



**YAPAY ZEKÂ TEKNİKLERİ KULLANILARAK  
KEMİK YAŞI TESPİTİ**

**Osman DEMİREL**

**2022  
YÜKSEK LİSANS TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı  
Dr. Öğr. Üyesi Emrullah SONUÇ**

**YAPAY ZEKÂ TEKNİKLERİ KULLANILARAK KEMİK YAŞI TESPİTİ**

**Osman DEMİREL**

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

**Tez Danışmanı  
Dr. Öğr. Üyesi Emrullah SONUÇ**

**KARABÜK  
Nisan 2022**

Osman DEMİREL tarafından hazırlanan “YAPAY ZEKÂ TEKNİKLERİ KULLANILARAK KEMİK YAŞI TESPİTİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Emrullah SONUÇ

.....

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 21/04/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Dr. Öğr. Üyesi Caner ÖZCAN (KBÜ)

ONLINE

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

ONLINE

Üye : Dr. Öğr. Üyesi Emrullah SONUÇ (KBÜ)

ONLINE

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

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

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

Osman DEMİREL

## ÖZET

Yüksek Lisans Tezi

### YAPAY ZEKÂ TEKNİKLERİ KULLANILARAK KEMİK YAŞI TESPİTİ

Osman DEMİREL

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Emrullah SONUÇ

Nisan 2022, 48 sayfa

Radyografiden kemik yaşının belirlenmesi, çocuk gelişiminin takibinde ve adli tıpta önemli bir yer tutar. Kemik yaşı tayini genellikle Greulich ve Pyle (G&P) yöntemi veya Tanner-Whitehouse (TW) yöntemi kullanılarak sol elin radyolojik muayenesi ile yapılmaktadır. Bu yöntemler gözlemsel eşleşmelere dayalı sonuçlar üretir ve bu durum radyologların tespitleri arasında farklara neden olabilmektedir. Çalışmamızın amacı, hekimlerin yaş tespitinde kullanabilecekleri destekleyici bir yöntem sunarak daha bir başarılı tahmin yapmalarına olanak sağlamaktır. Bu çalışmada, kemik yaşını otomatik olarak değerlendirmek için karpal kemiklerin hesaplanmış alanları ve radiusun distal epifiz bölgesinin birlikte kullanıldığı bir yöntem önerilmiştir. 1-7 yaş arası erkek ve kız çocukların sol el grafiklerini içeren yerli bir veri seti kullanılmıştır. Karpal kemikler, DICOM (Digital Imaging and Communications in Medicine, Tıpta Dijital Görüntüleme ve İletişim) görüntü penceresi değişkenleri, kenar ve kontur tespit ediciler kullanılarak ayrıştırılmıştır. Ayrışan karpal kemikler manuel olarak seçilerek alanlar hesaplanmıştır. Kontur alanları ve radiusun distal epifiz bölgesi veri seti olarak kullanılmıştır. Ağın eğitimi sonunda %87 doğrulama başarımına sahip model elde edilmiştir. Model test edildiğinde başarı oranı %85 olarak ölçülmüştür. Çalışma

sonunda önerilen yöntemin kemik yaşının belirlenmesinde etkili olduğu sonucuna varılmıştır.

**Anahtar Sözcükler :** Bilgisayarlı kemik yaşı değerlendirmesi; Evrişimsel sinir ağıları, Tanner-Whitehouse; Greulich ve Pyle.

**Bilim Kodu** : 92432

## **ABSTRACT**

**M. Sc. Thesis**

# **BONE AGE DETERMINATION USING ARTIFICIAL INTELLIGENCE TECHNIQUES**

**Osman DEMİREL**

**Karabük University**

**Institute of Graduate Programs**

**Department of Computer Engineering**

**Thesis Advisor:**

**Assist.Prof.Dr. Emrullah SONUÇ**

**April 2022, 48 pages**

Determination of bone age from radiography is important in pediatric development follow-up and forensic medicine. Bone age determination is usually made by radiological examination of the left hand using the Greulich and Pyle (G&P) method or the Tanner-Whitehouse (TW) method. These methods produce results based on observational matches, which can cause differences in the determinations of radiologists. The aim of our study is to provide a supportive method that physicians can use in age determination, allowing them to make a more successful estimation. In this study, a method is proposed in which the calculated areas of carpal bones and the distal epiphyseal region of the radius are used together to assess bone age automatically. A native data set containing left hand graphics of boys and girls aged 1-7 was used. Carpal bones were decomposed using DICOM (Digital Imaging and Communications in Medicine) image window variables, edge and contour detectors. Areas were calculated by manually selecting the dissociated carpal bones. Contour areas and the distal epiphyseal region of the radius were used as the data set. At the end of the training of the network, a model with a validation success of 87% was obtained. When the model was tested, the success rate was measured as 85%. As a

result of the study, it was concluded that the proposed method is effective in determining bone age.

**Key Word** : Computerized bone age assessment; Convolutional neural networks; Tanner–Whitehouse; Greulich and Pyle

**Science Code** : 92432



## TEŐEKKÖR

Bu tez alıőmasının planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Dr. Öęr. Üyesi Emrullah SONU'a sonsuz teőekkürlerimi sunarım.

Veri setini temin ettięimiz, Samsun İl Saęlık Müdürlüęüne teőekkür ederim.

Sevgili aileme manevi hiçbir yardımı esirgemedен yanımda oldukları için tüm kalbimle teőekkür ederim.

## İÇİNDEKİLER

	<b><u>Sayfa</u></b>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER .....	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ .....	xiv
KISALTMALAR DİZİNİ.....	xv
BÖLÜM 1 .....	1
GİRİŞ .....	1
1.1. PROBLEMİN TANIMI .....	2
1.2. ÇALIŞMANIN KAPSAMI.....	2
1.3. LİTERATÜR ÖZETİ .....	2
BÖLÜM 2 .....	6
KEMİKLEŞME VE YAŞ TAYİNİ .....	6
2.1. GREULICH VE PYLE YÖNTEMİ.....	7
2.3. TANNER-WHITEHOUSE YÖNTEMİ.....	8
BÖLÜM 3 .....	9
GÖRÜNTÜ İŞLEME VE VERİ SETİ.....	9
3.1. GÖRÜNTÜ İŞLEME .....	9
3.1.1. Hounsfield Birimi .....	9
3.1.2. Pencereleme.....	10
3.1.3. Kenar Belirleme.....	11
3.1.4. Kontur Belirleme .....	13
3.2. GEOMETRİK DÖNÜŞÜMLER.....	13

	<b><u>Sayfa</u></b>
3.2.1. Öteleme.....	13
3.2.2. Yansıtma .....	15
3.2.3. Ölçekleme .....	16
3.2.4. Döndürme .....	18
3.2.5. Tuval boyutunun belirlenmesi. ....	19
3.3. VERİ SETİ .....	20
3.3.1. Karpal kemiklerin seçimi.....	20
3.3.2. Radius kemiğinin seçilmesi ve kesme işlemi .....	21
3.3.3. Veri artırımı .....	23
3.3.4. Kesilen Radius bölgesinin yeniden ölçeklendirilmesi .....	24
3.3.5. Verilerin sınıf etiketlerinin oluşturulması.....	25
BÖLÜM 4 .....	26
EVİRİŞİMSEL YAPAY SİNİR AĞI.....	26
4.1. EVİRİŞİMSEL YAPAY SİNİR AĞI.....	26
4.1.1. Evrişimsel Katman.....	26
4.1.2. Havuzlama Katmanı .....	27
4.1.3. Düzleştirme.....	28
4.1.4. Tam Bağlantılı Katman.....	28
BÖLÜM 5 .....	29
ÇOK KATMANLI ALGILAYICI.....	29
BÖLÜM 6 .....	31
AĞIN EĞİTİMİ VE DOĞRULAMA .....	31
6.1. FARKLI VERİ TİPLERİNİN BİRLİKTE AĞA VERİLMESİ. ....	31
6.2. AĞIN EĞİTİMİ VE HİPER PARAMETRELERİNİN BELİRLENMESİ. .....	33
6.3. K-KATLAMALI ÇAPRAZ DOĞRULAMA VE TEST.....	33
BÖLÜM 7 .....	35
BULGULAR.....	35

	<b><u>Sayfa</u></b>
BÖLÜM 8 .....	41
TARTIŞMA VE SONUÇ .....	41
KAYNAKLAR .....	43
ÖZGEÇMİŞ .....	48

## ŞEKİLLER DİZİNİ

### Sayfa

Şekil 2.1. Bir ve altı yaşlarındaki çocukların sol el radyografileri .	6
Şekil 2.2. Bir yaş kız çocuğu sol el grafisi .	7
Şekil 2.3. Epifiz bölgesinin gelişimi .	8
Şekil 3.1. Farklı pencere değerleri .	11
Şekil 3.2. Kenar belirleyici Canny ile çalışan maskeler.....	12
Şekil 3.3. Piksel koordinatlarının ötelenmesi.....	14
Şekil 3.4. Tuval üzerinde öteleme işlemi. ....	15
Şekil 3.5. Yansıtma işleminin koordinat sisteminde gösterimi.....	16
Şekil 3.6. Piksel değiştirme işlemi .....	17
Şekil 3.7. İnterpolasyon matris işlemleri.....	17
Şekil 3.8. Döndürme işlemi.....	18
Şekil 3.9. Dönme işlemi sonrası tuval bilgisi.....	19
Şekil 3.10. Karpal kemiklerin alanları ve dizi yapısı.....	20
Şekil 3.11. Radius bölgesi açısı ve koordinatları Json görünümü. ....	21
Şekil 3.12. Radius ROI seçimi .....	21
Şekil 3.13. ROI Kesme maskesi uygulaması. ....	22
Şekil 3.14. Radius bölgesinin maske ile piksel dizisi verisi üzerinden kesilmesi. ....	22
Şekil 3.15. Kesilen DICOM görüntüsü. ....	23
Şekil 3.16. Veri büyütme kod parçası. ....	23
Şekil 3.17. Veri büyütme tek radius epifiz bölgesi .	24
Şekil 3.18. Etiket kodlama işlemine ait kod.....	25
Şekil 3.19. Ana veri setinden birbiriyle ilişkili yeni veri setlerinin elde edilmesi .....	25
Şekil 4.1. Evrişim katmanı özellik çıkarımı.....	27
Şekil 4.2. Havuzlama .	27
Şekil 4.3. Özellik matrisini düzleştirilmesi .	28
Şekil 4.4. Tam Bağlantılı Katman .	28
Şekil 5.1. Uygulamanın modeli .....	30
Şekil 6.1. Kesilen radius bölgesinin görüntü verisine ait bilgileri gösterir kod. ....	31
Şekil 6.2. Karpal kemik alanlarını içeren veri setine ait bilgiler.....	31

## Sayfa

Şekil 6.3. Eğitim ve doğrulama verilerinin ağa verilmesini gösterir kod parçası. ....	32
Şekil 6.5. Modelin serileşmiş evrişim katmanı .....	32
Şekil 6.4. Evrişim katmanına ait girdi tensorboard ekran görüntüsü.....	32
Şekil 6.3. Beş kat çapraz doğrulama .....	33
Şekil 6.4. 4100 görüntünün 5-kat çapraz doğrulama süreç grafiği. ....	34
Şekil 6.5. Model karşılaştırma grafiği.....	34
Şekil 7.1. KerasTuner kullanılarak elde edilen eniyi modelin başarımlar grafiği.....	35
Şekil 7.2. KerasTuner kullanılarak elde edilen eniyi modelin kayıp grafiği. ....	35
Şekil 7.3. Karışıklık Matrisi (F-Kız, M-Erkek, 1M -1 Yaş Erkek) .....	37
Şekil 7.4. Test verisinin model tahminine göre dağılımı (Kişi sayısı) .....	38
Şekil 7.5. Model başarımının test verisi üzerinde cinsiyet oransal dağılımı .....	38
Şekil 7.7. Ağın CNN bölümüne ait çapraz doğrulama performans grafiği.....	39
Şekil 7.6. Ana modelin CNN bölümü .....	39
Şekil 7.8 .Ana modelin MLP bölümü .....	40
Şekil 7.9. MLP modeli çapraz doğrulama performans grafiği.....	40

## ÇİZELGELER DİZİNİ

	<b><u>Sayfa</u></b>
Çizelge 3.1. Hounsfield Unit değerlerine karşılık gelen doku bilgisi.....	10
Çizelge 7.1. Çapraz doğrulama sonuçları. ....	36

## KISALTMALAR DİZİNİ

GP	: Greulich ve Pyle
Gb	: Gigabayt
CPU	: Central Process Unit(Merkezi İşlem Birimi)
GHz	: Gigahertz
TW	: Tanner Whitehouse
RUS	: Radius Unla Small
RMSD	: Root Mean Square Deviation (Ortalama Karekök Sapması)
R-CNN	: Region Based Convolutional Neural Networks (Bölgesel Evrişimsel Sinir Ağı)
RNN	: Recurrent neural network(Yinelemeli sinir ağı)
U-Net	: U-Shaped Convolutional Neural Network (U Şeklinde Evrişimsel Sinir Ağı)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağı)
HU	: Hounsfield Unit
LoG	: Laplacian of Gaussian
MLP	: Multi Layer Perceptiron (Çok Katmanlı Algılayıcı)
DICOM	:Digital Imaging and Communications in Medicine (Tıpta Dijital Görüntüleme ve İletişim)
ROI	:Region of interest(İlgili Bölge)
OTD	: Optimal transport distance(Optimum taşıma mesafesi)
GAN	:Generative Adversarial Networks(Çekişmeli üretici ağ)
BT	: Bilgisayarlı Tomografi
MR	: Manyetik Rezonans



## BÖLÜM 1

### GİRİŞ

Gelişimsel bozuklukların tedavi sürecinde çocukların kemik yaşının değerlendirilmesi önem arz etmektedir [1]. Büyüme hormonu eksikliği, hipotiroidizm, yetersiz beslenme ve kronik hastalığı olan çocuklarda yapısal büyüme geriliği görülebilmektedir [2]. Adli işlemlerde, yaşın şüpheli olduğu ve kişisel belgelerinin geçersiz veya mevcut olmadığı durumlarda yaş tespiti önem kazanmaktadır [3].

İnsanlar genelde sağ elini sürekli kullanmaktadır ve buna bağlı olarak sol el kemiklerinin deformasyonu az olduğundan değerlendirmelerde sol el kemikleri tercih edilmektedir [4]. Belirlenmiş standart bir prosedür olmamasına rağmen, çoğunlukla iki klinik yöntem kullanılmaktadır. En sık kullanılan yöntem Greulich ve Pyle (GP) yöntemidir. Ek olarak, TW2 ve TW3'ün en son sürümlerinde Tanner Whitehouse (TW) yöntemini içeren kemiğe özgü teknikler de uygulanmaktadır [5].

Greulich ve Pyle Atlası, erkek ve kadın sol el röntgen filmlerinin yer aldığı standart referans görüntüler içerir. Kemik yaşı tespiti, sol el bileği görüntülerinin atlastaki farklı yaşlar için standart olan görüntüler ile karşılaştırılması ve atlasta yer alan en yakın eşleşen referans görüntüleriyle tespit edilir [6].

TW Method, Tanner'ın Londra'da bakıma muhtaç çocukların kaldığı yurttaki 3000 erkek ve kız çocuk üzerinde her 6 ayda bir aldığı el bileği röntgen görüntülerini 12 yıl süreyle incelemesi sonucu oluşturulmuş bir kemik yaşı belirleme yöntemidir. Radius, unla ve kısa kemikler kısaca RUS harfleri ile ifade edilir ve 13 kemikten oluşur.

Bu yöntemde 13 kemik ve 7 karpal kemik 8 gelişim dönemine ayrılmıştır. Kemik gelişim süreci yaş hesabında kullanılmak üzere puanlandırılmıştır. Bireyin kemik yaşı, puanların toplamıyla elde edilmektedir [7].

### **1.1. PROBLEMİN TANIMI**

Kemik yaşı tespitinde atlasların kullanıldığı yöntemler uzmanların gözlemsel değerlendirmelerinin farklılıklarına bağlı olarak aynı sonuçları üretememe gibi bir sorunu ortaya çıkarır [8]. GP ve TW atlas yöntemleri genel kullanılabilirlik ve uzun değerlendirme süreci gibi dezavantajları bulunmaktadır. Bununla birlikte, bu yöntemler okuyucunun uzmanlığına ve tecrübesine son derece bağımlıdır [9]. Atlasla yapılan değerlendirmelerde gözlemci içi (aynı görüntü tekrar raporlama) veya gözlemciler arasında farklı yaş değerlendirmeleri ortaya çıkabilmektedir [10]. Objektif sonuçlar üreten yöntemlere ihtiyaç duyulmaktadır. Bilgisayar bilimi bu sorunsalı çözecek yeni yaklaşımları bilim dünyasına kazandırmaya devam etmektedir. Yapay zekâ algoritmalarını kullanan çözümlerin sayısı gün geçtikçe artmaktadır.

### **1.2. ÇALIŞMANIN KAPSAMI**

Kemik yaşının tespitine yönelik yöntemler ele alınarak, yaş tespitinde yapay zekâ algoritmalarından CNN ve MLP kullanımı bu tezin konusudur. Bu bağlamda kemik yaşında atlas kullanımı, DICOM görüntüsünün özellikleri, görüntü işleme ve yapay sinir ağı mimarisi ele alınacaktır. Farklı bir yaklaşımla tek bir DICOM görüntüsünden birden fazla görüntü örneği çıkarılarak karpal kemik seçimi yapılmıştır.

### **1.3. LİTERATÜR ÖZETİ**

Bilgi teknolojilerinin gelişimi, problemlerin çözümünde yeni yaklaşım ve yöntemlerin ortaya çıkmasına sebep olmuştur. Kemik yaşının tespitinde yapay zekânın kullanılması, bu yöntemlerden biri olarak literatürde karşımıza çıkmaktadır. Kemik yaşının tespitinde yapay zekanın kullanıldığı literatür hakkında bilgiler yazımızın bu bölümünde yer alacaktır.

Booz ve arkadaşları kemik yaşının tespitinde yapay zekanın etkinliğinin ortaya koyan çalışmalarında, görüntü analizini sıralı 3 ayrı adıma bölmüştür. İlk olarak, kemik yaşı tespitinde kullanılacak 13 kemik bölgesi otomatik olarak tespit edilir. İkinci adımda, tanımlanan her kemik için kemik yaşı değerleri belirlenir. Son olarak da hesaplanan kemik yaşı değerlerini Greulich-Pyle veya Tanner-Whitehouse kemik yaşı değerlerine dönüştürülerek yaş hesaplanır. Sonuçlar incelendiğinde kronolojik yaşın, yapay zekâ yaş tahmini ile RMSD değeri 0,56 yıl GP atlas yaş tahminine göre RMSD' si 1,12 yıl hesaplanmıştır. Çalışmada, kullanılan yapay zekâ sisteminin ortalama okuma sürelerini %87 azalttığı bilgisi de yerilmiştir [9]. Booz ve arkadaşları yapay zekâ tabanlı çözümlerin avantaj ve başarımını destekler sonuçlar elde etmiştir. Yapay zekâ tekniklerinin tekrarlanabilir doğru sonuçlar elde etmesi ve bunu yaparken zamanı çok iyi kullanması bu alanda ilgili üzerine çekmektedir.

Birçok çalışmada DICOM görüntüleri veri seti olarak kullanılmaktadır. Dijital görüntüleme cihazlarının yaygınlaşmadığı, manuel yöntemlerle baskının yapıldığı dönemlere ait veriler araştırmanın bir parçası olduğunda baskılar özel tarayıcı cihazlar aracılığıyla dijital ortama aktarılmaktadır. Literatürde görüntünün taranarak dijital ortama aktırıldığı birçok çalışma bulunmaktadır. Kemik yaşında sol el görüntülerinin kullanıldığı bir çalışmada 8 bit gri seviye ve 600 dpi parametreleri ile yüksek çözünürlüklü bir tarayıcı ile dijitalleştirilmiş görüntüler kullanılmıştır. Dijitalleştirilmiş görüntüler bilgisayar ortamında görüntü işleme teknikleri ile karpal kemikler ayrıştırılarak her bir kemik için özellik bilgileri elde edilmiştir. Özellikler x, y eksen bilgisine ait varyans, karpal kemik merkezlerinin en uzak ve en yakın noktaları, kemik alan ve çevresi olarak çıkarılmıştır. Kemik yaşını kategorize etmek için doğrusal, en yakın komşu, geri yayılım sinir ağı ve radyal temel işlevli sinir ağı olmak üzere dört sınıflandırıcı kullanarak kemik yaşı tespit edilmeye çalışılmıştır. Sonuç olarak çalışmadan geri yayılım sinir ağı ve radyal temel işlevli sinir ağının daha başarılı olduğu ayrıca alan özelliğinin sınıflandırmada baskın rol aldığı kanaatine varılmıştır [11].

Kemik yaşı tespitinde önemli yeri olan karpal kemikler görüntülerden manuel seçilebildiği gibi otomatik tespiti sağlayacak çözümlerde mevcuttur. Literatürde örnek olarak gösterilebilecek bir çalışmada görüntüden elin kemiklerini ayrıştırılması için

hafif bir U-Net mimarisi çok ölçekli evrişimsel ağ önerilmiştir. Kompakt yapı, iki alt örnekleme ve yukarı örnekleme işlemine sahip U-Net mimarisine dayanmaktadır ve çocuklarda büyüme sırasında el kemik ölçeği değişikliklerine karşı koymak için farklı çekirdek boyutuna sahip çoklu filtreler benimsenmiştir. U-Net ağı küçük kemiklerin ayrıştırılmasında başarılı olmuştur [12]. Kemik yaşının tespitinden elin karpal ve diğer küçük kemiklerine ihtiyaç duyulması, ilgili yöntemin kemik yaşı tespitinde tam otomatik olmuş bir yöntemin bir parçası olarak kullanılabilceğini ortaya koyar.

Tam otomatik bir yöntemin önerildiği başka bir çalışmada, sol elin 17 kemikleşme bölgesini tespit eden bir ağ ve diğer yandan tespit edilen bölgelerden erkek ve kızlar ayrı değerlendiren 12(6+6) regresyon modelini kullanarak yaş tahmin eden bir yöntem kullanmıştır. Veri seti 8bit PNG formatında sol el görüntülerden oluşmaktadır. Çalışma TW prosedürünü simüle etmek üzere tasarlanmıştır. Ağın başarımı test edildiğinde ortalama 4,56 aylık hata ile sonuçlanmıştır [13].

Şimdiye kadar literatürden verdiğimiz örneklerde veri setleri yeteri kadar örnekleri içermekteydi veri setinin yetersiz kaldığı durumlarda veri artırımına gidilebilmektedir. Literatürde veri artırma yöntemi kullanarak cinsiyet etiketi ve kemik yaşı bilgilerinin ayrı olarak ele alan, denetimli ve yarı denetimli eğitimler yapıldığı bir çalışmada yer almaktadır. Çalışmada sol el görüntülerinin 1 aydan 228 aya kadar olan yaşları, her sınıf 3 ayı kapsayan 76 sınıfa bölünmüştür. Veri setini 76 sınıfa yeniden düzenledikten sonra 10'dan az görüntüye sahip bazı sınıflar var olması veri çoğaltma ihtiyacını ortaya çıkarmıştır. Çalışmada önerilen yöntemin bileşenleri olarak gri tonlarda el ROI'sinin türetilmesi, verileri artırmak için bir alt ağ ve cinsiyet bilgilerini denetimli Inception v3 ağı veya yarı denetimli GAN tabanlı sınıflandırma ile birleştirerek kemik yaşı değerlendirmesi için bir alt ağ oluşturulması önerilmiştir. Çalışma sonunda CNN-GAN-OTD tabanlı veri artırma ve denetimli Inception v3 ağı ile denetimli cinsiyet-son sınıflandırma ile eğitim mimarisinin en iyi değerlendirmeyi verdiği sonucuna varılmıştır (ortalama hata 4,23 ay). [14].


Literatürde R-CNN modelini, elin orta falanks, üçüncü metakarpal, radius ve ulna gibi beş bölgesini kullanan bir çalışmada mevcuttur. Bu çalışmada hızlı RCNN'den elde edilen özellik haritaları doğrudan RNN modülüne beslenir. RNN'de yapılan bir

değişiklik olarak, antrenman ağırlığı ortalama uygunluk tabanlı ayçiçeği optimizasyonu ile optimize edilir ve optimize edilmiş ağ kemiğın yaşını tahmin eder. Çalışmada görüntü bölütleme yöntemleri ve diğer makine öğrenme yöntemleri kıyaslanmıştır. Uyarlanabilir otsu, en iyi doğruluğu sahip bölütleme yöntemi ve önerilen modelin diğer makine öğrenimi tekniklerinden daha iyi performans sergilediği sonucuna varılmışlardır [15].

## BÖLÜM 2

### KEMİKLEŞME VE YAŞ TAYİNİ

Kemik ossifikasyonu veya osteogenezi, kemik oluşum sürecidir. Bu süreç, embriyonik gelişimin altıncı ve yedinci haftaları arasında başlar ve yaklaşık yirmi beş yaşına kadar devam eder [16]. Kemikleşme oluş şekline göre intrakartilagenöz ve intramembranöz olmak üzere iki şekilde olur. Intramembranöz kemikleşme bağ dokusu kaynaklı olup, özellikle clavícula ve yassı kafa kemiklerinde görülür. Intrakartilagenöz kemikleşme, bağ dokusunun kıkırdak dokuya dönüşümü sonrasında gerçekleşir. Bu tür kemikleşmeler iki şekilde olur. Kemikleşme kısa kemiklerde merkezden dışa doğru uzun kemiklerde dış kısımda başlar. Fetus büyüdükçe, birincil kemikleşme merkezi genişler ve gelişen kemiğin bir veya iki ucunda ikincil kemikleşme merkezleri oluşur. Bu, kemiklerin uzunlamasına büyümesinden sorumlu olan epifiz büyüme plakası kıkırdağının gelişmesine neden olur [17]. Karpal kemikler kısa kemiklerden olup gelişimin ilk aşamalarında radyografilerde çok küçük noktalar kümesi olarak görüntülenir yaş ilerledikçe büyüklükleri içten dışa doğru artarak büyür. Şekil 2.1’de 1 ve 6 yaşlarındaki iki çocuğun karpal kemikleri görülmektedir. Yaşa bağlı kemikteki bu yapısal değişiklik yaş tespitinde kemik gelişimini parametre olarak kullanan atlasları ortaya çıkarmıştır.



Şekil 2.1. Bir ve altı yaşlarındaki çocukların sol el radyografileri [21].

## 2.1. GREULICH VE PYLE YÖNTEMİ

1959'da yayınlanan Greulich ve Pyle atlası, 3 aydan 16 yaşına kadar elde edilen sol el ve bilek için standart radyografik görüntüler sunar. Atlas, kız bebekler, çocuklar ve ergenler için 29 standart radyografi ve erkek bebekler, çocuklar ve ergenler için 31 standart radyografi listeler. Her bir radyografi için ayrı kemikleşme merkezlerinin tam yaşları belirtilir ve birbirlerinden biraz farklı olabilir. Atlas, öncelikle değerlendirilecek radyografinin yaş ve cinsiyet standartlarıyla karşılaştırılmasında kullanılır. Farklılıklar not edilerek, en iyi eşleşme bulunana kadar görüntü bir sonraki standartlarla karşılaştırılır [18]. Şekil 2.2'de atlas değerlendirmesi yapılan bir yaşındaki bir kız çocuğuna ait görüntü yer almaktadır.



Şekil 2.2. Bir yaş kız çocuğu sol el grafisi [19].

### 2.3. TANNER-WHITEHOUSE YÖNTEMİ

Tanner ve Whitehouse tarafından geliştirilen yöntemde, tek tek kemikleşme merkezleri boyutlarına göre değil, şekillerine ve olgunlaşma ilerledikçe değişme eğilimlerine göre analiz edilir. Yaygın olarak kullanılan TW2 yönteminde üç puanlama sistemi mevcuttur:

- RUS: Radius, ulna ve kısa kemikler.
- CARPALS: Tüm karpal kemikler; 12 yaşından sonra kullanışlı değildir.
- TW2: RUS artı karpallar.

En son TW3 sürümü yalnızca RUS ve CARPALS puanlama sistemlerini içerir. Sol elin radyografisinde, her bir epifiz ilgi merkezinin olgunluğu değerlendirilir ve bir aşamaya atanır. Yalnızca RUS yöntemiyle yapılan değerlendirme, tercihen standart bir protokol ve puanlama sırasını izleyerek klinik rutin için kabul edilebilir. Atlas görüntüleri, puanlanan 13 epifiz bölgesinin tümü için çizimleri ve karşılaştırmalı radyogramları içerir. Tüm kemikler için görünüm ve büyüklüklerine göre farklı evreler tanımlanır ve her evre için bir, iki veya üç kriter tanımlanır. Şekil 2.3'te kemikleşme evrelerinin görseli yer almaktadır. Erkek ve kadın elleri için farklı olan sayısal bir puan, kemik olgunlaşmasının her aşamasına atanır. Bu puanların toplamı, bir tablo kullanılarak iskelet yaşına dönüştürülen bir iskelet olgunluk puanı verir [18].

Sahne	Açıklama	
C	<ul style="list-style-type: none"><li>• Epifiz açıkça görülebilir; oval şekildedir ve açıkça sınırlanmıştır</li><li>• Maksimum çap (a), metafizin (b/2) genişliğinin yarısından azdır.</li></ul>	
D	<ul style="list-style-type: none"><li>• Epifizin maksimum çapı (a), metafizin genişliğinin (b/2) yarısından büyük veya buna eşittir</li><li>• Epifiz radyal tarafta yuvarlak ve ulnar tarafta sivrilmiştir.</li><li>• Epifizin proksimal yüzeyi düzleşir; epifiz plakasının genişliği yaklaşık 1 mm veya daha azdır</li></ul>	
E	<ul style="list-style-type: none"><li>• Epifiz merkezinin distal ucunun hemen proksimalinde, epifizin palmar sınırını temsil eden kalın beyaz bir çizgi bulunur.</li></ul>	

Şekil 2.3. Epifiz bölgesinin gelişimi [18].



## BÖLÜM 3

### GÖRÜNTÜ İŞLEME VE VERİ SETİ

Karabük Üniversitesi Etik Kurul Kararı ve Samsun İl Sağlık Müdürlüğü Bilimsel Araştırma Değerlendirme Komisyonu izni ile Samsun İl Sağlık Müdürlüğü Veri Merkezi tarafından 1-7 yaş kız ve erkek çocuklarına ait sol el radyograflerinin anonimleştirilmesi kurum tarafından yapılarak DICOM görüntü formatında teslim edilmiştir. Görüntüler üzerinde hareket, dalgalanma, yanlış organ yer aldığı görüntüler çıkarılarak 82 görüntü üzerinde çalışılmıştır. Veri büyütme ile 4100 örnek elde edilmiştir. 4100 örneğin %80 kısmı eğitim ve doğrulama %20 kısmı da test olarak ayrılmıştır. Eğitim ve doğrulama verisi 3280 örnekten oluşmakta bu görüntülerinde %80 eğitim verisi olarak ayrılmıştır.

#### 3.1. GÖRÜNTÜ İŞLEME

##### 3.1.1. Hounsfield Birimi

Hounsfield birimi, X ışınlarının dokular tarafından soğurulma ölçümünü gösteren ölçeklendirilmiş soğurma birimleridir [20]. Doku yoğunluğuna bağlı olarak soğurulma oranı değişiklik gösterir. X ışını algılayıcıları, taranan dokulardan geçen ışınların zayıflatma derecesini ölçer ve verileri bayt olarak saklayan görüntü işlemcisi, ekrandaki piksellerle orantılı olarak atanmış piksel parlaklığına sahip olması için bu değerleri dönüştürür [21].

$$(HU_{doku}) = \frac{(doku \mu - su \mu)}{su \mu} \times 1000 \quad (3.1)$$

Formülde (3.1) piksel için ortalama doğrusal zayıflama katsayısı  $\mu$  ve ölçek, suyun 0 HU ve havanın -1000 HU değerinde olacak şekilde tanımlanmıştır [22].

Görüntülerindeki HU değerleri 5000 birimlik bir ölçekte ifade edilse de insan gözü optimal koşullarda çok daha az sayıda gri değeri ayırt edebilir.

### 3.1.2. Pencereleme

Pencere genişliği, görüntüye dahil edilen HU aralığını temsil eder. Çizelge 3.1’ de HU değerlerine karşılık gelen doku bilgisi verilmiştir. Pencere seviyesi görüntü parlaklığını belirler. Seviye ne kadar büyük olursa, parlaklık da o kadar büyük olur.

Yağ sudan daha az yoğun olduğundan ve HU değeri -30 ila -70 aralığında olduğundan, görüntülerde yağ her zaman sudan daha koyu görünür [23].

Çizelge 3.1. Hounsfield Unit değerlerine karşılık gelen doku bilgisi.

HU	Doku
>1000	Kemik, kalsiyum, metal
100 ila 600	İyotlu BT kontrastı
30 ila 500	Noktasal kalsifikasyonlar
60 ila 100	Kafa içi kanama
35	Gri madde
25	Beyaz madde
20 ila 40	Kas, yumuşak doku
0	Su
-30 ila -70	Yağ
<-1000	Hava


Radyografik görüntüde Çizelge-3.1’de yer alan en büyük HU değerine sahip ile kemik dokusu beyaz en düşük değere sahip hava ise değeriyle siyah olarak görünür.

Pencereleme, görüntünün tüm piksel değerlerinden seçilen aralığa sahip görüntü değerlerin görüntülenmesini sağlar. Örneklendirecek olursak, DICOM görüntüsünün en küçük piksel değeri 0 ve en büyük piksel değeri ise 800 olabilir. Görüntünün daha parlak kısımlarındaki kontrast farklılıkları geliştirmek istenirse, 100’den 800’e kadar bir pencere seçilebilir. Seçim sonrası, 0 ila 100 arasında değerlere sahip pikseller en karanlık yoğunlukta görüntülenir ve bu nedenle monitörde görünmeyecektir [24].

DICOM görüntülerinde, tek renk kanalına sahip gri renkli görüntülerde piksel başına bir örnek bulunur ve görüntüde, depolanan renk bilgisi bulunmaz. Röntgen, bilgisayarlı tomografi (BT) ve manyetik rezonans (MR) görüntüleri gibi klinik radyolojik görüntüler gri skalaya sahiptir. Renk bilgisi bulunan pozitron emisyon tomografisi (PET) ve tek foton emisyon tomografisi (SPECT) gibi nükleer tıp görüntüleri tipik olarak bir renk haritası veya renk paleti ile görüntülenir. DICOM dosyasında piksel verileri bölümü, piksellerin sayısal değerlerinin saklandığı bölümdür. Veri türüne göre piksel verileri, gereken minimum bayt sayısı kullanılarak depolanır [25]. DICOM görüntüsünde bulunan piksel, eğim ve kesişim değerleri kullanılarak formül (3.2), HU değerleri hesaplayabilir [26].

$$HU = \text{PikselDeğer} \times \text{Eğim} + \text{Kesişim} \quad (3.2)$$

Çalışmada karpal kemiklerin istenilen ayrımın sağlanması için manuel olarak pencere genişliği ve merkezi Şekil 3.1’te görüldüğü gibi değiştirilmiştir.



Şekil 3.1. Farklı pencere değerleri [27].

### 3.1.3. Kenar Belirleme

Kontur çıkarma iki adımlı bir süreçtir. Öncelikle kenar algılama ve ardından kenar gruplandırma yapılır [28]. Kenar algılama, çok sayıda yaklaşımlı olan bilgisayarlı

göründeki temel işlemlerden biridir. Marr ve Hildreth 1980'de yaptıkları çalışmalarında, Gauss ve Laplace filtrelerini sıralı olarak uygulanmasına dayalı LoG filtresini ilk kez kullanmışlardır [29].

Polinom fonksiyonlarını yerel görüntü yoğunluklarına uydurarak ve fonksiyonların yönlü türevinin sıfır geçişlerini bularak kenarları belirlemesi mümkündür [30].

Canny yaptığı çalışmada bir optimizasyon işlemi ile kenarları belirlemiş ve Gauss düzgünleştirilmiş bir görüntünün gradyan büyüklüğünün maksimumu olarak optimal dedektörlü bir yaklaşım önerilmiştir [31].

Canny kenar tanımlayıcı belirleme adımları, istenen görüntü ayrıntılarını azaltmak için öncelikle görüntü uygun bir Gauss filtresiyle düzeltilmelidir, her pikselde gradyan büyüklüğü ve gradyan yönü belirlenmelidir, bir pikseldeki gradyan büyüklüğü gradyan yönündeki iki komşusundakinden daha büyükse pikseli bir kenar olarak işaretlenmelidir. Aksi takdirde, pikseli arka plan olarak işaretlenmeli, histerezis eşikleme ile zayıf kenarlar kaldırılmalıdır [32]. Şekil 3.2'de Canny filtre maskesi yer almaktadır.

Gauss standart sampa  $\sigma$ , olmak üzere,

$$\alpha(x, y) = \arctan\left(\frac{Gy}{Gx}\right) \quad (3.3)$$

Gradyan hesabı,

$$g(x, y) = [Gx^2 + Gy^2]^{1/2} \quad (3.4)$$

-1	0	1
-2	0	2
-1	0	1

Gx

1	2	1
0	0	0
-1	-2	-1

Gy

Şekil 3.2. Kenar belirleyici Canny ile çalışan maskeler.

Gradyanın büyüklüğü veya kenar kuvveti, aşağıdaki formül kullanılarak yaklaşık olarak hesaplanır [33]:

$$|G| = |G_x| + |G_y| \quad (3.5)$$

Çalışmada kontur belirlenmeden önce görüntü pencere değerleri değiştirilerek Canny filtresi uygulanmıştır. Uygun kontur seçimi sağlanana kadar pencere değerleri değiştirilerek işlem tekrarlanmıştır.

#### **3.1.4. Kontur Belirleme**

Konturlar nesne tespiti ve nesnenin boyutunu bulmada kullanılmaktadır. Kontur tespit operatörleri yerel ve global olarak ikiye ayrılır. Yerel operatör temelde faz uyumluluğuna, sıra filtreleri, diferansiyel analize, istatistiksel yaklaşımlara ve bunların kombinasyonlarına dayanır. Global operatör, kontur belirginliğinin hesaplanması, aktif konturları ,gevşeme etiketlemesini ve algısal gruplamayı içerir [34].

Temel olarak iki tip kontur izleme tekniği vardır, kenar izleme ve sınır izleme. Her ikisi de basit, kapalı eğriler için aynı kontur elemanları dizisini ürettiğinden, iki yaklaşım arasındaki fark teknikten ziyade kavramsaldir [35].

Kenar izlemede, kontur kenar oluşturan bitişik piksel çiftlerinden oluşur ve izleme, nesnenin etrafında prosedürü (örneğin saat yönünün tersine) izlenerek gerçekleştirilir [36].


### **3.2. GEOMETRİK DÖNÜŞÜMLER**

#### **3.2.1.Öteleme**

Bir şeklin ötelenmiş görüntüsü çerçevesinin dışına taşıdığında yeni koordinatların yok sayılması veya çerçeve sınırlarının genişletilmesi gibi ortaya iki durum çıkar. Öteleme işlemine ait formül 3.6'da gösterilmiştir.

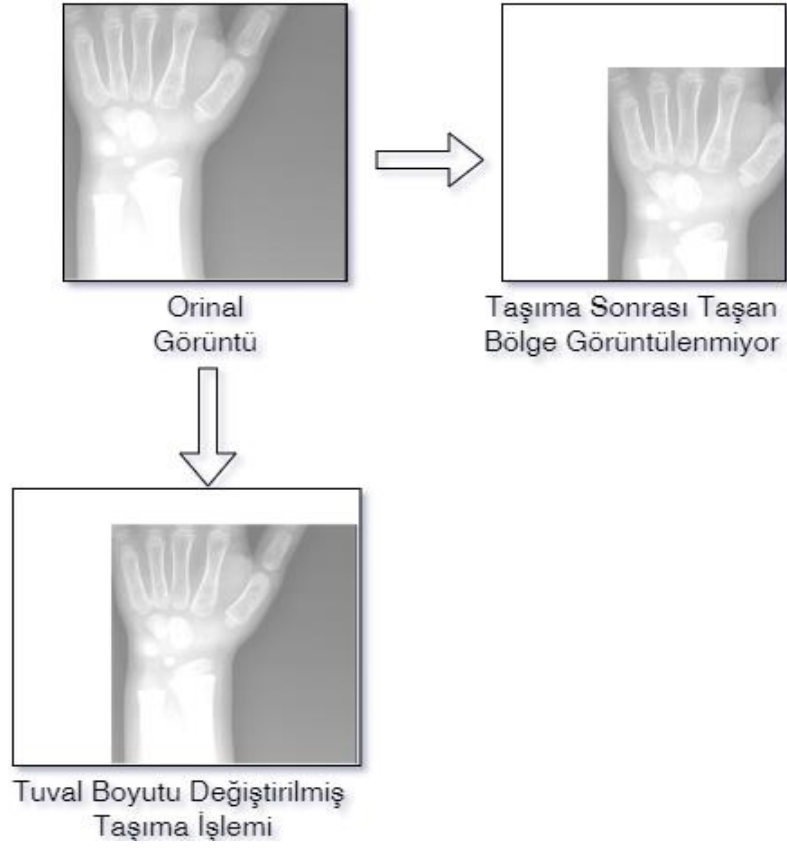
$$P = (x + a, y + b) \quad (3.6)$$

Formül (3.6)'da P yeni piksel koordinatlarını x, y ötelenmek istenilen piksel koordinatları a, b ise x, y eksen koordinatlarının ötelenme miktarıdır.



Şekil 3.3. Piksel koordinatlarının ötelenmesi.

Görüntü tuval içinde kaydırıldığında tuval dışına taşan bölgelerin görüntülenmesi için genelde resimle aynı boyutta olan tuval boyutu öteleme değerleri kadar değiştirilerek öteleme işlemi yapılmalıdır. Öteleme sonrası tuvalde eski koordinat piksel değerleri yerine tuval yer alacaktır. Tuval istenilen renkle boyanabilir. Şekil 3.4'te tuval üzerinde öteleme işlemine ait görsel yer almaktadır



Şekil 3.4. Tuval üzerinde öteleme işlemi.

### 3.2.2. Yansıtma

Yansıtma, bir şekildeki her noktayı alan ve bir çizgi üzerinde yansıtan bir dönüşüm türüdür. X eksenine göre yansımanın formülü (3.7)'de, y eksenine göre yansımanın formülü (3.8)'de,  $y=x$  göre yansıtma işlemine ait formül (3.9)'da ve  $y=-x$  göre yansıma işleminin formül (3.10)'da gösterilmiştir.

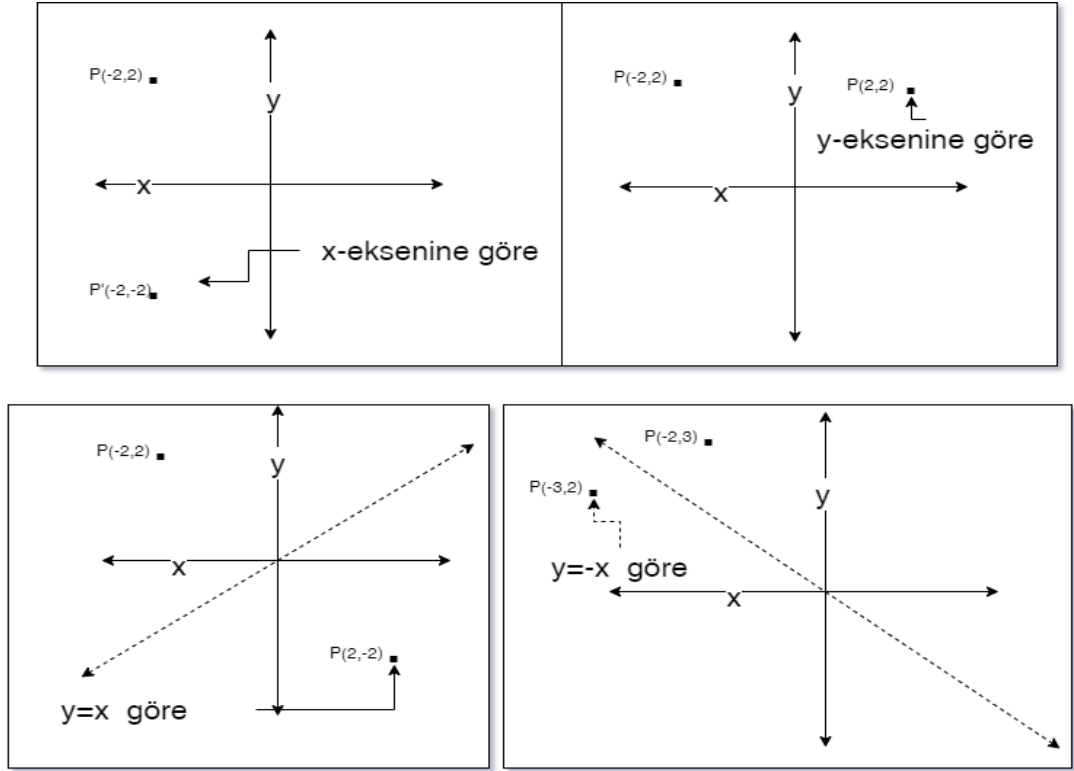
$$P(x, y) \rightarrow P'(x, -y) \quad (3.7)$$

$$P(x, y) \rightarrow P'(-x, y) \quad (3.8)$$

$$P(x, y) \rightarrow P'(y, x) \quad (3.9)$$

$$P(x, y) \rightarrow P'(-y, -x) \quad (3.10)$$

Formülde P piksele ait koordinatları  $P^1$  ise yansıma işlemi sonrası yeni koordinatları ifade etmektedir. Şekil 3.5'te yansıtma işleminin koordinat sisteminde gösterimi yer almaktadır.



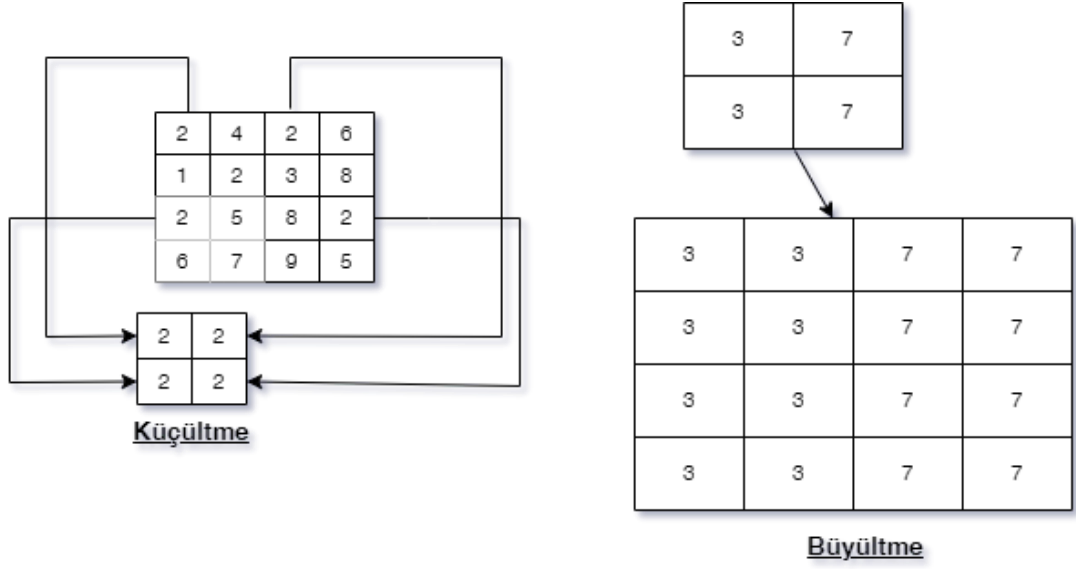
Şekil 3.5. Yansıtma işleminin koordinat sisteminde gösterimi.

### 3.2.3. Ölçekleme

Ölçekleme, resmin görünür alan boyutunu değiştirme resmi büyütme veya küçültme işlemidir. Bu işlem yapılırken görüntü matrisi yeni boyuta sığdırılması için piksel değerlerinin belirlenmesinde interpolasyon yöntemleri kullanılır.


Piksel kopyalama, görüntü büyütüldüğünde yeni oluşan boş görüntü matrisinde ana görüntü matris piksel değerleri yeni matris büyüklüğüne göre çoğaltılarak aktarılır. Görüntü küçültüldüğünde, yeni görüntü matrisine ait boş piksel değerlerine ana görüntüde yer alan komşu piksellerden biri seçilerek atanır. Şekil 3.6'da örnek matris işlemine ait görsel yer almaktadır.





Şekil 3.6. Piksel değıştirme işlemi.

İnterpolasyon işlemi, görüntü küçültülürken küçültme katsayısı kadar piksel atlanarak aradaki piksellerin ortalama değeri yeni matrise aktarılarak yapılır. Büyültme işleminde, ana görüntünün komşu piksellerin değeri arasında fark, oluşturulacak yeni matrisin ölçülerine göre kademeli şekilde belirlenir. Şekil 3.7’de interpolasyon işlemine ait matris işlemlerine ait görsel yer almaktadır.




Şekil 3.7. İnterpolasyon matris işlemleri.

### 3.2.4. Döndürme

Döndürme, bir nokta veya eksen etrafında görüntünün belli bir açıyla taşınmasıdır. Döndürme işlemi sonrası görüntü tuval sınırlarının dışına taşmaması için tuvalin yeniden boyutlandırılması gerekmektedir. Görüntünün döndürülmesi, görüntü önce koordinat düzlem merkezine oturtulur sonrasında döndürülerek tekrar eski konumuna taşınarak yapılır. Taşıma ve döndürme işlemine ait formül (3.11)'de gösterilmiştir.

$$\begin{aligned}x' &= (x - Mx) * \cos(\theta) - (y - My) * \sin(\theta) + Mx \\y' &= (x - Mx) * \sin(\theta) + (y - My) * \cos(\theta) + My\end{aligned}\quad (3.11)$$

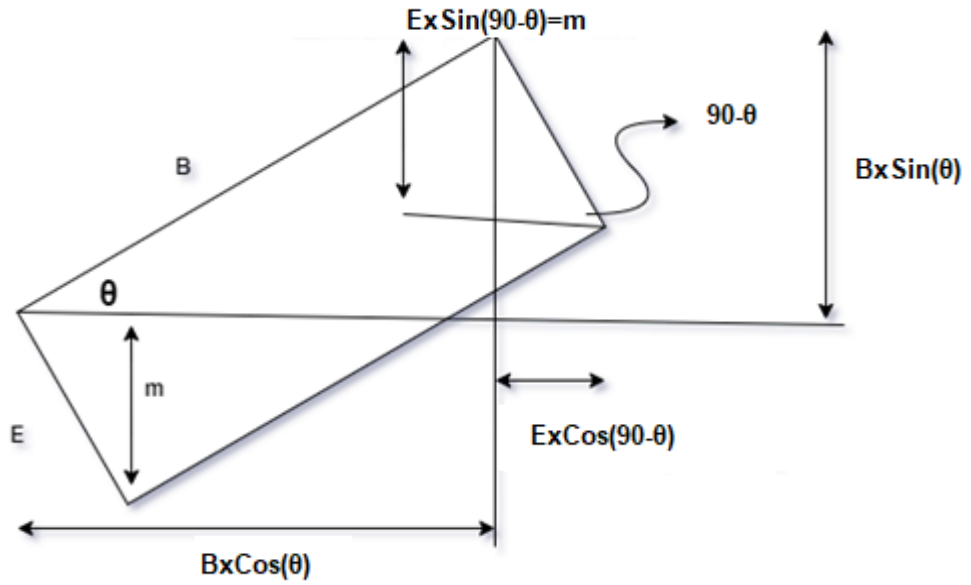
Formül (3.11)'de  $x, y$  taşınacak görüntü piksel koordinatı,  $Mx, My$  görüntü merkezindeki piksel koordinatını,  $\theta$  döndürme açısı ve  $x', y'$  döndürülme işlemi sonrası yeni koordinatları ifade etmektedir. Şekil 3.8'de döndürme işlemine ait görsel yer almaktadır.



Şekil 3.8. Döndürme işlemi.

### 3.2.5. Tuval boyutunun belirlenmesi.

Görüntünün dönme işleminde köşe noktalarına ait koordinatların tuval alanına dışını gösterdiği durumlar olabilmektedir. Taşan alanlar tuval boyutu değiştirilerek görünür hale getirilebilir. Yeni boyut hesaplanırken dönme açısına göre hesaplamada kullanılacak kenarlar değişiklik göstermektedir. Şekil 3.9'da hesaplamada kullanılacak açı köşe bilgileri yer almaktadır. Yükseklik, formül 3.12'de genişlik, formül 3.13'te hesaplanmıştır.



Şekil 3.9. Dönme işlemi sonrası tuval bilgisi.

$$E' = Bx\cos(\theta) + E x \cos(90 - \theta) \quad (3.12)$$

$$B' = Bx\sin(\theta) + E x \sin(90 - \theta) \quad (3.13)$$

Formül 3.12'de B döndürme öncesi tuvalin boy bilgisi, E en bilgisini ve  $\theta$  görüntü döndürme açısını ifade eder.  $E'$ ,  $B'$  ise döndürme sonrası tuvalin en ve boy bilgisini gösterir.


Görüntünün döndürme sonrası tuvale en uygun yerleşimini sağlamak için ilgili formüller kullanılmalıdır.

### 3.3. VERİ SETİ

#### 3.3.1. Karpal kemiklerin seçimi

Her ele ait DICOM dosyası gri skala görüntü formatına çevrilerek kenar belirleme ve kontur çıkarımı sayesinde karpal kemikler tespit edilmiştir.

OpenCV kütüphanesinin kenar belirlemede Canny filtresi, kontur tespitinde findContours() fonksiyonundan faydalanılmıştır. Oluşan konturlardan karpal kemikler bilgisayar faresi aracılığıyla seçilerek kütüphanenin contourArea fonksiyonu aracılığı ile alanlar tek tek hesaplatılmıştır. OpenCV alan hesaplaması için Green teoremini kullanmaktadır [37]. Hesaplanan alanlar sabit diskte tek boyutlu bir dizi halinde json dosyası olarak kaydedilmiştir. Şekil 3.10'da manuel seçilen karpal kemik alanları ve ağa verilen örnek veri yapısı gösterilmektedir. Veriler ağa verilmeden önce her bir el kendi içinde en büyük ve en küçük değerler üzerinde normalize edilmiştir.



Şekil 3.10. Karpal kemiklerin alanları ve dizi yapısı.

### 3.3.2. Radius kemiğinin seçilmesi ve kesme işlemi

DICOM görüntüleri gri skalaya sahip görüntülere dönüştürülerek, radius epifiz bölgesi bilgisayar faresi aracılığı ile sabit ölçekle açlandırma ve taşıma yapılarak ROI koordinatları oluşturulmuştur. Şekil 3.11’de Koordinatların saklandığı json veri görünümü yer almaktadır ilk 8 sayısal veri koordinatları göstermektedir. Şekil 3.12’de koordinatları belirlemede kullanılan kılavuz görüntü yer almaktadır.

```
{[[[[[167.0667724609375, 525.1769409179688],  
[202.903564453125, 431.81890869140625],  
[314.9332275390625, 474.82305908203125],  
[279.096435546875, 568.1810913085938]]],  
"canny": 19, "filterp": 0, "angles": [21, 0, 0, 0, 0]]]}
```

Şekil 3.11. Radius bölgesi açı ve kordinatları Json görünümü.



Şekil 3.12. Radius ROI seçimi.

Kılavuz görüntülerden elde edilen koordinat bilgisi, kesme maskesi hazırlamak için kullanılacaktır. Maske DICOM piksel dizisinin üzerinden veri kaybı olmadan ROI

alanını kesmede kullanılacak Şekil 3.13’ te Python dilinde maske oluşturulması gösterilmiştir.

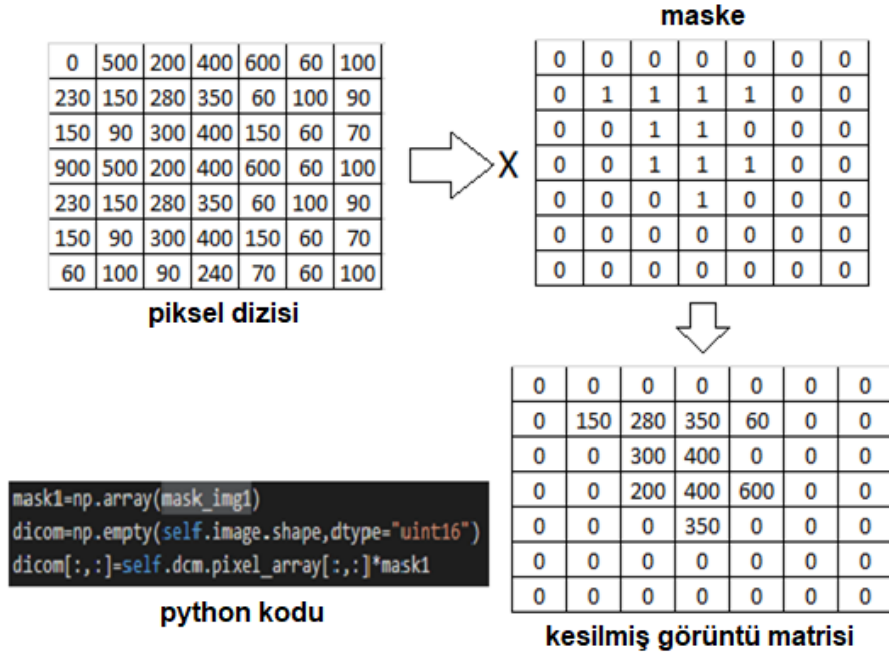
```

735 | | | ImageDraw.Draw(mask_img1).polygon([
736 | | |     (box[0][0],box[0][1]),
737 | | |     (box[1][0],box[1][1]),
738 | | |     (box[2][0],box[2][1]),
739 | | |     (box[3][0],box[3][1])],outline=0,fill=1)
...


```

Şekil 3.13. ROI Kesme maskesi uygulaması.

Kesilmiş görüntü, maskenin piksel dizisi ile çarpma işlemine tabi tutulması sonucu yeni görüntü olarak elde edilmiş olur. Şekil 3.14’ de kesme işlemi gösterilmiştir. Şekil 3.15’ de kesme işlemi tamamlanan DICOM görüntüsünün gri renk skalasına sahip görüntüsü yer almaktadır.



Şekil 3.14. Radius bölgesinin maske ile piksel dizisi verisi üzerinden kesilmesi.



Şekil 3.15. Kesilen DICOM görüntüsü.


### 3.3.3 Veri artırımı

Yapay sinir ağlarında aşırı öğrenme olmaması için büyük veri kümeleriyle çalışmak gerekir [38]. Aşırı öğrenme istenmeyen bir durumdur, modeller yüksek eğitim performansına sahip olacak, ancak yeni verilerle karşılaşıldığında performans aşırı düşecektir. Bu soruna, eğitim verilerinin miktarını, veri artırmayı veya ağda seyreltme gibi yöntemlerle çözüm bulunabilir [39]. Kesilmiş radius bölgelerine ait DICOM görüntülerinin her bir görüntünün piksel dizi değerleri veri çoğalma işlemine tabi tutulmuştur. Aynı el için 50 farklı Radius örneği çoğaltılmış ve her örnekle birlikte elin karpal kemik alanları da kopyalanarak çoğaltılmıştır. 82 el görüntüsünden 4100 radius görüntüsü, 4100 tane alan bilgi olmak üzere iyi veri seti oluşturulmuştur. Oluşan yeni görüntüler `astype('uint16')` komutu ile veri tipi işaretli 16 bit integer olarak korunmuştur. Şekil 3.16'da çoğalma işlemine ait kod parçası yer almaktadır.

```
datagen = ImageDataGenerator(rotation_range=10.0,width_shift_range=0.2,
                             height_shift_range=0.2,horizontal_flip=True)
image2= img_to_array(image1)
image3 =np.expand_dims(image2 ,axis=0)
datagen.fit(image3,seed=1)
aug_iter = datagen.flow(image3, batch_size=gencount,seed=1)
for i in range(gencount):
    rimg = next(aug_iter)[0].astype('uint16')
```

Şekil 3.16. Veri büyütme kod parçası.

Şekil 3.17’de Radius bölgesine ait görüntülerin öteleme (yatay-dikey), rotasyon ve yatay çevirme işlemine tabi tutularak üretilen 50 görüntü yer almaktadır.



Şekil 3.17. Veri büyüme tek radius epifiz bölgesi [27].

Veri çoğaltma işlemi sonrası oluşan yeni görüntüler 16bit bir kanala sahip görüntülerdir. Oluşan iki veri seti ilişkili olduğundan veriler aynı indeksli sırada tutulmuştur.

### 3.3.4 Kesilen Radius bölgesinin yeniden ölçeklendirilmesi.

Sinir ağları aynı boyutta girdiler aldığından, tüm görüntülerin CNN’ye girilmeden önce sabit bir boyuta yeniden boyutlandırılması gerekir [40]. Farklı boyutlarda bulunan radius görüntüleri 120x100 boyutuna ölçeklendirilmiştir. Daha önce hesaplanan alanlar 1x8 boyutuna sahip diziye kemik dizilim sırası sabit kalacak şekilde aktarılmıştır. Bulunmayan karpal kemik alanları için 0 atanmıştır.



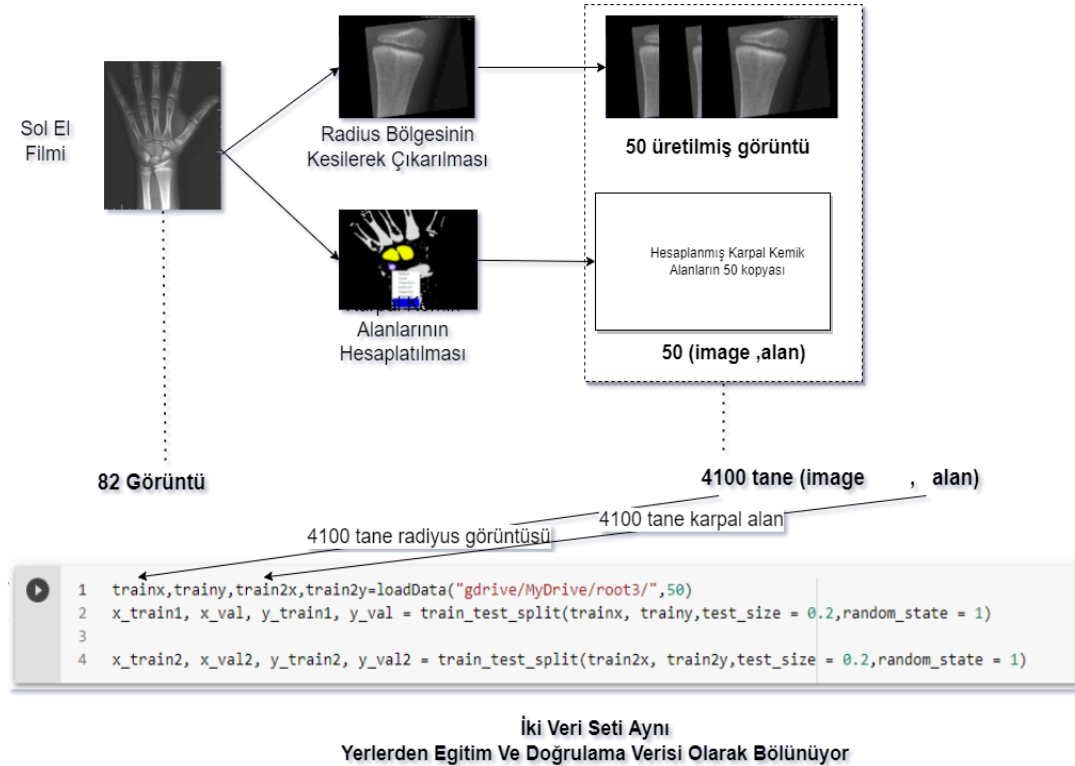
### 3.3.5 Verilerin sınıf etiketlerinin oluşturulması.

Veri artırımı sırasında oluşturulan her örnek için sınıf etiket bilgisi dicom dosyasının nitelik bilgilerinde yer alan yaş ve cinsiyet kullanılarak elde edilmiştir. Bu bilgiler etiket kodlama yöntemiyle sayısallaştırılmıştır. Şekil 3.18’de etiket kodlama işlemine ait kod yer almaktadır. Şekil 3.19’te veri setinden birbiriyle ilişkili iki farklı veri barındıran iki ayrı veri setinin oluşturulmasına ait diyagram yer almaktadır.

```
le = preprocessing.LabelEncoder()
labels=le.fit_transform(labels)

lbl=to_categorical(np.array(labels ,dtype='uint8'), len(set(labels)))
classname=le.classes_
```

Şekil 3.18. Etiket kodlama işlemine ait kod.



Şekil 3.19. Ana veri setinden birbiriyle ilişkili yeni verisetlerinin elde edilmesi.

## BÖLÜM 4

### EVRIŞİMSEL YAPAY SİNİR AĞI

Yapay sinir ağı, vektör olarak aldığı girdileri bir dizi gizli katmandan geçirir. Gizli katman bir dizi nörondan oluşur. Nöronlar tamamen önceki katmandaki diğer tüm nöronlara bağlıdır. Katmanlarda, her nöron bağımsızdır ve herhangi bir bağlantıyı paylaşmazlar. Çıkış katmanı olan son tam bağlı katman, görüntü sınıflandırma işlemlerinde sınıf puanlamasının yapıldığı yerdir. Genel olarak, evrişimsel yapay sinir ağının üç ana katmanı vardır. Bunlar evrişimsel katman, havuzlama katmanı ve tam bağlantılı katmandır [41].

#### 4.1. EVRIŞİMSEL YAPAY SİNİR AĞI

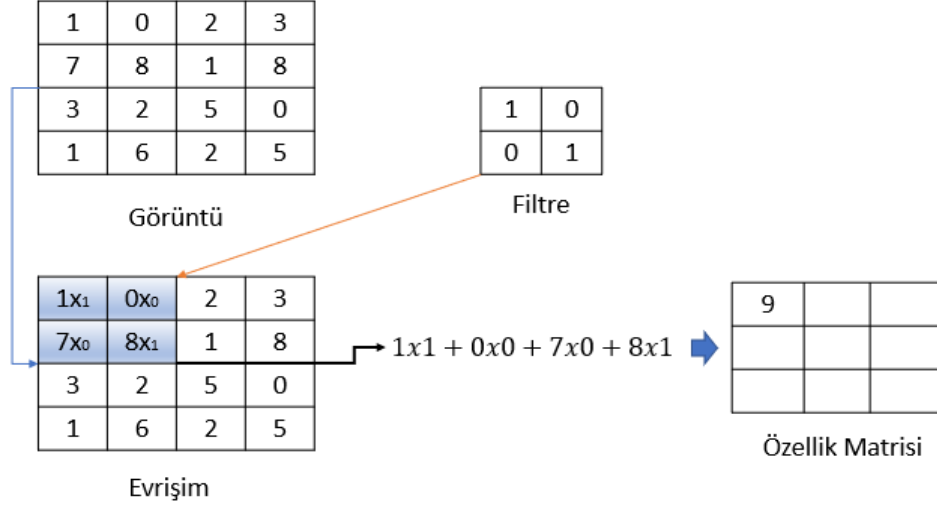
##### 4.1.1. Evrişimsel Katman

Evrişimsel katman giriş görüntülerinden özellik çıkartımı için kullanılır. Hesaplamaların yapıldığı katmandır. Görüntünün üzerine filtreler uygulayarak yeni özelliklerin matrislerini oluşturur. 2-B Evrişimsel sürecin matematiksel formülü şu şekilde verilmektedir:

$$H(x, y) = \sum_{n1=-\infty}^{n1=\infty} \sum_{n2=-\infty}^{\infty} F[n1, n2]xG[x - n1, y - n2] \quad (4.1)$$

Formülde (4.1), H çıktı, G girdi görüntüsünü temsil eden görüntü matrislerini, F çekirdek matrisini temsil eder. Formülde, x ve y indeksleri görüntü matrisleri, n1 ve n2 indeksleri ise çekirdek matrisleri için kullanılır.

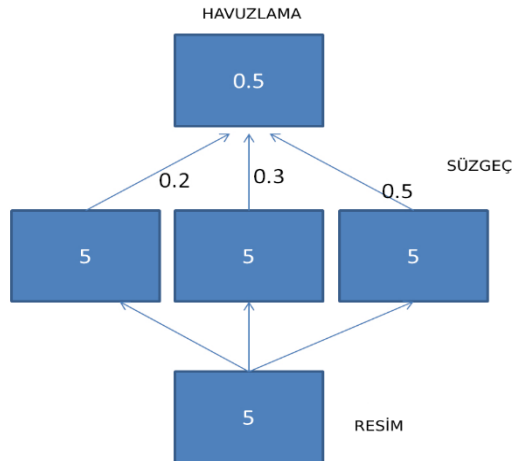
Evrişimsel sinir ağında evrişimsel katmanlar, çekirdek adı verilen küçük bir pencere ile kare benzeri bir şekilde bir giriş tensörünü filtreler. Çekirdek, bir evrişimsel işleminin filtreleyeceği verileri tam olarak tanımlayan ve aradığını bulduğunda güçlü bir yanıt üretecek olan yapıdır [42]. Şekil 4.1’de evrişimsel süreç modellenmiştir.



Şekil 4.1. Evrişim katmanı özellik çıkarımı.

#### 4.1.2. Havuzlama Katmanı

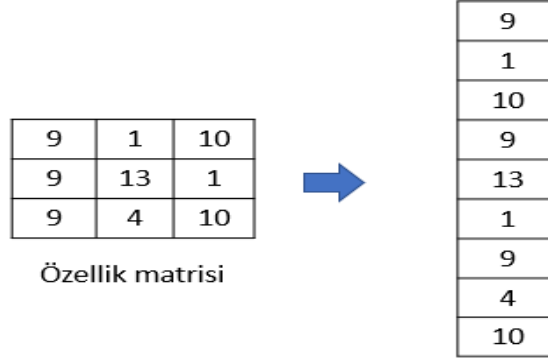
Havuzlama katmanı özellik haritalarının görünüşünü azaltmak için kullanılır [43]. Havuzlama, öğrenilebilir parametre sayısını büyük ölçüde azaltır. Maksimum havuzlama, hareketli bir çekirdek matrisin, görüntü matrisi üzerinde maksimum değerini çıktısı olacak şekilde uygulanmasıdır [44]. Modeldeki parametre sayısı Şekil 4.2’de gösterildiği gibi azaltılmış olur.



Şekil 4.2. Havuzlama [21].

### 4.1.3. Düzleştirme

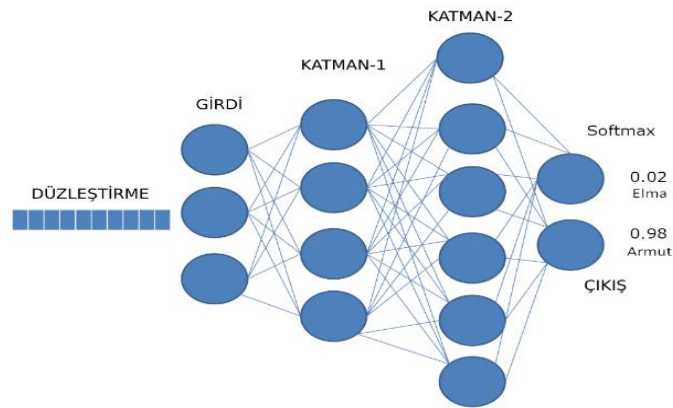
Düzleştirme, matris olarak ifade edilen verinin tek boyutlu hale getirilmesi işlemidir. Tam bağlı katman düzleştirilmiş veri üzerinde süreci devam ettirir. Şekil 4.3'te düzleştirme işlemine ait bir örnek yer almaktadır.



Şekil 4.3. Özellik matrisini düzleştirilmesi [21].

### 4.1.4. Tam Bağlantılı Katman

Tam bağlantılı katman, bahsedilen katmanlar içerisinde öğrenmenin başladığı katman diyebiliriz. Şekil 4.4'te gösterildiği gibi düzleştirilen veriler aktivasyon fonksiyonlarının yardımıyla sınıflandırmaya katılır.



Şekil 4.4. Tam Bağlantılı Katman [21].

## BÖLÜM 5

### ÇOK KATMANLI ALGILAYICI

Çok katmanlı algılayıcı (Multi Layer Perceptron, MLP), en yaygın kullanılan yapay sinir ağlarından biridir. İsminden birden çok katmana sahip tek bir algılayıcı gibi anlam çıksa da algılayıcı olabilen yapay nöron katmalarını içeren bir yapıdır. Çok katmanlı algılayıcının katmanları, yönlendirilmiş, döngüsel olmayan bir grafik oluşturur. Genel olarak, her katman bir sonraki katmana tam olarak bağlıdır; bir katmandaki her yapay nöronun çıktısı, bir sonraki katmandaki her yapay nöron için çıktıya doğru bir girdidir.

Çok katmanlı algılayıcılarda üç veya daha fazla yapay nöron katmanı bulunur. Giriş katmanı, basit giriş nöronlarından oluşur. Giriş nöronları, yapay nöronların en az bir gizli katmanına bağlanır. Gizli katman, gizli değişkenleri temsil eder; bu katmanın girdi ve çıktıları eğitim verisinde gözlemlenemez. Son olarak, son gizli katman bir çıktı katmanına bağlanır [45].

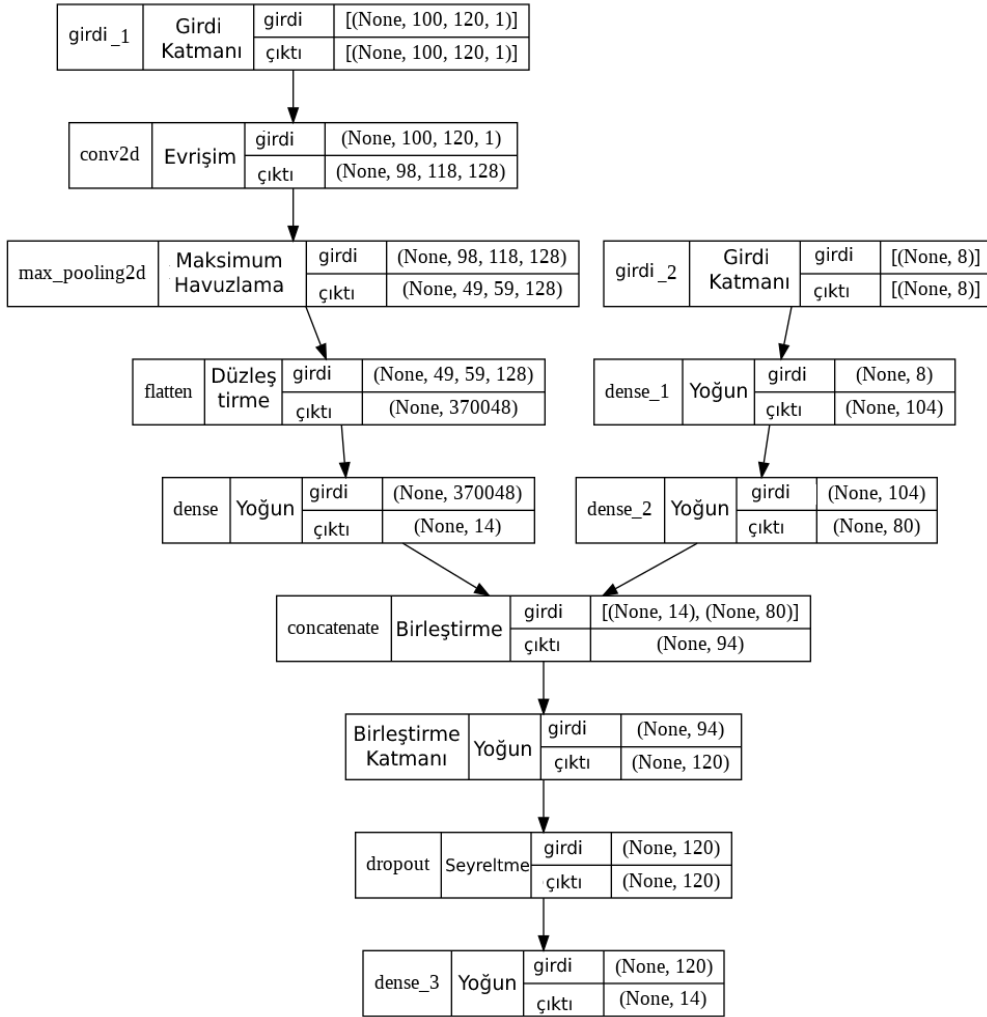
MLP ağının öğrenme süreci, hedef adı verilen  $N$  boyutlu girdi vektörü  $x$  ve  $M$  boyutlu istenen çıktı vektörü  $d$ ’ den oluşan veri örneklerine dayanmaktadır. Giriş vektörü işleyerek  $x$ , MLP çıkış sinyali vektör üreten  $y(x, w)$  burada  $w$  uyarlanmış ağırlıkların vektörüdür. Üretilen hata sinyali, öğrenme algoritmasının bir kontrol mekanizmasını harekete geçirir. Düzeltici ayarlamalar, çıkış sinyalini  $y_k$  ( $k = 1, 2, \dots, M$ ) istenen yanıt  $d_k$ ’ ye adım adım yapmak için tasarlanmıştır.

MLP’ nin öğrenme algoritmasına ait Öklid normunu gösteren formül (5.1) ‘de yer almaktadır. Öğrenme, Öklid normu kullanılarak öğrenme kümesinde tanımlanan hata fonksiyonunun minimizasyonuna dayanır [46]:

$$E(w) = \frac{1}{2} \sum_{i=0}^N \|y(xi, w) - di\|^2 \quad (5.1)$$

Formül (5.1) 'de E öklid, w uyarlanmış ağırlıkların vektörü, x girdi vektörü, y sinyal vektörü, d çıktı vektörü, i öğrenme verisinin indisini ifade etmektedir.

Çalışmada önerilen yapay sinir ağı Şekil 5.1'de görülmektedir. Görüntüler 120x100 piksel ölçeğinde getirilerek girdi\_1 olarak ve 8 karpal kemik alanı girdi\_2 olarak verilmiştir. Evrişim ve havuzlama işlemi sonrası sınıflandırma için veriler matris yapıdan tek boyutlu dizi yapısına geçirilerek düzleştirme yapılmıştır. Girdi olarak verilen alan bilgisi aktivasyon fonksiyonları ile birleştirme katmanına iletilir ve burada düzleştirilen veriler ile birleştirme işlemi yapılır. Sonrasında aşırı eğitimi önlemek için seyreltme işlemine tabi tutulurlar. Seyreltilen veriler softmax fonksiyonuna iletilerek sınıf olasılıkları oluşturularak model eğitilmiştir.



Şekil 5.1. Uygulamanın modeli [21].

## BÖLÜM 6

### AĞIN EĞİTİMİ VE DOĞRULAMA

#### 6.1. FARKLI VERİ TİPLERİNİN BİRLİKTE AĞA VERİLMESİ.

Sol el görüntülerinden kesilen radius bölgesinin görüntü piksel değerlerini tutan 120x100 boyutlu uint16 veri tipine sahip yeni bir veri seti oluşturulmuştur. Karpal kemik alan verisini tutan 1x8 boyutlu float dizi formatında ikinci bir veri seti de ağa verilmek üzere hazırlanmıştır. Şekil 6.1’de Radius piksel verisini içeren veri serine ait bilgilerin gösterildiği ekran çıktıları yer almaktadır. Şekil 6.2’de Karpal kemik alanlarına ait veri setine ait bilgileri gösteren ekran çıktıları yer almaktadır. Şekil 6.3’te model eğitiminde iki ayrı veri setinin aynı anda ağa verildiği kod görseli yer almaktadır. Ağa giren bir görüntü evrimsel süreçten sonra düzleştirilerek birleştirilme katmanına gelir bu süreç bir ele ait kemik alanlarının katman işlemleriyle aynı döngüde bağımsız devam eder. Birleştirme katmanında bir eli temsil eden iki veri tek bir dizi haline getirilerek sınıf tahmini için aktivasyon fonksiyonuna gönderilir.

```
1 print("Tum Radius Datası",trainx.shape)
2
3 print("Secilen tek radyusa ait boyut,tip,piksel verisi ",trainx[0].shape,trainx[0].dtype)
4 display(trainx[0])
```

Tum Radius Datası (4100, 100, 120, 1)  
Secilen tek radyusa ait boyut,tip,piksel verisi (100, 120, 1) uint16  
array([[4984],  
 [5120],  
 [4975],  
 ...])

Şekil 6.1. Kesilen radius bölgesinin görüntü verisine ait bilgileri gösterir kod.

```
1 print("Tum Karpal Kemik Alanlari",train2x.shape)
2
3 print("Secilen tek El ait ",train2x[0].shape,train2x[0].dtype)
4 display(train2x[0])
```

Tum Karpal Kemik Alanlari (4100, 8)  
Secilen tek El ait (8,) float32  
array([0. , 0.07637656, 0.2375666 , 0. , 0. ,  
 0. , 1. , 0.6634103 ], dtype=float32)

Şekil 6.2. Karpal kemik alanlarını içeren verisine ait bilgiler.

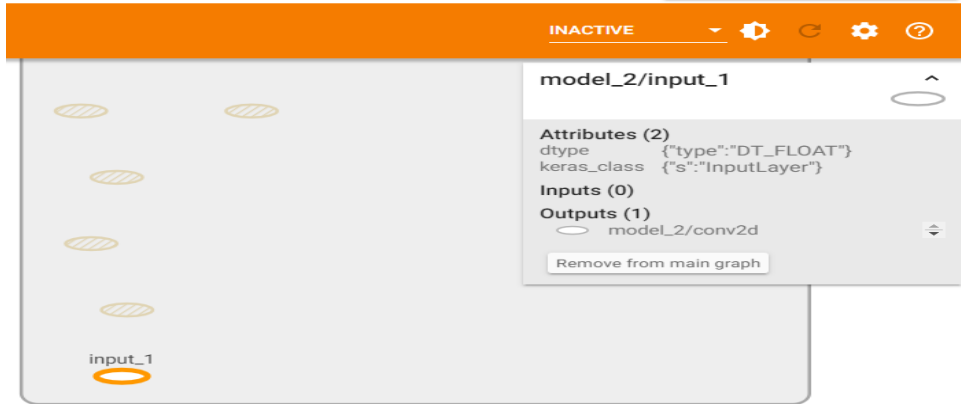
```

19
20 b.fit([t1,t2],y1,validation_data=([te1,te2],y2),epochs=50)

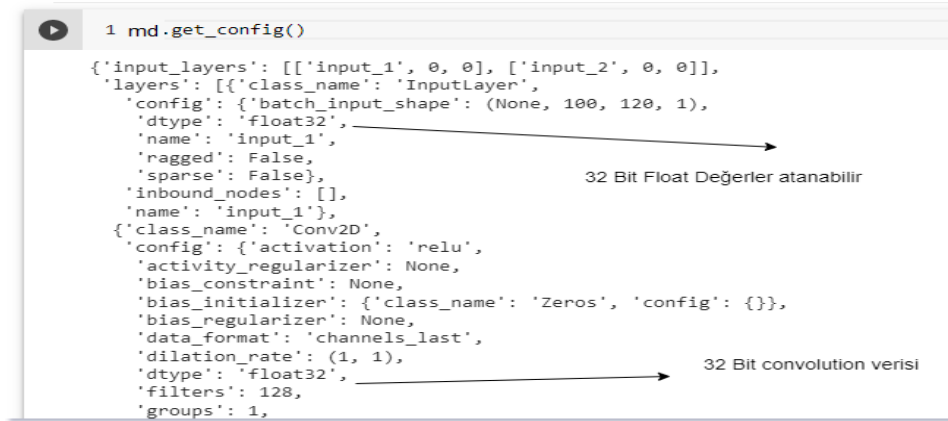
```

Şekil 6.3. Eğitim ve doğrulama verilerinin ağa verilmesini gösterir kod parçası.

Veri tip dönüşümleri bazen kayıplı olarak gerçekleşebilmektedir. Python dilinde matematiksel bir işlem sonrası oluşan ondalıklar sadece tamsayı değerleri kabul eden bir veri tipine atandığında tam kısmı korunarak ondalık kısmı kaybedilir. Şekil 6.4'te girdiye ait tensorboard görseli yer almaktadır. Şekil 6.5'te modelin CNN bölümüne ait



Şekil 6.4. Evrişim katmanına ait girdi tensorboard ekran görüntüsü.



Şekil 6.5. Modelin serileşmiş evrişim katmanı.


giriş ve evrişim katmanına ait serileştirilmiş içerik görünmektedir. Şekil 6.4'te ve Şekil 6.5'te gösterilen ağ girişlerinin 32 bit float değerleri kabul etmesi ve veri setinde değerlerin float veri tipinin tanım aralığı dışında olmayışı verilerin kayıpsız ağa dahil edildiği sonucunu ortaya koyar [47,48].



## 6.2. AĞIN EĞİTİMİ VE HİPER PARAMETRELERİNİN BELİRLENMESİ.

Yapay sinir ağının filtre boyutu, aktivasyon fonksiyonu, katman sayısı, kullanılacak nöron sayısı gibi birçok parametresi vardır. Parametrelerin manuel olarak değiştirilmesi ve başarıyı yüksek modelin elde edilmesi zahmetli bir süreçtir. Keras kütüphanesinin ek olarak eklenen KerasTuner kitaplığı süreci hızlandırmak için kullanılmıştır. Kütüphane kullanılarak 10 adet farklı model oluşturulmuş ve bu modeller üzerinde eğitim ve doğrulama işlemi yapılarak başarıyı yüksek model seçilmiştir.

## 6.3. K-KATLAMALI ÇAPRAZ DOĞRULAMA VE TEST

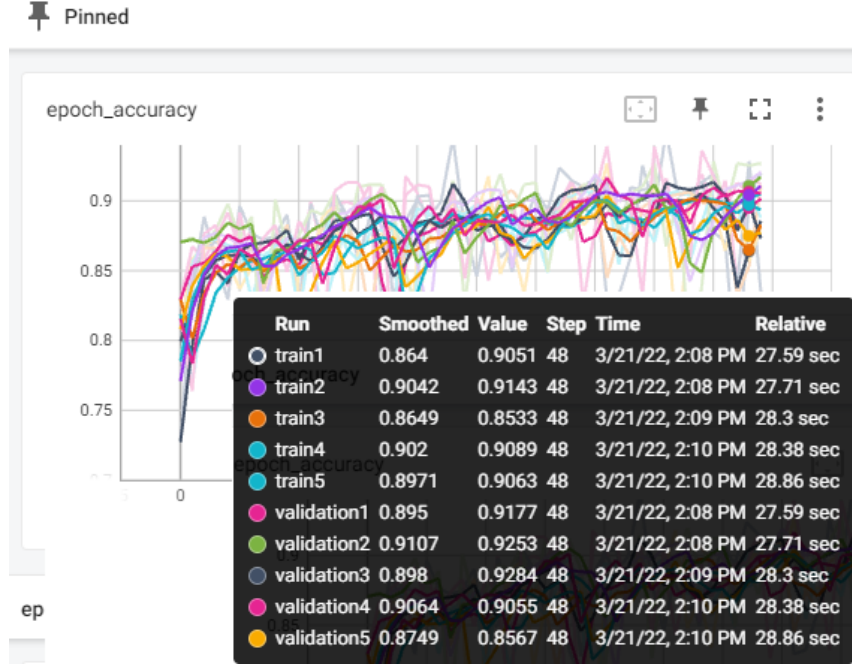


Şekil 6.3. Beş kat çapraz doğrulama.


K-Katlamalı çapraz doğrulama veri setimizi k farklı alt kümeye bölerek eğitim ve doğrulama sürecini farklılaştırarak modelin başarımını test etmenin bir yoludur. Birden fazla k alt örnekten, modeli test etmek için doğrulama verisi olarak tek bir alt örnek tutulur ve kalan k-1 alt örnek, eğitim verisi olarak kullanılır. Test sonucunda ortaya çıkan ortalama başarımlar modelimizi başarımını belirler [49]. Şekil 6.3'te k değeri 5 seçilen çapraz doğrulamaya ait görsel yer almaktadır.

Modelleme sürecinde 656 örnek doğrulama verisi 2624 örnek eğitim verisi kullanılmıştır. Oluşan model 820 örnekle yapılan test işleminde başarımlar %87 olarak tespit edilmiştir. Model 4100 örneğin tamamı üzerinden 5-kat çapraz doğrulamaya tabi tutulmuş başarımların %91 olduğu gözlenmiştir. Şekil 6.4'te 5-kat çapraz doğrulama

sürece tabi tutulan veri seti modeline ait eğitim ve doğrulama görseli yer almaktadır. Ana model CNN ve MLP olmak üzere iki parça olarak değerlendirildiğinde Şekil 6.5'te gösterilen çapraz doğrulama başarımları elde edilmektedir.



Şekil 6.4. 4100 görüntünün 5-kat çapraz doğrulama süreç grafiği.




Şekil 6.5. Model karşılaştırma grafiği.


## BÖLÜM 7

### BULGULAR

Bu tez çalışmasında Google Colab tarafından sağlanan sanal bilgisayar ortamı kullanılmıştır. Ortama ait özellikler; Nvidia Tesla T4 16Gb ekran kartı Intel(R) Xeon(R) CPU @ 2.20GHz işlemci ,12Gb Ram ve 30 Gb disk alanına sahiptir. Evrimsel yapay sinir ağı ücretsiz sunulan Colab sanal ortamda tasarlanıp test edilmiştir. Google drive hesabına entegre çalışan ilgili ortam Python dili ve kütüphanelerini kullanımına izin vermektedir. Çalışmamız Python dili kullanarak gerçekleştirilmiştir. Yapay sinir ağı ve veri çoğaltmada Keras, DICOM görüntüsü üzerindeki tüm işlemler için PyDicom, diğer görüntü işlemlerinde OpenCv gibi öne çıkan kütüphanelerden fayda sağlanmıştır.



Şekil 7.1. KerasTuner kullanılarak elde edilen eniyi modelin başarıım grafiği.



Şekil 7.2. KerasTuner kullanılarak elde edilen eniyi modelin kayıp grafiği.

Şekil 7.1 ve Şekil 7.2’de KerasTuner kütüphanesi kullanılarak elde edilen modelin başarımları ve kayıp değerlerine ait veriler yer almaktadır. Mavi renk doğrulama turuncu renk ise eğitim sürecini ifade etmektedir. Ağ 50 döngü süreçle eğitilmiştir, eğitim verileri ve doğrulama verilerinin başarımları genel olarak istikrarlı artış göstermiştir. %87 seviyesi modelin doğruluğunun en yüksek olduğu seviyedir. Eğitilmiş modelin başarımları 820 tane örnekle test edildiğinde modelin cinsiyet ve yaş tanımlama başarımları %85 olarak gerçekleşmiştir.

Modelin genelleme bilirliliği test etmek için model çapraz k-katlamalı doğrulamaya tabi tutulmuştur. Veri setinin beşe bölünmesiyle yapılan çapraz doğrulama modelin başarımlarını %91 olarak belirlemiştir. Şekil 7.3’te çapraz doğrulamaya ait verilere yer verilmiştir.

Çizelge 7.1. Ana model çapraz doğrulama sonuçları.

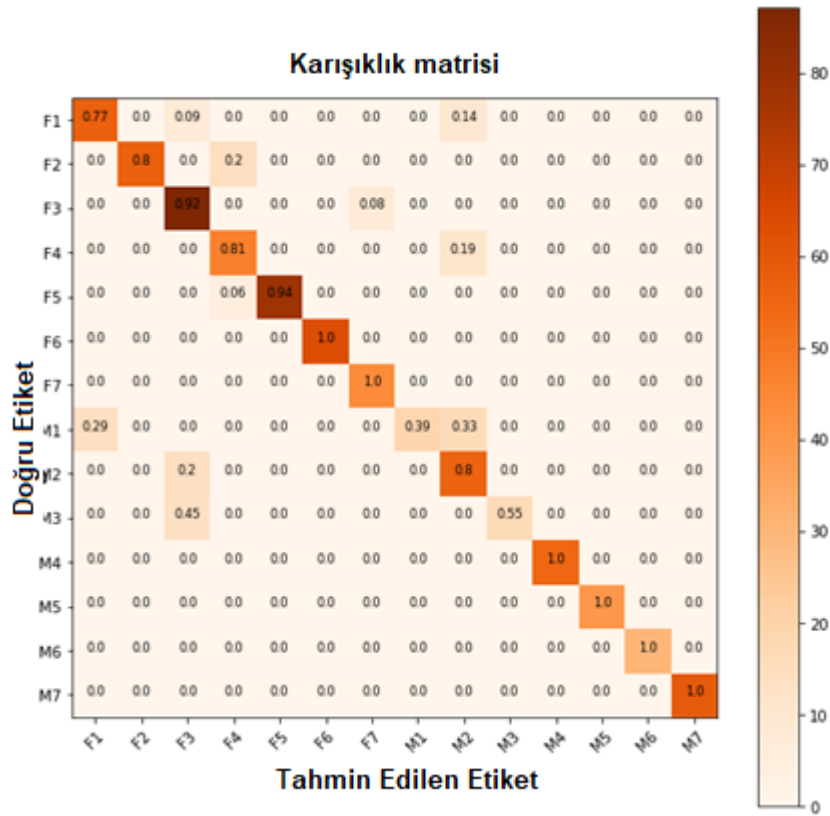
<b>Kat</b>	<b>Kayıp</b>	<b>Doğruluk (%)</b>
1	0.214	92.225
2	0.185	89.634
3	0.208	91.006
4	0.141	92.835
5	0.156	91.158

Şekil 7.3’te gösterilen karışıklık (hata) matrisinde yer alan kız çocuklarına ait yaş sınıflandırma tahminleri aşağıda verilmiştir:

Bir yaş olarak yapılan tahminlerin %77’si doğru, %9’u üç yaş kız ve %14’ü iki yaş erkek olarak hatalı tahmin edilmiştir. İki yaş olarak yapılan tahminlerin %80’ni doğru, %20’si dört yaş kız olarak hatalı tahmin edilmiştir. Üç yaş olarak yapılan tahminlerin %92’si doğru, %8’i yedi yaş kız olarak hatalı tahmin edilmiştir. Dört yaş olarak yapılan tahminlerin %81’i doğru, %19’u iki yaş erkek olarak hatalı tahmin edilmiştir. Beş yaş olarak yapılan tahminlerin %94’ü doğru, %6’sı dört yaş kız olarak hatalı tahmin edilmiştir. Altı yaş olarak yapılan tahminler %100’ü doğru tahmin edilmiştir. Yedi yaş olarak yapılan tahminler %100’ü doğru tahmin edilmiştir.

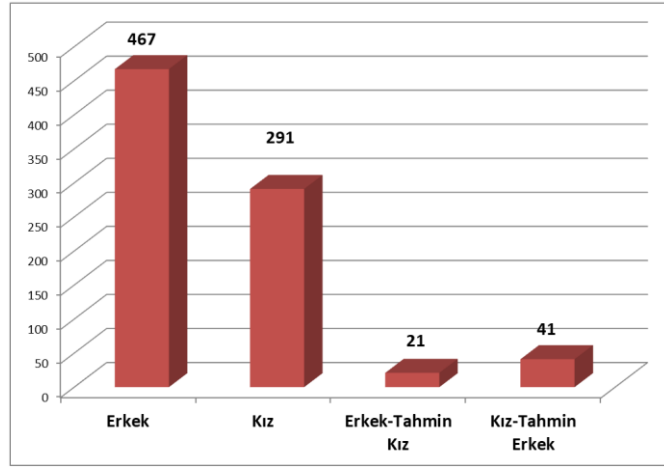
Şekil 7.3'te gösterilen karışıklık (hata) matrisinde yer alan erkek çocuklarına ait yaş sınıflandırma tahminleri aşağıda verilmiştir:

Bir yaş olarak yapılan tahminlerin %39'u doğru, %29'u bir yaş kız olarak hatalı ve %33'ü iki yaş erkek olarak hatalı tahmin edilmiştir. İki yaş olarak yapılan tahminlerin %80'ni doğru, %20'si üç yaş kız olarak hatalı tahmin edilmiştir. Üç yaş olarak yapılan tahminlerin %55'i doğru, %45'i üç yaş kız olarak hatalı tahmin edilmiştir. Dört yaş olarak yapılan tahminlerin %100'ü doğru tahmin edilmiştir. Beş yaş olarak yapılan tahminlerin %100'ü doğru tahmin edilmiştir. Altı yaş olarak yapılan tahminlerin %100'ü doğru tahmin edilmiştir. Yedi yaş olarak yapılan tahminlerin %100'ü doğru tahmin edilmiştir. Her iki cinsiyet için altılı ve yedili yaşlar en yüksek doğru tahmin oranına sahiptir.




Şekil 7.3. Karışıklık Matrisi (F-Kız, M-Erkek, 1M -1 Yaş Erkek) [27].

4100 tane örnekten oluşan veri setinin %20 test olarak ayrılmıştır Şekil 7.4 karışıklık matrisi kullanarak 820 örnek test verisinin dağılımı Şekil 7.5'te gösterilmiştir.



Şekil 7.4. Test verisinin model tahminine göre dağılımı (Kişi sayısı) [27].

Şekil 7.4'te yer alan dağılım incelendiğinde erkek çocuklara ait sınıflandırmada 467 kişi doğru olarak 21 kişi hatalı olarak sınıflandırılmıştır. Kız çocuklarda 291 kişi doğru 41 kişi hatalı sınıflandırmıştır. Sonuçlar karşılaştırıldığında modelin test verisinde yer alan erkek çocuklar için daha başarılı olduğu gözlenmektedir. Şekil 7.5'te modelin cinsiyete göre başarımını görmektedir.

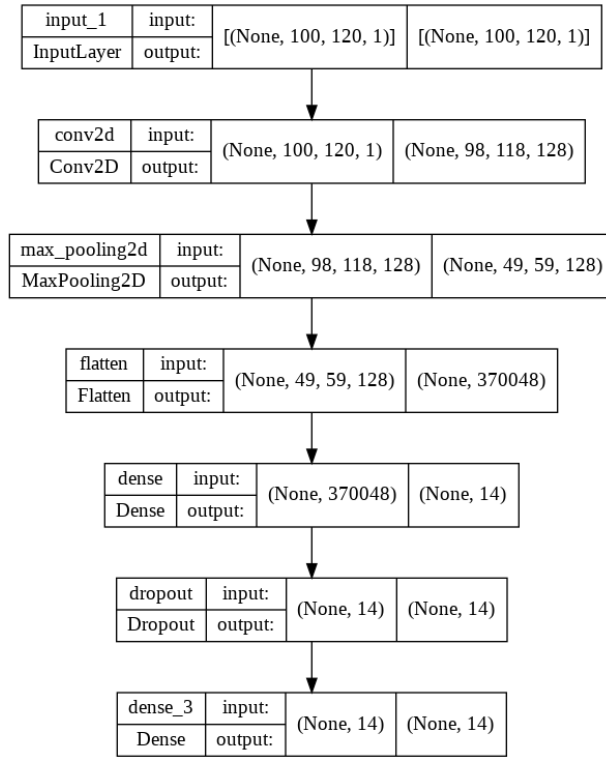


Şekil 7.5. Model başarımının test verisi üzerinde cinsiyet oransal dağılımı [27].

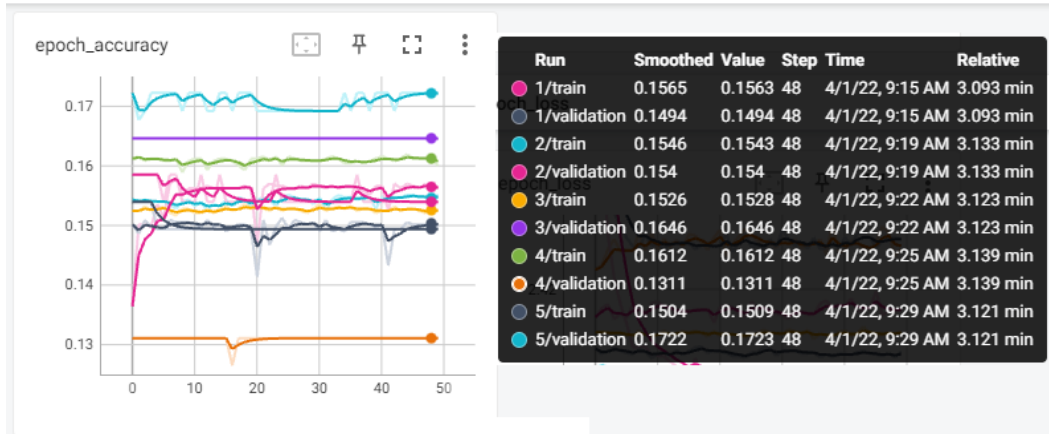
Şekil 7.5'te modelin test verileri üzerindeki başarımını erkek cinsiyeti için %95,70 kız cinsiyeti için %87,65'tir. Çalışmada veri setinin homojen olmayışı cinsiyet grupları

için olumsuz sonuçlar elde etmemiz de önemli bir faktördür. Veri sayısı arttıkça daha doğru sonuçlar üreten modeller tasarlanabildiği bir gerçektir.

Modelin CNN ve MLP olarak birlikte başarılı sonuçlar ürettiği söylenebilir modelin iki ayrı model olarak ele aldığımızda Şekil 7.6'de görseli yer alan ana modelden bağımsız CNN için Şekil 7.7'de görüntülenen çapraz doğrulama başarıımı %15 olarak gözlenmiştir.

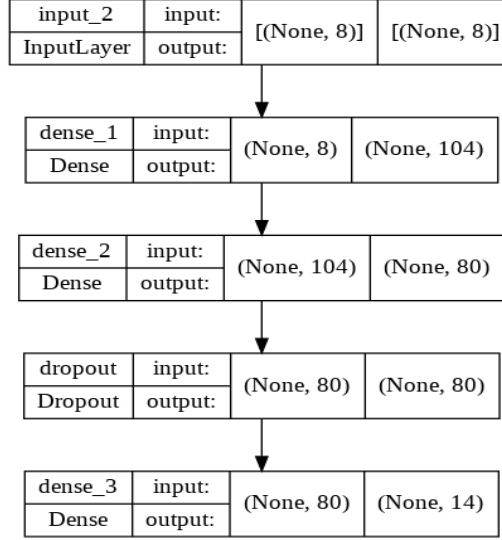


Şekil 7.6. Ana modelin CNN bölümü

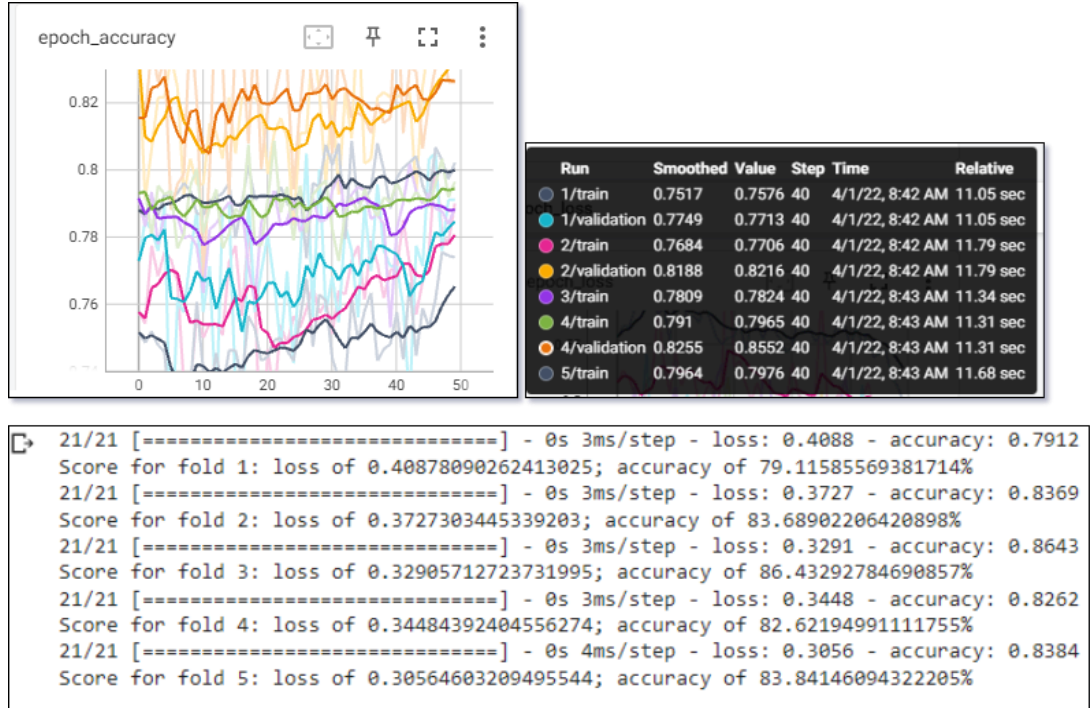


Şekil 7.7. Ağın CNN bölümüne ait çapraz doğrulama performans grafiği

Şekil 7.8’da modelin diğer bir parçası olan MLP ağı görseli yer almaktadır. Ana modelden bağımsız olarak yapılan çapraz doğrulamanın Şekil 7.9’da performans grafiği yer almaktadır. Ağın çapraz doğrulama başarımı %83 olarak gözlenmiştir.



Şekil 7.8 .Ana modelin MLP bölümü



Şekil 7.9. MLP modeli çapraz doğrulama performans grafiği



## BÖLÜM 8

### TARTIŞMA VE SONUÇ

Veri setinin görüntü formatının DICOM olması görüntü üzerinde daha fazla kontrol imkânı sağlamaktadır. Gri görüntü skalasına (0-255) sahip görüntüler tercih edilmekte ve araştırmalar bu görüntülerin bulunduğu veri setleri üzerinden yapılmaktadır. Aynı görüntünün farklı pencereleme seviyelerinde gri skalaya (0-255) çevrilen görüntülerin farklı sonuçlar üreteceği bir gerçektir. Çalışmada karpal kemiklerin ayrıştırılmasında DICOM verisinin farklı pencere seviyesinde görüntüler işlenerek ayrıştırma yapılmıştır. Görüntülerin farklı X-ray tüp mesafesinden elde edildiğini düşündüren, görüntüsel boyut farklılıkları mevcuttur [50]. Görüntüleme tekniğini uygulayan kişiye bağlı olarak X-ray ışın şiddetinin görüntülemeye göre farklılık göstermesi aynı doku için farklı HU değerleri üretilmesine sebep olabilmektedir [51]. Bu faktörler göz ardı edilerek yapılan eğitimin başarımı %70 seviyelerinde kalmıştır. Karpal kemik alan verilerinde en büyük ve en küçük alanı üzerinden normalleştirme yapılmıştır. Yapılan bu normalleştirme işlemi neticesinde eğitim başarımı %87 oranına taşınmıştır.

Karpal kemiklerin özellikle 6-7 yaşlarda gelişiminin fazla oluşu, kemiklerin görüntülerde üst üste gelerek örtüşmesine sebep olmuştur. Ayrıştırma işlemi çoğunlukla bu görüntülerde başarısız olmuştur. Model test sonuçları incelendiğinde ayrıştırılmada yaşanan zorluklara rağmen 5-6-7 yaş erkek ve kız çocuklarda yüksek başarımlar elde edilmiştir.

Ana modeli CNN ve MLP olarak iki parça olarak değerlendirildiğinde her parçanın kendine özgü başarımlar göstergeleri ana modele göre düşük, birbirleri arasında ise MLP ağı yüksek bir başarıma sahiptir. Aynı veri setinden üretilmiş farklı yeni veri setleri hibrit olarak tasarlanan ağ üzerinde başarılı tanımlama sonuçları üretmiştir

Çalışmada veri kaynağından çıkarılan farklı nitelikteki özellikler, evrimsel sinir ağı ve çok katmanlı algılayıcı ağıdan oluşan yapay sinir ağı modelinde başarılı olarak eğitilmiştir. Radyoloji kliniklerinde organ veya bölge etiketlenme işlemlerinin yapılması ve bu etiketli yapıyı saklayacak yeni formatların oluşturulması, ileride bu alanda yapılacak çalışmalar için önem arz etmektedir [52].

## KAYNAKLAR

1. Cheung, J. P. Y. and Luk, K. D.-K., "Managing the Pediatric Spine: Growth Assessment", *Asian Spine Journal*, 11 (5): 804–816 (2017).
2. İZgi, M. S. and Kök, H., "Kemik Yaşı ve Maturasyon Tespiti", *Selcuk Dental Journal*, (2020).
3. Schmeling, A., Olze, A., Reisinger, W., König, M., and Geserick, G., "Statistical analysis and verification of forensic age estimation of living persons in the Institute of Legal Medicine of the Berlin University Hospital Charité", *Legal Medicine*, 5: S367–S371 (2003).
4. Subramanian, S. and Viswanathan, V. K., "Bone Age", StatPearls [Internet], *StatPearls Publishing*, (2021).
5. Pinchi, V., De Luca, F., Ricciardi, F., Focardi, M., Piredda, V., Mazzeo, E., and Norelli, G.-A., "Skeletal age estimation for forensic purposes: A comparison of GP, TW2 and TW3 methods on an Italian sample", *Forensic Science International*, 238: 83–90 (2014).
6. Manzoor Mughal, A., Hassan, N., and Ahmed, A., "Bone Age Assessment Methods: A Critical Review", *Pakistan Journal Of Medical Sciences*, 30 (1): 211–215 (2014).
7. Öztürk, Y., Kiliçoğlu, H., and Saka, N., "İskeletsel 3. Sınıf Vakalarda Kemik Olgunluğunun Tanner-Whitehouse (Tw2-Rus) Yöntemi İle Belirlenmesi-The Assesment Of The Skeletal Maturity In Skeletal Class 3 Cases According To Tanner-Whitehouse (Tw2-Rus) Method", *Journal Of Istanbul University Faculty Of Dentistry*, 27 (1): 65–70 (2013).
8. Martin, D. D., Wit, J. M., Hochberg, Z., Sävendahl, L., Rijn, R. R., Fricke, O., Cameron, N., Caliebe, J., Hertel, T., Kiepe, D., Albertsson-Wikland, K., Thodberg, H. H., Binder, G., and Ranke, M. B., "The Use of Bone Age in Clinical Practice – Part 1", *Hormone Research In Paediatrics*, 76 (1): 1–9 (2011).
9. Booz, C., Yel, I., Wichmann, J. L., Boettger, S., Al Kamali, A., Albrecht, M. H., Martin, S. S., Lenga, L., Huizinga, N. A., D'Angelo, T., Cavallaro, M., Vogl, T. J., and Bodelle, B., "Artificial intelligence in bone age assessment: accuracy and efficiency of a novel fully automated algorithm compared to the Greulich-Pyle method", *European Radiology Experimental*, 4 (1): 6 (2020).

10. Mohammed, R. B., Rao, D. S., Goud, A. S., Sailaja, S., Thetay, A. A. R., and Gopalakrishnan, M., "Is Greulich and Pyle standards of skeletal maturation applicable for age estimation in South Indian Andhra children?", *Journal Of Pharmacy & Bioallied Sciences*, 7 (3): 218–225 (2015).
11. Hsieh, C.-W., Jong, T.-L., Chou, Y.-H., and Tiu, C.-M., "Computerized geometric features of carpal bone for bone age estimation", *Chinese Medical Journal*, 120 (9): 767–770 (2007).
12. Ding, L., Zhao, K., Zhang, X., Wang, X., and Zhang, J., "A Lightweight U-Net Architecture Multi-Scale Convolutional Network for Pediatric Hand Bone Segmentation in X-Ray Image", *IEEE Access*, 7: 68436–68445 (2019).
13. Koitka, S., Kim, M. S., Qu, M., Fischer, A., Friedrich, C. M., and Nensa, F., "Mimicking the radiologists' workflow: Estimating pediatric hand bone age with stacked deep neural networks", *Medical Image Analysis*, 64: 101743 (2020).
14. Su, L., Fu, X., and Hu, Q., "Generative adversarial network based data augmentation and gender-last training strategy with application to bone age assessment", *Computer Methods And Programs In Biomedicine*, 212: 106456 (2021).
15. Deshmukh, S. and Khaparde, A., "Faster Region-Convolutional Neural network oriented feature learning with optimal trained Recurrent Neural Network for bone age assessment for pediatrics", *Biomedical Signal Processing And Control*, 71: 103016 (2022).
16. Breeland, G., Sinkler, M. A., and Menezes, R. G., "Embryology, Bone Ossification", StatPearls [Internet], *StatPearls Publishing*, (2021).
17. Berendsen, A. D. and Olsen, B. R., "Bone development", *Bone*, 80: 14–18 (2015).
18. "Skeletal Age", Measurements and Classifications in Musculoskeletal Radiology, 2014. Ed., *Thieme Verlag*, (2014).
19. Gaskin, C. M., Kahn, S. L., Bertozzi, J. C., and Bunch, P. M., "Skeletal Development of the Hand and Wrist: A Radiographic Atlas and Digital Bone Age Companion", *Oxford University Press, Incorporated*, Cary, UNITED STATES, (2011).
20. Powsner, R. A., Palmer, M. R., and Powsner, E. R., "Essentials of Nuclear Medicine Physics and Instrumentation", *John Wiley & Sons, Incorporated*, Somerset, UNITED STATES, (2013).
21. Hermena, S. and Young, M., "CT-scan Image Production Procedures", StatPearls, *StatPearls Publishing*, Treasure Island (FL), (2021).

22. Rehani, M. M., Gupta, R., Bartling, S., Sharp, G. C., Pauwels, R., Berris, T., and Boone, J. M., "ICRP Publication 129: Radiological Protection in Cone Beam Computed Tomography (CBCT)", *Annals Of The ICRP*, 44 (1): 7–127 (2015).
23. Cuong, N. L. Q., Minh, N. H., Cuong, H. M., Quoc, P. N., Anh, N. H. V., and Hieu, N. V., "Porosity Estimation from High Resolution CT SCAN Images of Rock Samples by Using Housfield Unit", *Open Journal Of Geology*, 8 (10): 1019–1026 (2018).
24. Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., and Boone, J. M., "The Essential Physics of Medical Imaging", *Wolters Kluwer*, Philadelphia, UNITED STATES, (2011).
25. Larobina, M. and Murino, L., "Medical Image File Formats", *Journal Of Digital Imaging*, 27 (2): 200–206 (2014).
26. Elsayed, O., Mahar, K., Kholief, M., and Khater, H. A., "Automatic detection of the pulmonary nodules from CT images", *2015 SAI Intelligent Systems Conference (IntelliSys)*, *2015 SAI Intelligent Systems Conference (IntelliSys)*, 742–746 (2015).
27. Demirel, O. and Sonuç, E., "Yapay Zeka Teknikleri Kullanılarak Kemik Yaşı Tespiti", *Türkiye Sağlık Enstitüleri Başkanlığı Dergisi*, 4 (3): 17–30 (2021).
28. Gong, X.-Y., Su, H., Xu, D., Zhang, Z.-T., Shen, F., and Yang, H.-B., "An Overview of Contour Detection Approaches", *International Journal Of Automation And Computing*, 15 (6): 656–672 (2018).
29. Marr, D. and Hildreth, E., "Theory of edge detection", *Proceedings Of The Royal Society Of London*, 187–217 (1980).
30. Haralick, R. M., "Digital Step Edges from Zero Crossing of Second Directional Derivatives", *IEEE Transactions On Pattern Analysis And Machine Intelligence*, PAMI-6 (1): 58–68 (1984).
31. Canny, J., "A Computational Approach to Edge Detection", *A Computational Approach To Edge Detection*, (1986).
32. Jain, R., Kasturi, R., and Schunck, B. G., "Machine Vision", *McGraw-Hill New York*, (1995).
33. Das, S., "Comparison of Various Edge Detection Technique", *International Journal Of Signal Processing, Image Processing And Pattern Recognition*, 9 (2): 143–158 (2016).
34. Papari, G. and Petkov, N., "Edge and line oriented contour detection: State of the art", *Image And Vision Computing*, 29 (2): 79–103 (2011).

35. Rosenfeld, A., "Connectivity in Digital Pictures", *Journal Of The ACM (JACM)*, 17 (1): 146–160 (1970).
36. Codrea, M. C. and Nevalainen, O. S., "Note: An algorithm for contour-based region filling", *Computers & Graphics*, 29 (3): 441–450 (2005).
37. "OpenCV: Structural Analysis and Shape Descriptors", [https://docs.opencv.org/3.4/d3/dc0/group\\_imgproc\\_shape.html#ga2c759ed9f497d4a618048a2f56dc97f1](https://docs.opencv.org/3.4/d3/dc0/group_imgproc_shape.html#ga2c759ed9f497d4a618048a2f56dc97f1) (2022).
38. Wang, L., Ge, L., Li, R., and Fang, Y., "Three-stream CNNs for action recognition", *Pattern Recognition Letters*, 92: 33–40 (2017).
39. Mutasa, S., Sun, S., and Ha, R., "Understanding artificial intelligence based radiology studies: What is overfitting?", *Clinical Imaging*, 65: 96–99 (2020).
40. Hashemi, M., "Enlarging smaller images before inputting into convolutional neural network: zero-padding vs. interpolation", *Journal Of Big Data*, 6 (1): 98 (2019).
41. Sewak, M., Karim, R., and Pujari, P., "Practical Convolutional Neural Networks : Implement Advanced Deep Learning Models Using Python", *Packt Publishing, Limited*, Birmingham, UNITED KINGDOM, (2018).
42. Zafar, I., Tzanidou, G., Burton, R., Patel, N., and Araujo, L., "Hands-On Convolutional Neural Networks with TensorFlow: Solve Computer Vision Problems with Modeling in TensorFlow and Python", *Packt Publishing, Limited*, Birmingham, UNITED KINGDOM, (2018).
43. Han, X., Zhong, Y., Cao, L., and Zhang, L., "Pre-Trained AlexNet Architecture with Pyramid Pooling and Supervision for High Spatial Resolution Remote Sensing Image Scene Classification", *Remote Sensing*, 9 (8): 848 (2017).
44. Dias, C. A., Bueno, J. C. S., Borges, E. N., Botelho, S. S. C., Dimuro, G. P., Lucca, G., Fernández, J., Bustince, H., and Drews Junior, P. L. J., "Using the Choquet Integral in the Pooling Layer in Deep Learning Networks", *Fuzzy Information Processing*, Cham, 144–154 (2018).
45. Hackeling, G., "Mastering Machine Learning with Scikit-Learn", *Packt Publishing, Limited*, Olton Birmingham, UNITED KINGDOM, (2014).
46. Zanaty, E. A., "Support Vector Machines (SVMs) versus Multilayer Perception (MLP) in data classification", *Egyptian Informatics Journal*, 13 (3): 177–183 (2012).
47. "TensorFlow - Tensor Ranks, Shapes, and Types", [https://chromium.googlesource.com/external/github.com/tensorflow/tensorflow/+r0.10/tensorflow/g3doc/resources/dims\\_types.md](https://chromium.googlesource.com/external/github.com/tensorflow/tensorflow/+r0.10/tensorflow/g3doc/resources/dims_types.md) (2022).

48. Internet: LeGro, M., "Why Training Your CNN with 16 Bit Images Isn't Working", <https://towardsdatascience.com/why-training-your-cnn-with-16-bit-images-isnt-working-e91da350c49d> (2022).
49. Fuentes, A., "Mastering Predictive Analytics with Scikit-Learn and TensorFlow: Implement Machine Learning Techniques to Build Advanced Predictive Models Using Python", *Packt Publishing, Limited*, Birmingham, UNITED KINGDOM, (2018).
50. Griffiths, M. R., Noakes, K. A., and Pocock, N. A., "Correcting the Magnification Error of Fan Beam Densitometers", *Journal Of Bone And Mineral Research*, 12 (1): 119–123 (1997).
51. Afifi, M. B., Abdelrazek, A., Deiab, N. A., Abd El-Hafez, A. I., and El-Farrash, A. H., "The effects of CT x-ray tube voltage and current variations on the relative electron density (RED) and CT number conversion curves", *Journal Of Radiation Research And Applied Sciences*, 13 (1): 1–11 (2020).
52. Martín Noguero, T., Paulano-Godino, F., Martín-Valdivia, M. T., Menias, C. O., and Luna, A., "Strengths, Weaknesses, Opportunities, and Threats Analysis of Artificial Intelligence and Machine Learning Applications in Radiology", *Journal Of The American College Of Radiology*, 16 (9, Part B): 1239–1247 (2019).

## ÖZGEÇMİŞ

Osman DEMİREL ilk, orta ve lise öğrenimini Erzincan'da tamamladı. 2001 yılında Uludağ Üniversitesi Radyoloji programından mezun oldu. 2005 yılında İnönü Üniversitesi Sağlık Memurluğu bölümünden mezun oldu. Malatya ilinde başladığı kamu hizmetine Erzurum ilinde devam etti. 2017 yılında Atatürk Üniversitesi Bilgisayar Mühendisliği Bölümünden mezun oldu. Samsun İl Sağlık Müdürlüğünde mühendis olarak görevine devam etti. Halen Erzincan Binali Yıldırım Üniversitesi Mengücek Gazi Eğitim Araştırma Hastanesinde Bilgisayar Mühendisi olarak görevine devam etmektedir.