda ortalama havuzlama (average pooling) adı verilen bir havuzlama katmanı kullanılmaktadır. Bu katman 7x7'lik özellik haritasını alır ve 1x1'e düşürür. Tam bağlı katmanlardan ortalama havuzlamaya geçişin eğitilebilir parametre sayısını 0'a düşürdüğü ve en yüksek doğruluğu yaklaşık %0.6 kadar arttırdığı bulunmuştur.

Bununla birlikte, tam bağı katmanlar çıkarılsa bile seyreltme'nin kullanımının zorunlu olduğu bulunmuştur. Burada, %70 seyreltme oranına sahip bir seyreltme katmanı mevcuttur.

GoogLeNet yapısında sınıflandırıcının alt aşamalarında sınıflandırmayı iyileştirmek, geri yayılan gradyan sinyalinin arttırmak ve ek düzenleme sağlamak için iki yardımcı sınıflandırıcı da kullanılmışlar. Bu sınıflandırıcılar, Inception modüllerinin çıktısının üstüne konulan daha küçük evrimsel ağlar şeklindedir. Yardımcı ağlar (yardımcı sınıflandırıcıya bağlı dallar) sadece eğitim için olup test veya tahmin aşamasında devreden çıkarılmaktadır. Eğitim sırasında bu yardımcı ağların kayıpları, 0.3 değerindeki bir ağırlık ile ağın toplam kaybına eklenir. Bu yardımcı sınıflandırıcı, 5×5'lik bir Ortalama Havuzlama (3 değerinde bir kaydırma adımı ile) katmanı, doğrultulmuş doğrusal aktivasyon (ReLU) ile boyut küçültmek için 128 filtreli bir 1x1'lik evrişim ve yine doğrultulmuş doğrusal aktivasyon (ReLU) ile 1024 nörona sahip bir tam bağı katman ve son olarak sınıflandırıcının görevini yerine getiren bir Softmax fonksiyonundan oluşmaktadır.

Çizelge 3.2. GoogleNet mimarisi; burada 3x3 azaltma ve 5x5 azaltma, 3x3 ve 5x5 evrişimlerden önce kullanılan azaltma katmanındaki 1x1 filtre sayısını ifade eder (Szegedy ve ark., 2015)

Katman Tipi	Çıkış Boyutu	Derinlik	1×1	3×3 Azaltma	3×3	5×5 Azaltma	5×5	Havuzlama	Parametre
Evrişim	112×112×64	1							2.7 bin
Maks. Havuz.	56×56×64	0							
Evrişim	56×56×192	2		64	192				112 bin
Maks Havuz.	28×28×192	0							
Inception(3a)	28×28×256	2	64	96	128	16	32	32	159 bin
Inception(3b)	28×28×480	2	128	128	192	32	96	64	380 bin
Maks Havuz.	14×14×480	0							
Inception(4a)	14×14×512	2	192	96	208	16	48	64	364 bin
Inception(4b)	14×14×512	2	160	112	224	24	64	64	437 bin
Inception(4c)	14×14×512	2	128	128	256	24	64	64	463 bin
Inception(4d)	14×14×528	2	112	144	288	32	64	64	580 bin
Inception(4e)	14×14×832	2	256	160	320	32	128	128	840 bin
Maks. Havuz.	7×7×832	0							
Inception(5a)	7×7×832	2	256	160	320	32	128	128	1072 bin
Inception(5b)	7×7×1024	2	384	192	384	48	128	128	1388 bin
Ort. Havuzlama	1×1×1024	0							
Seyreltme(40%)	1×1×1024	0							
Lineer	1×1×1000	1							1000 bin
Softmax	1×1×1000	0							

GoogleNet'teki sınıflandırıcıdan önce ortalama havuzlamanın kullanımı da "Network In Network" (Lin ve ark., 2013) makalesine dayanmaktadır. Ancak, GoogLeNet'in farkı fazladan bir doğrusal katman kullanımınıdır. Bu doğrusal katman, yeni etiketler için ağın ince ayarının yapılmasını sağlamaktadır.

Şekil 3.25'te açık bir şekilde gösterilen ve çizelge 3.2'de özetlenen GoogleNet (Inception-v1) mimarisi, 22 parametrelili katmandan oluşmaktadır. Havuzlama katmanlarını da saydığımızda ağ 27 katman derinliğindedir. GoogleNet (Inception-v1) mimarisi sonradan geliştirilerek 4 farklı versiyonu daha tanıtılmıştır. Bunlar BN-GoogLeNet, Inception-v2, Inception-v3 ve Inception-v4'tür.

Test prosedürü için VGGNet'te olduğu gibi 256, 288, 320 ve 352 (4 ölçek) boyutlarına sahip çoklu ölçek testi kullanılmaktadır. Ayrıca, çoklu kırpma testi de kullanılır. Bu testte ilk olarak her ölçek için sol, orta ve sağ veya üst, orta ve alt kareler (3 kare) alınır. Daha sonra, her kare için 4 köşe ve merkezin yanı sıra yeniden boyutlandırılan kare (6 kırpma) kırpılır ve karşılık gelen döndürmeler (2 farklı döndürme) oluşturulur. Toplamda; 4 ölçek \times 3 kare \times 6 kırpma \times 2 döndürme = 144 görüntüdür. Softmax olasılıklarının (0 ile 1 arasındaki sonuç değerler) tüm kırpmalar üzerinde ortalaması alınmıştır.

3.5.6.4. ResNet50 mimarisi

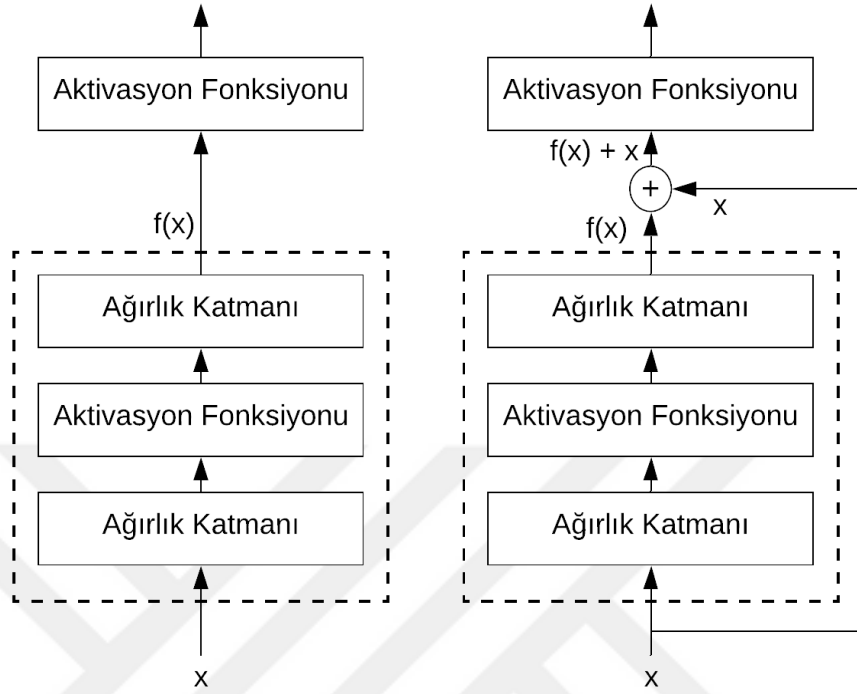
GoogleNet ve VGGNet çalışmaları maksimum derinlik eşiği olduğunu göstererek Ağ derinliğinin sınıflandırma doğruluğu ile doğru orantılı olduğunu söyleyen düşünceleri kırmıştır (Simonyan ve Zisserman, 2015; Szegedy ve ark., 2015). Bir sinir ağının çok fazla gizli katmana sahip olması, aslında onu kullanılamaz hale getiren kaybolan gradyanlar sorununa yol açmaktadır (bkz., Bölüm 3.5.2).

Derin sinir ağlarının derinliği arttıkça eklenen katmanların etkisi ve modele katkısını anlamak zor olmaya başlar. Aslında, rastgele katman eklemek değil, eklenen katmanların performansı iyileştirmeleri için ağların nasıl tasarlanması gerektiği önemlidir.

ResNet (He ve ark., 2016) mimarisindeki yaklaşım, her eklenen katmanın bir kimlik fonksiyonu (identity function) içermesidir. Yeni eklenen katmanlar bir kimlik haritalama fonksiyonu ($f(x) = x$) ile eğitilirse, eğitim hataları azaltılabilir. Bu kimlik fonksiyonlarının kullanımı artık bloklar olarak tanımlanan bloklarda görülebilmektedir. Artık bloklar'ın yardımıyla, kaybolan gradyanlar sorununa maruz kalmadan gizli katmanların sayısı isteğe göre artırılabilir.

Artık bloklar, çıktının girdiye eşit olduğu bir kimlik haritalama ağırlık fonksiyonu yardımıyla ağın daha önce öğrendiklerini (öğrenecek bir şey yoksa) tekrar kullanmak üzere korumasını sağlar. Böylece sinir ağı, öğrenilen bilgilerin silinmesine neden olan dönüşümler uygulamayarak, katmanlar yeni bilgiler öğrenebiliyorsa eski öğrenilenleri onlara ekler, katmanlar yeni bilgiler öğrenmiyorsa da eskileri kullanır.

Şekil 3.26'da sağdaki blok, ResNet'in temel artık bloğunu göstermektedir. Soldaki blokta noktalı kutudaki bölüm doğrudan $f(x)$ haritalama fonksiyonuna uymalıdır. Sağ blokta noktalı kutunun içindeki bölümün çıktısı ise $x + f(x)$ ile eşit olması gerektiğinden yalnızca kimlik (x) olarak adlandırılan girişten sapmanın parametrelendirilmesi gerekir. Pratikte $f(x) = 0$ olarak ayarlandığı için artık bloğun optimize edilmesi daha kolaydır.




Şekil 3.26. Normal blok (solda) ve artık blok (sağda) arasındaki fark (He ve ark., 2016)

ResNet mimarisi, VGG mimarisinin 3×3 'lük evrişimsel katman tasarımını örnek almıştır. Her artık blok, aynı sayıda çıkış kanalına sahip iki adet 3×3 evrişimsel katmanı içerir. Her evrişimsel katmanın ardından bir toplu (batch) normalizasyon katmanı ve bir ReLU aktivasyon fonksiyonu gelmektedir. Ardından, bu iki evrişim işlemi atlanır ve giriş (kimlik) son ReLU aktivasyon fonksiyonundan önce eklenir. Böyle bir tasarım, iki evrişimsel katmanın çıkışının, birbirleriyle toplanabilmeleri için giriş ile aynı boyutta olmasını gerektirir. Girişi istenen boyuta dönüştürmek için 1×1 'lik bir evrişimsel katman eklenmesi gerekir (ResNet50, ResNet101 ve ResNet152'de olduğu gibidir).

Resnet'i tanıtan makalede (He ve ark., 2016), ResNet'in farklı versiyonları sunulmuştur. Bunlar: ResNet18; ResNet34; ResNet50; ResNet101 ve ResNet152. Şekil 3.27'de ResNet34 mimarisi ve ilham verdiği VGG mimarisi gösterilmektedir.

2015 yılındaki ILSVRC adlı ImageNet veri kümesi sınıflandırma yarışmasında, ResNet (Residual Neural Network) %3.57'lik bir hata oranına ulaşmıştır.



Şekil 3.27. ResNet34 ve VGG19 mimarileri (He ve ark., 2016)


3.5.6.5. Inception-v3 mimarisi

GoogleNet mimarisinin, ilk başta toplu normalizasyonun (batch normalization) (Ioffe ve Szegedy, 2015) (BN-GoogLeNet mimarisi), daha sonra ise Inception-v2 olarak adlandırılan ek faktörizasyon uygulanması ile çeşitli versiyonları geliştirilmiştir. Inception-v3 ise (Szegedy ve ark., 2016), Inception-v2'nin TN-Yardımcı (Toplu Normalizasyon-yardımcı sınıflandırıcı) ağı ile bir araya gelmiş halidir.

Inception-v3 mimarisini anlamak için Inception-v2 ve TN-Yardımcı ağ'ı açıklamak gerekmektedir. GoogLeNet (Inception-v1) mimarisinin asıl başarısı ciddi bir şekilde boyut küçültmenin uygulanmasından kaynaklanmaktadır. Bu, hesaplama gücü azaltılacak evrişimleri çarpanlarına ayırmanın (factorizing) özel bir durumu olarak görülebilir. Szegedy ve ark. (2016) Inception-v2 mimarisini geliştirirken hesaplama verimliliğini artırmak için çeşitli ayarlarla evrişimleri çarpanlara ayırmanın başka yollarını araştırmıştır. Inception ağları (blokları) tamamen evrişimsel olduğundan, her ağırlık, aktivasyon başına bir çarpma işlemine karşılık gelir. Bu nedenle, hesaplama maliyetindeki herhangi bir azalma, parametre sayısının ve eğitim süresinin azalmasına neden olur.


Uzamsal olarak büyük filtrelere sahip evrişimler (örneğin 5×5 veya 7×7) hesaplama açısından uzamsal olarak daha az yer kaplayan filtrelere göre daha maliyetlidir. Örneğin, m filtreli bir kılavuz üzerinde n filtreli bir 5×5 evrişim, aynı sayıda filtreye sahip 3×3 evrişimden hesaplama açısından $25/9 = 2.78$ kat daha pahalıdır.

Filtrelerin geometrik boyutlarının azaltılması, ilk katmanlarda büyük miktarda bilgi kaybına neden olmaktadır. Ancak, Inception-v3 mimarisinde, 5×5 'lik evrişim aynı giriş boyutu ve çıkış derinliğine sahip daha az parametrelili çok katmanlı bir ağ ile değiştirilerek bu sorunun önüne geçilmiştir. Şekil 3.28'de 5×5 'lik bir evrişim gösterilmektedir. Görülebileceği gibi, her bir çıkış, 5×5 'lik girişin üzerinde kayan, tam bağlı küçük bir ağa benzemektedir. Bu küçük ağın giriş ızgarası üzerine kaydırılması, 5×5 'lik evrişim yerine iki 3×3 'lik evrişimin kullanılabileceğini göstermektedir. Bu yaklaşım ile, bitişik kareler arasındaki ağırlıkları paylaşarak parametre sayısı büyük ölçüde azaltılabilir. Bir adet 5×5 filtre katmanı



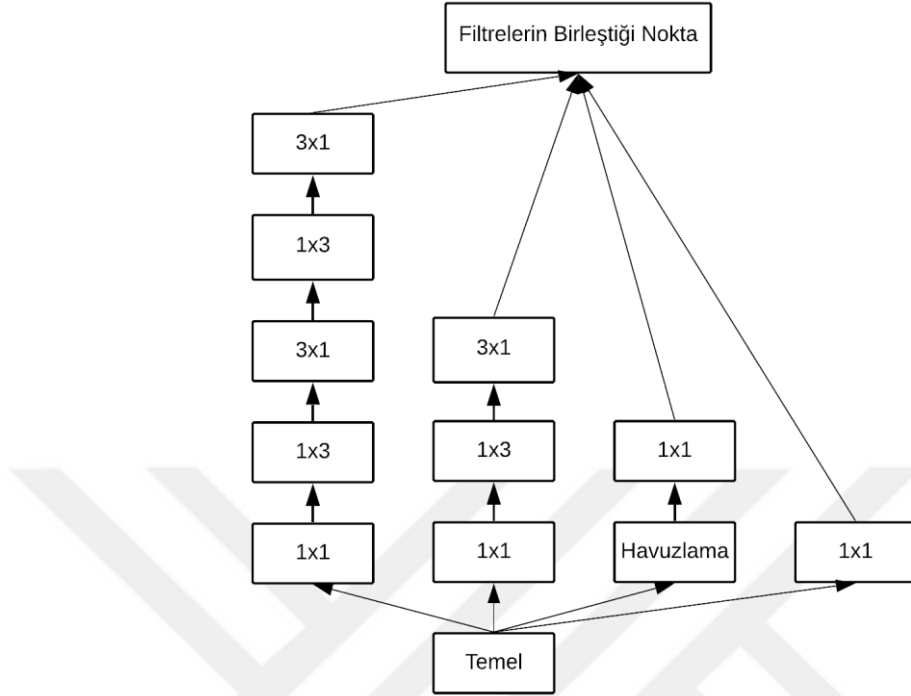
Şekil 3.28. 5 x 5 evrişimin yerini alan 3x3 evrişim (Szegedy ve ark., 2016)

kullanıldığında, parametre sayısı $5 \times 5 = 25$ iken, 3x3 filtreden oluşan 2 katman kullanarak, parametre sayısı $3 \times 3 + 3 \times 3 = 18$ 'e düşürülerek %28 kadar azaltmış olur. Bu teknikle, Şekil 3.29'deki sol taraftaki (a) Inception modülü, sağ taraftaki (b) şekli alır.



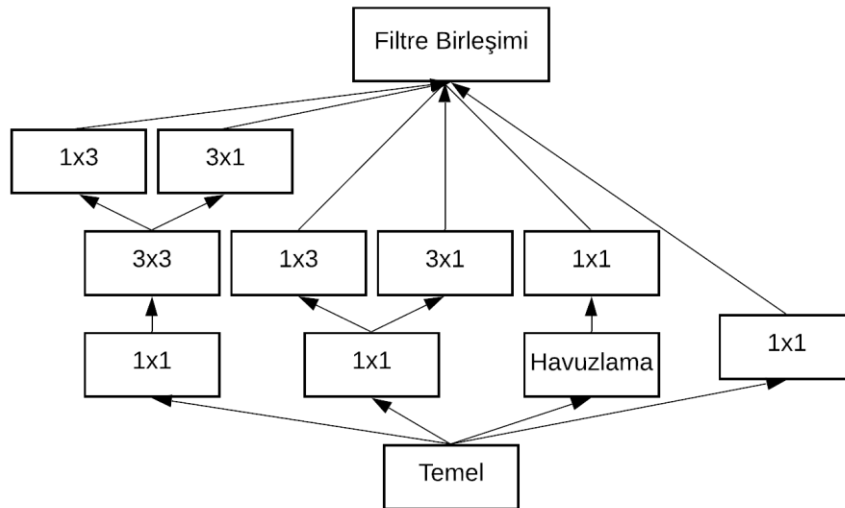
Şekil 3.29. (a) Orijinal Inception modülü, (b) 5x5 evrişimin iki 3x3 evrişim ile değiştirildiği Inception modülü (Szegedy ve ark., 2016)

Bu 3 x 3'lük filtreler, asimetrik evrişimler kullanılarak daha küçük çarpanlarına ayrılabilir. Örneğin, 3 x 1'lik bir evrişim ve ardından 1 x 3'lük bir evrişim kullanmak, 3 x 3 evrişimdeki ile aynı uzamsal alana sahip iki katmanlı bir ağ kullanmaya eşdeğerdir. Şöyle ki; 3 x 3 bir filtre kullanarak, parametre sayısı $3 \times 3 = 9$ iken, 3×1 ve 1×3 boyutunda iki ayrı filtre kullanarak parametre sayısı $3 \times 1 + 1 \times 3 = 6$ 'ya düşürülerek %33'e kadar azaltılır. Bu yaklaşımla, Şekil 3.29 (b)'deki modül Şekil 3.30'da gösterilen modüle dönüşmektedir.




Şekil 3.30. 3x3 evrişimlerin çarpanlarına ayrılmasından sonra Inception modülü (Szegedy ve ark., 2016)

Ayrıca, filtre çıktılarını genişleten başka bir Inception modülü de tanıtılmıştır. Bu modül, Şekil 3.29. (b)'deki modülün 3 x 3 filtrelerinin genişletilmiş halidir. Şekil 3.31'de gösterilen yeni modül, 8 x 8 gibi çok büyük boyutlara sahip filtrelerin kullanılmasını desteklemek için üretilmiştir (Inception-v2 ve Inception-v3 mimarilerinde bulunmaktadır).



3.31. Filtrelerin genişletildiği Inception modülü (Szegedy ve ark., 2016)

Inception-v2 mimarisi, yukarıda tanıtılan yeni Inception modüllerinden oluşmaktadır. Ayrıca, son 17×17 katmanın üstünde Inception-v1'den farklı olarak yalnızca Şekil 3.32'de gösterilen bir yardımcı sınıflandırıcı kullanılmaktadır.



3.32. Inception-v2 mimarisindeki yardımcı sınıflandırıcı (Szegedy ve ark., 2016)


Inception-v1'deki iki yardımcı sınıflandırıcı daha derin bir ağa sahip olmak için kullanılırken, Inception-v2'de yardımcı sınıflandırıcı, düzenleştirici olarak kullanılır. Inception-v2 mimarisi, Çizelge 3.3'te gösterilmektedir.

Çizelge 3.3. Inception-v2 mimarisi (Szegedy ve ark., 2016)

Katman tipi	Yama (Patch) Boyutu/ Kaydırma Adımı	Giriş Boyutu
Evrişim	3x3/2	299 x 299 x 3
Evrişim	3x3/1	149 x 149 x 32
Eklemenin uygulandığı bir evrişim (Padded Conv)	3x3/1	147 x 147 x 32
Havuzlama	3x3/2	147 x 147 x 64
Evrişim	3x3/1	73 x 73 x 64
Evrişim	3x3/2	71 x 71 x 80
Evrişim	3x3/1	35 x 35 x 192
3 x Inception	Şekil 3.37 (b)'de olduğu gibi	35 x 35 x 288
5 x Inception	Şekil 3.38'de olduğu gibi	17 x 17 x 768
2 x Inception	Şekil 3.39'de olduğu gibi	8 x 8 x 1280
Havuzlama	8 x 8	8 x 8 x 2048
Doğrusal	Logit fonksiyonu	1 x 1 x 2048
Softmax	sınıflandırıcı	1 x 1 x 1000

Sonunda, Inception-v3 mimarisi, Inception-v2'nin yukarıda bahsedilen yardımcı sınıflandırıcısında toplu normalizasyonun kullanıldığı halidir. TNYS (Toplu Normalizasyon-yardımcı sınıflandırıcı), yardımcı sınıflandırıcının sadece evrişim katmanları değil de tam bağlı katmanının da toplu olarak normalleştirildiği (Bach normalized) versiyonu ifade eder. Yardımcı sınıflandırıcıda toplu normalizasyonun kullanımı, en iyi doğruluğu %0.4 kadar arttırmıştır (Szegedy ve ark., 2016).

48 kat derinliğindeki Inception-v3, hesaplama maliyeti GoogLeNet'ten sadece 2,5 kat daha yüksektir ve VGGNet'ten çok daha verimlidir. Şekil 3.29 (b)'deki Inception modülüne Inception A, Şekil 3.30'dakine Inception B, Şekil 3.31'dekine Inception C denilir ve Şekil 3.32'deki yardımcı sınıflandırıcı TNYS (Toplu Normalizasyon Yardımsı Sınıflandırıcı) olarak ifade edilirse, Inception-v3 mimarisi Şekil 3.33'de olduğu gibi görselleştirilebilir.



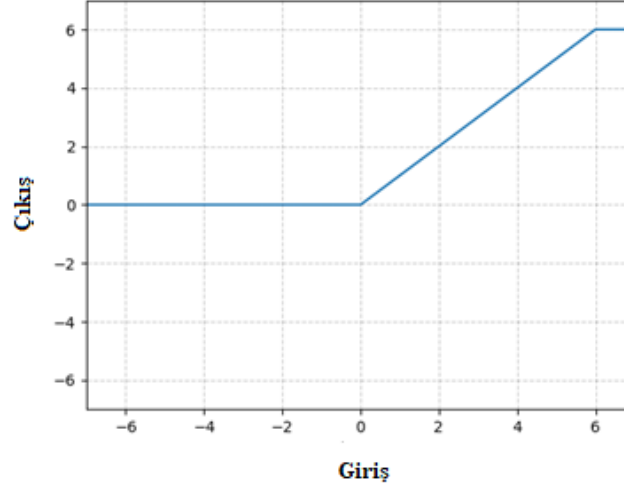
Şekil 3.33. Inception-v3 mimarisi

3.5.6.6. MobileNetV2 mimarisi

MobileNetV2 (Sandler ve ark., 2018), mobil görme uygulamaları yüksek performans sağlayan ters çevrilmiş artık ve doğrusal darboğaz katmanı adı verilen yeni bir ESA katmanına dayanmaktadır. Bu katman, MobileNetV1'de tanıtılan derinlemesine ayrılabilir evrişimler üzerine kuruludur (Howard ve ark., 2017).

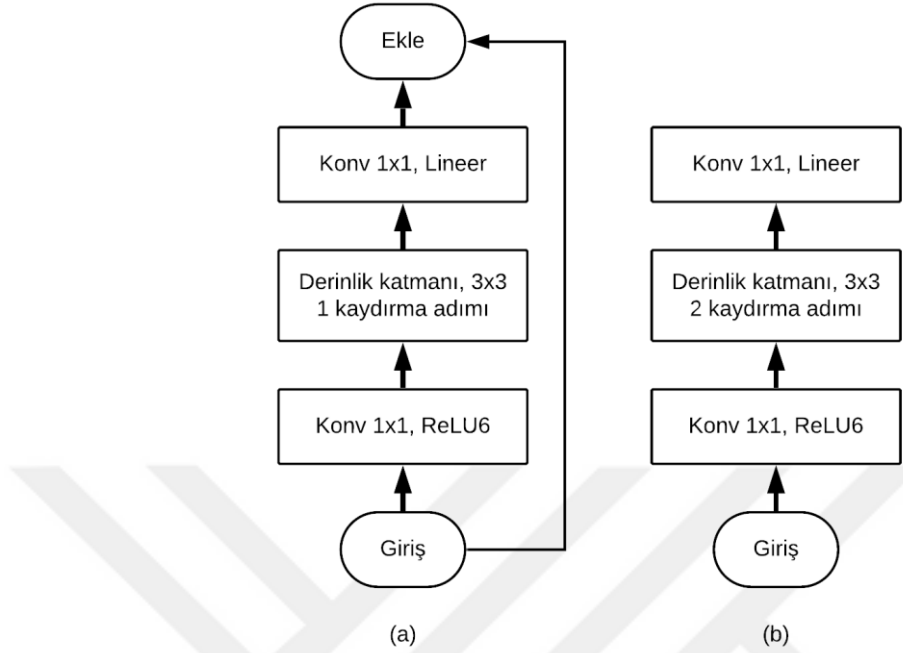
Derinlemesine ayrılabilir evrişimler, standart evrişimlerle kıyasla hesaplama maliyetini ve doğruluk kaybını azaltan evrişimlerdir. Standart evrişim, uzamsal filtreleme ve doğrusal kombinasyonlar içermesine rağmen, iki aşamayı ayrıştırmak veya çarpanlarına ayırmak mümkün değildir. Aksine, derinlemesine ayrılabilir evrişimde bu ayrıştırmayı temel almaktadır.

Derinlemesine ayrılabilir evrişim iki katmana bölünür; birincisi ReLU6 aktivasyon fonksiyonunu kullanan bir 1×1 noktasal evrişimdir. Şekil 3.34'teki ReLU6, düşük hassas hesaplamada kararlılığı nedeniyle kullanılmıştır (Howard ve ark., 2017). İkincisi ise derinlemesine evrişimdir.



Şekil 3.34. ReLU6 aktivasyon fonksiyonu (Howard ve ark., 2017)

MobileNetV2'de Şekil 3.35'te gösterilen iki çeşit blok bulunmaktadır. Biri, kaydırma adımı 1 olan bir ters çevrilmiş darboğaz artık blok (bottleneck residual block), diğeri de kaydırma adımı 2 olan bir boyut küçülme bloğudur (ters çevrilmiş darboğaz, artık değildir). Her iki blok iki katmandan oluşan derinlemesine ayrılabilir evrişimi ve ReLU içermeyen doğrusal bir 1×1 evrişim içermektedir. Katmana darboğaz adının verilmesinin sebebi boyutları çok azaltmasıdır.



Şekil 3.35. 1 ve 2 kaydırma adımlarıyla darboğaz blokları (Sandler ve ark., 2018)

MobileNetV2 ağı ağırlıklı olarak aşağıda Çizelge 3.4'te gösterildiği gibi ters çevrilmiş artık katmanları içeren darboğazlardan oluşmaktadır. Ağ hesaplama maliyeti 585 milyon işlemdir. Parametre sayısı ise 1,7 milyon ile 6,9 milyon arasında değişmektedir.

Çizelge 3.4. MobileNetV2 mimarisi; Burada t: genişleme faktörü, c: çıkış kanalı sayısı, n: tekrarlama sayısı ve s: kaydırma adımdır (Sandler ve ark., 2018)

Giriş	Katman	t	c	n	s
$224^2 \times 3$	Konv2B	-	32	1	2
$112^2 \times 32$	Darboğaz	1	16	1	1
$112^2 \times 16$	Darboğaz	6	24	2	2
$56^2 \times 24$	Darboğaz	6	32	3	2
$28^2 \times 32$	Darboğaz	6	64	4	2
$14^2 \times 64$	Darboğaz	6	96	3	1
$14^2 \times 96$	Darboğaz	6	160	3	2
$7^2 \times 160$	Darboğaz	6	320	1	1
$7^2 \times 320$	Konv2B 1x1	-	1280	1	1
$7^2 \times 1280$	Ort havuzlama 7x7	-	-	1	-
$1 \times 1 \times 1280$	Konv2B 1x1	-	K	-	-

3.6. Osteoporozun Sınıflandırılması için Modellerin Eğitilmesi

Yukarıda anlatılan modellerin her biri farklı bir derinliğe, parametre sayısına ve giriş boyutuna sahiptir. Bu modellerin hepsi ImageNet veri kümesi üzerinde eğitilmiştir.

Çalışmada kullanılan tüm modellerin son katmanları ImageNet'e göre yapılan 1000 sınıf yerine problemimize uyması için 2 sınıfa göre (osteoporoz, kontrol) düzenlenmiştir. Ayrıca, giriş görüntüleri tüm deneylerde her modelin varsayılan boyutuna uyacak şekilde yeniden boyutlandırılmıştır. Çizelge 3.5, bu çalışmada kullanılan modellerin giriş boyutunu, derinliğini ve parametre sayısını göstermektedir.

Çizelge 3.5. Kullanılan modeller için giriş boyutu, derinlik ve parametre sayısı.

Mimari	Eğitildiği Veri	Giriş Boyutu	Katman Sayısı	Parametre Sayısı
AlexNet	ImageNet	227x227	8	60.000.000
GoogleNet	ImageNet	224x224	22	6.797.700
Resnet50	ImageNet	224x224	50	25.636.712
MobileNet V2	ImageNet	224x224	53	3.538.984
Inception V3	ImageNet	299x299	48	23.851.784

Modellerin eğitimi birkaç deneyde gerçekleştirilmiştir. İlk deneyde modelleri eğitmek için sadece orijinal veri seti (174 görüntü) kullanılmışken, sonraki deneylerde sırasıyla *A* (696 görüntü), *B* (1392 görüntü) ve *C* (1566 görüntü) veri setleri kullanılmıştır. Bu deneylerin amacı uygulanan veri arttırma yaklaşımın sınıflandırma doğruluğu üzerindeki etkisini değerlendirmektir. K-katlamalı çapraz doğrulama deneyi hariç, geri kalan tüm deneylerde veri setleri %80 eğitim ve %20 test olarak ayırt edilmiştir. Mini batch boyutu değeri 5 olarak ayarlanmış ve görüntüler karıştır (shuffle) komutu ile karıştırılmıştır. Epoch sayısı ise tüm deneylerde 20 olarak seçilmiştir. Her deneydeki iterasyon sayısı aşağıdaki denklem ile hesaplanabilir;

$$\text{İterasyon sayısı} = (\text{eğitim verisindeki görüntü sayısı} / \text{mini batch boyutu}) \times \text{epoch sayısı} \quad (3.4)$$

Diğer eğitim ayarları Çizelge 3.6'da gösterilmiştir. Tüm ayarlar çalışma boyunca sabit tutulmuştur.

Çizelge 3.6. Tüm deneylerde sabit tutulan eğitim ayarları

Eğitim Verisinin Yüzdesi	% 80
Öğrenme Oranı	0.0001
Aktivasyon Fonksiyonu	ReLU
Optimize Edici	MSGİ
Epoch Sayısı	20
Mini Batch Boyutu	5

Kaybolan gradyan probleminin üstesinden gelmek ve eğitim süresini azaltmak için ReLU aktivasyon fonksiyonu kullanılmıştır (bkz., Bölüm 3.5.2). Çizelge 3.6’da gösterildiği gibi, MSGİ veya Momentum ile Stokastik Gradyan İniş, modellerin optimizasyonu için kullanılmıştır.

3.7. K-Katlamalı Çapraz Doğrulama

Derin sinir ağlarını eğitmek için yeterli veri olmadığı zaman, verinin bir parçasını doğrulama işlemi için ayırmak, aşırı uyuma yol açabilir. Bazı veri örneklerinin eğitim verisinde bulunmaması, ağın o örneklerde bulunan önemli özellikleri öğrenmemesine ve dolayısıyla hata fonksiyonunun artmasına neden olmaktadır. Bu yüzden, modeli eğitirken doğrulama için kullanılacak veriyi eğitim için de kullanmamıza izin veren bir doğrulama tekniğine ihtiyaç vardır.

Bu tez çalışmasında K-Katlamalı Çapraz Doğrulama yöntemi kullanılmıştır. K-Katlamalı Çapraz Doğrulama yönteminde veri k alt kümeye bölünür ve klasik çapraz doğrulama işlemi k kez tekrarlanır. Her seferinde k alt kümelerinden biri test seti olarak kullanılır ve diğer k-1 alt kümeleri bir eğitim seti oluşturmak için bir araya getirilir. Daha sonra tüm k eğitim iterasyonları boyunca ortalama hata hesaplanır. Bu yöntemin avantajı, her veri kümesi bir kez test setinde ve k-1 kez eğitim setinde olacağı için verilerin nasıl paylaştırıldığına daha az önem taşınması ve model aşırı uyumunu önlemesidir. K-Katlamalı Çapraz Doğrulama C veri seti (1566 görüntü) üzerine uygulanmış ve her biri 522 örnek içeren 3 alt kümeye bölünmüştür. 3-Katlı Çapraz Doğrulama ile her model 3 kez eğitilmiştir.

3.8. Performans Değerlendirmesi için Karmaşıklık Matrisi

Karmaşıklık matrisi, sınıflandırma algoritmalarının performanslarını özetlemek için kullanılan bir tekniktir. Aynı veri setlerindeki farklı sınıfların sayısı eşit olmadığı durumlarda

veya çok sayıda sınıf içeren veri setlerin olduğu durumlarda sadece doğruluk oranına bakmak yanıltıcı olabilir. Bir karmaşıklık matrisini hesaplamak, sınıflandırma modelinin ne kadar doğru sonuçlar verdiğini ve ne tür hatalara yol açtığına dair daha iyi bir fikir verebilir. Şekil 3.36, sonraki bölümdeki deneylerin değerlendirilmesinde kullanılan karmaşıklık matrisini göstermektedir

		Tahmin Edilen Sınıf	
		Negatif	Pozitif
Gerçek Sınıf	Negatif	Doğru Negatif (DN)	Yanlış Pozitif (YP)
	Pozitif	Yanlış Negatif (YN)	Doğru Pozitif (DP)

Şekil 3.36. Kullanılan karmaşıklık matrisi

Bu matriste, doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP) ve yanlış negatif (YN) gibi kavramlar verilerin doğru veya yanlış sınıflandırılmasıyla ilgili bilgi vermektedir. Doğru pozitif, pozitif verilerin doğru olarak sınıflandırıldığını, doğru negatif, negatif verilerin doğru sınıflandırıldığını, yanlış pozitif, negatif verilerin pozitif olarak sınıflandırıldığını, yanlış negatif ise pozitif verilerin negatif olarak sınıflandırıldığını göstermektedir. Bu değerlere göre doğruluk (Doğ) oranı aşağıdaki formül ile bulunabilir;

$$\text{Doğruluk (Doğ)} = (DP + DN)/(DP + DN + YP + YN) \quad (3.5)$$

Duyarlılık (Duy) veya doğru pozitif oranı (DPO) aşağıdaki formül ile bulunabilir;

$$\text{Duyarlılık (Duy)} = DP/(DP + YN) \quad (3.6)$$

Özgüllük veya doğru negatif oranı (DNO) ise aşağıdaki formül ile bulunmaktadır.

$$\text{Özgüllük (Özg)} = DN/(DN + YP) \quad (3.7)$$

Burada duyarlılık, pozitif örneklerin doğruluk oranı, özgüllük ise negatif örneklerin doğruluk oranıdır.



4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Tez çalışmasında OP (osteoporotik) ve KT (kontrol) hastalardan alınan kalkaneus kemiğinin X-ışını görüntülerinden elde edilen ROI'ları içeren farklı veri kümeleri kullanılmıştır. Örneklerin sayısı ile derin modelin doğruluğu arasında doğru orantılı bir ilişki olduğundan, modelleri daha iyi eğitmek için veri arttırma teknikleri kullanılmıştır. Kontrast, Parlaklık ve Keskinlik modifikasyonu, X-ışını taramalarını iyileştirip sınıflandırma probleminde önemli rol oynayan tanımlayıcı bilgileri çıkarmak amacıyla uygulanmıştır. Dört veri kümesini (Orijinal, A, B, C) sınıflandırmak için AlexNet, MobileNetV2, GoogleNet, Inception-v3 ve Resnet50 mimarileri kullanılmıştır. Kullanılan mimarilerin normalde 1000 sınıfa (ImageNe veri seti) göre düzenlenen son katmanları, 2 sınıfa (OP/KT) göre düzenlenmiş ve eğitim ayarları tüm deneyler için Çizelge 3.6'da gösterildiği gibi seçilmiştir. Gerçekleştirilen deneylerin sonuçları aşağıda verilmiştir.

4.1. Deney 1: Orijinal Verilerin Sınıflandırılması

Bu deney, orijinal veriler (N) kullanılarak elde edilen sınıflandırma sonucunu, veri arttırmanın uygulandığı deneylerde elde edilenlerle karşılaştırmak için gerçekleştirilmiştir.

Test verileri 34 görüntüden oluşmaktadır (17 görüntü KT, 17 görüntü OP olarak etiketli). Bu veriler orijinal veri kümesinin %20'sini temsil etmektedir.

Önceden eğitilmiş farklı mimariler (AlexNet, GoogleNet, ResNet50, MobileNetV2 ve Inception-v3) kullanılarak elde edilen sınıflandırma sonuçları (Doğ, Duy, Özg) Çizelge 4.1'de gösterilmektedir. Görüldüğü gibi doğruluk değerleri InceptionV3 ile elde edilen %47'den ResNet50 ile elde edilen %58.8'e kadar farklılık göstermiştir. Beklendiği gibi, kullanılan tüm modeller veri sayısının azlığı sebebiyle iyi sonuç vermemiştir. Çizelge 4.2'de hem doğru sınıflandırılmış hem de yanlış sınıflandırılmış örneklerin sayısı (DP, DN, YP, YN) gösterilmiştir. ResNet50'e bu deneyin en iyi performans göstereni olarak bakıldığında, KT etiketli 17 görüntünün 6'sı yanlış sınıflandırılmış (YP) ve OP etiketli 17 görüntünün 8'i KT (YN) olarak sınıflandırılmıştır. Şekil 4.1'de bu deneye ait karmaşıklık matrisleri gösterilmektedir.

		Kontrol		Osteoporotik		Kontrol		Osteoporotik		Kontrol		Osteoporotik		Kontrol		Osteoporotik	
		Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik				
Gerçek	Kontrol	11	6	8	9	11	6	9	8	5	12						
	Osteoporotik	11	6	7	10	8	9	6	11	6	11						
		AlexNet		GoogleNet		ResNet50		MobileNetV2		Inception-v3							
		Tahmin															

Şekil 4.1. Deney 1'e ait karmaşıklık matrisleri

4.2. Deney 2: A Veri Kümesinin Sınıflandırılması

A veri kümesi, 90 ve 270 derecelik rotasyon uygulandığı ve ardından görüntülerin kontrast ve parlaklığının farklı oranlarla ayarlandığı iki adım uygulanarak elde edilmiştir. A veri kümesi OP ve KT olarak eşit sayıda etiketlenmiş toplam 696 görüntü içermektedir.

Bu deneydeki test verileri, 70 KT ve 70 OP'ye bölünmüş 140 görüntü içermiştir (696 görüntünün %20'si). Görüldüğü gibi, beş modeli (AlexNet, MobileNetV2, GoogleNet, Inception-v3 ve Resnet50) kullanılarak elde edilen doğruluk değerleri, %77.8 (MobileNetV2 ile) ve %82.1 (Inception-v3 ile) arasında değişerek önemli ölçüde gelişmiştir. ResNet50 ve GoogleNet %80'lik bir doğruluk değerine ulaşırken, AlexNet %81,4'lük bir doğruluk değeri ile onlardan daha iyi performans göstermiştir. Çizelge 4.2'de görülebileceği gibi, tüm modellerde DN oranları DP oranlarından daha yüksektir, bu nedenle bu deneyde tüm modeller duyarlıdan daha çok özgüdür. Şekil 4.2'de bu deneye ait karmaşıklık matrisleri gösterilmektedir.

		Kontrol		Osteoporotik		Kontrol		Osteoporotik		Kontrol		Osteoporotik		Kontrol		Osteoporotik	
		Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik				
Gerçek	Kontrol	62	8	55	15	56	14	50	20	57	13						
	Osteoporotik	18	52	13	57	14	56	11	59	12	58						
		AlexNet		GoogleNet		ResNet50		MobileNetV2		Inception-v3							
		Tahmin															

Şekil 4.2. Deney 2 için karmaşıklık matrisleri

4.3. Deney 3: B Veri Kümesinin Sınıflandırılması

Orijinal X-ışını görüntülerindeki kemik yapısının çizgileri oldukça bulanık ve belirsizdir. Bu nedenle, A veri kümesi görüntülerinin keskinliği %50 oranıyla yoğunlaştırılmış, bu da görüntüleri daha anlaşılır hale getirmiştir. A veri kümesine yeni keskin görüntüler eklenerek 1392 görüntüden oluşan yeni bir veri kümesi (B) oluşturulmuştur. Bu deneydeki test veri kümesi, 139 KT ve 139 OP görüntüsü olarak bölünmüş 278 görüntü içermiştir (1392'nin %20'si). Çizelge 4.1'de görüleceği gibi, doğruluk, özgüllük ve duyarlılık değerleri GoogleNet ile %98.5'lik ve InceptionV3 ile %97.4'lük doğruluk değerlerine ulaşacak şekilde etkileyici bir şekilde artmıştır. AlexNet, ResNet50 ve MobileNetV2 modelleri sırasıyla %95.3, %96 ve %94.9'lük doğruluk değerlerine ulaştırılmıştır. Çizelge 4.2'de, YN ve YP oranlarının azaldığını gösterilmiştir. GoogleNet, KT etiketli tüm 139 test görüntüsünü doğru bir şekilde sınıflandırmayı başarmıştır. Şekil 4.3'te bu deneye ait karmaşıklık matrisleri gösterilmektedir.

		Kontrol		Osteoporotik		Kontrol		Osteoporotik		Kontrol		Osteoporotik		Kontrol		Osteoporotik	
		Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik				
Gerçek	Kontrol	135	4	135	4	133	6	136	3	133	6						
	Osteoporotik	9	130	0	139	5	134	11	128	1	138						
		AlexNet		GoogleNet		ResNet50		MobileNetV2		Inception-v3							
		Tahmin															

Şekil 4.3. Deney 3 için karmaşıklık matrisleri

4.4. Deney 4: C Veri Kümesinin Sınıflandırılması

Önceki deneylerdeki veri kümeleri orijinal görüntüleri içermemiştir. Bu deneyde, original veri (174 görüntü) B veri kümesine (1392 görüntü) eklenerek toplam 1566 görüntü içeren C veri kümesi oluşturulmuştur. Bu deneydeki test veri kümesi, 157 KT ve 157 OP görüntüsü olarak bölünmüş 314 görüntü içermiştir (1566'nın %20'si). Çizelge 4.1 ve 4.2, elde edilen sonuçları göstermektedir. B veri kümesi ile ulaşılandan daha düşük doğruluk değerine sahip tek model olan GoogleNet dışında doğruluk değerleri artmaya devam etmiştir.

ResNet50 %99.02, AlexNet ve Inception-v3 ise %98.4 doğruluk değerlerine ulaşmıştır. Şekil 4.4'te bu deneye ait karmaşıklık matrisleri gösterilmektedir.

		Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik	Kontrol	Osteoporotik
Gerçek	Kontrol	152	5	154	3	157	0	155	2	157	0
	Osteoporotik	0	157	6	151	3	154	4	153	5	152
		AlexNet		GoogleNet		ResNet50		MobileNetV2		Inception-v3	
Tahmin											

Şekil 4.4. Deney 4'e ait karmaşıklık matrisleri

Çizelge 4.2'de gösterildiği gibi, AlexNet tüm KT örneklerini doğru olarak sınıflandırırken ($YN = 0$), ResNet50 ve Inception-v3 tüm OP örneklerini doğru olarak sınıflandırmıştır ($YP = 0$).

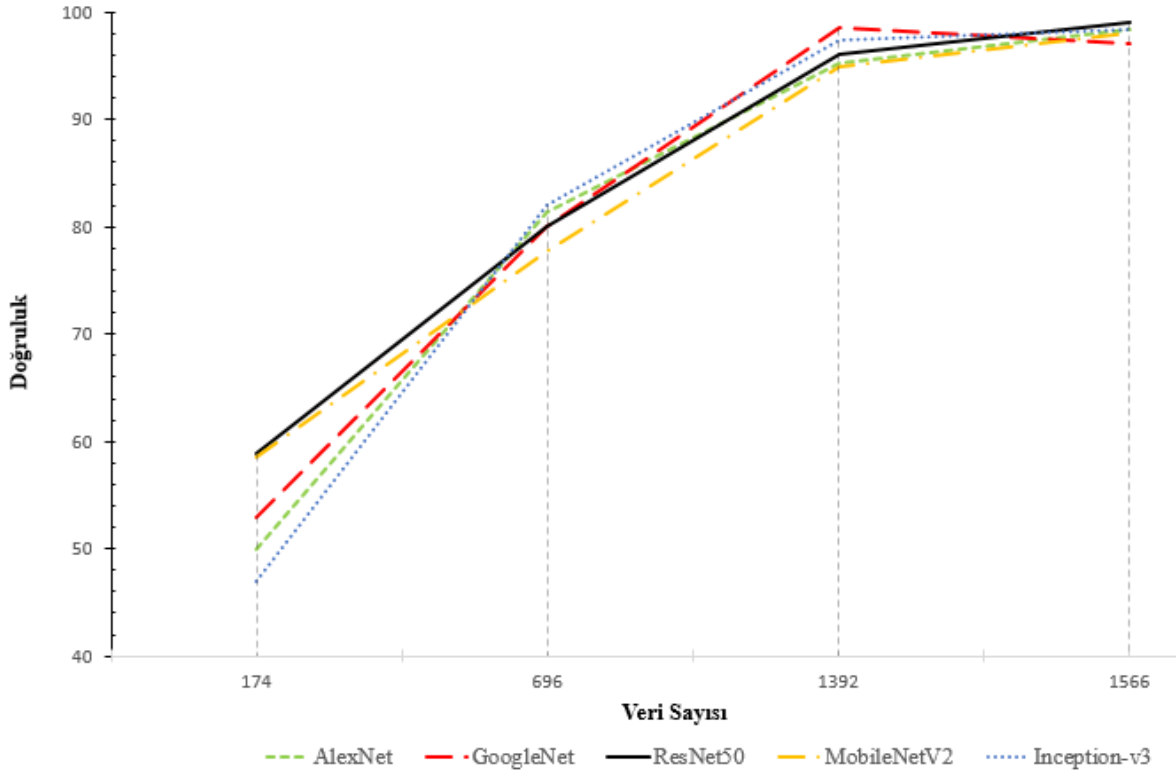
Çizelge 4.1. Tüm veri kümeleri için her mimari ile elde edilen doğruluk, duyarlılık ve özgüllük değerleri

Deney	Metrik	AlexNet	GoogleNet	ResNet50	MobileNetV2	InceptionV3
Deney 1 174 görüntü <i>N</i>	Doğruluk	%50	%52.9	%58.8	%58.6	%47
	Duyarlılık	%35.2	%58.8	%52.9	%64.7	%64.7
	Özgüllük	%64.7	%47	%64.7	%52.9	%29.4
Deney 2 696 görüntü <i>A</i>	Doğruluk	%81.4	%80	%80	%77.8	%82.1
	Duyarlılık	%88.5	%81.4	%80	%84.2	%82.8
	Özgüllük	%74.2	%78.5	%80	%71.4	%81.4
Deney 3 1392 görüntü <i>B</i>	Doğruluk	%95.3	%98.5	%96	%94.9	%97.4
	Duyarlılık	%93.5	%100	%96.4	%92.1	%99.2
	Özgüllük	%97.1	%97.1	%95.6	%97.8	%95.6
Deney 4 1566 görüntü <i>C</i>	Doğruluk	%98.4	%97.1	%99.02	%98	%98.4
	Duyarlılık	%100	%96.1	%98	%97.4	%96.8
	Özgüllük	%96.8	%98	%100	%98.7	%100

Genel bir gözlem olarak, ResNet50 ve Inception-v3 en iyi sınıflandırma sonuçlarına ulaşmıştır. Şekil 4.5'te, kullanılan farklı transfer öğrenme modellerinin performansları arasında bir karşılaştırma ve veri arttırmanın sınıflandırma başarısı üzerindeki etkisi gösterilmiştir.

Çizelge 4.2. Tüm veri kümeleri için her mimari ile elde edilen DP, DN, YP ve YN oranları.


Deney	Metrik	AlexNet	GooleNet	ResNet50	MobileNetV2	InceptionV3
Deney 1 N, 174 görüntü	DN	11	8	11	9	5
	DP	6	10	9	11	11
	YP	6	9	6	8	12
	YN	11	7	8	6	6
Deney 2 A, 696 görüntü	DN	52	55	56	50	57
	DP	62	57	56	59	58
	YP	18	15	14	20	13
	YN	8	13	14	11	12
Deney 3 B, 1392 görüntü	DN	135	135	133	136	133
	DP	130	139	134	128	138
	YP	4	4	6	3	6
	YN	9	0	5	11	1
Deney 4 C, 1566 görüntü	DN	152	154	157	155	157
	DP	157	151	154	153	152
	YP	5	3	0	2	0
	YN	0	6	3	4	5



Şekil 4.5. Deney 1, 2, 3 ve 4'te veri sayısının yeniden eğitilmiş transfer öğrenme modellerinin performansı üzerindeki etkisi

4.5. Deney 5: Basit bir ESA Modelinin Sıfırdan Eğitimi

C veri kümesinin (1566 görüntü) transfer öğrenme modelleri ile sınıflandırılmasına ek olarak, basit bir ESA modeli kullanılarak da sınıflandırılmıştır. Kullanılan model 5 katmandan oluşur; 4 evrimsel katman ve bir tam bağlı katman. İlk 3 evrimsel katmanın her birini bir maksimum havuzlama katmanı izlemektedir. Tam bağlı katmanı da çıktısını normalleştirecek bir softmax fonksiyonu takip etmektedir. Kullanılan ESA mimarisi, Şekil 4.6'da görülebilir. Bu deneyde de Çizelge 3.6'da gösterilen eğitim ayarları kullanılmıştır. Elde edilen sonuçlar Çizelge 4.3'te ve Şekil 4.7'deki karmaşıklık matrisinde gösterilmektedir.



Şekil 4.6. Kullanılan ESA mimarisi

Çizelge 4.3. Basit bir ESA modeli ve C veri seti ile elde edilen doğruluk, özgüllük ve duyarlılık değerleri

Doğruluk	Özgüllük	Duyarlılık	DP	DN	YP	YN
%96.1	%95.5	%96.8	152	150	7	5

		Gerçek	
		Kontrol	Osteoporotik
Gerçek	Kontrol	150	7
	Osteoporotik	5	152
		Tahmin	

Şekil 4.7. Deney 5'e ait karmaşıklık matrisi

4.6. Deney 6: 3-Katlamalı Çapraz Doğrulama

Ulaşılan sonuçları doğrulamak ve aşırı uyum probleminden kaçınmak için, son bir doğrulama deneyi olarak bir 3-katlamalı Çapraz Doğrulama (ÇD) gerçekleştirilmiştir. *C* veri kümesi (1566 görüntü), her biri 522 örnek içeren 3 alt kümeye bölünmüştür. 3-Katlı Çapraz Doğrulama ile her model 3 kez eğitilmiştir. Eğitim sürecinin sonunda, elde edilen doğrulukların ortalaması hesaplanmıştır. Çizelge 4.4'te, her model için elde edilen ortalama doğruluk değeri gösterilmiştir. Görüldüğü gibi GoogleNet, üç eğitim sürecinin her birinde tüm test görüntülerini doğru bir şekilde sınıflandırmayı başarmış ve %100'lük bir doğruluk elde edilmiştir. AlexNet mimarisi, önceki deneylere göre daha yüksek doğruluğa ulaşmıştır (%99.4). ResNet50, Inception-v3 ve MobileNetV2 modellerinin performansları, deney 4'teki performanslarıyla kıyasla azalmıştır.

Çizelge 4.4. Her model için 3 kat çapraz doğrulama ve *C* veri kümesi ile elde edilen ortalama doğruluk

3 Katlı Çapraz Doğrulama	AlexNet	GoogleNet	ResNet50	MobileNetV2	InceptionV3	Basit ESA
1566 görüntü	%99.4	%100	%97.6	%91.8	%94.4	90.7%

4.7. Deney 7: Maksimum (Çoğunluk) Oylama Yaklaşımı

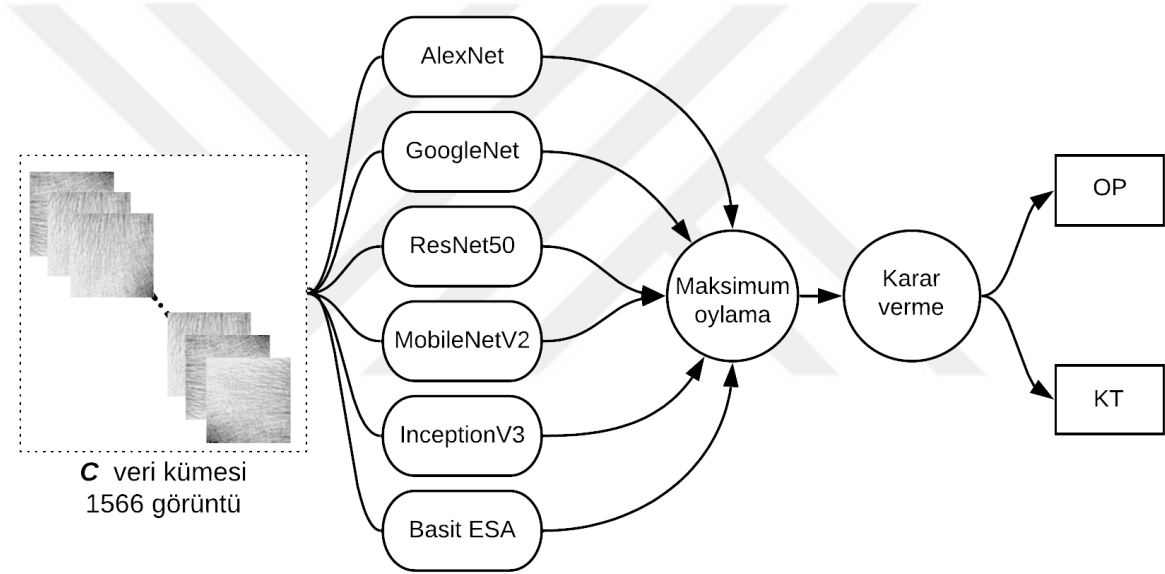
Maksimum (Çoğunluk) Oylama, yanlış sınıflandırılmış veri örneklerini en aza indirmek ve sonunda modelin doğruluğunu artırmak için kullanılan bir toplu öğrenme yöntemidir. Makine öğreniminde, karar vermek için bir grup sınıflandırıcıları birleştirmek için toplu öğrenme yöntemleri kullanılır (Opitz ve Maclin, 1999; Sagi ve Rokach, 2018). Bu çalışmada, önceden eğitilmiş modeller ve yukarıdaki basit ESA mimarisinden alınan kararlar birleştirilmiş ve sadece modellerin çoğunluğu tarafından doğru bir şekilde sınıflandırılmış örnekler (bu durumda çoğunluk 4 modeldir) doğru sınıflandırılmış olarak kabul edilmiştir. 2'den fazla model tarafından yanlış sınıflandırılan örnekler dikkate alınmamıştır. Bu yaklaşım kullanılarak, deney 4'te ResNet50 ile elde edildiği gibi %99.02'lik doğruluk oranına ulaşılmıştır. Bunun nedeni, ResNet50 tarafından yanlış sınıflandırılan üç OP görüntüsünün diğer 5 model tarafından da yanlış sınıflandırılmış olmasıdır. Bu deneyde, *C* veri kümesi kullanılmıştır. Test örneklerinin sayısı sınıf başına 157 görüntü olup toplamı 314 görüntüdür.

OP etiketli 157 görüntüden üç görüntü KT olarak, KT etiketli 157 görüntünün tamamı da KT olarak sınıflandırılmıştır.

Çizelge 4.4. Maksimum (çoğunluk) oylama yaklaşımı kullanılarak elde edilen sonuçlar

Doğruluk	Özgüllük	Duyarlılık	DP	DN	YP	YN
%99.02	%100	%98	154	157	0	3

Şekil 4.8, nihai bir karar vermek için kullanılan çoğunluk oylama yapısını göstermektedir.



Şekil 4.8. Çoğunluk oylama yaklaşımı ile osteoporozun belirlenmesi

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

X-ışını görüntülerinde sağlıklı ve osteoporotik hastaların kemik mikromimarisi arasındaki yüksek benzerlik nedeniyle, uygun bir veri arttırma yaklaşımı uygulamadan derin öğrenme modelleri kullanılarak osteoporoz sınıflandırması çok zorlayıcı bir problemdir. Buna rağmen, uygun bir veri arttırma stratejisi ile derin transfer öğrenme mimarileri kullanmak osteoporoz tanısını geliştirmekte büyük ölçüde katkı sağlayabilir. Elde edilen sonuçlar, uygulanan kontrast, parlaklık ve keskinlik manipülasyonunun, yeniden eğitilmiş modellere, sağlıklı ve osteoporotik veri örneklerinin sınıflandırılması için sınıflandırma doğruluğunu ciddi bir şekilde geliştiren ayrımcı bilgiler sağladığını göstermektedir.

İlk olarak, daha fazla eğitim verisi sağlamak ve modelin geliştirilebilirliğini arttırmak için orijinal verilere hem 90 hem de 270 derece rotasyon uygulanmıştır. Kontrast, parlaklık ve keskinlik ayarlamaları, kemik mikro mimarisinin ayrıntılarını canlandırarak kontrol ve osteoporotik görüntüler arasındaki benzerliği azaltmış ve görüntülerle ilgili daha fazla ayrımcı öznelilikler ortaya çıkarmıştır.

Veri artırmanın etkisi önceki bölümde anlatılan sınıflandırma deneyleri boyunca kolayca görülebilir. İlk olarak, orijinal veriler (174 görüntü) sınıflandırılmıştır. Orijinal veri ile eğitim yapıldığında önceden eğitilmiş modeller %47 ile %58.8 arasında değişen doğruluk değerleri sağlamıştır. Sonradan, 696 görüntü içeren *A* veri kümesi sınıflandırılmış ve doğruluk değerleri %77.8'den %82.1'e kadar değişerek yükseltilmiştir. Üçüncü deneyde, 1392 görüntüden oluşan *B* veri kümesi kullanılarak derin mimariler test edilmiştir. Bu deneyde mimarilerin performansı ciddi bir şekilde gelişerek doğrulukları büyük ölçüde artmıştır. *B* veri kümesi ile elde edilen en düşük doğruluk %94.9 iken (MobileNetV2 ile) %98.5 doğruluk ile GoogleNet en iyi performans göstermiştir. En iyi sınıflandırma sonuçları, 1566 görüntüden oluşan *C* veri kümesi kullanılarak elde edilmiştir. Bu deneyde, ResNet50 modeli ile %99,02'lik bir doğruluk elde edilmiştir. *C* veri kümesine veri arttırma uygulanarak görüntü sayısı 1566 aştığı zaman kullanılan modellerle elde edilen doğruluk değerlerinin hemen hemen aynı oldukları fark edilmiştir. Bu, veri sayısının bir eşik değeri olduğunu göstermiştir.

ResNet50 kullanılarak elde edilen sonuçlar incelendiğinde, orijinal veri seti (174 görüntü) kullanılarak ulaşılan %58.8 doğruluğunun, *A* veri seti (696 görüntü) ile %80'e çıktığı görülebilir. Daha sonra ResNet50 mimarisi *B* veri seti (1392 görüntü) ile eğitildiğinde veri arttırmanın etkisi ortaya çıkarak doğruluk oranı %96'ya yükselmiştir. Son olarak *C* veri kümesi (1566 görüntü) ile ResNet50 mimarisi %99,02 doğruluğa ulaşmıştır. Sınıflandırma doğruluğundaki bu gelişmeler, önerilen veri arttırma yaklaşımının modellerin performansı üzerindeki olumlu etkisini açık bir şekilde göstermektedir. Ayrıca, 3-katlamalı çapraz doğrulama kullanıldığında GoogleNet mimarisi test verisindeki tüm örnekleri doğru bir şekilde sınıflandırmış ve %100 doğruluk değerine ulaşmayı başarmıştır.

Kullanılan veri arttırma stratejisini daha ciddi bir şekilde test etmek için, *C* veri kümesi sıfırdan eğitilmiş basit bir ESA modeliyle sınıflandırılmıştır. Model, izlenen veri arttırma yaklaşımının katkısını ortaya koyacak şekilde %96.1'lik bir doğruluk oranına ulaşmıştır.

Önerilen yaklaşımın verimliliği, literatürde mevcut yöntemlerle karşılaştırılmıştır. Çizelge 5.1, Literatür Traması bölümünde bahsi geçen ilgili çalışmaları ve onlarla ilişkin bilgileri ele almıştır. Görüldüğü gibi Transfer Öğrenme, %84 ve %79.3 doğruluk değerlerinin elde edildiği farklı çalışmalarda da kullanılmıştır (Lee ve ark., 2020; Sylvia Grace ve ark., 2019). Evrişimsel Sinir Ağları'nın kullanıldığı ve %93.8 ve %89.2 doğruluk değerlerinin elde edildiği çalışmalar da Çizelge 5.1'de görülebilir (Ciuşdel ve ark., 2017; Tomita ve ark., 2018)

Tez çalışmasında ulaşılan ResNet50 ile %99.02 ve 3-Katlamalı Çapraz Doğrulama ile GoogleNet kullanılarak %100 doğruluk değerleri, literatürde osteoporoz sınıflandırmak için makine öğrenimi tekniklerini kullanan çalışmalardan daha başarılı sonuçlara ulaşıldığını göstermektedir.

Çizelge 5.1. Tez çalışmasında elde edilen sonuçlar ile literatürdeki çalışma sonuçlarının karşılaştırılması

Çalışma	Yıl	Veri	Yöntem	Doğruluk
3D image analysis and artificial intelligence for bone disease classification (Akgundogdu ve ark., 2010)	2010	18 trabeküler kemik örneği	Genetik Algoritma	% 100
Genetic Algorithm and Image Processing for Osteoporosis Diagnosis (Jennane ve ark., 2010)	2010	18 trabeküler kemik örneği	Genetik Algoritma	% 100

Trabecular Bone Texture Classification Using 1D LBP and Wavelet Coefficients in High-pass Bands(Houam ve ark., 2011)	2011	80 X-ışını topuk kemiği görüntüleri	1B Yerel İkili Desen (1DLBP)	%85 AUC
Early Diagnosis Of Osteoporosis Using Artificial Neural Networks And Support Vector Machines (İstanbulu ve ark., 2012)	2012	80 bilgisayarlı tomografi görüntüsü	Destek Vektör Makinesi (DVM)	%86
Osteoporosis Assessment Using Multilayer Perceptron Neural Networks (Harrar ve ark., 2012)	2012	120 X-ışını topuk kemiği görüntüleri	Çok Katmanlı Algılayıcı (ÇKA)	%97
Osteoporosis Diagnosis using Fractal Analysis and Support Vector Machine (Tafraoui ve ark., 2014)	2014	77 X-ışını topuk kemiği görüntüleri	Destek Vektör Makinesi (DVM)	%95
Diagnosis of osteoporosis disease from bone X-ray images with Stacked Sparse Auto-encoder and SVM classifier (Nasser ve ark., 2017)	2017	174 X-ışını topuk kemiği görüntüleri	Destek Vektör Makinesi (DVM)	%95.5
Towards Deep Learning Based Estimation of Fracture Risk in Osteoporosis Patients (Ciuşdel ve ark., 2017)	2017	Sentetik veriler 25000 trabeküler kemik örneği	Evrışimsel Sınır Ağları (ESA)	%93.8
Classification Of The Trabecular Bone Structure Of Osteoporotic Patients Using Machine Vision (Singh ve ark., 2017)	2017	174 X-ışını topuk kemiği görüntüleri	Destek Vektör Makinesi (DVM)	%98
Deep neural networks for automatic detection of osteoporotic vertebral fractures on CT scans (Tomita ve ark., 2018)	2018	1432 bilgisayarlı tomografi görüntüsü	ESA + Uzun Kısa Süreli Bellek (UKSB)	%89.2
Osteoporosis identification based on the validated trabecular area on digital dental radiographic images (Sela ve Pulungan, 2019)	2019	84 dijital diş radyografik görüntüleri	Çok Katmanlı Algılayıcı (ÇKA)	%87.87
Osteoporosis Detection Using Deep Learning (Sylvia Grace ve ark., 2019)	2019	174 X-ışını topuk kemiği görüntüleri	Transfer Öğrenme (TÖ) - VGG16	%79.3
Evaluation of Transfer Learning with Deep Convolutional Neural Networks for Screening Osteoporosis in Dental Panoramic Radiographs (Lee ve ark., 2020)	2020	680 hasta	Transfer Öğrenme (TÖ) - VGG16	%84
Bu Çalışma	2020	1566 X-ışını topuk kemiği görüntüleri	Çoğunluk Oylama	%99.02
Bu Çalışma	2020	1566 X-ışını topuk kemiği görüntüleri	TÖ - GoogleNet + 3-Katlamalı Çapraz Doğrulama	%100

5.2. Öneriler

Bu tez çalışmasında elde edilen yüksek doğruluk değerlerine, önerilen veri artırma yaklaşımının, kullanılan transfer öğrenme mimarilerinin ve seçilen eğitim parametrelerinin sayesinde ulaşılmıştır.

Tez çalışmasında kullanılan topuk kemiğinin X-ışını görüntülerine benzer ve kemik mikro yapısındaki detayların yeterli şekilde açık olmadığı verilerin sınıflandırılacağı problemlerde, görüntülerin parlaklığı ve kontrastı değiştirerek daha iyi görüntüler elde edilebilir. Parlaklık ve kontrast azaltma veya artırma oranları veriye göre değişebildiğinden denemeler yapılarak en ideal sonuçları veren oranlar seçilmiştir.

Ayrıca, kemik mikro yapısındaki çizgilerin bulanık olduğu durumlarda, keskinliğin artırılması kesinlikle önerilir. Bu tez çalışmasında görüntüler bulanık olduğu için, keskinliği 50% oranı ile arttırılmıştır. Keskinlik arttırmanın uygulanması, görüntüleri netleştirdiği için sınıflandırma doğruluklarını büyük ölçüde yükseltmiştir.

Veri arttırma stratejisinden ziyade, seçilen eğitim ayarları ve aktivasyon fonksiyonlar çok önemli rol oynamaktadır. ReLU aktivasyon fonksiyonunun kullanılması, kaybolan gradyanlar sorununu önleyerek ve eğitim sürelerini azaltarak modellerin verimli bir şekilde eğitilmesine yardımcı olmuştur. Ayrıca, MSGİ (Momentum ile Stokastik Gradyan İniş) optimize edicinin kullanılması, gradyan vektörlerini optimum yönde hızlandırarak hatanın minimize edilmesine yardımcı olmuştur.

Benzer sınıflandırma problemlerinde, ResNet50 ve GoogleNet mimarilerin kullanılması uygun bulunmuştur. Ardından Inception-v3 ve AlexNet mimarileri gelmektedir. MobileNetV2 en düşük doğruluk değerlerini elde ederek diğer mimariler kadar başarılı olmamıştır. Eğitim için harcadıkları süreleri göz önüne alınırsa, AlexNet en az süre gerektiren mimari olmuştur. Bu, en az katman içeren mimari olduğundan doğmaktadır. AlexNet'ten sonra GoogleNet gelmektedir. ResNet50, Inception-v3 ve MobileNetV2 mimarileri ise, AlexNet ve GoogleNet'in harcadığı sürelerin 2 katından fazla harcamaktadır.

Sonuç olarak, önerilen veri artırma stratejisine ve eğitim ayarlarına sahip bir yaklaşım, osteoporozun erken tanısına kayda değer bir katkıda bulunabileceği söylenebilir.

KAYNAKLAR

- Adams, J. E., 2009, Quantitative computed tomography, *European journal of radiology*, 71(3), 415-424.
- Akgundogdu, A., Jennane, R., Aufort, G., Benhamou, C. L., Ucan, O. N. ,2010, 3D image analysis and artificial intelligence for bone disease classification, *Journal of medical systems*, 34(5), 815-828.
- Allaire, B., Lu, D., Johannesdottir, F., Kopperdahl, D., Keaveny, T., Jarraya, M., Kiel, D., 2019, Prediction of incident vertebral fracture using CT-based finite element analysis, *Osteoporosis International*, 30(2), 323-331.
- Alom, M. Z., Taha, T.M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Asari, V. K., 2018, The history began from alexnet: A comprehensive survey on deep learning approaches, *arXiv preprint arXiv:1803.01164*.
- Anonymous, Osteoporosis: a silent disease [online], Retrieved from <https://www.thedailystar.net/health/news/osteoporosis-silent-disease-1722598> [Ziyaret Tarihi: 14 Haziran 2020].
- Anonymous, 2020, National Osteoporosis Foundation [online], <https://www.nof.org/patients/diagnosis-information/bone-density-examtesting>, [Ziyaret Tarihi: 14 Haziran 2020].
- Anonymous, MathWorks [online], <https://www.mathworks.com/help/images/ref/imsharpen.html> [Ziyaret Tarihi: 05 Mayıs 2020].
- Binkley, N., 2009, A perspective on male osteoporosis, *Best Practice & Research Clinical Rheumatology*, 23(6), 755-768.
- Cao, G., Huang, L., Tian, H., Huang, X., Wang, Y., Zhi, R., 2018, Contrast enhancement of brightness-distorted images by improved adaptive gamma correction, *Computers & Electrical Engineering*, 66, 569-582.
- Chollet, F., 2017, *Xception: Deep learning with depthwise separable convolutions*, Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Christodoulou, C., Cooper, C., 2003, What is osteoporosis? *Postgraduate medical journal*, 79(929), 133-138, doi:10.1136/pmj.79.929.133.
- Ciuşdel, C. F., Vizitiu, A., Moldoveanu, F., Suci, C., Itu, L. M., 2017, *Towards deep learning based estimation of fracture risk in osteoporosis patients*, Paper presented at

- the 2017 40th International Conference on Telecommunications and Signal Processing (TSP).
- Deng, J., Dong, W., Socher, R., Li, L.J., Li, K., Fei-Fei, L., 2009, *Imagenet: A large-scale hierarchical image database*, Paper presented at the 2009 IEEE conference on computer vision and pattern recognition.
- Elliot, J.R., Fenton, A.J., Young, T., Mansfield, A., Burton, C., Wilkinson, T. J., 2005, The precision of digital X-ray radiogrammetry compared with DXA in subjects with normal bone density or osteoporosis, *Journal of Clinical Densitometry*, 8(2), 187-190.
- Glüer, C.-C., Jergas, M., Hans, D., 1997, *Peripheral measurement techniques for the assessment of osteoporosis*, Paper presented at the Seminars in nuclear medicine.
- Goodfellow I, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, Courville A, Bengio Y., 2014, Generative adversarial nets, *In Advances in neural information processing systems*, pp. 2672-2680.
- Gonzalez, C. R. and Woods, R.E., 2006, *Digital Image Processing (3rd Edition)*, Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 35, 63-85.
- Harrar, K., Hamami, L., Akkoul, S., Lespessailles, E., Jennane, R., 2012, *Osteoporosis assessment using Multilayer Perceptron neural networks*, Paper presented at the 2012 3rd International Conference on Image Processing Theory, Tools and Applications (IPTA).
- Haykin, S., 1996, Neural networks expand SP's horizons, *IEEE Signal Processing Magazine*, 13(2), 24-49.
- He, K., Zhang, X., Ren, S., Sun, J., 2016, *Deep residual learning for image recognition*, Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Hinton, G.E., Srivastava, N., Krizhevsky, A., Sutskever, I., Salakhutdinov, R.R., 2012, Improving neural networks by preventing co-adaptation of feature detectors, *arXiv preprint arXiv:1207.0580*.
- Hochreiter, S., 1998, The vanishing gradient problem during learning recurrent neural nets and problem solutions, *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(02), 107-116.
- Houam, L., Hafiane, A., Boukrouche, A., Lespessailles, E., Jennane, R., 2012, *Texture characterization using local binary pattern and wavelets, Application to bone radiographs*, Paper presented at the 2012 3rd International Conference on Image Processing Theory, Tools and Applications (IPTA).

- Houam, L., Hafiane, A., Jennane, R., Boukrouche, A., Lespessailles, E., 2011, *Trabecular bone texture classification using 1d lbp and wavelet coefficients in high-pass bands*, Paper presented at the International Conference on Signal, Image, Vision and their Applications SIVA.
- Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Adam, H., 2017, Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K.Q., 2017, *Densely connected convolutional networks*, Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Ioffe, S., Szegedy, C., 2015, Batch normalization: Accelerating deep network training by reducing internal covariate shift, *arXiv preprint arXiv:1502.03167*.
- İşık, G., Artuner, H., 2016, *Recognition of radio signals with deep learning Neural Networks*, Paper presented at the 2016 24th Signal Processing and Communication Application Conference (SIU).
- İstanbullu, M., Aydin, M., Benveniste, R., Uçan, O.N., Jennane, R., 2012, *Early diagnosis of osteoporosis using artificial neural networks and support vector machines*, Paper presented at the 2012 20th Signal Processing and Communications Applications Conference (SIU).
- Jennane, R., Almhdi-Imjabber, A., Hambli, R., Ucan, O.N., Benhamou, C.-L., 2010, *Genetic algorithm and image processing for osteoporosis diagnosis*, Paper presented at the 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology.
- Jennane, R., Harba, R., Lemineur, G., Bretteil, S., Estrade, A., Benhamou, C.L., 2007, Estimation of the 3D self-similarity parameter of trabecular bone from its 2D projection, *Medical Image Analysis*, 11(1), 91-98.
- Johannesdottir, F., Allaire, B., Bouxsein, M. L., 2018, Fracture prediction by computed tomography and finite element analysis: current and future perspectives, *Current osteoporosis reports*, 16(4), 411-422.
- Kling, J.M., Clarke, B.L., Sandhu, N.P., 2014, Osteoporosis prevention, screening, and treatment: a review, *Journal of women's health*, 23(7), 563-572.
- Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012, *Imagenet classification with deep convolutional neural network*,. Paper presented at the Advances in neural information processing systems.

- LeCun, Y., Boser, B.E., Denker, J. S., Henderson, D., Howard, R.E., Hubbard, W. E, Jackel, L.D, 1990, *Handwritten digit recognition with a back-propagation network*, Paper presented at the Advances in neural information processing systems.
- Lee, K.-S., Jung, S.-K., Ryu, J.-J., Shin, S.-W., Choi, J., 2020, Evaluation of Transfer Learning with Deep Convolutional Neural Networks for Screening Osteoporosis in Dental Panoramic Radiographs, *Journal of Clinical Medicine*, 9(2), 392.
- Lespessailles, E., Gadois, C., Kousignian, I., Neveu, J., Fardellone, P., Kolta, S., Benhamou, C., 2008, Clinical interest of bone texture analysis in osteoporosis: a case control multicenter study, *Osteoporosis International*, 19(7), 1019-1028.
- Lin, M., Chen, Q., Yan, S., 2013, Network in network, *arXiv preprint arXiv:1312.4400*.
- Marcelino, P., 2018, Transfer learning from pre-trained models [online]. Towards Data Science. <https://towardsdatascience.com/transfer-learning-from-pre-trained-models> [Ziyaret Tarihi: 14 Haziran 2020].
- Nasser, Y., El Hassouni, M., Brahim, A., Toumi, H., Lespessailles, E., Jennane, R., 2017, *Diagnosis of osteoporosis disease from bone X-ray images with stacked sparse autoencoder and SVM classifier*, Paper presented at the 2017 International Conference on Advanced Technologies for Signal and Image Processing (ATSIP).
- Nwankpa, C., Ijomah, W., Gachagan, A., Marshall, S., 2018, Activation functions: Comparison of trends in practice and research for deep learning, *arXiv preprint arXiv:1811.03378*.
- Obulesu, M. and Kishore, V.V., 2012, A new approach for sharpness and contrast enhancement of an image, *International Journal of Advanced Research in Computer Engineering & Technology*, 1(4), 530-535.
- Opitz, D. and Maclin, R., 1999, Popular ensemble methods: An empirical study, *Journal of artificial intelligence research*, 11, 169-198.
- Perez, L. and Wang, J., 2017, The effectiveness of data augmentation in image classification using deep learning, *arXiv preprint arXiv:1712.04621*.
- Pisani, P., Renna, M. D., Conversano, F., Casciaro, E., Muratore, M., Quarta, E., Casciaro, S., 2013, Screening and early diagnosis of osteoporosis through X-ray and ultrasound based techniques, *World journal of radiology*, 5(11), 398.
- Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural networks*, 12(1), 145-151.
- Rawat, W. and Wang, Z., 2017, Deep convolutional neural networks for image classification: A comprehensive review, *Neural computation*, 29(9), 2352-2449.

- Reddy, T. and Kumaravel, N., 2010, Segmentation and Classification of Jaw Bone CT images using Curvelet based Texture features, *Bangladesh Journal of Medical Science*, 9(1), 33-43.
- Rosholm, A., Hyldstrup, L., Baeksgaard, L., Grunkin, M., Thodberg, H., 2001, Estimation of bone mineral density by digital X-ray radiogrammetry: theoretical background and clinical testing, *Osteoporosis International*, 12(11), 961-969.
- Ruder, S., 2016, An overview of gradient descent optimization algorithms, *arXiv preprint arXiv:1609.04747*.
- Sagi, O. and Rokach, L., 2018, Ensemble learning: A survey, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), e1249.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.-C., 2018, *Mobilenetv2: Inverted residuals and linear bottlenecks*, Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Scanlan, J., Li, F.F., Umnova, O., Rakoczy, G., Lövey, N., Scanlan, P., 2018, Detection of osteoporosis from percussion responses using an electronic stethoscope and machine learning, *Bioengineering*, 5(4), 107.
- Sela, E. I. and Pulungan, R., 2019, Osteoporosis identification based on the validated trabecular area on digital dental radiographic images, *Procedia Computer Science*, 157, 282-289.
- Sevestre-Ghalila, S., Benazza-Benyahia, A., Ricordeau, A., Mellouli, N., Chappard, C., Benhamou, C.L., 2004, *Texture image analysis for osteoporosis detection with morphological tools*, Paper presented at the International Conference on Medical Image Computing and Computer-Assisted Intervention.
- Shinde, P.P. and Shah, S., 2018, *A Review of Machine Learning and Deep Learning Applications*, Paper presented at the 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA).
- Shorten, C., Khoshgoftaar, T. M., 2019, A survey on image data augmentation for deep learning, *Journal of Big Data*, 6(1), 60.
- Simonyan, K., Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*.
- Sindel, D. and Gula, G., 2015, Assessment of Bone Mineral Density in Osteoporosis, *Türk Osteoporoz Dergisi*, 21(1).
- Singh, A., Dutta, M.K., Jennane, R., Lespessailles, E., 2017, Classification of the trabecular bone structure of osteoporotic patients using machine vision, *Computers in biology and medicine*, 91, 148-158.

- Smith, S. W., 1997, The scientist and engineer's guide to digital signal processing.
- Sözen, T., Özışık, L., Başaran, N.Ç., 2017, An overview and management of osteoporosis, *European journal of rheumatology*, 4(1), 46.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., 2014, Dropout: a simple way to prevent neural networks from overfitting, *The journal of machine learning research*, 15(1), 1929-1958.
- Sylvia Grace, J., Kumar, D., Gautam, R., Mark Sachin, K., 2019, Osteoporosis Detection Using Deep Learning.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A., 2015, *Going deeper with convolutions*, Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z., 2016, *Rethinking the inception architecture for computer vision*, Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Tafraouti, A., El Hassouni, M., Toumi, H., Lespessailles, E., Jennane, R., 2014, *Osteoporosis diagnosis using fractal analysis and support vector machine*, Paper presented at the 2014 Tenth International Conference on Signal-Image Technology and Internet-Based Systems.
- Tang, Y., 2013, Deep learning using linear support vector machines. *arXiv preprint arXiv:1306.0239*.
- Tomita, N., Cheung, Y.Y., Hassanpour, S., 2018, Deep neural networks for automatic detection of osteoporotic vertebral fractures on CT scans, *Computers in biology and medicine*, 98, 8-15.
- Touvier, J., Winzenrieth, R., Johansson, H., Roux, J., Chaintreuil, J., Toumi, H., Lespessailles, E., 2015, Fracture discrimination by combined bone mineral density (BMD) and microarchitectural texture analysis. *Calcified tissue international*, 96(4), 274-283.
- Tuck, S. P. and Francis, R. M., 2002, Osteoporosis. *Postgraduate medical journal*, 78(923), 526-532, doi:10.1136/pmj.78.923.526
- Yates, A.J., Ross, P.D., Lydick, E., Epstein, R.S., 1995, Radiographic absorptiometry in the diagnosis of osteoporosis, *The American journal of medicine*, 98(2), 41S-47S.
- Zoph, B., Vasudevan, V., Shlens, J., Le, Q.V., 2018, *Learning transferable architectures for scalable image recognition*, Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Mohamad Melad Ali ASHAMES
Uyruğu : Libya
Doğum Yeri ve Tarihi : Trablus / 01.09.1994
Telefon : 05414685007
E-Posta : muhashames@gmail.com

EĞİTİM

Lise : Al-Asma Mühendislik Lisesi/Trablus/Trablus / 2012
Üniversite : Selçuk Üniversitesi / Selçuklu / Konya / 2018
Yüksek Lisans : Konya Teknik Üniversitesi/ Selçuklu / Konya / 2020

UZMANLIK ALANI: ELEKTRİK – ELEKTRONİK MÜHENDİSLİĞİ

YABANCI DİLLER: ARAPÇA / İNGİLİZCE