

T.C.
SIİRT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME YÖNTEMLERİ İLE EL BİLEK GRAFİSİNDEN
KEMİK YAŞININ TAHMİNİ

DOKTORA TEZİ

Cüneyt ÖZDEMİR
(183113001)

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Yılmaz KAYA

Mart-2022
SIİRT

TEZ KABUL VE ONAYI

Cüneyt ÖZDEMİR tarafından hazırlanan “Derin Öğrenme Yöntemleri ile El Bilek Grafisinden Kemik Yaşının Tahmini” adlı tez çalışması 29/03/2022 tarihinde aşağıdaki jüri tarafından oybirliği ile Siirt Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof.Dr. Necmettin SEZGİN

.....

Danışman

Doç.Dr. Yılmaz KAYA

.....

Üye

Doç.Dr. Ömer Faruk ERTUĞRUL

.....

Üye

Doç.Dr. Mehmet Recep MİNAZ

.....

Üye

Dr. Öğr. Üyesi MAHMUT KAYA

.....

Yukarıdaki sonucu onaylarım.

Doç. Dr. Fevzi HANSU
Fen Bilimleri Enstitüsü Müdürü

ÖN SÖZ

Doktora öğrenim sürecimde bana yol gösteren, bilgi birikimini ve manevi desteğini benden esirgemeyen danışman hocam Doç.Dr. Yılmaz KAYA'ya,

Bu doktora çalışması için gerekli veri setini sunan ve çalışmanın birçok noktasında radyoloji alanı ile ilgili yardımlarını esirgemeyen, konu ile ilgili her aradığımda gerekli bilgileri sunan Radyolog Dr. Mehmet Ali GEDİK'e,

Tezimin ilerleme sürecinde, tez izleme toplantılarına katılarak çalışmanın ilerlemesine katkı sunan ve süreç içerisindeki motivasyonumu arttıran değerli hocalarım Doç.Dr.Ömer Faruk ERTUĞRUL ve Doç.Dr.Mehmet Recep MİNAZ'a, teşekkürü bir borç bilirim.

Bu tezi 22 yıldır bana katlanan, sabır gösteren, her türlü kahrımı ve nazımı çeken sevgili eşime ve çok sevdiğim çocuklarıma ithaf ediyorum...

Cüneyt ÖZDEMİR
SİİRT-2022

İÇİNDEKİLER

ÖN SÖZ	iii
İÇİNDEKİLER	iv
TABLOLAR LİSTESİ	vi
ŞEKİLLER LİSTESİ	vii
KISALTMALAR VE SİMGELER LİSTESİ	x
ÖZET	xi
ABSTRACT	xii
1. GİRİŞ	1
1.1. Yaş ile İlgili Bazı Kanun Maddeleri	3
1.2. Kemik Gelişimi	6
1.3. Yaş Tespitinin Tarihçesi	9
1.4. G&P Yöntemi	10
1.5. T-W Yöntemi	13
1.6. Gök Atlası	16
1.7. Tezin Amacı	16
1.8. Tezin Özgün Değeri	19
2. LİTERATÜR ARAŞTIRMASI	20
2.1. 18 Yaş Altı İçin Yapılan Araştırmalar	20
2.2. 18 Yaş Üstü Kemik Yaşı Tespiti İçin Yapılan Araştırmalar	39
3. MATERYAL VE METOT	45
3.1. Materyal	45
3.1.1. 18 yaş altı veri seti	46
3.1.2. 18 yaş üstü veri seti	50
3.1.3. Veri setlerine uygulanan ön işlem adımları	54
3.2. Metot	58
3.2.1. Yapay sinir ağları	60
3.2.2. Derin öğrenme	64
3.2.3. Evrişimsel sinir ağları	65
3.2.4. Aktivasyon fonksiyonları	73
3.2.5. Normalizasyon katmanı	77
3.2.6. Seyreltme katmanı	77
3.2.7. Derinlik birleştirme katmanı	78
3.2.8. Hiperparametreler	79
3.2.8.1. Döngü sayısı ve yığın büyüklüğü	79
3.2.8.2. Öğrenme hızı	80

3.2.8.3. Düzenleştirme	81
3.2.9. Transfer öğrenme modelleri.....	82
3.2.9.1. InceptionV3.....	83
3.2.9.2. Modifiye edilmiş InceptionV3	86
3.2.9.3. MobileNetV2	87
3.2.9.4. EfficientNet.....	90
3.2.9.5. ResNet50V2	91
3.2.9.6. DenseNet201	92
3.2.10. Kemik yaşı tespitinde görüntü işleme prosedürü.....	93
3.2.11. 18 yaşından küçük bireylerde kemik yaşı tespiti blok diyagramı... 95	
3.2.12. 18 yaşından büyük bireylerde kemik yaşı tespiti blok diyagramı... 96	
3.2.13. 18 yaşından küçük bireyler için önerilen ağ yapısı.....	97
3.2.14. 18 yaşından büyük bireyler için önerilen ağ yapısı.....	98
3.2.15. Performans ölçütleri.....	98
4. BULGULAR.....	100
4.1. 18 Yaş Altı Bireylerde Kemik Yaşı Tespiti Deneysel Sonuçları	100
4.2. 18 Yaş Üstü Bireyler İçin Deneysel Sonuçlar.....	125
5. TARTIŞMA VE SONUÇ	135
5.1. 18 Yaş Altı	136
5.2. 18 Yaş Üstü	139
KAYNAKÇA.....	141
EKLER.....	152
EK 1: Kütahya Sağlık Bilimleri Üniversitesi Rektörlüğü Etik Kurulu Karar Formu Üst Yazı	152
EK 2: Kütahya Sağlık Bilimleri Üniversitesi Rektörlüğü Etik Kurulu Karar Formu (18 yaş altı bireyler için).....	153
EK 3: Kütahya Sağlık Bilimleri Üniversitesi Rektörlüğü Etik Kurulu Karar Formu (18 yaş üzeri bireyler için).....	154
ÖZGEÇMİŞ	155

TABLolar LİSTESİ

Sayfa

Tablo 1.1. Bazı ülkelerde cezai sorumluluk yaşları.....	4
Tablo 1.2. Bazı ülkelerde yasal evlilik yaşları.....	5
Tablo 3.1. Veri setlerinin cinsiyete göre dağılımları	48
Tablo 3.2. KRV veri setindeki görüntülerin cinsiyet ve yaşlara (yıl) göre dağılımı	48
Tablo 3.3. RSNA veri setindeki görüntülerin cinsiyet ve yaşlara (yıl) göre dağılımı	49
Tablo 3.4. 18 yaş üstü görüntülerin cinsiyete göre dağılım tablosu	51
Tablo 3.5. Farklı anatomik bölgeler için kullanılan popüler transfer öğrenme modeller	82
Tablo 3.6. Evrişimli sinir ağı modellerinin mimari yapıları	83
Tablo 3.7. Inceptionv3 model mimarisi.....	85
Tablo 3.8. MobileNetV2 ağ yapısı.....	89
Tablo 4.1. Tez çalışmasında derin öğrenme modellerinin uygulandığı platformlar ve donanımsal yeterlilikler	100
Tablo 4.2. Transfer öğrenme modellerine göre sonuçlar.....	102
Tablo 4.3. Optimizasyon fonksiyonu olarak SGD kullanıldığında önerilen modelin başarıları	104
Tablo 4.4. Aktivasyon fonksiyonu olarak RELU kullanıldığında önerilen modelin başarıları	108
Tablo 4.5. KRV veri seti için önerilen modelin cinsiyete göre yaş grup performansı .	111
Tablo 4.6. RSNA veri seti için önerilen modelin cinsiyete göre yaş grup performansı	115
Tablo 4.7. Önerilen modelin cinsiyet katmanına göre performans sonuçları	117
Tablo 4.8. Kemik yaşı tahmini ile ilgili yapılan çalışmalar.....	123
Tablo 4.9. Eğitim veri seti için transfer öğrenme modellerin başarı oranları	126
Tablo 4.10. Doğrulama veri seti için transfer öğrenme modellerin başarı oranları.....	126
Tablo 4.11. Test veri seti için transfer öğrenme modellerin başarı oranları	127
Tablo 4.12. Erişkin yaş tayininde dental grafilere manuel yöntemlerle başarı oranları	133
Tablo 4.13. Erişkin yaş tayininde derin öğrenme yöntemleri başarı oranları.....	133

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.1. (A) 14 aylık kız çocuğuna ait görüntü, (B) 22 aylık erkek çocuğuna ait görüntü	6
Şekil 1.2. Doğumdan, gelişimin tamamlandığı ergenliğe kadar el ve bilekte ki kemik gelişimi.....	7
Şekil 1.3. G-P atlas yöntemi kullanarak kemik yaşı tahmini.....	11
Şekil 1.4. G&P yöntemine göre odaklanan alanlar.....	12
Şekil 1.5. (a) TW yönteminde analiz edilen ROI'ler, (b) ROI'nin metafizlere, diyafizlere ve epifizlere bölünmesi	15
Şekil 1.6. El röntgeninin ROI alanları	15
Şekil 3.1. KRV veri setindeki kayıtların yaşlara (aylık) göre dağılımı. (A) Tüm veri seti, (B) Erkeklerle ait dağılım, (C) Kadınlara ait dağılım	47
Şekil 3.2. RSNA veri setindeki kayıtların yaşlara (aylık) göre dağılımı. (A) Tüm veri seti, (B) Erkeklerle ait dağılım, (C) Kadınlara ait dağılım.....	47
Şekil 3.3. KRV veri setindeki görüntülerin cinsiyet ve yaşlara(yıl) göre dağılımı	49
Şekil 3.4. RSNA veri setindeki görüntülerin cinsiyet ve yaşlara(yıl) göre dağılımı	50
Şekil 3.5. KYRV veri setindeki görüntülerin cinsiyetlere göre yaşlarının dağılımı.....	51
Şekil 3.6. KYRV veri setinin cinsiyetlere göre yaşlarının dağılımı	54
Şekil 3.7. Döndürme	55
Şekil 3.8. Yatay kaydırma.....	56
Şekil 3.9. Dikey kaydırma	56
Şekil 3.10. Rastgele parlaklık	57
Şekil 3.11. Rastgele yakınlaştırma.....	58
Şekil 3.12. Makine öğrenmesi ve derin öğrenme arasındaki farklılıklar.....	59
Şekil 3.13. Yapay zekâ, makine öğrenmesi ve derin öğrenme	60
Şekil 3.14. Basit bir sinir hücresi (Nöron)	61
Şekil 3.15. Yapay sinir ağı.....	62
Şekil 3.16. Bir sinir hücresinin YSA katman karşılığı	63
Şekil 3.17. Çok katmanlı yapay sinir ağı	64
Şekil 3.18. Evrimsel sinir ağı yapısı.....	66
Şekil 3.19. Filtreleme kullanılarak yapılan evrişim işlemi	67
Şekil 3.20. Dolgu kullanılmayan evrişim örneği	68
Şekil 3.21. İsteğe bağlı dolgulu evrişim örneği	69
Şekil 3.22. Yarım dolgu evrişim örneği.....	70
Şekil 3.23. Tam dolgulu evrişim örneği	70
Şekil 3.24. Maksimum havuzlama örneği	72
Şekil 3.25. Ortalama havuzlama örneği.....	72
Şekil 3.26. Sigmoid fonksiyonu.....	74
Şekil 3.27. Tanh fonksiyonu	75
Şekil 3.28. ReLu fonksiyonu	76
Şekil 3.29. Sızıntı ReLu fonksiyonu	76
Şekil 3.30. Seyreltme katmanı	78
Şekil 3.31. Derinlik birleştirme yapısı	79
Şekil 3.32. Temel Inception Modülü	84
Şekil 3.33. Boyutu azaltılmış Inception modülü.....	85
Şekil 3.34. InceptionV3 ağ yapısı	86
Şekil 3.35. Modifiye edilmiş InceptionV3 ağ mimarisi.....	87

Şekil 3.36. Sol: Batchnormalization ve ReLU ile standart evrişim katmanı. Sağ: Batchnormalization ve relu tarafından takip edilen derinlik yönünde ve nokta yönünde katmanlarla derinlemesine ayrılabilir evrişimler.....	88
Şekil 3.37. MobileNet yapısı	89
Şekil 3.38. EfficientNetB4 temel ağ yapısı.....	90
Şekil 3.39. ResNet ile Artık Ağ Evrişimi	91
Şekil 3.40. Resnet50V2 temel ağ yapısı	92
Şekil 3.41. DenseNet ağ mimarisi	92
Şekil 3.42. DenseNet201 layer mimarisi	93
Şekil 3.43. Görüntülere uygulanan otomatik kontrast ve parlaklık işlemi. (A) Orijinal görüntüler (B) Otomatik kontrast ve parlaklık ayarı uygulandıktan sonra elde edilen görüntüler	94
Şekil 3.44. 18 yaş altı için kemik yaşı tespiti için derin öğrenme yöntemlerinin genel mimarisi	95
Şekil 3.45. 18 yaş üstü bireylerde kemik yaşı tespiti için derin öğrenme yöntemlerinin genel mimarisi.....	96
Şekil 3.46. Görüntülere uygulanan otomatik kontrast ve parlaklık işlemi. (A) Orijinal görüntüler, (B) Otomatik kontrast ve parlaklık ayarı uygulandıktan sonra elde edilen görüntüler, (C) Yeniden ölçeklendirildikten sonra elde edilen görüntüler.....	96
Şekil 3.47. Önerilen kemik yaşı ağ mimarisi.....	97
Şekil 3.48. Önerilen kemik yaşı ağ mimarisi.....	98
Şekil 4.1. KRV veri seti için Modifiyeli InceptionV3 modeline ait loss grafiği	103
Şekil 4.2. KRV veri seti için Modifiyeli InceptionV3 modeline ait MAE grafiği	103
Şekil 4.3. KRV veri seti için Modifiyeli InceptionV3 yöntemi ile elde edilen tahmin sonuçlarına ait birkaç görüntü.....	104
Şekil 4.4. Modifiyeli InceptionV3 modelinde SGD optimizasyon fonksiyonunun kullanımı sonucu MAE grafiği	105
Şekil 4.5. Modifiyeli InceptionV3 modelinde SGD optimizasyon fonksiyonunun kullanımı sonucu kayıp grafiği	105
Şekil 4.6. KRV veri seti için Modifiyeli InceptionV3 modelinin SGD optimizasyon fonksiyonunun kullanımı sonucu gerçek ve tahmin ettiği değerlere ait sonuçları.....	106
Şekil 4.7. KRV veri seti için Modifiyeli InceptionV3 modelinin SGD optimizasyon fonksiyonunun kullanımı sonucu elde edilen tahmin sonuçlarına ait birkaç görüntü	107
Şekil 4.8. Modifiyeli InceptionV3 modelinde RELU aktivasyon fonksiyonu kullanımı sonucu MAE grafiği.....	108
Şekil 4.9. Modifiyeli InceptionV3 modelinde RELU aktivasyon fonksiyonu kullanımı sonucu kayıp grafiği.....	109
Şekil 4.10. Modifiyeli InceptionV3 modelinin RELU aktivasyon fonksiyonunu kullanması sonucu gerçek ve tahmin ettiği değerlere ait sonuçları	109
Şekil 4.11. Modifiyeli InceptionV3 modelinin RELU aktivasyon fonksiyonunu kullanması sonucu elde edilen tahmin sonuçlarına ait birkaç görüntü	110
Şekil 4.12. KRV veri setinde erkeklere ait performans sonuçlarının grafiği.....	112
Şekil 4.13. KRV veri setinde kızlara ait performans sonuçlarının grafiği.....	112
Şekil 4.14. RSNA veri seti için modifiyeli InceptionV3 modeline ait MAE grafiği....	113
Şekil 4.15. RSNA veri seti için modifiyeli InceptionV3 modeline ait loss grafiği	113
Şekil 4.16. RSNA veri seti için modifiyeli InceptionV3 yöntemi ile elde edilen tahmin sonuçlarına ait birkaç görüntü.....	114

Şekil 4.17. RSNA veri setinde erkeklere ait performans sonuçlarının grafiği	115
Şekil 4.18. RSNA veri setinde kızlara ait performans sonuçlarının grafiği	115
Şekil 4.19. KRV veri seti için modifiye edilmiş Inception V3 Modeline ait ısı haritası örneği (Grad-CAM)	116
Şekil 4.20. RSNA veri seti için modifiye edilmiş Inception V3 Modeline ait ısı haritası örneği	117
Şekil 4.21. Cinsiyet katmanı olmadan modifiyeli InceptionV3 modelinin MAE grafiği	118
Şekil 4.22. Cinsiyet katmanı olmadan modifiyeli InceptionV3 modelinin loss grafiği	118
Şekil 4.23. Cinsiyet katmanı olmadan modifiyeli InceptionV3 modelinin gerçek ve tahmin ettiği değerlere ait başarı grafiği	119
Şekil 4.24. Cinsiyet katmanı olmadan modifiyeli InceptionV3 modelinin gerçek ve tahmin ettiği değerlere ait sonuçlar	120
Şekil 4.25. KRV Eğitim seti için performans değerleri	121
Şekil 4.26. KRV doğrulama seti için performans değerleri	121
Şekil 4.27. KRV Test seti için performans değerleri	122
Şekil 4.28. KRV Eğitim, doğrulama ve test setleri için regresyon grafikleri	122
Şekil 4.29. Modifiye edilmiş InceptionV3 modelinin KRV test verileri üzerinde başarı	124
Şekil 4.30. Modifiye edilmiş InceptionV3 modelinin RSNA test verileri üzerinde başarısı	124
Şekil 4.31. DenseNet201 için erkek ve kadınlara ait regresyon grafikleri	128
Şekil 4.32. InceptionV3 için erkek ve kadınlara ait regresyon grafikleri	128
Şekil 4.33. ResNet50V2 için erkek ve kadınlara ait regresyon grafikleri	129
Şekil 4.34. DenseNet201 ile test seti için erkek ve kadınlara ait gerçek yaş değerleri ile tahmin edilen yaş değerleri	129
Şekil 4.35. InceptionV3 ile test seti için erkek ve kadınlara ait gerçek yaş değerleri ile tahmin edilen yaş değerleri	130
Şekil 4.36. ResNet50V2 ile test seti için erkek ve kadınlara ait gerçek yaş değerleri ile tahmin edilen yaş değerleri	130
Şekil 4.37. Cinsiyete göre bazı örneklerle ait gerçek yaşlar ve DenseNet201 modelinin tahmin ettiği yaşlar	131
Şekil 4.38. Erkek ve Kadın hastalar için DenseNet201 modelinin ısı haritası	132

KISALTMALAR VE SİMGELERLİSTESİ

<u>Kısaltma</u>	<u>Açıklama</u>
TCK	Türk Ceza Kanunu
G&P	Greulich ve Pyle
TW	Tanner-Whitehouse
MRG	Manyetik Rezonans Görüntüleme
ROI	Region of Interest
RUS	Radius-Ulna-Short bones
KRV	Kütahya Radyoloji Veri seti
KYRV	Kütahya Yetişkin Radyoloji Veri seti
KYT	Kemik Yaşı Tahmini
RSNA	Radiologic Society of North America
PACS	Picture Archiving and Communication System
ESA	Evrişimsel sinir ağları
YSA	Yapay Sinir Ağı
RELU	Rectified Lineer Unit
RMSE	Hata kareler ortalamasının karekökü
MAE	Mutlak hatalar ortalaması
R2	Belirleme katsayısı (R2)
Grad-CAM	Gradientweighted Class Activation Mapping

ÖZET

DOKTORA TEZİ

DERİN ÖĞRENME YÖNTEMLERİ İLE EL BİLEK GRAFİSİNDEN KEMİK YAŞININ TAHMİNİ

Cüneyt ÖZDEMİR

**Siirt Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman : Doç.Dr. Yılmaz KAYA

2022, 156 + XII Sayfa

Yaş tespiti medikal alanda, çocukluk çağında, büyüme ve gelişmenin takibinde, çocuklarda büyümeyi ve gelişmeyi etkileyen çeşitli hastalık durumlarında, adli tıpta, yaşa göre cezai sorumluluk durumlarında, evlilik, askere alınma, rekabetçi sporlarda ve işe başlama durumlarında, mültecilerde, çocuk erişkin ayrımında bulunmak gibi birçok farklı konuda istenebilmektedir. Bu tez çalışması ile pediatrik kemik yaşı tahmini için radyologların iş akışını hızlandıracak, sol el bilek grafilerinden derin öğrenme teknolojisi kullanılarak bilgisayar temelli bir karar destek sistemi geliştirilmiştir. Bu çalışmada kullanılan veri setleri Kütahya ilinden temin edilen görüntülerden ve literatürde public olarak dağıtılan RSNA veri setinden oluşmaktadır. Veri seti Kütahya sağlık bilimleri üniversitesi rektörlüğün'den etik kurul izni ile alınmıştır. Çalışmada 18 yaş üstü ve 18 yaş altı şeklinde iki farklı senaryo için denemeler gerçekleştirilmiştir. 18 yaş altı için yapılan çalışmada derin öğrenme metotlarından InceptionV3, MobileNetV2, EfficientNetB4 ve modifiye edilmiş InceptionV3 modellerinin performansları karşılaştırılmıştır. 18 yaş altı sonuçlara bakıldığında veri setimiz üzerinde modifiye edilmiş InceptionV3 transfer derin öğrenme yöntemi ile MAE=4,3, RMSE=5,76, R2=0,99 olarak bulunmuştur. Önerilen InceptionV3 transfer öğrenme modeli ile public olarak dağıtılan veri seti üzerinde MAE=5.75, RMSE=7.42 ve R2=0.96 olarak tespit edilmiş olup literatürde bu veri seti üzerinde yapılan çalışmalar arasında ki en iyi sonuçlardan biri elde edilmiştir. Bu çalışma ile modellerin cinsiyetlere ve yaş gruplarına göre farklılıkları ölçülmüştür. Ayrıca bu çalışma Türkiye'den toplanan el bilek grafi veri seti ile yapılan ilk derin öğrenme çalışmalarından biridir. Bu çalışma el bilek grafilerinden kemik yaşı tespitinde kullanılmak üzere yeni bir veri seti oluşturulmuş olup, yeni bir model tavsiye edilmiştir.

Bu çalışmada yapılan diğer bir çalışma ise 18 yaş üstündeki bireylerin el bilek görüntülerinden kemik yaşının tespitine yönelik olarak yapılmıştır. Literatürde 18 yaş üstündeki bireylerin sol el bilek grafilerinden erişkin bireylerde yaş tespitinin derin öğrenme yöntemleri ile yapıldığına dair herhangi bir araştırmaya rastlanmamıştır. Bu çalışma ile 18 yaş üzeri bireylerde yaş tespiti derin öğrenme yöntemleri (DenseNet201, InceptionV3, ResNet50V2) ile yapılmıştır. Tarafımızca oluşturulan veri setinin kullanılması ile erkeklerde MAE=1,666, RMSE=2,665, R2=97,32 ve kadınlarda MAE=2,044, RMSE=3,069, R2=96,84 performans sonuçları gözlenmiştir. Bu çalışmada kullanılan yöntem ve bulunan sonuçlar bu alanda yapılan ilk çalışmadır. Bu sonuçlar ışığında bu çalışmada kullanılan metot bize derin öğrenme metotlarının 18 yaş üstü bireylerde kemik yaşı tespitinde yardımcı bir araç olarak kullanılabileceğini göstermiştir.

Anahtar Kelimeler: Kemik yaşı tespiti, derin öğrenme, X-Ray, 18 yaşından küçük, 18 yaşından büyük, yetişkin

ABSTRACT

Ph.D THESIS

AGE ESTIMATION FROM LEFT-HAND RADIOGRAPHS WITH DEEP LEARNING METHODS

Cüneyt ÖZDEMİR

**The Graduate School of Natural and Applied Science of Siirt University
Doctor of Philosophy In Electrical-Electronics Engineering**

Supervisor : Associate Prof.Dr. Yılmaz KAYA

2022, 156+ XII Pages

Age estimation is required in many different circumstances s, in the medical field monitoring the growth and development in children, in forensic medicine describing criminal liability cases according to age. Additionally, marriage, military recruitment, competitive sports and employment situations, and discrimination between children and adults in refugees may require age estimation. In this thesis, a computer-based decision support system which will speed up the workflow of radiologists for pediatric bone age estimation has been developed by using deep learning technology from left hand wrist radiographs. For this purpose, the performances of InceptionV3, MobileNetV2, EfficientNetB4 and modified InceptionV3 deep learning methods were compared. RSNA dataset which is publicly distributed in the literature and a newly formed dataset from the left-hand radiographs of children from the Kütahya province is used in this study. The data set was obtained from Kütahya University of Health Sciences with the permission of the ethics committee. For this essay, trials for two different scenarios: over 18 years old and under 18 years old were carried out. The results for below the 18 years age group with the modified InceptionV3 transfer deep learning method on new data set are as MAE=4,3, RMSE=5,76, R2=0,99. Additionally with the proposed InceptionV3 transfer learning model on the publicly distributed data set results are as MAE=5,75, RMSE=7,42 and R2=0,96. These are one of the best results among the studies on this data set In addition, this research is one of the first deep learning studies conducted on a dataset that contains images from turkish people. Furthermore for this study, a new data set was created for bone age estimation from hand-wrist radiographs, and also a new deep learning model was recommended.

Another part of this research is for bone age determination with hand-wrist radiographs for adults. Upto our knowledge there is no research in the literature for adult bone age determination with deep learning methods from left hand wrist radiographs. Deep learning methods which are DenseNet201, InceptionV3 and ResNet50V2 are used for bone age estimation of subjects over the age of 18. Performance results on the newly created data set are as following, for females MAE=1,666, RMSE=2,665, R2=97,32, for males and MAE=2,044, RMSE=3,069, R2=96,84 With these settings the method used and the results found are the first in this specific field. In the light of these results, we can conclude deep learning methods can be used as an assistant tool for determining bone age in individuals over the age of 18.

Keywords: Bone age estimation, deep learning, X-Ray, under 18 years old, over 18 years old, adult

1. GİRİŞ

Kemik yaşı tespiti; birçok bilim dalında tıbbi ve hukuki konuları aydınlatmak için önemli bir yere sahiptir (Yarimoğlu ve ark., 2005). Yaş; bireyin medikal kimliğini oluşturan fiziksel özelliklerden biridir (Büken ve ark., 2003). Yaş tespiti çocukların genetik ve büyüme bozukluklarını araştırmak için yaygın bir klinik uygulamadır.

Klinik yorumlama ve kemik yaşı analizleri zaman alıcı, yoğun emek gerektiren ve genellikle gözlemciler arası değişkenliğe maruz kalabilmektedir.

Şüpheli ölümler, bebek cesetleri, kendini ifade edemeyecek durumdaki kişiler ve kimliği belirsiz kişilerde yaş tespitinin yapılması gerekebilmektedir. Yaş tayinine ülkemizin kırsal kesimlerde özellikle sağlıklı doğum ve nüfus kayıtlarının olmamasından kaynaklı başvurular sıklıkla yapılmaktadır. Adli tıp uygulamalarında cezai sorumluluğun tespiti, hukuki ehliyetle haiz olup olmadığı, işlediği eylemin hukuksal manasını ve önemini kavrama ve davranışlarını yönlendirme yeteneğinin tespiti, karşılaşılan cinsel istismar olaylarında psikolojik açıdan kendini koruyup koruyamayacağının tespiti, yasalara aykırı eylemlerde bulunmuş zanlılarda, askere alınma, memuriyete girme, evlenme, emeklilik, okula çağında, sürücü belgesine başvuru durumlarında kişinin yaşının bilinmesi gerekmektedir. Özetle kişilerin yargıya yansıyan olaylarda ve insanların sosyal ilişkilerinde yaş tespiti büyük öneme sahiptir. Söz edilen durumlarda yargı mercileri adli tıp doktorlarından kişinin yaşının tespitinin yapılmasını istemektedir. (Gök ve ark., 1985b; Aykaç, 1987; Çöloğlu, 1987; Schmeling ve ark., 2000; Koc ve ark., 2001; Bilgin ve ark., 2003; Büken ve ark., 2003; Isır ve Dulger, 2007). Bireysel olarak gerçek yaşını öğrenme isteği gibi durumlarda, ayrıca tedavi uygulanacak hastanın tedavi protokolünün seçilmesi, uygulanacak ameliyat yönteminin belirlenmesi, ilaçların belli yaşlara uygun olarak başlanması, hasta onayı alınırken kişinin 18 yaşından büyük olması gibi tıbbi uygulamalarda da yaş önemli olduğundan yaş tahminin yapılması da önemli bir duruma gelmiştir (DAŞ, 2019). Çocuk hastalarda büyüme gelişimin takip edilmesi önemlidir. Kronolojik yaşa göre çocuğun bilinç derecesi, ağırlığı, boyu ve dişlerinin sayısı değerlendirilmektedir. Aynı ırk, cinsiyet ve yaştaki bireyler arasında fizyolojik farklılıklar olabilir. Bu nedenle bazı bireylerin biyolojik yaşı kronolojik yaşına göre farklılık gösterebilir. Çocuğun gelişim durumunun belirlenmesi, normal gelişimden farklılıkların tespitine varılması, tedavi seçimi, tedaviye zamanında başlama gibi konularda biyolojik yaş temel alınmaktadır (Hägg ve Taranger, 1980; Saini, 2013).

Türkiye’de geçmişte yeni doğan çocuklar nüfusa geç kaydedilmekte ve ölen çocukların kimlik bilgileri yeni doğan çocuklar verildiğinden birçok kişinin yaşı büyük olarak görünmektedir. Bu tarz kişilerin gerçek yaşları ile kimlikte ki yaşları farklı olmaktadır. Türkiye’de nüfus kayıtlarının bazı bölgelerde zamanında yapılmadığı bilinmektedir. Buna benzer sorunlar ile birlikte miras olayları, spor kulüpleri, adli olaylar, emeklilik durumunda gerçek yaşı saklanması ya da sahte kimlik kullanılması durumları yaşanmaktadır. (Baransel Isır, 2009). Geçmişte ulaşımın zorluğundan kaynaklı olarak özellikle kırsal kesimde yaşayan bireylerin şehre gitmek yerine yeni doğan çocuklarına ölen çocuklarının kimliklerini verildiği bilinmektedir. Bu ve benzeri olaylar ile birlikte ölü kişilerin kimlik tespitine yardımcı olması açısından yaş tespitinin yapılması önemini korumaktadır.

Ülkemizin sosyoekonomik açıdan düşük alanlarında ve kırsal kesimlerinde nüfus ile ilgili kayıtların düzgün tutulmaması, ayrıca komşu ülkelerde yaşanan iç savaşlardan kaynaklı olarak ülkemize gelen mültecilerde kimlik bilgileri ile ilgili problemlerin yaşanması sebebiyle yaş tespitinin yapılması önemli bir hal almıştır.

Günümüzde dünya genelinde yaşanan etnik, siyasi veya sosyal çatışmalar ile ekonomik kaygılardan dolayı göç hareketleri hızlanmıştır (Güllüpinar, 2012). Ülkemize son yıllarda Suriye'deki iç savaş nedeniyle sığınan çok sayıda mülteci, Türkiye'yi dünya çapında en çok mülteci barındıran ülke konumuna getirmiştir (Şen ve Özkorul, 2016). Türkiye’de 27 Ocak 2022 itibari ile sadece Suriye’den gelen yaklaşık 3.736.091 geçici koruma kapsamında bulunmaktadır. Bunların 1 milyon 767 bin 063’ü (%47,3) 0-18 yaş arasındadır. (<https://www.goc.gov.tr/gecici-koruma5638>).

Birleşmiş Milletler Çocuk Sözleşmesi'ne göre onsekiz yaşına kadar her insan çocuk sayılır ve özel haklara sahiptir. Bu durumu istismar etmek isteyen sığınmacılar genellikle 18 yaşından küçük olduklarını beyan ederek Birleşmiş Milletler Çocuk Sözleşmesi'nden yararlanmak istemektedirler.

Kemik olgunlaşması, yaşa bağlı olarak farklı metotlarla değerlendirilebilir. Olgunlaşma süreci; kalıtım, etnik köken, cinsiyet, sosyoekonomik durum gibi farklı değişkenlere göre değişim göstermektedir. Kemik yaşı tespitinde genel olarak ilk 5 yılda ki ossifikasyon merkezlerinin görülme zamanı, 5-14 yaş aralığında epifizlerin durumu ve sesamoid kemikler gibi olgunlaşma kriterleri, 15-25 yaş aralığında ise sekonder ossifikasyon merkezlerinin kemik ile füzyon zamanı araştırılır (Tuncel, 2008).

İskelet gelişiminin değerlendirilmesi için farklı yöntemler kullanılmaktadır. Bu yöntemler arasında en yaygın kullanılanı el-bilek radyografi yöntemidir.

El, vücudumuzun ince hareketlerini yapabilmesini sağlayan en gelişmiş kısımlarından biri olup, dokunma duyusunun temel organıdır. Elin şekillenerek gelişmesinde ve farklılaşmasında genetik yapının önemi büyüktür. Elin gelişim sürecinde; elin karşılaştığı dış etkenler el yapısının şekillenmesinde önemli bir faktördür. Eller kemik, kıkırdak ve kas dokusundan meydana gelmektedir (Demirel, 2005).

Toplumlarda dominant elin sağ el olması ve sol elde deformasyon riskinin daha az olması nedeniyle değerlendirme için sol el tercih edilmektedir. Sol el röntgen görüntülerinin analizi, minimum radyasyona maruz kalma ve çoklu kemikleşme merkezlerinin mevcudiyeti nedeniyle kemik yaşının tespiti için yaygın olarak kullanılmaktadır. Genellikle, baskın olmayan elin kemikleşme evrelerinin ayırt edici özelliklerinden yararlanarak, radyolojik muayenesinin yapılması ve ardından kronolojik yaşla karşılaştırılması sonucu kemik yaşı tespiti yapılır.

1.1. Yaş ile İlgili Bazı Kanun Maddeleri

5237 Sayılı Türk Ceza Kanunu (TCK) göre; TCK'nın birçok maddesinde fail veya mağdurun suçun işlendiği tarihteki yaşına bağlı olarak cezaları değişmektedir. TCK 6. maddesinde çocuk “henüz onsekiz yaşını doldurmamış kişi” olarak tanımlanmaktadır. TCK'da çocukların faili olduğu suçlar için cezasızlık veya ceza indirimi uygulanması; erişkin bireylerin çocuklara karşı işlediği suçlarda ise erişkin bireylere verilecek cezada artış halleri düzenlenmiştir.

Ceza kanununa göre bireyin suçlu sayılabilmesi için ceza ehliyetine haiz olması gerekmektedir. Ceza ehliyetine haiz olması için; kişinin suç işlediği anda tam bir bilinç ve iradeye sahip olması istenir.

Türk Ceza Kanunu'nun 6. maddesine göre çocuk “henüz 18 yaşını doldurmamış kişi” olarak tanımlanmaktadır. TCK'nın 31. maddesi “yaş küçüklüğü” ile ilgili cezai sorumlulukla ilgilidir.

Türk Ceza Kanunu'nun 31. maddesinin;

1. fıkrasında “*Fiili işlediği sırada oniki yaşını doldurmamış olan çocukların ceza sorumluluğu yoktur. Bu kişiler hakkında, ceza kovuşturması yapılamaz; ancak, çocuklara özgü güvenlik tedbirleri uygulanabilir.*”;

2. fıkrasında “*Fiili işlediği sırada on iki yaşını doldurmuş olup da on beş yaşını doldurmamış olanların işlediği fiilin hukukî anlam ve sonuçlarını algılayamaması veya davranışlarını yönlendirme yeteneğinin yeterince gelişmemiş olması hâlinde ceza*

sorumluluğu yoktur. Ancak bu kişiler hakkında çocuklara özgü güvenlik tedbirlerine hükmolunur. İşlediği fiilin hukukî anlam ve sonuçlarını algılama ve bu fiille ilgili olarak davranışlarını yönlendirme yeteneğinin varlığı hâlinde, bu kişiler hakkında suç, ağırlaştırılmış müebbet hapis cezasını gerektirdiği takdirde oniki yıldan onbeş yıla; müebbet hapis cezasını gerektirdiği takdirde dokuz yıldan onbir yıla kadar hapis cezasına hükmolunur. Diğer cezaların yarısı indirilir ve bu hâlde her fiil için verilecek hapis cezası yedi yıldan fazla olamaz.”;

3. fıkrasında “Fiili işlediği sırada onbeş yaşını doldurmuş olup da onsekiz yaşını doldurmamış olan kişiler hakkında suç, ağırlaştırılmış müebbet hapis cezasını gerektirdiği takdirde onsekiz yıldan yirmidört yıla; müebbet hapis cezasını gerektirdiği takdirde oniki yıldan onbeş yıla kadar hapis cezasına hükmolunur. Diğer cezaların üçte biri indirilir ve bu hâlde her fiil için verilecek hapis cezası oniki yıldan fazla olamaz.” denilmektedir. Yukarıda ki Türk ceza kanunu maddesinde belirtildiği gibi Türkiye’de 12, 15 ve 18 yaş sınırları cezai ve hukuki yönden önem arz etmektedir. (Türk ceza kanunu, 2004).

Tablo 1.1. Bazı ülkelerde cezai sorumluluk yaşları (DAŞ, 2019)

Ülke Yaş	(Yıl)
Kuzey Caroline (ABD)	6
Tayland, Singapur, Hindistan, Pakistan, Güney Afrika, Sudan, Ürdün	7
İskoçya	12
İngiltere, Galler, Kuzey İrlanda, Avusturalya	10
Türkiye	12
Kanada, Hollanda	12
Çin, Avusturya, Almanya, Japonya, Yeni Zelanda, İspanya	14
İsveç, Norveç, Finlandiya	15
Portekiz	16
Fransa	17
Belçika	18

Yaşa bağlı olarak ayrıca ülkeden ülkeye göre yasal evlilik yaşları da değişmektedir. Tablo 1.2’de bazı ülkelerin yasal evlilik yaşları gösterilmiştir.

Tablo 1.2. Bazı ülkelerde yasal evlilik yaşları (DAŞ, 2019)

Ülkeler	Cinsiyet	
	Kadın	Erkek
Güney Afrika (Geleneksel evlilik)	12	14
Paraguay	14	
Kanada Meksika (Yargı izni ile)	14	14
Venezuela (Ebeveyn izni ile)	14	
Estonya (Ebeveyn izni ile)	15	15
Kenya, İskoçya	16	16
Paraguay		16
Tanzanya	16	
Hong Kong, Belçika, Macaristan, Hollanda, Portekiz, İrlanda, Kanada, Meksika, ABD, (Ebeveyn izniyle)	16	16
Venezuela, Arjantin (Ebeveyn izni ile)		16
Pakistan, Japonya (Ebeveyn izni ile)	16	
Malezya (Özel lisans ile)	16	
İsrail, Ermenistan	17	
Tayland, Türkiye (Ebeveyn izniyle)	17	17
Güney Afrika, Belçika, Filipinler Türkiye, Fransa, İngiltere, Galler, Kuzey İrlanda, Kanada, Meksika, ABD	18	18
Tanzanya, Ermenistan, İsrail		18
Cezayir, Hindistan, Vietnam	18	
Malezya, Güney Kore, (Ebeveyn izni ile)	18	18
Pakistan, Japonya (Ebeveyn izni ile)		18
Japonya, Güney Kore	20	20
Vietnam		20
Çin	20	22
Hong Kong, Malezya, Singapur, Arjantin	21	21
Cezayir, Hindistan		21

TCK'nın 31. maddesi “Sağır ve dilsizlik” ile ilgili cezai sorumlulukla ilgilidir;

1. fıkrasında “Bu Kanunun, fiili işlediği sırada oniki yaşını doldurmamış olan çocuklara ilişkin hükümleri, onbeş yaşını doldurmamış olan sağır ve dilsizler hakkında;

oniki yaşını doldurmuş olup da onbeş yaşını doldurmamış olanlara ilişkin hükümleri, onbeş yaşını doldurmuş olup da onsekiz yaşını doldurmamış olan sağır ve dilsizler hakkında; onbeş yaşını doldurmuş olup da onsekiz yaşını doldurmamış olanlara ilişkin hükümleri, onsekiz yaşını doldurmuş olup da yirmibir yaşını doldurmamış olan sağır ve dilsizler hakkında da uygulanır.” (Türk ceza kanunu, 2004).


Ülkeden ülkeye göre cezai sorumluluk yaşları değişmektedir. Cezai sorumluluk yaşları Tablo 1.1’de gösterilmiştir.

1.2. Kemik Gelişimi

Kişiler de kemik yaşı gelişimi benzer süreçlerden geçtiği için benzerlik gösterebilmekte, fakat aynı kronolojik yaşta olan bireylerin kemik yaşları farklılık gösterebilmektedir (Garn ve Tanner, 1986). Genetik, beslenme, metabolik, sosyal ve duygusal etkenler, tiroksin, büyüme hormonları kemik gelişiminde önemli rol oynamaktadır (De Sanctis ve ark., 2014).

Kemikleşme hemen doğumdan sonra gerçekleşebildiği gibi 14-17 yaşına kadar da devam edebilir. Kadınların kemikleri erkeklere göre daha çabuk olgunlaşmaktadır. İskelet olgunlaşma süreci, erkeklerde kızlara göre daha uzun sürmektedir. El ve bilek yapısı uzun ve kısa kemikler olarak 2’ye ayrılır. Uzun kemikler Radius, ulna ve falanks kemikleri olarak adlandırılır (Garn ve Rohmann, 1960).

El parmak iskeleti ya da el bilek iskeletindeki kemikleşme durumu ile kemik yaşını tespit etmek için birçok yöntem mevcuttur. Ancak 2 yöntem çok popülerdir. Bu yöntemler Greulich ve Pyle (G&P) yöntemi (Greulich ve Pyle, 1959) ve Tanner-Whitehouse (TW) yöntemi (Morris, 2003). Şekil 1.1’de 2 farklı cinsiyete ait el-bilek görüntü örneği verilmiştir.




Şekil 1.1. (A) 14 aylık kız çocuğuna ait görüntü, (B) 22 aylık erkek çocuğuna ait görüntü

Sağlıklı insanlar için kronolojik yaşlarına göre belirli standartlar belirlenmiştir. Kemik yaşı; iskeletteki kemikleşme durumuna bakılarak değerlendirilen, kemik büyümesini değil, kemik olgunlaşmasını gösteren, iskelet gelişimleri standartlara uygun olarak gelişen bireylerin kronolojik yaşı şeklinde ifade edilir. Kemik olgunlaşması çeşitli faktörlerden dolayı farklılık gösterdiğinden bu standartlar her ülkeye göre değişir (Tuncel, 2008).

Bir insanın kronolojik ve kemik yaşı olmak üzere 2 yaş türü vardır. Kronolojik yaş kişinin doğum tarihine bağlı olan gerçek yaşıdır. Kemik yaşı ise kişinin gelişimindeki değişiklikleri temel alır. Kemik yaşı kişinin büyüme gelişme düzeyini ve olgunlaşma derecesini yansıtır (De Sanctis ve ark., 2014).

Kişiler doğum öncesi kıkırdaklı bir iskelete sahiptir. Sağlıklı bir insan ergenliğe ulaştığında olgun bir kemik iskeletine sahip olur. İskelet büyümesi kişi ergenliğe ulaşana kadar devam eden bir süreçtir. İskelet olgunlaşması kişinin ergenliğe girdiğinin bir göstergesidir. Şekil 1.2’de bir kişinin ilk doğumdan ergenliğe kadar geçen sürede el ve bileğinde ki kemik gelişimi gösterilmiştir.



Şekil 1.2. Doğumdan, gelişimin tamamlandığı ergenliğe kadar el ve bilekte ki kemik gelişimi (Cunningham ve ark., 2016)

Kemik yaşı tahmini yapmak için kişilerin el bilek grafisi, standart görüntülerden oluşan bir atlas ile karşılaştırılır veya el bilek grafisi üzerinde skrolama metotları kullanılır.

G-P metodunda bireylerin kemik radyografik görüntüleri, kişilerin yaş ve cinsiyetine göre oluşturulan standart radyografik görüntüleri ile mukayese edilmektedir (Greulich, 1950).

Kemik yaşı değerlendirmesi geleneksel olarak sol el bilek grafilerinden oluşan atlas yöntemleri ile yapılmaktadır. Ancak son zamanlarda ultrasonografi, manyetik rezonans ve bilgisayarlı tomografi görüntüleri ile deneysel düzeyde yöntemler de kullanılmaktadır (Devecioğlu ve ark., 2006; Štern ve ark., 2019).

Ülkemizde kemik yaşı tayini, Şemsi Gök ve arkadaşları tarafından 1969 yılında Greulich ve Pyle (G-P) atlası kullanılarak ülkemize göre uyarlanarak meydana getirilen gök atlası, Tanner-Whitehouse (TW) skrolama yöntemi ve batı standartlarına göre oluşturulan atlaslar ile yapılmaktadır (Korkut ve ark., 2001). Fakat ülkemizdeki vatandaşlarımız baz alınarak yapılmış ve genel kabul görmüş yaş tayini atlası henüz bulunmamaktadır (Koc ve ark., 2001).

Gök atlasında sol el-bilek, dirsek, omuz ve pelvis grafileri kullanılırken, GP ve TW yöntemlerinde sadece sol el bilek grafileri kullanılmaktadır. Yapılan bir araştırmada ülkemizde, adli tabiplerin %45'i Gök atlasını, %21,7 si GP atlasını, %17,4 ü TW yöntemini kullanmaktadır (Büken ve ark., 2007, 2009). G-P atlasında bireyin kemikleşme durumunu belirli kriterlere göre eşleştirilmekte, TW3'te el ve bilekteki belirli metakarpal ve falanks kemikleri, radius, ulna gibi belirli kemikleşme merkezleri değerlendirilerek farklı safhalar altında sınıflandırılmaktadır. Her bir kemik için yapılan skrolama hesabından sonra toplam kemik yaşına ulaşılmaktadır (Haiter-Neto ve ark., 2006).

Türk çocuklarında erkeklerin ergenlik çağında kemik olgunlaşmasının G-P standartlarından farklı olduğu bu nedenle G-P atlasında değişimlerin yapılması ile erkek çocuklarda kullanılabileceği belirtilmiştir (Büken ve ark., 2007). Başka bir çalışmada G-P atlasının Türk çocukları için 12 ve 15 yaşındaki kız çocuklarında 12, 15 ve 18 yaşlarındaki erkek çocuklarında 1 yıldan fazla standart sapma gösterdiğini tespit edilmiştir. Bu durumdan kaynaklı olarak dikkatli biçimde yorumlanarak kullanılması gerektiği vurgulanmıştır (Koc ve ark., 2001). 2010 yılında yayınlanan bir araştırmaya göre, kemik yaşı tayininde ülkemiz çocukları için TW3 atlasının kullanılabileceği belirtilmiştir (Büken ve ark., 2010).

1.3. Yaş Tespitinin Tarihçesi

1833 yılında İngiltere'de çocuklar üzerinde sömürüyü önlemek ve çocukların çalışma şartlarını iyileştirmek için İngiliz Fabrika Kanunu çıkarıldı. İngiliz Fabrika Kanununa göre tekstil endüstrisinde 9 yaşından küçük çocukların çalışması, 9-13 yaş aralığındaki çocukların 8 saatten fazla çalışması, 14-18 yaş aralığındaki çocukların günde 12 saatten fazla çalışması ve 18 yaşından küçük çocukların gece çalışması yasaklanarak, 18 yaşından küçük çocuklara 1 saat öğle yemeği molası verilmesi zorunlu hale getirildi. Kanunun çıktığı yıllarda yaş tespiti nispeten eğitimsiz kişiler tarafından yapılmaktaydı. X-ışınlarının keşfedilmesinden bir yıl sonra Von Ranke, 1 Nisan 1896'da Münih Tıp Derneği'nin gerçekleştirdiği konferansta çocukların yaşının el röntgeni ile incelenebileceğini iddia etti. O tarihlerde röntgen görüntüleri ile ilgili veriler kısıtlı sayıda ve genellikle arkeolojik kazılar sonucu elde edilen kemiklerden oluşan görüntülerden oluşmaktaydı. Vücudun kolayca erişilebilen bir parçası olması nedeniyle kemik yaşı tespitine yönelik çalışmalar el üzerine yoğunlaşmıştır. El ile ilgili ilk radyolojik görüntülerden biri, 22 Aralık 1895'te çekilmiştir. Bu görüntü 1 Ocak 1896'da Freiburg Üniversitesi'ne sunulan Wilhelm Conrad Röntgen'in eşinin el röntgeniydi. 1897'de Behrendsen tarafından insan elinin kemikleşmesine ilişkin bir çalışma yayınladı. İlk el / bilek atlası 1898'de yayınlandı. Yayınlanan bu atlasta cinsiyet farklılıkları hesaba katılmamıştır. J.W. Pryor ABD'de 1907 yılında el bileği iskeleti gelişimini radyografiyle inceleyen, bazı vakalarda kemikleşme sırasının atipik ilerlediğini bildiren ilk kişidir. J.W. Pryor'e göre kızların kemikleri erkeklerden daha önce gelişmektedir. Amerikalı çocuk doktoru Rotch 1909 yılında, bir çocuğun okula hazır olduğunu bildirmek için röntgen iskelet yaşı değerlendirmesi kullanarak tahmin etmenin mümkün olduğunu belirten bir çalışma yayınladı. Carter 1926 yılında ve Baldwin, Busby ve Garside 1928 yılında, iskelet yaşı değerlendirmesi için X-ışınları üzerinde doğrudan kemik alanı ölçümleri yaptılar. Sayısal yöntemler ile mevcut ossifikasyon merkezlerinin sayısının tespit edildiği ve bunların toplamalarını normal sağlıklı çocuklardan gelen değerlerle karşılaştırmaları yapıldı. 1935'de Siegert tarafından normal el ossifikasyonu için bir atlas yayınlandı, ardından yapılan çalışmalar neticesinde klinisyenler için ilk kılavuz 1937'de T. Wingate Todd tarafından "Atlas of Skeletal Maturation of the Hand" adlı el ve el bileği atlası yayınlandı. Prof. T. Wingate Todd öncülüğünde 1929 yılında kemik yaşını tespit etmek amacıyla Amerika'nın, Ohio eyaletinde çalışma başlatılmış ve 1942 yılında tüm yaş örneklemeleri yapılmıştır. Çalışma için öncelikle eğitim ve ekonomik olarak üst sınıftan

sayılan kuzey Avrupa kökenli beyaz ABD’li çocuklar seçilmiştir. Prof. Todd daha sonra 1936 yılında, ekonomik olarak üst sınıfta yer almayan ve devlet okullarından gelen çocukları da dâhil etmiştir. Topladığı 27 kesitsel grafipleri ile bu konudaki ilk atlası oluşturmuştur. Günümüzde yaygın olarak kullanılan Greulich-Pyle (GP) atlası 1950’de ilk olarak çıkarılmış ve 1959’da ikinci baskısı yapılmıştır. Tanner-Whitehouse-Healy 1962’de yeni bir yöntem ve atlas geliştirdiler. Bu atlas ilk olarak 1976 yılında sağlıklı 3000 İngiliz çocuğun el ve el bileği grafipleri değerlendirilerek yapılmış ve 2000 yılında yeniden gözden geçirilerek yayınlanmıştır (TW2, TW3). İncelenen vücut segmentine bağlı olarak mevcut birkaç radyografik anatomi atlası vardır. Bu atlaslara örnek olarak 1981; Gilsanz ve Ratib, 2005; Thiemann, Nitz ve 2006; Schmeling vb. düzenli olarak yeni veriler ortaya çıkmaktadır. 2012 yılında Ernesto Tomei ve arkadaşlarının yayınladığı “Text-atlas of skeletal age determination MRI of the hand and wrist in children” isimli atlasla yaşları 3 ila 19 arasında değişen erkek, yaşları 4-17 arasında değişen sağlıklı 27 kafkasyalı çocukların kronolojik yaşlarına dayanan MRG (Manyetik Rezonans Görüntüleme) iskelet yaşı tahmini atlası yayınlanmıştır. Yirminci yüzyıldan itibaren el bileği radyografilerinde alınan radyasyonun dozu %50, maliyet ise %30 ile %40 arasında düştüğü için her iki el yerine tek el ve elin sol tarafı kullanılmıştır. Sol elin kullanımı ilk olarak Todd ve bu konuyu araştıran ilk araştırmacıların çalışmalarında kullanmasıyla başlamıştır. 1906 ve 1912 yıllarında Monako ve Cenova’da yapılan Fiziksel Antropologlar Kongre’lerinde hazırlanan Canlı Bireylerde Yapılacak Antropometrik Ölçümlerin Birliğine Dair Uluslararası Antlaşma’da pek çok toplumda sağ elini kullananların sayısının fazla olması ve sağ elin daha çok hata riskine sahip olmasından kaynaklı olarak ölçümlerin vücudun sol tarafından yapılması kararı alınmıştır (Üzel, 2002a, 2002b; Uğur Ersoy, 2003; Yılmaz, 2006; Black ve ark., 2010; DAŞ, 2019).

1.4. G&P Yöntemi

Bu yöntem Greulich ve Pyle (G-P) tarafından tavsiye edilmiştir. G-P kemik yaşı atlası 1931-1942 yılları arasında Amerika’da Cleveland Ohio da orta-üst sosyoekonomik düzeydeki yaklaşık 1000 sağlıklı çocuğun el-bilek röntgenleri ile oluşturulmuştur. Standart bir şablon oluşturmak için 31 adet radyolojik görüntü 0 ile 19 yaş arasındaki bireylerden alınmıştır. Kız çocuklara yönelik standart şablonlar, 0-18 yaş arasındaki 27 radyoloji görüntüsünden oluşmaktadır (Gungor ve ark., 2015). Dünyada en yaygın kullanılan yöntemdir.

İlk Greulich-Pyle atlası 1950 yılında (Greulich, 1950), ikincisi 1959 yılında (Greulich ve Pyle, 1959) ve sonuncusu 1988 yılında basılmıştır (Büken ve ark., 2009).

G-P atlası, kronolojik yaş gruplarından oluşan standart el-bilek kemik haritalarından oluşmaktadır (Hasaltın & Beştok, 2004). Yaş ve cinsiyete göre bir atlas içerisinde gruplandırılmış röntgen örnekleri ile bireyin sol el bileği görüntüsünün görsel olarak karşılaştırılmasına dayanan bir yöntemdir (Martín-Fernández ve ark., 2009). G-P atlasında, sol el kullanılarak kız ve erkek çocukları ayrı ayrı, her yaş ve bazı buçuklu yaşlar için 18-19 yaşına kadar standartlar ve standart sapmalar verilmiştir (Boyunağa, 2002).

G-P atlasında standartlar cinsiyetlerin her biri için farklı olacak şekilde oluşturulmuştur. İlk cinsiyete göre standart grup seçilerek değerlendirmeye başlanır. Her grafi resim örneğinin altında karşılaştırma anında bakılacak özellikler ayrıntılı olarak açıklanmıştır. Kişinin yaşına uygun örneği; cinsiyete ait grafi resim örneklerinin içinde aranarak örnek bulunur ve karşılaştırılır. Şayet her iki grafi resim karşılaştırıldığında aynı ise, aranan kişinin kemik yaşının G-P standardına göre yaşına uygun olduğu anlaşılır. Fakat genellikle grafiler birbirinin aynısı olmaz. Bu durumda incelenen kişinin grafisine en yakın grafi örneği bulunana kadar atlas ileriye veya geriye doğru ayrıntılı incelenir. Uygun grafi örneği bulunur ise o örneğe ait yaş incelenen kişinin kemik yaşı olarak kabul edilir. Kimi zaman incelenen kişinin grafisi atlasta ki hiçbir örneğe uymaz. Bu durumda incelenen grafiye en yakın özellikler gösteren iki örnek grafiye ait yaşlar arasında ki değer tespiti yapılır. Genel görünüme bakarak kemik yaşı belirlenebildiği gibi her kemik için ayrı ayrı kemik yaşı belirlenebilir. Bunun için ise atlasın sonundaki, her bir kemiğe ait gelişim süreçlerinin çizimlerinin bulunduğu bölümden yararlanılır (Uğur Ersoy, 2003; Yılmaz, 2006). Şekil 1.3'te G-P atlası yöntemi kullanılarak kemik yaşı tahmini görsel olarak verilmiştir.



Şekil 1.3. G-P atlas yöntemi kullanılarak kemik yaşı tahmini


Greulich ve Pyle hazırladıkları atlasın farklı parametrelere bağlı olmadan çalışacağını ve küçük bir hata payı ile kemik yaşının yapılacağını belirtmişlerdir. Farklı parametrelerin cinsiyet, genetik, ırk ve coğrafik faktörler olduğunu ifade etmişlerdir. G-P atlasının siyah ve beyaz çocuklar üzerinde yaş tespitinin yapılabilirliği üzerine yapılan bir çalışmada G-P atlasının, özellikle siyah çocuklar için yapılamayacağı sonucu elde edilmiştir (Baransel Isır, 2009).

G-P yönteminde el-bilek röntgen filmi, atlastaki şablonlar ile karşılaştırılması sonucu en yakın eşleme kemik yaşını vermektedir (Pietka ve ark., 2003; Zhang ve ark., 2007).

Sol elin muayene esnasında düşük radyasyona maruz kalınması, basit olması gibi sebeplerden dolayı kullanılmaktadır (Cao ve ark., 2000).

G-P yöntemi hekimler arasındaki eğitim seviyelerinin farklı olması ve uzman radyolog tarafından uygulanan bir yöntem olduğu için gözlemciden kaynaklı bazı sapmalar olabilir. Ayrıca uygulama esnasında zaman alması bir diğer dezavantajdır (Hsieh ve ark., 2007; Kim ve Kim, 2007).

Bu yöntemde Şekil 1.4'te gösterildiği gibi ele ve bilek eklemlerinin belirli ilgi alanlarına (ROI=Region of Interest) odaklanılır. Radyolog daha sonra ROI'lerdeki görüntüyü referans için atlaslarla karşılaştırır. Karşılaştırma sonucu olarak %100 bir eşleşme bulmak zor olduğundan en yakın eşleşen radyolojik şablon seçilir. Kemik büyümesi cinsiyete göre farklılık gösterdiğinden erkekler ve kadınlar için ayrı şablonlar oluşturulmuştur.



Şekil 1.4. G&P yöntemine göre odaklanan alanlar (Gertych ve ark., 2007)

1.5. T-W Yöntemi

Kemik gelişimini etkileyen cinsiyet, ırk, endokrin bozukluklar, beslenme bozuklukları, kronik hastalıklar, doğumsal bozukluklar, konjenital miyastenik sendromlar, yapısal gelişme geriliği, çevresel ve coğrafik etkenler gibi birçok farklı faktör olduğu bilinmektedir. Yaş tayini tespitinin kemik gelişimine göre yapılması sıklıkla kullanılan bir yöntemdir. (Gök ve ark., 1985a; Çöloğlu, 1987; Özel ve ark., 1988; Neyzi ve Ertuğrul, 2000; Schmeling ve ark., 2000; Koc ve ark., 2001; Bilgin ve ark., 2003; Büken ve ark., 2003; Payne-James ve ark., 2003; Isır ve Dulger, 2007).

T-W yöntemi 1950-1960'lı yıllarda İngiltere'de orta sosyoekonomik düzeydeki çocukların sol el bilek röntgenlerinden elde edilen veri seti ile oluşturulmuştur. 2001'de güncellenmiştir. Bu yöntemde radius, ulna, karpal kemikler ve elin 13 kısa kemiği değerlendirilir. Bu kemiklerin bazıları A-I şeklinde sınıflandırılarak sayısal bir toplam değer oluşturulur. Bu değere göre yaş ve cinsiyete uygun referans değer üzerinden kemik yaşı belirlenir (Satoh, 2015).

Tanner ve Whitehouse tarafından 1962 yılında geliştirilen, kemik yaşının değerlendirmek için radius, ulna ve kısa kemiklerin kullanıldığı bir yöntemdir. Bu yöntemin ilk şekline TW1 ismi verilmiştir. 1983 yılında TW2, 2001 yılında TW3 modeli geliştirmişlerdir. TW3 yönteminde Belçika, İspanya ve Amerika'da yapılan çalışmalara göre referans gruplar güncellenmiştir. (Tanner, 1962; Garn ve Tanner, 1986).


TW2 yönteminde ilgili kemiklere bir değer atanmaktadır. Bu değerlerin toplanması ile bireye ait bir skor elde edilir. TW2 yöntemi bu skora bağlı olarak kemik yaşının tespit edilmesine dayalı bir yöntemdir (De Luis-García ve ark., 2003). Bu yöntemde 8 sınıf bulunmaktadır. Görüntüde ki her bir parça bu sınıflar ile kıyaslanarak bir puan verilir. Bu puanların toplamı ile kemik yaşı tespit edilir (Pietka, 2003).

Görüntüler üzerine yorum yapmak, kemik yaşını tespit etmek gözlemciden gözlemciye göre değişebilmektedir. Gözlemci için değişken ortalama TW2 için 0,74 yıl ve GP için 0,96 yıldır (King ve ark., 1994; Ontell ve ark., 1996).

TW metodunun en büyük üstünlüğü el ve el bileği kemiklerinin her bir evresinde ki gelişimlerine bir değer atanmış olması ve bu değerlerin toplamı sonucu kemik yaşının tespit ediliyor olmasıdır. (Büken ve ark., 2010). TW yönteminin en büyük dezavantajlarından biri; el ve el bilek grafisi çekilirken herhangi bir açı hatasından kaynaklı olarak kemiklerin skorları yanlış hesaplanabilir ve bu da kemik yaşının yanlış


hesaplanmasına sebep olabilir. Buna benzer durumların TW yönteminde daha fazla karşılaşıldığı belirtilmektedir (Yarimoğlu ve ark., 2005).

TW3 ve TW2' de RUS (Radius-Ulna-Short bones) skorlaması ile 13 kemik, Carpus skorlaması ile 7 karpal kemik, her ikisinin birleşimi ile toplam 20 kemik skorlanarak değerlendirilir. TW3' yönteminde TW2' den farklı olarak yeni normlar oluşturulmuştur. Bu normlar TW3'ün esasını oluşturmaktadır. Avrupa-Avrupa kökenli Amerika normları olarak ifade edilmiştir. Buna göre RUS ve karpal skorlar değiştirilmemiştir. Fakat referans değerleri ve RUS çizelgeleri değişmiştir. Normların oluşturmak için Britanya'lı ve Texas'ın Woodlands bölgesinde yaşayan Avrupa kökenli Amerikanlı çocukların gelişim verileri değerlendirilmiştir. Araştırmacıların yapmış oldukları çalışmalarda boy ölçümlerinin farklı olduğu ancak kemik gelişiminin evrensel olduğu ve tüm toplumlar için yapılabilir olduğunu göstermiştir (Malina ve Beunen, 2002; Yılmaz, 2006). TW3 yönteminde el, el bileği kemikleri ile Radius ve ulnanın distal uçları ile birlikte radius ve ulna kemikleri incelenir. Bu yöntemde skorlama cinsiyetlere göre değişmektedir. Kızlar ve erkeklerde farklı skorlar belirlenmiştir. RUS ve karpal skoru şeklinde farklı skorlamalar yapılmaktadır. RUS skoru: Radius, ulna ve kısa kemiklerin, Karpal skoru ile karpal kemiklerinin ölçümlendirmesidir. Bu ölçüm sonucunda elde edilen skor ile her bir cinsiyet için hazırlanmış olan RUS ve karpal kemik yaşı tablolarından bunlara uygun yaş bulunur ve vakanın kemik yaşı tespit edilmiş olur. TW3 atlasında örnek görüntüler ve açıklamalar mevcuttur. Vakalar incelenirken tüm kemiklerin gelişim evreleri ve bu evrelere göre skorlanan değerler bu atlas yardımıyla belirlenir. Bu işlem için genellikle RUS skorlarının kullanılması tavsiye edilmektedir. Bireyin kemikleşme süreci son buluna kadar geçirdiği tüm evreler farklı harfler ile isimlendirilmiştir. Örneğin "A" harfi henüz kemikleşmenin başlamadığını ifade eder (DAŞ, 2019).



Şekil 1.5. (a) TW yönteminde analiz edilen ROI'ler, (b) ROI'nin metafizlere, diyafizlere ve epifizlere bölünmesi (Spampinato, 1995)

Şekil 1.5'de verilen şekillerden sol tarafta ki görsel TW yönteminde analiz edilen ROI'leri, sağ tarafta verilen görsel ise ROI'nin metafizlere, diyafizlere ve epifizlere bölünmesini göstermektedir.



Şekil 1.6. El röntgeninin ROI alanları (Wibisono ve Mursanto, 2020)

1.6. Gök Atlası

Ülkemizde Şemsi Gök ve arkadaşları tarafından G-P atlası sıklıkla kullanılmaktadır. Gök atlası G-P atlasının ülkemize göre uyarlanması ile oluşturulmuştur. Gök Atlası özellikle adli tıp uzmanları tarafından kullanılmaktadır (Baransel Isır, 2009).

Yaş tespiti vücudumuzda ki belli kemiklerinin röntgen incelenmesi ile yapılır. 0-22 yaşları arasında el parmak ve tarak kemikleri, radius, ulna alt epifiz grafipleri, ön ve yan dirsek grafişi, humerus boynu ve skapula boynunu gösteren omuz röntgen grafişi, iliak üst, iskion alt kenarını içine alan tek taraflı pelvis grafişi, 23-40 yaşları arasında yan sakrum ve koksiks grafişi, 40 yaş civarında yan sternum grafişi, 45-50 yaşlarında ön göğüs grafişi çekimleri ile yaş tespiti değerlendirilmektedir (Gök ve ark., 1985b).

1.7. Tezin Amacı

Sağlık hizmetinde kalite ve verimi arttırmak için, medikal teknolojilerdeki ilerlemeler klinisyenlere büyük kolaylıklar sağlamaktadır. Bilgisayarlı görüye dayalı biyomedikal görüntüleme uygulamaları radyologlara daha verimli iş akışı ve tanıda yüksek doğruluk sağlayan ön bilgiler sağlamaktadır.

El ve bilek radyograflerinin değerlendirilmesi için otomatik yöntemler geliştirilmekte ve bu da manuel yöntemlere kıyasla değerlendiriciler arası değişkenliği azaltmaktadır. Kemik yaşı hesaplaması için ultrasonografi gibi el ve bilek kemiklerini görselleştirmeye yönelik radyasyona dayalı olmayan teknikler geliştirilmiştir (Mentzel ve ark., 2005). Bu tür görüntülerin okunması ve onlardan çıkarım yapılabilmesi için çok fazla deneyim ile pediatrik radyologlar gibi yüksek eğitimli uzmanlar için yoğun emek gerektirmektedir.

Bu çalışmada kullanılan veri seti bir il merkezi ve üç ilçe merkezindeki Devlet hastanelerinde çekilen el bilek grafiplerinden oluşturulmuştur. Kemik gelişimin coğrafya, ırk, zaman dilimi ve sosyoekonomik düzeye göre değişmesi nedeniyle ülkemizin tüm coğrafi bölgelerinden örneklem alınarak oluşturulacak bir veri seti ülkemiz çocuklarının kemik yaşını en doğru gösteren veri seti olacaktır. Bu amaç için çalışmalar yapılmış ve ilk etapta veri seti Kütahya ilinden oluşturulmuştur. Bu çalışmanın bu konuda öncü olacağına inanıyoruz. Bu ve benzeri çalışmalarda oluşturulan veri setlerinin birleştirilmesi hem geliştirilecek yapay zekâ algoritmaları için hem de yeni bir atlas için altyapı oluşturacaktır.

Kemik yaşı tespitinde kullanılan yöntemlerde bazen radyologlar farklı etiketlemeler yapabilmektedir. Bu çalışma için tek ildeki, 4 farklı hastaneden elde edilen görüntülerde 9 yıllık deneyimli radyolog doktorun etiketlediği el bilek grafilerinden elde edilen veri seti kullanılmıştır. Kütahya Radyoloji Veriseti (KRV) farklı hastanelerde ve farklı röntgen cihazlarında elde edilen görüntülerden oluştuğu için görüntülerin kontrast ve parlaklık ayarları karışıktır, kimi çok aydınlık kimisi çok karanlıktır.

Sağlıkta görüntülemenin dijitalleştiği günümüz zaman diliminde kemik yaşı tespitinin ülkemizde yaşanan büyük göç sorununa katkı sağlayacağı düşünülmektedir. Son zamanlarda yaşadığımız coğrafya 'da artan savaş ve şiddet olaylarına paralel olarak ülkemize özellikle Suriye, Irak, Afganistan ve Afrika'dan çok fazla göç olayları yaşanmıştır. Mültecilerin büyük bir kısmında kimlik veya doğum belgesi olmaması nedeniyle kimlik ve kimliğin bir parçası olan yaş tespiti önemli sorun teşkil etmektedir. Kimlik ve yaş tayini kişi beyanı ile yapıldığında, birçok göçmen yaşını çeşitli sebeplerden ötürü yanlış beyan etmektedir. Bu durumun önüne geçmek için yapılan manuel çalışmalar doktorların farklı atlas ve yöntem kullanmasından kaynaklı olarak bir bütünlük arz etmediğinden hem zaman kaybına sebep olmakta hem de bütünlükten kaynaklı olarak maliyetleri artırmaktadır. Bu ve benzeri problemlere çözüm üretmek, zaman probleminin önüne geçmek ve bu konu ile ilgili kişilere yardımcı olmak amacı ile bu çalışma yapılmış ve bir karar destek sistemi tasarlanmıştır.

İlaveten radyologların iş akışını değiştirmeden işlerini taklit ederek pediatrik kemik yaşı tahmini için radyologların işlerini hızlandıran ve radyologlara yardımcı olacak bir karar destek sistemi geliştirilmiştir.

Derin öğrenme, makine öğrenmesi algoritmalarındandır. Derin öğrenme, nesneleri tanıma, nesneleri tespit etme, görüntü veya metinleri sınıflandırma işlemlerinde yoğun olarak kullanılmaktadır. Derin öğrenme, özellikle görüntülerin sınıflandırılmasında elde ettiği yüksek başarımla orani ile kullanımı hızla artmaktadır. Bu çalışmada derin öğrenme yöntemlerini kullanarak el bilek grafisi görüntülerinden yaş tahmini yapılması hedeflenmiştir.

Bu tez çalışması 2 farklı alanda yapılmıştır. Öncelikle 18 yaş altındaki görüntülerden kemik yaşı tespiti yapılmıştır. Ardından bu çalışmadan bağımsız ancak bu çalışmaya paralel olarak 18 yaş üstündeki görüntülerden kemik yaşı tespiti yapılmıştır.

Bu çalışmada derin transfer yöntemleri ile el bilek grafilerinden yaş tahmini gerçekleştirilmiştir. 18 yaş altı görüntüler üzerinde ki çalışmada InceptionV3,

EfficientNet ve MobileNetV2 derin transfer yöntemleri ile kemik yaşı tahmini (KYT) gerçekleştirilmiştir. Ayrıca InceptionV3 modifiye edilerek KYT için kullanılmıştır.

Çalışma 18 yaş altındaki görüntüler için 8-216 ay aralığındaki görüntüler üzerine odaklanmıştır. 8 ay'dan küçük olan kişilere ait görüntü sayısı çok az olduğundan 0-7 ay aralığındaki görüntüler kaldırılmıştır.

18 yaş altında ki bireylerin yaş tespitini yaparken modellerin başarısını ölçmek için public olarak dağıtılan RSNA (Radiologic Society of North America) veri seti de kullanılmıştır.

Literatürde 18 yaş üstündeki bireylerin sol el bilek grafilерinden yaş tespitinin derin öğrenme yöntemleri ile yapıldığına dair herhangi bir araştırmaya rastlanmamıştır. Bu çalışma ile literatüre 18 yaşından büyük bireylerin yaş tespitinin derin öğrenme modelleri ile yapılabileceğine dair yapılan ilk çalışmalardan biri olup, bu çalışma neticesinde elde edilen sonuçların 18 yaş üstündeki kişilerin kemik yaşını tespit etmek için kullanılan diğer yöntemlerden daha iyi olduğu tespit edilmiştir.

Bu çalışma ile Türkiye özelinde el bilek grafileri ile ilgili çalışmaların yapılmamış olması bizi bu çalışmaya yönelten ana unsurlardan biri olmuştur. Bu çalışmanın katkısı;

- Derin öğrenme yöntemleri ile el bilek grafilерinden yaş tespitine yönelik farklı bir çevre ve coğrafyaya (Türkiye'ye) ait yeni bir veri seti oluşturulmuştur. Bu veri seti 18 yaş altında ve üstünde olacak şekilde ayrılmıştır. Ayrıca 18 yaş altı public olarak dağıtılan farklı bir coğrafya ya ait bir veri seti temin edilmiştir. Bu 3 farklı veri seti üzerinde çalışmalar yapılmıştır.
- Bu 3 farklı veri seti ile derin öğrenme yöntemlerinin görüntüler üzerine etkileri incelenmiştir. Bu bakış açısı doğrultusunda bir karar destek sistemi geliştirilmiştir.
- Kullanılan veri setlerindeki görüntülere ait anlamlı alanların/bölgelerin kaybolmamasına dikkat edilmiştir.
- El bilek grafilерinden yaş tespiti çalışmalarında farklı bir çevre ve coğrafyanın bu çalışmalara katkısı incelenmiştir. Oluşturulan bu veri seti ile el bilek grafilерinden kemik yaşı tespiti yapılan çalışmalara katkıda bulunulmuştur.
- 18 yaş altı için oluşturulan ve public yayınlanan veri setinde yapılan çalışmalar neticesinde farklı çevre ve coğrafyaların el bilek grafilерinden yaş tespiti yapılmasında önemli bir faktör olduğu tespit edilmiştir. Tüm insanlarda ortak olan

ancak coğrafik olarak farklılık gösteren el bilek grafiglerinin yaş tespiti yapılmasında derin öğrenme modellerinin başarısını etkilediği tespit edilmiştir.

- 18 yaş üstü oluşturulan veri setinde erkek ve kadınlarda yaş tespiti tahminlerinde derin öğrenmenin yüksek performans sonuçları gösterdiği gözlenmiştir. Bu çalışmada kullanılan yöntem ve bulunan sonuçlar bu alanda yapılan ilk çalışmadır. Bu sonuçlar ışığında bu çalışmada kullanılan metot bize derin öğrenme metotlarının 18 yaş üstü bireylerde kemik yaşı tespitinde yardımcı bir araç olarak kullanılabileceğini göstermiştir.
- Bu çalışmada insan faktörünü ortadan kaldırmadan insana yardımcı olacak bir karar destek sistemi geliştirilmiştir. Bu karar destek sistemi ile birlikte radyologların zamandan tasarruf etmeleri amaçlanmıştır. Deneyimli bir radyolog, bir hastayı G&P yöntemiyle değerlendirmek için ortalama 1,4 dakika ve TW2 yöntemi ile 7,9 dakika harcamaktadır (Çöloğlu, 1987).

Yaşadığımız çevre ve coğrafya da çalışan doktorlar için bir karar destek sistemi geliştirilmiştir.

1.8. Tezin Özgün Değeri

18 yaş altında ki kişilerin kemik yaşının belirlenmesi literatürden görüleceği üzere farklı yöntemlerle yapılmaktadır. Ülkemizde el bilek grafiglerinden kemik yaşı tespiti üzerine farklı çalışmalar yapılmıştır ancak Türkiye'ye özgü bir veri seti ilk defa bu çalışma ile toplanmış ve bu veri seti üzerinde çalışmalar yapılmıştır.

Tarafımızca oluşturulan bir derin öğrenme modelinin; literatürde halka açık olarak dağıtılan ve üzerinde çalışmalar yapılan bir veri seti üzerinde ki başarısı ve tarafımızca oluşturulan veri seti üzerinde ki başarısı ölçülmüştür. Önerdiğimiz modelin hem public dağıtılan veri seti üzerinde, hem de oluşturduğumuz veri seti üzerinde başarılı sonuçlar elde ettiği tespit edilmiştir.

Bir sonraki bölümde kaynak araştırması kısmında verilen literatür araştırmasında görüleceği üzere 18 yaş üstünde kişilerin yaş tespitini yapmak için el bilek grafiglerinden derin öğrenme modelleri ile yapılan bir çalışmaya rastlanmamıştır. 18 yaş üstü bireylerin kemik yaşının derin öğrenme modelleri ile bu çalışma da yapılması ile literatüre katkı sağlanmıştır.

2. LİTERATÜR ARAŞTIRMASI

Kemik yaşı tahmini ile ilgili literatür araştırması yapılırken 18 yaş üstü ve 18 yaş altı için yapılan çalışmalar ayrı ayrı incelenmiştir.

2.1. 18 Yaş Altı İçin Yapılan Araştırmalar

Kemik yaşı tahmini için literatürde makine öğrenmesi tabanlı yaklaşımlar mevcuttur. Son yıllarda derin öğrenme yöntemlerinin KYT’de sıkça kullanıldığı görülmektedir.

Cao ve ark. (2000), internet tabanlı kemik yaşı tespiti için bir web-kullanıcı arabirimi geliştirmişlerdir. Farklı etnik gruplarından oluşan el görüntülerinden yeni bir veri seti oluşturulmuştur. Web ara yüzü üzerinden el röntgen görüntülerinin bilgisayar destekli teşhis sistemine gönderilmesi ve bu görüntülerin işlenerek görüntüye ait özellikler atlastakiler ile karşılaştırılarak kemik yaşı tespiti yapılmaktadır. Görüntüler etnik köken ve cinsiyete göre kategorize edilmiştir. Önceki tahminlerine dayanarak, puberte (ergenlik) öncesi çocuklar için distal, orta ve proksimal kemiklerin manuel ve bilgisayar destekli ölçümleri arasındaki farkı saptamak için her grup için 5 görüntüye ihtiyaç duyulmuştur. Ergenlik çağındaki çocuklar için, manuel ve bilgisayar ölçümleri arasındaki farkı tespit etmek için her grupta 10 görüntüye ihtiyaç duyulmuştur. Sonuç olarak, normal yenidoğandan 18 yaşına kadar her bir ırk±cinsiyet grubu için 140 referans görüntüye ihtiyaç duyulmuştur. Avrupa, Afrika, İspanyol ve Asya kökenli erkek ve kızlardan toplam 1120 referans görüntü (140 * 8 grup) toplanmıştır. Görüntü işleme aşamasında falanks, karpal ve epifiz kemikleri ile ilgili alanlar tespit edilmiştir.

Chang ve ark. (2003), yaptığı çalışmada sol el röntgen görüntülerinden Gabor filtreleri ve Canny kenar tespit yöntemlerini kullanarak en baskın 10 frekans bileşenini öznitelik olarak kullanmıştır. 824 kişiden alınan görüntüler üzerine bu çalışma yapılmıştır. Geriye yayımlı sinir ağından yararlanarak sınıflandırma yapılmıştır. Elde edilen ilk 10 özniteliklerin yapay sinir ağına verilmesi sonucu %77,69 sınıflandırma başarısına ulaştıklarını ifade etmişlerdir. Ayrık cosinüs dönüşümünden elde edilen 10 frekans bileşeninden elde edilen özniteliklerin kullanılması ile sınıflandırma başarısı %81,46’e yükseldiği görülmüştür.

De Luis-García ve ark. (2003), otomatik bir şekilde el röntgen çekimlerindeki falanks ve metakarpal kemiklerinin şekillerini tespit etmek için aktif konturlar algoritmasını kullanmıştır. Konturlar için ilk konturlara ihtiyaç vardır, bu nedenle

önerilen algoritma iki ana adıma bölünmüştür: ilgilenilen her bir kemiğin içindeki ilk konturların belirlenmesi ve segmentasyonun elde edilmesi için konturların kullanılması. Çalışmanın amacı falangeal konturları tespit etmek olsada, başlangıç kontur bulma algoritmasını tamamlamak için ihtiyaç duyulduğu için meta-karpallar için de başlangıç konturları bulunmuştur. Algoritmanın kemik figürlerini otomatik tespit etme başarısını ölçebilmek için 59 görüntü kullanılmıştır. Bu görüntüler için yüksek çözünürlük için 8, düşük çözünürlük için 51 görüntü üzerinde çalışılmıştır. Düşük çözünürlükteki röntgen görüntülerinden kemik şekillerini tespit başarısı %71,7 iken yüksek çözünürlükteki röntgen görüntülerinin tespit başarısının %95,7 olduğu gözlemlenmiştir. Bu çalışma sonucunda el ve kol pozisyonlarının uygun olması ile görüntülerin yüksek çözünürlükte işlenmesi gerektiği sonucunu ortaya çıkarmışlardır.

Pietka (2003), bilgisayar destekli iki modülden oluşan kemik yaşı tespiti için klinik görüntülerden veri elde eden ve bunları depolayabilen bir iş istasyonu geliştirmiştir. Veri tabanı, bir el radyografisinden çıkarılan özellikleri ve görüntü analizinin değerlendirilmesi için ilgilenilen bölgeyi (ROI) geri yüklemek için gereken veriler elde edilmiştir. Çalışma normal bir popülasyondan seçilen siyah erkek ve kadın ile beyaz erkek ve kadın olmak üzere dört gruba ayrılan sol el bilek radyografileri üzerinde gerçekleştirmiştir. Ön sonuca göre, puberte öncesi çocuklarda (0-9 yaş) her yaş grubu için 5 görüntü, ergenlik dönemindeki çocuklarda (10-18 yaş) ise her yaş grubu için 10 görüntü toplanmıştır. Bu grup başına 135 görüntü olmak üzere toplam 540 görüntü verir. Bu görüntüler, Los Angeles/USC Çocuk Hastanesi'nde elde edilmiştir. Veri tabanı, üç tür veri elde eder. Görüntü analizinden elde edilen sonuçlardan biri, hasta demografisini ve radyograftan çıkarılan özellikleri içerir. Geliştirmenin erken ve sonraki aşamasının özellik kümeleri için ayrı yapılar oluşturulur. Gelişimin erken veya geç aşamasını yansıtan bir radyografiden yalnızca bir dizi özellik çıkarılır. Yine de her iki bulgu grubunu da sağlayabilecek bir dizi hasta yaşı vardır. İkinci tür özellikler, ilgilenilen bölgenin incelenmesine izin veren verileri çıkarır. Ayrıca, özellik çıkarmada referans seviyeleri olarak hizmet eden tüm işaretçiler (çizgiler ve kenarlar) gösterilir. Veri tabanında arşivlenen bulunan nesnelerin koordinatları ve mesafeleri, görüntülenilen ilgili bölgedeki konumlarına izin verir. Üçüncü tip veri, bir referans formatında olduğu kadar tam bir teşhis çözünürlüğünde arşivlenen görüntülerden oluşur. Teşhis edilen görüntü ile en yakın eşleşmeyi göstermek için kullanılırlar. 1 ile 19 yaş arasındaki iki etnik gruba ait normal erkek (270 vaka) ve kız (270 vaka) popülasyonunun el görüntülerinden elde edilen özellikler Değerlendirilen kemik yaşı ile kronolojik yaş hatası arasındaki ortalama farkın

1 yaşı geçmediğini, 16-17 yaşındaki kız çocuklarında daha yüksek bir farkın olduğu ve bu farkın falankslarda epifiz füzyonu tamamlandıktan sonra kesin olmayan bir yaş değerlendirmesinden kaynaklı olduğu sonucu çıkarılmıştır.

Pietka ve ark. (2003), yapmış oldukları çalışmada, görüntü işleme yöntemleri ile kemik yaşı tespiti gerçekleştirmişlerdir. Görüntü işleme ile öznelilikler çıkarılmıştır. Altı ilgilenilen bölgenin yerini, bunların segmentasyonu ve özellik çıkarımı takip eder. Yaşa bağlı olarak metafiz ve epifiz bölgeleri arasındaki boşluk kaybolmakta ve nihayetinde kapanmaktadır. Sistem performansı, 1 ila 19 yaşındaki bir etnik grubun erkek (115 vaka) ve kız (116 vaka) normal popülasyonu için test edilmiştir. Standart olmayan bir el pozisyonu (bağlı veya döndürülmüş parmaklar) veya kötü görüntü kalitesi nedeniyle, başlangıçta standart olarak toplanan görüntülerin %14'ü reddedilmiştir. Değerlendirilen kemik yaşı ve kronolojik yaş hatasının ortalama farkı erkeklerde 0,94, kızlarda 1,13'e eşittir. Kızlarda daha yüksek bir fark olmasının nedeni, epifasal füzyon infalanjları tamamlandıktan sonra (yani 15-16 yaşında) kesin olmayan yaş değerlendirmesinden kaynaklanır. 15 yaşına kadar kızlarda ortalama hata 0,75 yıla eşittir.

Hasaltın ve Beştok (2004), yapmış olduğu çalışmada toplam 2-9 yaş arası toplam 307 çocuk (144 kız, 163 erkek) olguya ait veriler kullanılmış daha sonra çalışmanın ilerleyen aşamalarında test için 251 tanesi kullanılmıştır. Kemik yaşı tespitinde karpal kemik alanların yanı sıra cinsiyet ve kronolojik yaş üzerine odaklanılmıştır. Kemik yaşı tayininde yapay sinir ağları kullanarak yarı – otomatik bir sistem geliştirilmiştir. Yapay sinir ağlarından Esnek Öğrenme (Resilient propagation - RP), Levenberg- Marquardt (LM), Momentumlu ve Adaptif Öğrenme Oranlı Gradiyent Azaltımlı Öğrenme (GDX) algoritmalarının sonuçları değerlendirilmiştir.

Pietka ve ark. (2005), kemik yaşı değerlendirmesinde uygulanan bilgisayar destekli bir teşhis (CAD) sisteminin bir bileşeni olarak bir e-atlas geliştirmişlerdir. Bu atlas, standart röntgen kümelerini içeren bir radyograf seti, ilgi alanları (ROI'ler) ve görüntü işleme aşamasında çıkarılan özellikleri içerir. Görüntü işleme yöntemi ile geliştirilen bu e-atlas kemik yaşı tespiti yapabilmektedir. Görüntü analizi birkaç aşamada gerçekleştirilir. Ön işleme aşaması olarak ilkin öncelikle arka plan görüntüleri bastırılarak kemiklerin tanınması sağlanır. El bölgesi içinde altı ilgi alanı çıkarılır ve her bölgenin içindeki kemik yapısı çizilir. Bu aşamada iki işlem uygulanır. İlki rastgele Gibbes alanları yöntemine dayanarak kabaca konturu bulur, ikincisi ise, aktif konturları kullanarak sonucu pürüzsüzleştirir. Gibbes alanları metodu ile 11 özellik çıkarılmıştır. Kemik kalınlığını yansıtan yoğunluk özelliklerinin yanı sıra belirli mesafeleri ve alanları bularak

epifiz ve metafizlerin şeklini tanımlarlar. Bir PACS sunucusuna çevrimiçi erişim sayesinde, değerlendirme çok sayıda görüntü üzerinde gerçekleştirilebilir. Görüntü kitaplığında önceden tanımlanmış bir anahtar sözcük kullanılarak görüntüler aranabilir. İncelenen bir görüntü belirli kriterleri karşılıyor gibi görünüyorsa, bir veri havuzuna eklenebilir. Bu, görüntü sayısını hızla artıracak ve klinik karşılaştırmanın yapılmasına izin verecektir.

Gertych ve ark. (2007), Los Angeles'da bir çocuk hastanesinden 1-18 yaş arası çocuklara ait elde edilen 1400 röntgen görüntüler üzerine yaptıkları çalışmada sayısal el atlasını kullanmışlardır. Bu çalışmada, çocukların kemik yaşı değerlendirmesi için otomatik bir yöntem geliştirmişlerdir. Dört farklı ırktan çocuğun (Kafkas, Asyalı, Afrikalı-Amerikalı, İspanyol) sol el röntgen görüntüleri incelenmiştir. Veriler sekiz kategoriye ayrılmıştır. Bu çalışmada kullanılan veri setinde 12 özellik çıkarılmıştır. Bir çocuğun kemik yaşını değerlendirmek için her ırk ve cinsiyet için bir tane, kadın için bir, erkek için bir tane ve bir kadın ve erkek için bir tane kullanılmıştır. Görüntülerin yarısı eğitim yarısı test için kullanılmıştır. Geliştirdikleri sistem DICOM standartlarına ve PACS iş istasyonlarında çalışacak şekilde dizayn edilmiştir. Bu sistemin değerlendirmesi iki farklı uzman tarafından yapılmıştır. %93,7 oranında “iyi” ve “kabul edilebilir” olarak tespit edilmiştir.

Zhang ve ark. (2007), kemik yaşı tespiti için 0-7 yaş arası çocukların karpal kemikleri üzerinde çalışmışlardır. Bu çalışmada tam otomatik karpal kemik segmentasyonu ve morfolojik özellik analizi için bilgiye dayalı bir yöntem geliştirilmiş ve karpal kemiklerin üst üste gelmediği tüm vakalarda başarıyla uygulanmıştır. Sonuçlarda yaşı 5.5 olan erkek çocukları ve 4 yaştan itibaren kız çocuklarında kemik yaşı tespitinde tutarsızlıklar olduğunu belirtmişlerdir. Erkek çocukları için 5.5, kız çocukları için 4 yaşından itibaren çocukların karpal kemiklerinin dikkate alınması ile başarı oranında artış olacağı belirtilmiştir. İlave kemik yaşı tespitinde ırk ve cinsiyetin de önemli faktörler olduğu ve işlemlerde dikkat edilmesi gerektiği vurgulanmıştır. İki farklı radyolog tarafından yorumlanan sonuçlarla 0.5 yıl olduğu gözlemlenmiştir.

Hsieh ve ark. (2007), Tayland'da gerçekleştirdikleri çalışmada, 2-10 yaş aralığı için kemik yaşı tespiti için bir sistem geliştirmiştir. Veri tabanı olarak 720 adet çocuk röntgen görüntüsü kullanılmıştır. Kadın ve erkek veri tabanında, her 0,5 yaş aralığında 0,5 ila 18 yaş arası on resim bulunmaktadır. Önerilen otomatik kemik yaşı tahmin sistemi, falanks geometrik özelliklerine ve karpals bulanık bilgisine dayanmıştır. Sistem, el görüntülerinin geometrik özelliklerini analiz ederek otomatik kalibrasyon yapmıştır.

Bölütleme aşamasında medius görüntüsünden fizyolojik ve morfolojik özellikler çıkarılmıştır. Falanks kemik yaşını sınıflandırmak için geri yayılım, radyal temel fonksiyon ve destek vektör makinesi sinir ağıları uygulandı. Bu çalışmanın görüntü işleme kısmında medyan filtreleme, kontrast iyileştirme ve morfolojik inceltme yöntemlerinden yararlanılmıştır. Görüntü işleme prosedürünün ardından karpal kemiklerin biçimi, alanı ve sırası ile ilgili nitelikler çıkarılmıştır. Önerilen bulanık kemik yaşı değerlendirmesi, karpalların normalize edilmiş kemik alanı oranına dayanıyordu. Yapay zekâ tekniklerinden Fisher, kNN, geri yayımlı yapay sinir ağıları (BPNN) ve radyal temelli yapay sinir ağıları (RBFNN) ile sınıflandırma yapılmıştır. Olgular 9 yaşından küçük olduğunda karpal özelliklerin sınıflandırma hatalarını etkili bir şekilde azaltabileceğini ortaya koymuştur. Bu arada, karpal özellikler, çocuklar 10 yaşına kadar büyüdüğünde BA'yı değerlendirmek için daha az etkili olacaktır. Öte yandan, falanks özellikleri, 10 yaşından yetişkinliğe kadar olan kemik olgunluğunu gösteren önemli parametreler haline geldiği, bu özellikler sayesinde, önerilen yeni BA değerlendirme sistemi, falanks ve karpal değerlendirmeyi birleştirilmiştir. Ayrıca, sistem sadece sinir ağı sınıflandırıcılarını değil, bulanık kemik yaşı hapsini de benimsemiştir. BPNN ve RBFNN algoritmalarının sonuçları daha yüksek bulunmuştur.

Giordano ve ark. (2007), görüntü işleme teknikleri ile EMROI (Epifiz/Metafiz Bölgesi İlgi Alanı) özellikleri çıkarma yöntemini kullanarak iskelet kemik yaşı değerlendirmesi için otomatik bir sistem geliştirmiştir. Önerilen yöntemin ilk adımı, arka plan tanımlama için bir ön işleme aşamasıdır. Bu küresel ve yerel görüntü istatistikleri kullanılarak yapılır. Bu ön adımdan sonra birinci, üçüncü ve beşinci parmağı çıkarılmıştır. Orta, küçük parmak ve başparmak için parmaklar arasındaki morfolojik farklılıklardan yararlanmak için farklı algoritmalar kullanılmıştır. Her parmak için, mutlaka enterpolasyon yapılmayan bir noktalar dizisi olarak uzun ekseni bulunmuştur. Bu eksen boyunca, gri seviyede yerel maksimumları aramak için türevi hesaplanmıştır: bunlar kemik sınırını gösterir ve EMROI'leri çıkarmak için kullanılmıştır. Çıkarılan her bölgede, bölgenin yaklaşık eşik değeri için kullanıcı tarafından tanımlanan standart sapma ile bir Gaussian algoritma farkına (DoG) dayalı bir dizi izotropik filtre uygulanmıştır. Sistem daha sonra epifiz, diyafiz ve metafiz olması gereken en büyük üç alanı bulunmuştur. Bu konturların her biri, üç bölgenin geometrik bir temsilini elde etmek için bir dışbükey gövde ile yuvarlatılmıştır. Her bir dışbükey gövdeden, TW2 aşamalı sınıflandırma modelinden çıkarılan özniteliklerle karşılaştırılan bazı öznitelikler çıkarılmıştır. Son

olarak, ana özellikler bu kemiklerin TW2 (Tanner Whitehouse) değerlendirmesi için çıkarılır. 20 X-ışını örneğinden elde edilen sonuçlar tartışılmıştır.

Liu ve ark. (2008), otomatik kemik yaşı değerlendirmesi yapan bir çalışma yapmıştır. Çalışmada el röntgen görüntülerinden TW3 yöntemi ile benzer bir şekilde özellikler çıkarılmıştır. Kemik üzerinde RUS ve karpal skorlama ile incelemeler yapılmış ve her bir kemikten 5 öznelik (çap, uzunluk, alan, genişlik, çevre) elde edilmiştir. Geri yayımlı ileri beslemeli yapay sinir ağı kullanılmıştır. 1046 el röntgen görüntüsü kullanılmıştır. Çalışmada elde edilen kemik yaşı tahmini ile TW3 metodu ile elde edilen sonuçların uyumlu olduğu tespit edilmiştir. Karpal kemik sınıflandırmasında sınıflandırma hatalarının 9 yaş altında azaldığı, 10 yaş üzerinde ise bu etkinin azaldığı görülmüştür. 10 yaşından itibaren RUS kemiklerinden elde edilen parametrelerin önem kazandığı görülmüştür.

Van Rijn ve ark. (2009), kemik yaşını BoneXpert olarak isimlendirdikleri yazılım ile otomatik tespit eden bir sistem geliştirmişlerdir. Çalışmaya 3-17 yaş arasında 226 erkek ve 3-15 yaş arasında 179 kız çocuğu olmak üzere toplam 405 görüntü dahil edilmiştir. Yedi denek, manuel ve otomatik tahmin arasında 1.9 yıldan fazla bir sapma göstermiştir. Bu yedi derecelendirmeyi düzelttikten sonra, 405 denekte manuel ve otomatik tahmin arasındaki ortalama karekök hatası 0,71 yıl (0,66-0,76 yıl aralığı, %95 CI) olarak tespit edilmiştir.

Hsieh ve ark. (2010), 2010'da gerçekleştirdikleri çalışmada karpal kemiklerin morfolojisini çıkarıp, iskeletin olgunluğunu tahmin etmek için temel bileşen analiziyle bulanık mantığı uygulamışlardır. Çalışma da yaşları 0.5-10.5 arası 550 Tayvanlı çocuklara ait sol el görüntüler kullanılmıştır. Kemik alanı, alan oranı ve karpal kemik konturu dahil olmak üzere karpalların beş geometrik özelliği çıkarılmıştır. Bu özellikleri analiz etmek için, bir karpal büyüme modeli oluşturmak için temel bileşen analizi ve üç farklı prosedür tipiyle birleştirilmiş istatistiksel korelasyon kullanılmıştır. Çalışmada, çocukluk çağında karpalların kemikleşmiş süreçlerini betimlemek ve karpal lokasyonunu yarı otomatik bilgisayar grafik algoritması ile analiz etmek için özellik niceleme temelli bir büyüme modeli önerilmiştir; bu nedenle model, karpal kemikleşmenin açık morfolojik tanımlarını sağlayabilmiştir. Son olarak, küçük çocuk doktorlarına BA'yı değerlendirmede yardımcı olmak için PCA ile birleştirilmiş bulanık BAA prosedürleri de önerilmiştir. Sonuçlara bakıldığında tip 1 ve tip 2 için %89, tip3 için %87'nin üzerinde başarı göstermiştir.

Jantan ve ark. (2010), radius ve radiusun distali kemiği tarafından sunulan basit öznitelik çıkarma yöntemine ve güvenilirliğine dayanarak ilgili özellikleri çıkararak kemik yaşını sınıflandırmak için bulanık model kullanılmışlardır. Bunun için yaşları 0 ile 18 arasında olan 167 Asyalı Amerikalı erkek (ASIM) ve 167 Asyalı Amerikalı kadın (ASIF) kızı içeren 333 sol el dijital X-ray görüntüsü ile çalışmışlardır. Erkek ve kadınlarda 1,5 yıllık tolerans içinde sırasıyla yaklaşık %63 ve %57 ile test edilen verilerde bulanık BAE tarafından üretilen zayıf doğru oran yüzdesi ile gösterilmiştir. Çalışmanın yarıçap kemiğinin kemik alanı, yarıçap ve distal uç kemikleşme alanı arasındaki mesafe gibi diğer özelliklerinin yanı sıra kemiğin şekli, kompaktlığı ve dokusu gibi diğer özelliklerini de kapsayacak şekilde genişletilmesi önerilmiştir.

Somkantha ve ark. (2011), vektör görüntü modelinden ve kenar haritasından gelen bilgileri kullanarak X-ışını görüntülerinde karpal kemiklerin sınırlarını tespit etmeye çalışmışlardır. Karpal kemiklerin özellik analizi, kemik yaşı değerlendirmesi için önemli bilgileri ortaya çıkarabileceği düşünülmüşlerdir. Kemik yaşı değerlendirmesi için beş özellik, her karpal kemiğin sınır çıkarma sonucundan hesaplamışlardır. Tüm özellikler, kemik yaşını değerlendiren destek vektör regresyonuna (SVR) girdi olarak alınır. SVR'yi sinir ağı regresyonu (NNR) ile karşılaştırmışlardır. 0 ile 6 yaş arasındaki küçük çocukların kemik yaşını değerlendirmek için dijital bir el atlasından 180 el bilek görüntüleri alınarak otomatik kemik yaşı tespiti yapılmıştır. Erkekler için 0-6 yaş, kadınlar için 0-5 yaş grubuna odaklanılmıştır. Segmentasyon için, karpal kemik görüntülerinin nesnelerini segmentlere ayırmak için önerilen kenar izleme tekniği kullanılmıştır. Bir görüntüdeki sadece bir nesneyi tespit edebilen orijinal önerilen yöntem, sol ventriküllerin manyetik rezonans görüntülerinde bölütleme problemine başarıyla uygulanmıştır. Temel fikirleri, vektör görüntü modelinden ve kenar haritasından gelen bilgileri kullanarak karpal kemiğin sınırlarını tespit etmektir. Önerilen vektör görüntü modeli hem yön hem de büyüklüğün hesaba katıldığı kenar vektör alanlarının ortalaması alınarak türetilmiştir. Önerilen kenar haritası, doku özelliklerinden ve Canny kenar algılamasından türetilmiştir. Karpal kemiklerin özellikleri, her bir karpal kemiğin sınır tespiti sonuçlarından hesaplanmıştır. Görüntü işleme aşamasında görüntü iyileştirme işlemi için histogram eşitleme, ilgili alanın çıkarılması ve kenar çıkarımı işlemleri uygulanmıştır. Bu yöntem sonucunda 5 öznitelik çıkarılmıştır. Destek vektör regresyonu (DVR) ve sinir ağı regresyonu ile kemik yaşı tespiti yapılmıştır. DVR ile ortalama 0,5 ile 1 arasında bir hata ile sonuçların tespit edildiği ifade edilmiştir.

Harmsen ve ark. (2013), yarı otomatik kemik yaşı değerlendirme sistemi önermişlerdir. Bunun için ilkin 14 epifiz bölgesinin özellik çıkarımı yapılmıştır. Bu özellikler kullanılarak sınıflandırma yapılmıştır. Sınıflandırma için SVM ve kNN algoritmaları kullanılmıştır. Nominal ve gerçek değerli SVM'yi k-en yakın komşu sınıflandırması ile karşılaştıran sistematik bir değerlendirme yapılmıştır. Yaşları 0 ile 19 arasında değişen 1097 el ve el bilek radyografisi kullanılmıştır. Yaş tahmininde ortalama hatanın SVM için 0,83, kNN için 1 yıl olduğu gözlemlenmiştir.

Kashif ve ark. (2016), el radyografilerin kemik yaşının tespiti için anahtar nokta seçimi ile ilgili epifiz bölgeleri (eROI) içinde SIFT, SURF, BRIEF, BRISK ve FREAK özellik tanımlayıcıları kullanılarak öznitelikler çıkarılmış ve destek vektör makinesi sınıflandırma metodu kullanılarak kemik yaşı tahmin edilmiştir. Seyrek ve yoğun özniteliklerin çıkarılması için SIFT ve SURF uygulanırken, yalnızca yoğun öznitelik noktaları için BRIEF, BRISK ve FREAK kullanılmıştır. Bunun nedeni, seyrek özellik noktalarının eROI sınırına yakın yerleştirilmiş olmasıdır. Bu nedenle, BRIEF, BRISK ve FREAK için geçersizdirler. Veriler, 0-18 yaş arasındaki kemik yaş aralığını temsil eden 30 sınıfa ayrılmıştır. Güney Kaliforniya Üniversitesi'nden elde edilen 1101 radyograf kullanılmıştır. 1101 USC görüntüsünden 552'si erkek, 549'u kız çocuklardan oluşmaktadır. Bu çalışmadaki görüntü işleme zinciri birkaç adımdan oluşur. Bu adımlar eROI çıkarma, özellik noktaları belirleme, özellik tanımlama ve sınıflandırmadır. 5 kat çapraz doğrulama ile ortalama 0,605 yıllık bir hata ile yoğun SIFT öznitelik çıkarımı ile en iyi sonuca ulaşılmıştır.

Štern ve ark. (2016), radyologların fiziksel olgunlaşmayı izleyen yerleşik evreleme şemalarını kullanarak görsel olarak yaş tahminini gerçekleştirme biçiminden esinlenerek, el MRI hacimlerinden otomatik kemik yaşı tahmini yapan derin evrişimli sinir ağlarının (DCNN) kullanımını önermiştir. TW2 yöntemini taklit eden bir mimari kullanarak yeni otomatik yaş tahmin DCNN geliştirilmiştir. DCNN olarak LeNet kullanılmıştır. Model karmaşıklığını daha da azaltmak için, aynı fiziksel olgunlaşma sürecinden geçen SE kemik blokları arasında ağ ağırlıklarını paylaşmayı denedikleri çalışmada, bu fikrin TW2 evreleme şemasından ödünç alındığı belirtilmiştir. Sentetik dönüşümlerle büyütme yoluyla ek eğitim verileri kullanılmıştır. DCNN'ne girdi olarak önceden işlenmiş filtrelenmiş görüntüleri kullanılmıştır. Çalışma sonunda görsel kemik yaşı tahmini için geliştirilen sistem radyologlarla aynı doğrultuda olan $0,36 \pm 0,30$ yıllık bir sapma ile tahmin yaptığı tespit edilmiştir. Önerdiğimiz DCNN yönteminin 3D MR görüntülerinde BA tahmini için uygun bir yöntem olduğu belirtilmiştir.

Spampinato ve ark. (2017), açık kaynak 700 erkek, 691 kadınlara ait görüntülerden oluşan toplam 1391 X-ray görüntülerindeki tüm eli kullanarak iskelet kemik yaşını değerlendirmek için farklı derin öğrenme yöntemi (OverFeat, GoogLeNet ve OxfordNet) ve sıfırdan eğitilmiş özel bir Bonet önermiş ve test etmişlerdir. Dijital El Atlası veri kümesi üzerinde önceden eğitilmiş CNN modellerinin ince ayarının yapılması, yaklaşık %30'luk bir ortalama performans artışıyla sonuçlandıklarını ve klinik prosedürlere dayalı düşük seviyeli görsel tanımlayıcılardan yararlanan yöntemlerden daha iyi performans gösterdiğini tespit etmişlerdir. Ayrıca çalışmada, ırklar, yaş aralıkları ve cinsiyetler arasında kemik yaşını değerlendirmede en etkili ve sağlam çözüm olduğu kanıtlanan özel bir CNN-BoNet tasarlanmış ve sıfırdan eğitilmiştir. BoNet, katı olmayan nesne deformasyonu ile yüzleşmek için son evrişim katmanından önceki bir deformasyon katmanı, bir 2048-tam bağlı katman ve ardından tek bir çıkış nöronu olmak üzere beş evrişim katmanından oluşmaktadır. Manuel ve otomatik değerlendirme sonuçları arasında 0,8 yıllık bir ortalama hata tespit edilmiştir.

Lee ve ark. (2017), el ve bileği otomatik olarak algılamak, segmentlere ayırmak, görüntüleri bir ön işleme motoru kullanarak standart hale getirmek, ince ayarlı bir CNN ile otomatik BAA gerçekleştirmek ve nihai kararlar yapılandırılmış radyoloji raporları oluşturmak için tam otomatik, derin öğrenme sistemi geliştirmişlerdir. Çalışma için 2005-2015 yılları arasında hastaneye gelen hastaların görüntülerinden yararlanılmıştır. Bu görüntüler arasından 0-4 yaş aralığında ki görüntüler çıkarılmıştır. 5-18 yaş aralığında ki hastalara ait görüntüler üzerinde çalışma yapılmıştır. Kadınlar için 4278 radyografi ve erkekler için 4047 radyografi kullanılmıştır. Toplam görüntünün %15'i test, %15 doğrulama ve geri kalan %70 'i eğitim için ayrılmıştır. ROI'ler kullanılarak normalleştirme işlemi yapılmıştır. GoogleNet, Alexnet ve VGG16 modelleri kullanılmıştır. Bu sistemde, test görüntülerinde kadın ve erkek için %57,32 ve %61,40 doğruluk başarıları elde etmek için önceden eğitilmiş, ince ayarlı bir evrişimsel sinir ağı (CNN) kullanılmıştır. Kadın ve erkek kohortları için 2 yıllık %98,56 ve 1 yıllık %92,29 gibi bir ortalama BAA doğruluğuna ulaşmışlardır.

Larson ve ark. (2018), Stanford Üniversitesi'ndeki Lucile Packard Çocuk Hastanesi ve Colorado Çocuk Hastanesinden temin edilen toplam 14036 klinik el radyografisi ile kemik yaşı tahmin etmek için derin öğrenme metodlarını kullanmıştır. Bu görüntüler, radyoloji raporunda iskelet yaşını Greulich ve Pyle'in El ve Bileğin İskelet Gelişimi Radyografik Atlası ile görsel karşılaştırma temelinde belgeleyen pediatrik radyologlar tarafından yorumlanmıştır. Görüntülerin %90'ı (n = 12611) eğitim seti için

rastgele seçilmiş ve %9'u ($n = 1425$) doğrulama seti olarak kullanılmıştır. Modelin performansını aşağıdakilere göre değerlendirmek için cinsiyete göre sınıflandırılmış 200 el radyografından (100 erkek hastalardan ve 100 kadın hastalardan) oluşan ilk test seti kullanılmıştır. Eğitim seti ve modelin kesinliği, 1558, 3141, 6295 ve 12611 görüntülerin rastgele seçilen eğitim alt kümesi boyutlarına dayalı olarak dört ayrı model oluşturulmuştur. Dijital El Son test seti kullanılarak, her alt küme boyutu için bir ortalama karekök (RMS) hesaplandı. Çalışmada model tahminleri ile referans standart kemik yaşları arasındaki kök ortalama kare (RMS) ve ortalama mutlak fark (MAD) karşılaştırılarak değerlendirilen çalışmada RMSE 0,63 yıl hata ile kemik yaşları tespit edilmiştir.

Tong ve ark. (2018), heterojen özellikleri işlemek için çoklu çekirdek öğrenme (MKL) algoritmasını kullanarak vektör regresyonunu (SVR), evrişimli sinir ağlarına (CNN'ler) dayalı derin bir otomatik iskelet kemiği yaşı değerlendirme modeli geliştirmiştir. Bu derin çerçeve, yalnızca el ve bükülmenin X-ışını görüntülerini değil, aynı zamanda ırk ve cinsiyet gibi diğer bazı heterojen bilgileri keşfederek inşa edilmiştir. Deneysel sonuçlar, tekniğin bilinen durumuna kıyasla iki farklı veri setinde daha yüksek kemik yaşı değerlendirme doğruluğu ile daha iyi performansını kanıtlanmış ve bu kaynaşmış heterojen özelliklerin kemiklerin olgunlaşma derecesinin daha iyi bir tanımını sağladığını göstermiştir. X-ray görüntülerinden özellikleri iyileştirmek için ilk olarak iyi performans gösteren VGG-Net'in ara evrişimli katmanları kullanılmıştır. Daha sonra bu rafine görüntü özellikleri, test edilen nesne için kaynaşmış bir tanım oluşturmak için ırk ve cinsiyet gibi diğer bazı heterojen özelliklerle birleştirilmiştir. Son olarak, yukarıda bahsedilen heterojen özelliklere göre destek vektör regresyonu (SVR) ile bir iskelet kemiği yaşı tahmini yapılmıştır. Ek olarak, bu regresyon probleminin çıktı gereksinimini karşılamak için, "softmax" ve "fc-1000" katmanlarını kaldırılmış ve son "maxpool" dan özellikleri alan bir regresyon ağı (RN) oluşturmak için tek nöron katmanı eklenmiştir. Çalışmada VGG-Net transfer öğrenme modeline ince ayar yapılmıştır. Çalışmada 2 farklı veri setinde kullanılmıştır. Bunlardan ilki, halka açık çevrimiçi dağıtılan yaşları 0 ile 18 arasında değişen, dört ırka ait (Asyalı, siyah, beyaz ve İspanyol) ve iki tür cinsiyet (erkek ve kadın) sahip veri seti; diğeri ise görüntüleri kadın ve çocuk hastanesinden elde edilen ve 224×224 boyutlarında ön işleme tabi tutulmuş, kronolojik yaşı 0 ile 18 arasında değişen sağlıklı Çinli çocuklarına ait 20.000 sol el röntgen görüntüsünden oluşan ve cinsiyete göre aynı büyüklükte ki iki alt gruba ayrılmış özel bir veri setidir. Sonuç olarak BoNet + RN iki veri setinde MAE değerleri sırasıyla 0,794 ve 0,653 tespit edilmiştir.

Castillo ve ark. (2018), VGG-16 modelini kullanarak kemik yaşını tahmin ettiği çalışmasında veri seti ilk olarak Kuzey Amerika Radyoloji Derneği'nin 2017 yarışmasında kullanılan ve daha sonra halka açık erişimi için Kaggle'da yayınlanan 12612 görüntüden oluşan RSNA veri seti kullanılmıştır. Karpal ve metakarpal kemiklerin, kemik yaşı tahmini hakkında elin diğer alanlarına göre daha fazla bilgi içerdiğini, en sondaki yaş için daha yüksek tahmin doğruluğuna sahip olduğunu ve bunun sebebi olarak 10 yaş civarında kızların erkeklerden çok daha hızlı büyümesi ve bu da iki cinsiyeti birlikte eğitirken yüksek farklılıkların ortaya çıkmasından kaynaklı olduğu dile getirilmiştir. Ayrıca sınıflandırılması daha zor olan noktaların, ergenliğin başladığı ve bittiği döneme tekabül eden 100 ila 175 ay arasında olduğunu söylenmiştir. Yaptıkları deneylerin MAE sonucu erkek hastalar için 9,82 ay ve kadın hastalar için 10,75 ay olarak bulunmuştur.

Wang ve ark. (2018), kemik yaşının değerlendirilmesi için kemik parçalarını röntgen resimlerinde görülen kemik bileşenlerinin gelişimine göre Radius ve ulna kemiği olarak sınıflandırıp Faster R-CNN ağını kullanmıştır. Veri kümesi olarak 1101 el ve bilek radyografından oluşan bir veri seti kullanılmıştır. Deneylerde, üçüncü basamak bir skolyoz kliniğinde tedavi gören adolesan idiyopatik skolyozu (AIS) olan hastalardan tüm el ve el bileği radyografileri alınmıştır. Etiket bilgilerini de içeren toplam 400 radius görüntüsü ve 600 ulna görüntüsü alınmıştır. Alakasız bölgelerin olumsuz etkilerini azaltmak için, öncelikle distal radius ve ulna bölgelerini çıkarmak için nesne algılama araçlarını kullanmaya karar verilmiştir. Ardından, algılanan görüntü parçalarını yarıçap ve ulna bölgelerini ayrı ayrı kesmek için kullanılmış ve aynı çözünürlüklerde yeniden boyutlandırılmıştır. Radius ve ulna bölgeleri görüntüleri alındıktan sonra bunlara yeni etiketler atanarak yeni bir dosyaya kaydedilmiştir. Elde edilen bu görüntüler CNN modellerini eğitmek için giriş olarak verilmiştir. CNN modelinde; Radius için %92 ve ulna için %90 sınıflandırma doğruluğu elde edilmiştir.

Van Steenkiste ve ark. (2018), derin öğrenme ve Gauss süreç regresyonunun güçlü bir birleşiminden oluştuğu belirtilmiştir. Bu kombinasyonu kullanarak, derin öğrenme modelinin giriş görüntülerinin dönüşlerine ve dönüşlerine duyarlılığı, yalnızca derin öğrenme ağını kullanmaya kıyasla genel tahmin performansını artırmak için kullanılabilir iddiası ile 0 ile 19 yaş arasındaki hastaların 12611 radyografisinden oluşan bir veri seti üzerinde bu çalışma yapılmıştır. Veri seti, 6833 erkek hasta radyografisi ve 5778 kadın hastaların radyografileri olmak üzere kemik yaşları 0 ile 228 ay arasında değişen toplam 12611 görüntüden oluşmaktadır. Önerilen metot, derin öğrenme tahminlerinin

radıyografıların dönüşlerine ve dönüşlerine duyarlılıđından yararlanmak için Gauss Süreç Regresyonu (GPR) ile güçlü bir derin öğrenme kombinasyonuna dayanmaktadır. Modelin eğitimi için transfer öğrenme modellerinden VGG16 kullanılmıřtır. Önerilen model %94,45 ve MAE değeri olarak 6,80 aylık bir hata ile sonuçları bulmuřtur.

Hao ve ark. (2019), regresyon evriřimsel sinir ađı ile otomatik ve verimli bir yaklařım ile ilgi bölgesi (ROI) kullanarak karpal kemiklerin sınır çıkarımını gerçekteřtirerek regresyon tabanlı evriřimli sinir ađı ile küçük çocukların sol el bilek radyografisinden iskelet yařını tahmin eden çalıřmalarında ortalama 2,75 aylık bir sapma/hata ile kemik yařı tahmininde bulunan bir yaklařım geliřtirmişlerdir. Bunun için tüm sol el bilek radyografisinden ROI'yi segmentlere ayırır ve yumuřak dokudan karpal kemikleri çıkarılır. Çalıřma Çin Zhejiang Üniversitesi Tıp Fakóltesi Çocuk Hastanesinden kronolojik yařı 0 ila 6 yıl olan 432 radyografi üzerinde yapılmıřtır. Veri seti 156 erkek radyografisi ve 276 kadın radyografisinden oluřmaktadır. Karpal bölge (M2) için büyütmeli orijinal test radyografileri, doğrulukları sırasıyla 0,5 yıl, 1 yıl ve 2 yıl içinde %47,47±6,04, %77,99±4,44 ve %95,37±2,02'ye düşmektedir. Tüm el için büyütmeli orijinal test radyografileri (M1) iken, doğruluklar 0,5 yıl, 1 yıl ve 2 yıl içinde sırasıyla %38,79±2,20, %73,06±1,39 ve %97,21±0,37'ye düşmektedir. Çıkartılan karpal kemikler (M3) için büyütmesiz orijinal test radyografileri sırasıyla 0,5 yıl, 1 yıl ve 2 yıl içinde %51,52±10,50, %82,24±8,90 ve %95,24±5,50 doğruluk elde etmektedir. Sonuç olarak, karpal bölge (M2) için segmentasyonsuz orijinal test radyografileri, doğrulukları sırasıyla 0,5 yıl, 1 yıl ve 2 yıl içerisinde %41,35±6,04, %66,71±4,44 ve %88,80±2,02'ye düşmektedir. Ve orijinal test radyografilerinin tamamı için büyütmesiz (M1), doğrulukları sırasıyla 0,5 yıl, 1 yıl ve 2 yıl içinde %35,87±2,20, %64,46±1,39 ve %92,75±0,37'ye yükselmektedir.

Bui ve ark. (2019), arařtırmalarında TW3 yöntemi ile derin öğrenme kullanarak kemik yařını bulmaya çalıřmışlardır. Veri seti olarak, 0-18 yař arasındaki 693 erkek ve 682 kadından oluřan çocukların sol el bilek görüntüleri kullanılmıřtır. Önerilen yöntem, ROI'lerden gelen uzman bilgisinden yararlanır. TW3 yönteminin her bir ROI'sinden olgunluk aşaması, özellik mühendisliđini çıkarmak için derin evriřim ađları tarafından öğrenilir. TW3 yönteminde, kemik yařı analizi için 13 ROI kullanılır. Çalıřmada TW3 yönteminden altı (dp1, pp1, dp5, mp5, pp5, mc5) ROI kullanılmıřtır. Çalıřmada TW3 ve CNN tabanlı yöntemleri entegre edilmeye çalıřılmıřtır. GP tabanlı derin öğrenme yönteminden daha iyi performans gösterdiđi iddia edilmiřtir. Çalıřmada, özellik çıkarımı sırasında tüm katmanlar için bařlangıç ađırlıđı ve ince ayar olarak ResNet-101 ve

InceptionV4 modeline ait eğitilmiş ağırlıklar kullanılmıştır. Kemik yaşlarını yıl olarak 0,59 mutlak hata oranı ile tespit etmişlerdir.

Li ve ark. (2019), adli yaş tahmini için pelvik radyografilere dayalı bir derin öğrenme kemik yaşı değerlendirme modeli geliştirmiş ve performansını mevcut kübik regresyon modeliyle karşılaştırmıştır. Sichuan Üniversitesi Batı Çin Hastanesinden alınan 10 ila 25 yaş arasındaki 1072 kadın (%57,2) ve 803 erkek (%42,8) olmak üzere 1875 geleneksel pelvik ön-arka radyografi görüntüsünden oluşan bir veri seti toplanmıştır. Toplama verilerinden yalnızca 18 yaşın altındaki bireyleri dikkate alınmıştır. Bu çalışmada ImageNet veri kümesi kullanılarak önceden eğitilmiş değiştirilmiş bir AlexNet benimsenmiştir. Öznitelik çıkarımı için orijinal evrişim katmanları korunmuştur. Orijinal AlexNet'te tamamen bağlı birkaç katmandan oluşan regresyon kısmı, 2048, 1024 ve 1 nöronlu üç yeni tam bağlantılı katmanla değiştirilmiştir. Tüm pelvik radyograflar merkezi olarak kırılmış ve AlexNet'in orijinal boyutlarıyla uyumlu hale getirmek için 227×227 piksel olarak yeniden boyutlandırılmıştır. Modelin performansını artırmak için eğitim görüntüleri 0° , 90° , 180° ve 270° döndürülerek veri büyütme yapılmıştır. Ortalama kare hata kaybı fonksiyonu benimsenmiş ve Adam optimizasyon yöntemi kullanılarak eğitim gerçekleştirilmiştir. Öğrenme oranı 10-4'e başlatılmış ve kademeli olarak 10-6'ya düşürülmüştür. Yığın (Batch) boyutu 256 olarak ayarlanmıştır. Önerilen CNN modeli tüm test örnekleri için (10 ile 25 yaş arası), önerilen derin öğrenme modeli ve referans standardı kullanılarak yapılan otomatik tahminler arasındaki ortalama MAE ve RMSE sırasıyla 0,94 ve 1,30 yıl olarak tespit edilmiştir. Mevcut kübik regresyon modeliyle karşılaştırılabilir test örnekleri için (14 ve 22 yaş arası), derin öğrenme modeli için ortalama MAE ve RMSE sırasıyla 0,89 ve 1,21 olarak tespit edilmiştir. Ayrıca modelin 22 yaş üzerinde önerilmediği dile getirilmiştir.

Liu ve ark. (2019), kemik yaşını tahmin etmek için ön işleme ile ilgili farklı bir yöntem denemiştir. Alt örneklenmemiş konturlet dönüşümüne (NSCT) ve evrişimli sinir ağlarına (CNN'ler) dayalı X-ışını görüntüleri ile kemik yaşı değerlendirmesi için çok ölçekli bir veri füzyonu çerçevesi önermişlerdir. Orijinal uzamsal alan görüntüsünü doğrudan ağ girişi olarak benimseyen mevcut CNN tabanlı BAA yöntemlerinin aksine, çok ölçekli ve çok yönlü temsillerini elde etmek için NSCT gerçekleştirerek giriş görüntüsü için zengin bir özellik kümesini önceden çıkarılır. Bu özellik çıkarma öncesi stratejisi, BAA problemindeki açıklamalı örneklerin sayısı tipik olarak oldukça sınırlı olduğu için ağ eğitimi için faydalı olabilir. Her ölçekte elde edilen NSCT katsayı haritaları tek tek evrişimli bir ağa beslenir ve daha sonra nihai tahmine ulaşmak için farklı

ölçeklerden gelen bilgiler birleştirilir. Spesifik olarak, BAA için farklı veri füzyon stratejilerine sahip iki CNN modeli sunulmaktadır: özellik düzeyinde füzyonlu bir regresyon modeli ve karar düzeyinde füzyonlu bir sınıflandırma modelidir. Derin öğrenme modeli ile eğitimden önce resimlere alt örnekleme-siz Konturlet Dönüşümü (NSCT) yapılmıştır. NSCT gerçekleştirerek, uzamsal alan görüntüsünde bulunan bilgiler, farklı ölçeklere iyi bir şekilde ayrılır, bu da veri füzyonu yoluyla etkili CNN modelleri tasarlama esnekliğini önemli ölçüde geliştirir. Bu stratejiden oluşturulan RMSE 8,28 olarak bulunmuştur.

Son ve ark. (2019), derin öğrenme yöntemi ile kemikte epifiz-metafiz büyüme bölgelerinin 13 farklı noktasına odaklanarak kemik yaşını tahmin etmeye çalışmıştır. Önerilen sistemin, 13 ROI'nin epifiz-metafiz büyüme bölgelerinin lokalizasyonundan başlayarak ve karşılık gelen BA'nın tahmini ile biten TW3 yönteminin tüm sürecini otomatikleştiren ilk uçtan uca sistem olduğu dile getirilmiştir. Bir ROI'nin olgunluk düzeyinin sınıflandırılması ve ROI'lerin epifiz-metafiz büyüme bölgelerinin yerleştirilmesi için CNN'lere ve bölge tabanlı CNN'lere (R-CNN'ler) dayalı teknikler geliştirilmiştir. Önerilen sistemin temel işlevleri, 13 ROI'nin çıkarılması ve ROI'lerin iskelet olgunluk seviyelerinin sınıflandırılmasıdır. Bu çalışma için sistemi eğitmek ve değerlendirmek için 3300 X-ray görüntüsünden oluşan açıklamalı bir veri tabanı oluşturulmuştur. Deneysel sonuçlar, ilgilenilen 13 bölge için iskelet kemiği olgunluk seviyeleri için ortalama ilk 1 ve ilk 2 tahmin doğruluklarının sırasıyla %79,6 ve %97,2 olduğunu göstermiştir. Yaş tahmininde ortalama mutlak hata ve ortalama karekök hata sırasıyla 0,46 yıl ve 0,62 yıldır ve bir yıl içinde doğruluk %97,6'lık temel doğruluk elde edilmiştir.

Ren ve ark. (2019), Pediatrik kemik yaşını el radyografisinden otomatik olarak değerlendirmek için bir regresyon konvolüsyonel sinir ağı (CNN) önerilmiştir. Önerilen ağ, X-ray görüntülerinde kemik yaşıyla ilgili bölgelere daha fazla dikkat çekmek için özel olarak eğitilmiştir. Spesifik olarak, ilk önce tüm görüntüleri işlemek ve regresyon ağı için girdiler olarak kaba/ince dikkat haritaları oluşturmak için dikkat modülünü kullanılmıştır. Önerilen ağın kemik yaşı ile ilgili bölgelerden ve görsel görünümünden haberdar olması için el radyografisinin kaba-ince dikkat haritaları oluşturulmuş ve elde edilen ROI'ler regresyon CNN modeline verilmiştir. Ön-işlem adımlarında görüntülerde ki alakasız arka plan ortadan kaldırılmış ve ardından ellerin ön planına odaklanılmıştır. Elin yakınlaştırıldığı ön planı kırpma hedeflenmiştir. Bu sayede röntgen görüntüsündeki alakasız arka plan ortadan kaldırılmıştır. Bundan önce, bir girdi görüntüsü, yoğunluk

görünümünü normalleştirmek için histogram eşleşmesinden geçmelidir. Böylece tüm görüntüler benzer histogram dağılımlarını paylaşır. Kaba dikkat haritasını oluşturmak için, el ön zemini için bir sınırlayıcı kutu yerleştirmek için Faster-RCNN kullanılmıştır. Faster-RCNN'nin eğitimi, doğru ancak zaman alıcı olduğundan 1.000 görüntü için dikkdörtgen sınırlayıcı kutular çizilmiştir. Ardından kaba dikkat haritasını filtrelemek ve hassas dikkat haritası elde etmek için Hessian filtrele kullanılmıştır. Bu model için iki büyük veri setinden (sırasıyla 12.480 ve 12.390 denekten) oluşan görüntüler kullanılmıştır. Deneysel sonuçlar, önerilen yöntemin iki büyük veri setinde klinik ve otomatik kemik yaşı değerlendirmeleri arasında ortalama 5,2 – 5,3 aylık bir tutarsızlık elde ettiğini göstermiştir.

Liang ve ark. (2019), çalışmalarında, görüntülere ait önemli bölgeler ele alınmış ve bölge tabanlı evrişimsel sinir ağı (R-CNN) aracılığıyla yeni bir derin otomatik iskelet kemiği yaşı değerlendirme modeli önerilmiştir. Epifiz ve karpal kemiklerin kemikleşme merkezlerini tespit etmek ve kemik yaşını değerlendirmek için, doğru RoI tespiti için Daha Hızlı Bölge Tabanlı Evrişimsel Sinir Ağı (Daha Hızlı R-CNN) modeli kullanılmıştır. Önerilen model, büyük ölçekli orijinal X-ışını görüntülerini girdi olarak alarak diğer CNN tabanlı modellerin sınırlamasının üstesinden gelmiştir. Fast R-CNN kilit bölgeleri, yani epifiz ve karpal kemikleri otomatik olarak bulma, özellikleri çıkarma yeteneğine sahiptir. Özellikleri otomatik olarak çıkarılmış, kilit bölgeleri tespit edilmiş ve kemik yaşının daha fazla tahmin edilmiştir. Deneyler, iki veri seti kullanılarak gerçekleştirilmiştir. Biri, çevrimiçi olarak halka açık olan Dijital El Atlası veri setidir. 0-18 yaş arası çocukların baskın olmayan ellerini gösteren 1369 röntgen görüntüsü içeren, çocukların cinsiyetleri (erkek ve kadın) ve ırkları (Asyalı, Siyahi, Kafkas ve Hispanik) gibi özellikler barındıran bir setidir. Diğer veri seti, 0-18 yaş arası Çinli çocukların baskın olmayan ellerini gösteren farklı boyutlarda 23.482 X-ray görüntüsünü içeren özel bir veri setidir. Bu veri seti çocukların kronolojik yaşı, cinsiyeti ve kemik yaşının özelliklerini içerir. Önerilen modelin etkinliğini doğrulamak için, farklı önceki yöntemler gerçekleştirilmiş ve Ortalama mutlak hataları (MAE) hesaplamak için 10 kat çapraz doğrulama kullanarak iki veri seti üzerinde bir dizi deney gerçekleştirilmiştir. Sonuçlar, önerilen modelin MAE değerlerinin sırasıyla 0,51 ve 0,48 yaşında olduğunu göstermiştir.

Tajmir ve ark. (2019), derin öğrenme tabanlı bir BAA algoritmasının performansını bir pediatrik radyolog grubuyla karşılaştırmış ve derin öğrenme tabanlı bir BAA algoritmasının uygulanmasının radyolog doğruluğu ve değişkenliği üzerindeki etkisini değerlendirilmiştir. Çalışma Altı kurul onaylı, alt uzmanlık eğitilmiş pediatrik

radlyolog tarafından yorumlanan, 5 ila 18 yař arasında deęiřen 280 farklı ırk ve  lkelere ait 280 g r nt   zerinde yapılmıřtır. Giriř g r nt lerinden siyah arka plan ve tek tip bir boyuta (512×512 piksel) sahip olacak řekilde normalleřtirilmiř, ardından eli otomatik olarak segmentlere ayrılmıř ve gereksiz verileri kaldırmak i in 32×32 g r nt leme yama boyutu ve 4 adımlı LeNet-5 tabanlı bir  n segmentasyon CNN'yi kullanılmıřtır. Par alara ayrılmıř ve normalleřtirilmiř g r nt ler daha sonra kemik ayrıntılarını geliřtirmek i in uygulanan kontrast sınırlı uyarlanabilir histogram eřitleme (CLAHE), g r lt  giderme ve keskinleřtirme iřlemleri yapılmıř ve son olarak iskelet sınıflandırması i in CNN mimarisine verilmiřtir. Modelin ařırı  ęrenmesini engellemek i in g r nt lere Data augmentation uygulanmıřtır. Son olarak bu g r nt leri  n eęitimli transfer  ęrenme modellerinden GoogLeNete verilmiřtir. Doęruluk  l  leri olarak kemik yařı doęruluęu ve k k ortalama kare hatası (RMSE) kullanılmıřtır. Sınıf i i korelasyon katsayısı deęerlendiriciler arası deęiřimi olarak kullanılmıřtır. Doęruluk genel olarak %68,2 ve 1 yıl i inde %98,6 ve ortalama altı okuyuculu kohort doęruluęu 1 yıl i inde %63,6 ve %97,4 iken RMSE 0.601 yıl, ortalama tek okuyuculu RMSE 0.661 yıl olarak tespit edilmiřtir. Havuzlanmıř RMSE, 0,661'den 0,508 yıla d ř r lm řt r.

Wu ve ark. (2019), kemik yařı deęerlendirmesi i in birleřik bir derin  ęrenme tabanlı  er eve tasarlamıřlardır.  nemli kemik b lgelerine odaklanmıřtır. Bu, iki adımda elde edilmiřtir. İlk olarak, Maske R-CNN alt aęı, dikkat daęılmalarını  nlemek i in dięer nesneleri  ıkarmak i in X-ıřını g r nt lerinden el b lgelerini  ıkarılmıřtır. İkinci olarak, aęı  nemli b lgelere otomatik olarak katılmaya zorlamak i in artık bir dikkat alt aęı kullanılmıřtır.  nerilen model  nce ekstra nesnelere ait olanlar gibi alakasız pikselleri maskelemek i in Mask R-CNN kullanır. Ardından, maskelenmiř g r nt   zerinde tahminde bulunmak i in artık dikkat tabanlı bir aę (Residual attention) kullanır. Model yaklařık 12.500 etiketli g r nt  i eren RSNA pediatrik kemik yařı veri seti  zerinde deęerlendirilmiřtir. T m g r nt lerin kendileriyle iliřkili bir cinsiyeti vardır. %90 / %10 eęitim/doęrulama ayrımı kullanılmıřtır. Eęitim setindeki el maskeleri, histogram normalleřtirilmiř g r nt ler  zerinde Canny kenar tespiti y ntemi kullanılarak segmentlere ayrılmıřtır.  nerilen model, sonu ları iki farklı ayarla rapor eden VGG-16 ve U-Net sinir aęının bir kombinasyonu ile t m ellerde elde edilmiřtir.  nerilen model t m el i in 8,08 aylık bir MAE deęeri elde etmiřtir.

Han ve Wang (2020), derin  ęrenme algoritmasındaki ResNet modeline g re, kemik yařı deęerlendirme modeli tarafından tespit edilen kemik yařının ortalama mutlak hatası, geleneksel y ntemlerden 0,455 daha iyi  ıkmıřtır. 0-17 yař arası 1.229 g r nt 

verisi test seti olarak toplanmıştır. Orijinal görüntüler veri kümesi, 300×300 piksel çözünürlüğe eşit olarak ölçeklenmiştir. Görüntü Ön İşleme: openCV histogram tekdüzelik eşleştirme yöntemini kullanarak tüm gri tonlama dağılımlarını aynı gri tonlama dağılımıyla eşleştirir. Daha sonra gri değeri 0–1'e normalleştirilir. Bir görüntüye labelImg aracı kullanılarak deneyimli bir radyolog tarafından açıklama eklenmiş ve karpal kemik, distal metakarpal, proksimal falanksın kemik yaşı görüntüsü üzerinde bir sınırlayıcı kutu kullanılarak bir doktor tarafından gözden geçirilmiştir. Proksimal ve distal falanks proksimal humerus, humerus ve ulna 17 alan ile işaretlenmiştir. Veriler rastgele bir eğitim kümesine ve 8:2 oranında bir doğrulama kümesine ayrılmış ve görüntülere çevirme, döndürme gibi veri geliştirme işlemleri gerçekleştirilmiştir. Sol X-ray görüntülerinde 17 anahtar alanın özelliklerini çıkarılıyor. Her bir anahtar alan 2.048 boyutlu özellikler üretir ve görüntüye dayalı olarak toplam 17×2.048 boyutlu özellikler oluşturulur. Öğrenme oranı 0.0005'ten büyük olduğunda, Inception Resnet v2 modelinin MAE'si çoğu modelden daha yüksek çıkmıştır 1.110 X-ışını görüntüsünün analizi ve karşılık gelen kemik yaşı verileri kullanılarak, bu çalışmanın kemik yaşı MAE'si 0,455 ve her görüntünün işlenmesi için geçen ortalama süre 0,4 s olarak tespit edilmiştir. Erkeklerin MAE'si 0.445 ve kadınların MAE'si 0,474 olarak tespit edilmiştir. Yaş grubuna göre, erkek ve kadınların minimum MAE'si 0 ila 2 yaşında ve maksimum MAE 17-18 yaşında ortaya çıkmıştır. 2 ila 16 yaş aralığında, erkek ve kadınların MAE'si 0,308 ile 0,668 arasında dağılmıştır.

Reddy ve ark. (2020), yaptığı çalışmada tüm elden ziyade sadece işaret parmağını kullanarak radyografilerden kemik yaşını doğru bir şekilde tahmin edip edemediklerini belirlemeye çalışmıştır. Bu işlem için eğitim için 12.611 el radyografisi ve test için 200 radyograf içeren halka açık olarak dağıtılan RSNA veri seti kullanılmıştır. İşaret parmağı, ikinci bir veri kümesi oluşturmak için bu görüntülerden kırılmıştır. Özel bir etiketleme aracı kullanılarak 1.000 radyografda işaret parmağının etrafına manuel olarak terminal falanksı, orta falanksı ve proksimal falanksın başını içeren bir kutu çizilmiştir. CNN modellerin, kırılmış ikinci basamaklı veri seti kullanılarak eğitilmiştir. Bu çalışmada transfer öğrenme modellerinden Xception kullanılmıştır. Görüntüler 500*500 şeklinde yeniden boyutlandırılmıştır. Tüm el ve işaret parmağı için referans ve CNN kemik yaşı arasındaki ortalama mutlak farkın 4,7 ile 5,1 ay arasında değişen sonuçlar elde etmişlerdir.

Chen ve ark. (2020), yaptıkları çalışmada X-ray görüntü tanıma yoluyla kemik yaşını tespit etmek için LBP, GLCM ve derin öğrenme yöntemlerinden 2 farklı öznetelik

çıkartım yöntemi ile kemik yaşını tespit etmeye çalışmışlar. Çin Tıp Üniversitesi Shengjing Hastanesi Ortopedi Cerrahisi Anabilim Dalı'nın resim arşivleme ve iletişim sistemi (PACS) tarafından toplanan 12536 DICOM verisi, Aralık 2017'den Aralık 2018'e kadar 12000 hasta vakası toplanmıştır. Yaşları 0-18 arasında değişen hasta görüntüleri için tercih edilen Modelin en iyi parametrelerini bulması için doğrulama seti olarak toplam verinin %15'i, kalan %85'i eğitim veri seti olarak rastgele seçilmiştir. Görüntü, histogram eşleştirme ve normalleştirme ile normalleştirilir. Dosya analizi gri dağılımını ayarlar ve görüntünün giriş boyutunu 500 x 500'e ayarlar. Bölge tabanlı evrişimli sinir ağı (RCNN) kullanarak, kilit konumları belirleyerek, görüntü üzerinde kayan bir pencere oluşturarak ve kayan pencereyi görüntü boyunca hareket ettirerek potansiyel hedef alanı elde etmek için, RCNN, hedef alanın standart özelliklerini çıkarmak için kullanılır. Kemik yaşı ResNet ve Spatial Transformer'a dayalı ST-Res Net ağ yapısı modeli kullanılarak tahmin edilmektedir. Derin sinir ağına dayalı öznelilik çıkarma yönteminin, özellik bilgisini geleneksel görüntü analizi yönteminden daha iyi çıkarabildiğini göstermişlerdir.

Shin ve ark. (2020), Koreli çocukların ve ergenlerin el-bilek radyografilerindeki klinik etkinliğini TW3 tabanlı tam otomatik kemik yaşı değerlendirme sistemini ölçen bir sistem üzerinde çalışmışlardır. Çalışmalar 7-15 yaş aralığında 40 erkek ve 40 kadın dan oluşan 80 denek üzerinde yapılmıştır. Klinik etkinlik, sistem kullanılarak belirlenen kemik yaşları ile 2 radyolog tarafından üretilen referanslar karşılaştırılarak değerlendirilmiştir. Karşılaştırmalar, eşleştirilmiş t-testi ve basit regresyon analizi kullanılarak yapılmıştır. Referans standart ($P>0,05$) ile elde edilenlerden önemli ölçüde farklı olmadığı ve %95 güven aralığında ($-0,07$ ila $0,22$) 0,6 yıllık eşdeğerlik kriterini karşılayarak performans göstermiştir. Benzer şekilde cinsiyet alt gruplarının karşılaştırılmasında da sistem tarafından üretilen değerler ile referans standart arasında kemik yaşı açısından anlamlı bir fark gözlenmediği (hem erkek hem de kız çocukları için $P>0,05$) tespit edilmiştir. Regresyon analizi ile elde edilen belirleme katsayıları sırasıyla erkek, kız ve genel için 0,962, 0,945 ve 0,952 ($P=0,000$) olarak bulunmuştur; dolayısıyla radyolog tarafından belirlenen kemik yaşları ile sistem tarafından belirlenen kemik yaşları arasında güçlü bir korelasyon olduğu tespit edilmiştir.

Wibisono ve Mursanto (2020), Röntgen görüntüsünden kemik yaşını tahmin etmek için bir karar destek sistemi geliştirilmiştir. Geleneksel makine öğrenimi yöntemlerini ve derin öğrenme kullanılmıştır. El röntgeninin temel bölümlere ayrılmış bölgesinden Bölge Tabanlı Özellik Bağlantılı Katmanı (RB-FCL) önerilmiştir. Derin

öğrenme modellerini, el röntgen kemiğinin her bölgesi için özellik çıkarımı olarak ele alınmıştır. Özelliğe Bağlı Katmanlar, 1-radius-ulna, 2-carpal, 3-metacarpal, 4-phalanges ve 5-ephyphysis gibi eğitilmiş önemli bölgenin çıktılarıdır. DenseNet121, InceptionV3 ve InceptionResNetV2, kritik bölgeyi eğitmek için kullandıkları derin öğrenme modelleridir. Her bölgeden birkaç çıktı katmanı özelliğinin bir kombinasyonuna dayalı olarak elde edilmiştir. Değerlendirme sonuçlarından, üretilen Ortalama Mutlak Hata (MAE) değeri 6,97 olarak bulunmuştur. Sonuçların karşılaştırmasına bakılırsa, bölge tabanlı özellik katmanı RB-FCL yönteminin kullanılması, standart derin öğrenme prosedürlerine kıyasla daha iyi kemik yaşı tahmin değerleri elde ettiği tespit edilmiştir.

Lee ve ark. (2021), kemik yaşı değerlendirmesi için bir melez Greulich-Pyle (GP) ve modifiye Tanner-Whitehouse (TW) yapay zekâ (AI) modelinin doğruluğunu ve klinik etkinliğini değerlendirmiştir. Derin öğrenmeye dayalı bu model, birden çok etnik kökene ait açık bir veri kümesi üzerinde eğitilmiştir. Harici doğrulama için tek bir kurumdan toplam 102 el radyografisi (51 erkek ve 51 kadın; ortalama yaş $\pm$ standart sapma = 10.95 $\pm$ 2,37 yıl) seçilmiştir. İki çalışma radyoloğu, okuma süresinin kaydedildiği iki ayrı oturumda AI modeli yardımı ile ve olmadan kemik yaşı değerlendirmeleri gerçekleştirmiştir. AI yazılımının performansı, AI tarafından hesaplanan kemik yaşı ile referans standart arasındaki ortalama mutlak fark karşılaştırılarak değerlendirilmiştir. Okuma süresi, eşleştirilmiş bir t testi kullanılarak AI ile ve AI olmadan okuma arasında karşılaştırılmıştır. Ayrıca, iki çalışma radyoloğunun kemik yaşı değerlendirmeleri arasındaki güvenilirlik, sınıf içi korelasyon katsayıları (ICC'ler) kullanılarak değerlendirilmiştir ve sonuçlar AI ile ve AI olmadan okuma arasında karşılaştırılmıştır. Uzmanlar ve AI modeli tarafından değerlendirilen kemik yaşları önemli ölçüde farklı çıkmamıştır (sırasıyla 11,39 $\pm$ 2,74 yıl ve 11,35 $\pm$ 2,76 yıl, $p = 0,31$). Otomatik AI değerlendirmesi ile referans standart arasındaki ortalama mutlak fark 0,39 yıl (%95 güven aralığı, 0,33-0,45 yıl) tespit edilmiştir. İki çalışma radyoloğunun ortalama okuma süresi, AI model yardımı ile 54.29 saniyeden 35.37 saniyeye düşürüldüğü görülmüştür ($p < 0,001$). İki çalışma radyoloğunun ICC'si, AI model yardımı ile biraz artmıştır (0,945'ten 0,990). Önerilen AI modelinin, kemik yaşını değerlendirmek için doğru olduğu, Ayrıca, bu modelin okuma süresini azaltarak ve gözlemciler arası güvenilirliği artırarak klinik etkinliği arttırdığı ortaya çıktığı belirtilmiştir. Model üç adımdan oluşur: ROI tespiti, bölge olgunluk sınıflandırması ve entegre kemik yaşı. İlk olarak, evrişimli sinir ağı (CNN) algoritması kullanılarak TW3'e dayalı yedi bölge otomatik olarak algılanmıştır. TW3 kemik yaşı değerlendirmesi için 13 ROI kullanırken, önerilen modifiye yöntem

eğitim boyunca yedi bölge (yarıçap, ulna, distal falanj, orta falanj, proksimal falanj, üçüncü basamağın metakarpı ve birinci basamağın metakarpı) kullanmıştır. İkinci olarak, her bir ROI ve bütünsel el görüntüsü, CNN algoritması kullanılarak olgunluk için otomatik olarak sınıflandırılmıştır. TW3, her bir ROI'nin olgunluğunu değerlendirmek için A'dan I'ye dokuz aşama kullanırken, önerilen yöntem olgunluk için 1,5 ila 18 yıl arasında 6 aylık bir boşlukla 34 aşama kullanmıştır. Ek olarak, bütünsel el görüntüsü otomatik olarak sınıflandırılmış ve AI modeline uygulanmıştır. İki genel veri seti kullanılmıştır. Birincisi, 2017 yarışmasından Stanford Üniversitesi ve Colorado Üniversitesi'nden 14236 el radyografisini içeren Kuzey Amerika Radyoloji Derneğine (RSNA) ait veri seti, diğeri ise 1375 el radyografisini içeren Güney Kaliforniya Üniversitesine ait Dijital El Atlası veri setidir. Önerilen modelin MAD ve RMSE değerleri sırasıyla 0,39 ve 0,50 olarak tespit ettiği belirtilmiştir. Benzer çalışmalara göre diğeri çalışma sonuçlarına yakın değerler elde ettiği belirtilmiştir.

Mehta ve ark. (2021), kemik yaşı değerlendirmesi için tam otomatik bir derin öğrenme yaklaşımı önermiştir. Kullanılan veri seti, Kuzey Amerika Radyoloji Derneği tarafından yayınlanan 2017 Pediatrik Kemik Yaşı Mücadelesinden alınmıştır. Görüntüler ön işlemden geçirilmiş ardından görüntülere ilgilenilen bir bölgeyi (el maskesi) çıkarmak ve tüm yabancı nesneleri çıkarmak için ROI tabanlı maskeleme uygulanmıştır. Çalışmada, ilgili bölge için bir sınırlayıcı kutu çizerek bir maske oluşturmak için SelectROI API kullanılmıştır. Görüntünün kontrastını ve Parlaklığını iyileştirmek için bir ön işleme yöntemi olan ve doğrusal olmayan Gama düzeltme işlemi kullanılmıştır. Bu veri集中的 her X-Ray görüntüsü, hastanın yaşı ve cinsiyeti ile etiketlenmiş bir sol elin görüntüsüdür. Transfer öğrenimi, önceden eğitilmiş sinir ağı mimarisi kullanılmıştır. Mevcut çalışmada InceptionV3 mimarisi kullanılmış ve elde edilen gerçek ve tahmini yaş arasındaki fark 5,921 ay olarak tespit edilmiştir.

2.2. 18 Yaş Üstü Kemik Yaşı Tespiti İçin Yapılan Araştırmalar

Yapılan araştırmada 18 yaş üstü kemik yaşının tespitinin sol el bileklerinden tespitine yönelik yeterli çalışmanın olmadığı tespit edilmiştir.

Almanya Adli Yaş Tespiti Çalışma Grubunun (Study Group on Forensic Age Diagnostics-Arbeitsgemeinschaft für Forensische Altersdiagnostik; AGFAD) kriminal olaylarda, canlı bireylerde yaş tespiti önerilerine göre süreç, öncelikle fizik muayene (boy, kilo, cinsiyet belirteçleri), sol el bilek grafisi, dental muayene ve dental grafi

içermelidir. Sol el bilek grafisinde kemikleşme tamamlandıysa ek olarak Bilgisayarlı Tomografi (BT) veya direkt grafi ile klavikula mediyal yüzü değerlendirilir (Schmeling ve ark., 2008) . 18 yaş altı bireylerde yaş tayininde sol el bilek grafiilerinden atlas yöntemleri ile karşılaştırma ve dental grafiilerden skorlama yöntemleri kullanılmaktadır. Toplumlarda dominant elin sağ el olması ve sol elde deformasyon riskinin daha az olması nedeniyle değerlendirme için sol el tercih edilmektedir.

El kemiklerinde ossifikasyon tamamlandıktan sonra kişinin 18 yaşına girip girmediğini değerlendirmekte vücutta en son füzyon hattı kapanan klavikula mediali ince kesit bilgisayarlı tomografi ile değerlendirilmektedir.

Dental grafiilerle erişkin yaş değerlendirmesinde; 17-21 yaş aralığında 3ncü molar kemiğin erüpsüyonu ile kalıcı dişlerin tamamlanması nedeniyle, bu yaştan sonra radyolojik olarak yaş tayini zorlaşmaktadır. Dental grafiilerde dişlerde hacim ölçümü, diş-koronal indeks ve 3ncü molar kemiğin gelişiminin değerlendirilmesi ile yaş tayini yapılabilmektedir (Panchbhai, 2011).

Gurses ve ark. (2017), ince kesit BT ile epifiz, Alman Adli Tıp Derneği Adli Yaş Teşhisi Çalışma Grubu tarafından önerilen yöntemlerden biridir. Bu retrospektif çalışmada yaşları 13-28 arasında değişen 254 hastanın (146 erkek, 108 kadın) ince kesit BT (kesit kalınlığı 0,6 ve 1 mm) görüntülerini Kellinghaus alt evre sistemine göre değerlendirilmiştir. Kadın hastaların ortalama değerlerinin evre 2a için erkek hastaların ortalama değerlerinden yaklaşık 10 ay, evre 2b için yaklaşık 13 ay ve evre 2c için yaklaşık 18 ay daha düşük olduğu gözlenmiştir. Evre 3c için en erken görünüm her iki cinsiyette de 19 yaşında görüldüğünü göstermişlerdir.

Yi ve ark. (2021), göğüs radyografiilerinde yaş ve cinsiyetin otomatik olarak sınıflandırılması için derin evrişimli sinir ağlarının (DCNN'ler) performansını geliştirmiş ve test etmişlerdir. Ulusal Sağlık Enstitüleri (NIH) ChestX-ray veri tabanından 112.120 ön CXR ile çalışmalar yapılmıştır. Bu CXR'ler, 1 ila 95 yaşları arasında 48.780 kadın (%44) ve 63.340 erkekte (%56) gerçekleştirilmiştir. Bu CXR'ler, 5941 pediatrik (< 18 yaşında) CXR'den (%5), 2546'sı (%43) kadın ($p = 0.3$) ve 1803'ü 11 yaşından (%30) oluşmaktadır. Veri kümesi eğitim (%70), doğrulama (%10) ve test (%20) veri kümelerine bölündü. Cinsiyet belirleme, yaşın belirlenmesi < 18 yaşında veya ≥ 18 yaşında ve yaşın belirlenmesi < 11 yaşında veya 11-18 yaşı için ImageNet'te önceden eğitilmiş ResNet-18 DCNN'lere ince ayar yapmak için kullanılmıştır. Tüm veri setinde cinsiyeti belirlemek için eğitilen DCNN'ler ve pediatrik CXR'ler yalnızca sırasıyla 1.0 ve 0.91 AUC'ye sahip olduğunu ($p < 0,0001$), yaş < veya ≥ 18 yaşındaki ve < 11 ve 11-18 yaşındaki yaşı

belirlemek için eğitilen DCNN'lerin AUC'leri sırasıyla 0,99 ve 0,96 ($p < 0,0001$) olduğu tespit edilmiştir.

Erişkin yaş tespitinde dental skorlama sık kullanılmaktadır. Bu konuda çoğunlukla periapikal grafiler ve Orthopantomagram (OPG) kullanılsa da teknolojik gelişimle birlikte dental Bilgisayarlı Tomografi (BT) ve Manyetik Resonans Imaging (MRI) görüntülerinden yaş tayini son zamanlarda sıklıkla araştırılmaktadır

Kvaal ve ark. (1995), yaptıkları çalışmada tam ağız diş radyografilerinde pulpa boyutunun ölçümlerinden bir yetişkinin kronolojik yaşını tahmin etmek için kullanılabilecek bir yöntem bulmaya çalışmışlardır. Materyal, Oslo'daki Dişhekimliği Fakültesi kliniklerine devam eden dişhekimisi hastasından alınan 100 periapikal radyografilerden oluşmaktadır. Her çeneden altı tip dişin radyografileri ölçülmüş: maksiller merkezi ve yan kesici dişler ve ikinci küçük azılar ve mandibular yan kesici dişler, köpek dişleri ve birinci küçük azılar alınmıştır. Radyograflardaki büyütme ve açılı farklılıklarını telafi etmek için, üç farklı seviyede pulpa/kök uzunluğu, pulpa/diş uzunluğu, diş/kök uzunluğu ve pulpa/kök genişliği oranları hesaplanmıştır. İstatistiksel analizler, diş ve kök uzunluğu arasındaki oran dışında, yaş ve her diş tipi için farklı oranlar arasındaki Pearson korelasyon katsayısının anlamlı olduğunu göstermiştir. Çalışmada pulpa-diş oranını kullanarak 19-29, 29-39 şeklinde 10'lu dekadlar halinde erişkinlerde yaş tayini belirleme çalışmasında toplam 100 hasta üzerinde çalışmış ve ortalama 9 yıl standart hata ile kemik yaşını hesaplamışlardır.

Drusini (2008), benzer şekilde 11-20, 21-30 şeklinde onlu dekadlara ayırarak yaptıkları çalışmada 5,8 – 6,7 yıl standart hata ile kemik yaşını hesaplamışlardır.

Hatice ve ark. (2017), 200 kişi üzerinde yaptıkları çalışmada Drusini metodunun Türk popülasyonuna uygun olmadığını, Cameriere metodunun 9,23 yıl standart hata ile Türk popülasyonuna uyduğunu belirtmişlerdir.

Akay ve ark. (2020) yaşları 18-60 arasındaki 860 bireyin OPG grafileri üzerinde yaptıkları çalışmada, diş koronal indeksi ve Olze metodu ile manuel olarak yaş tayini yaptıkları çalışmada yaklaşık 5,64- 6,08 yıl SEE ile yaş tayininde bulunmuşlardır.

Vila-Blanco ve ark. (2020), bu çalışmada, Ortopantomogram (OPG) görüntüsünden bir öznenin kronolojik yaşını tahmin etmek için iki tam otomatik yöntem önermişlerdir. Birincisi (DANet), yaş tahmin etmek için sıralı bir Evrimsel Sinir Ağı (CNN) yolundan oluşurken, ikincisi (DASNet) cinsiyeti tahmin etmek için ikinci bir CNN yolu ekler ve yaş tahmin performansını iyileştirmek amacıyla cinsiyete özgü özellikleri kullanır. Her iki yöntem de hem kötü radyolojik kalitedeki görüntülerin hem de

kondisyonlama dış özelliklerini gösteren görüntülerin atılmadığı, 4,5 ila 89,2 yaşındaki 2289 beyaz İspanyol bireyin OPG görüntüsü üzerinde testler yapılmıştır. Sonuçlar, DASNet'in her açıdan DANet'ten daha iyi performans gösterdiğini, tüm veritabanında medyan Hata (E) ve medyan Mutlak Hatanın (AE) yaklaşık 4 ay azalttığını göstermiştir. 2 yıl 10 ay AE ve 0,12 yıl median error ile yaş tayini yapılmıştır. DASNet'i azaltılmış veri kümelerinde değerlendirirken, deneklerin gerçek yaşı azaldıkça, 15 yaşından küçük deneklerde yaklaşık 8 aylık bir ortancaya ulaşana kadar AE değerlerinin düştüğü gözlenmiştir. DASNet'in, özellikle gelişmekte olan dişleri olan genç deneklerde, bir denneğin kronolojik yaşını otomatik olarak doğru bir şekilde tahmin etmek için kullanılabileceği sonucuna varılmıştır. Bu çalışmada bireylerin yaşı azaldıkça başarı oranı artmış, AE değeri azalmıştır

Son yıllarda yüz resimlerinden otomatik yaş tespitinde bulunan derin öğrenme yöntemlerini araştıran çok sayıda araştırma mevcuttur.

Xing ve ark. (2017), 16-77 yaş arasında yaklaşık 13000 bireyin yaklaşık 55000 yüz resimlerinden oluşan Morph II veri seti ve WebFace veri seti üzerinde derin öğrenme yöntemleri ile yaptıkları çalışmada regresyon bazlı metotlar ile WebFace veri seti için 2,96 yıl MAE (mean absolute error), Morph II veri seti için NetVGG yöntemi ile 2,96 yıl MAE ile bireylerin yüzlerinden yaş tayininde bulunmuşlardır. Morph II, 13.000'den fazla öznenin yaklaşık 55.000 yüz görüntüsünü içerir. Yaşları 16 ile 77 arasında değişmektedir. Morph II, cinsiyet ve ırk etiketleri içeren çok etnik gruptan oluşan bir veri kümesidir. Yaklaşık %77'si Siyah yüz görüntüleri ve %19'u Beyaz yüzlere ait görüntüler iken, kalan %4'ü Asyalı, İspanyol, Hintli ve Diğerlerini içerir. WebFace veri kümesi 59.930 yüz görüntüsü içerir. Yaş 1 ile 80 arasında değişmektedir. WebFace veri kümesi aynı zamanda ek cinsiyet etiketlerine sahip çok ırklı bir veri kümesidir. MAE kaybı ile regresyona dayalı formülasyonun en iyi seçim olduğunu bulmak için beş farklı kayıp fonksiyonuna sahip üç farklı formülasyon türünü araştırarak yaş tahmini problemi için derin öğrenme modellerinin kapsamlı teşhisini gerçekleştirmişlerdir. Aynı anda yaş tahmini, cinsiyet ve ırk sınıflandırması yapmak için yeni bir mimar önerilmiştir.

Dallora ve ark. (2019), boy uzamasının durduğu ve büyüme bölgelerinin kapandığı (14-21 yaş) yaş aralığındaki gençlerin ve genç yetişkinlerin diz MRG'sini kullanarak derin öğrenmeyi kullanarak yaş değerlendirmesi için otomatik bir yaklaşım önermektedir. Bu çalışma için, 14-21 yaşları arasındaki 221 erkek (%55) ve 181 (%45) kadın olmak üzere toplam 402 gönüllü denneğin dizlerinin MRI incelemelerini gerçekleştirilmiştir. Yöntem iki evrimsel sinir ağı (CNN) modelinden oluşmuştur: ilki,

yaş değerlendirme amaçlarıyla ilgili olarak bir MRI dizisinin en bilgilendirici görüntülerini seçilmiştir. Bunun için kemiğin büyüme plakası, epifiz ve metafizi içeren ilgili anatomik yapıları içeren bilgiler elde edilmiştir. Bunlar daha sonra yaş tahmininden sorumlu olan ikinci modülde kullanılmıştır. Yaş tahmin modeli, girdi olarak N kanallı bir MRI görüntüsü alır ve ardından konunun tahmini kronolojik yaşını verir. Hem sıfırdan eğitim hem de transfer öğrenimi kullanılarak farklı CNN mimarileri test edilmiştir. En iyi sonuçları sağlayan CNN mimarisi, ImageNet veri tabanında önceden eğitilmiş GoogLeNet olmuştur. Önerilen yöntem, 0.793 yıllık bir ortalama mutlak hata (MAE) ile 14-20.5 yaş aralığındaki erkek deneklerin yaşını ve 0.988 yıllık MAE ile 14-19.5 yaş aralığındaki kadın denekleri değerlendirmiştir. 18 yaş eşiği ile küçüklerin sınıflandırılmasıyla ilgili olarak, erkek denekler için %98,1 ve kadın denekler için %95,0 doğruluk elde edilmiştir. Modellerin kesinliğini ve MAE'sini iyileştirebilecek daha fazla verinin toplanmasına yönelik daha fazla çalışma yapılması gerektiği ifade edilmiştir.

Othmani ve ark. (2020), yüz görüntülerinden Otomatik Yaş Tahmini için insan yüz görüntülerden oluşan public veri setleri üzerinde derin öğrenme yöntemlerini karşılaştırmışlardır. Bu karşılaştırma sonucunda Xception ağına dayalı modelin, ImageNet'te önceden eğitildiğinde 2,35 yıllık bir MAE ve CASIA- üzerinde önceden eğitildiğinde 2,01'lik bir MAE ile otomatik yaş tahmini için derin veya yüzeysel öğrenmeye dayalı son teknoloji yöntemlerden daha iyi performans gösterdiğini bulmuşlardır. Deneysel sonuçlar, siyah yüzler üzerinde yapılan testlerin ve diğer etnik kökenler üzerinde yapılan eğitimin, çapraz etnik köken testlerinde en yüksek hatayı gösterdiğini gösterdiğini ifade etmişlerdir.

Radyolojik yaş tayininde Türkiye'de kullanılan ve bizim kliniğimizde de kullandığımız Gök atlasına göre, öncelikle sol el bilek grafisi, 14 yaş sonrası iki yönlü dirsek grafisi ve omuz grafisi, 18-22 yaş arasında pelvis grafisi, 25 li yaşlarda yan sakrum ve koksiks grafisi, 40-50 yaş civarı sternum-ksifoid ve kot değerlendirmesi amacıyla iki yönlü akciğer grafisi kullanılmaktadır. Bu yöntemle erişkin bireylerde kabaca 22 yaşa kadar yıl olarak daha sonra ise 22-25 yaş arası, 25-40 yaş arası, 40-50 yaş arası, ve 50 yaş üstü şeklinde bir sınıflandırma yapılmaktadır (Gök ve ark., 1985a). Bu atlasa göre erişkin yaş tayininde en az 5 direkt grafi çekimi yapılmalıdır. Buda bireylerin alacağı radyasyon dozunu arttırmaktadır. Ayrıca elde edilen yaş aralığı derin öğrenme yöntemleri ile kıyaslanamayacak kadar geniştir.

18 yaş sonrası el kemiklerinde fizis hatlarının kapanması ve kemikleşmenin tamamlanması nedeniyle ek grafi istenmektedir. Ancak yaşla beraber tüm vücutta

olduđu gibi el kemiklerinde de etkilenme olmaktadır. Zamanla kemiklerde korteks/medulla oranı ve mineralizasyon miktarı deđiřmektedir (Çölođu, 1987). Eldeki bu deđiřimler atlas yöntemleri ile hekim deđerlendirmesi için uygun olmayabilir ancak derin öğrenme yöntemleri ile deđerlendirilebilir. Bu fikirle bu çalışmada 18 yař üstü bireylerde sol el bilek grařlarını içeren yeni bir veri seti oluşturulmuř ve sadece sol el bilek grařisi kullanılarak canlı erişkin bireylerde derin öğrenme yöntemleri ile yař tespiti yapılmaya çalışılmıştır. Bildiđimiz kadarı ile literatürde sadece sol el bilek grařisi ile erişkin bireylerde yař tespiti yapan çalışma yoktur. El-bilek grařisi erişimi kolay, invazif olmayan, basit ve ucuz bir yöntemdir. Bu çalışmada geleneksel yöntemlerden çok daha başarılı sonuçlar elde edilmiştir.

Farklı görüntüleme metotlarıyla vücut farklı miktarlarda radyasyona maruz kalmaktadır. Bunlar içerisinde vücudun en az radyasyona maruz kaldıđı yöntem el bilek grařisidir. Ayrıca efektif radyasyon dozu el-bilek grařisinde 0.1 μ Sv iken, OPG de 20 μ Sv (MicroSievert) tir (Mettler ve ark., 2008; Mansour ve ark., 2017).

3. MATERYAL VE METOT

Bu çalışmada kullanılan görüntüler Kütahya sağlık bilimleri üniversitesi rektörlüğün'den evrak tarih ve sayısı: 22.04.2021-10381 olan etik kurulu kararı ile elde edilmiştir. Etik kurul kararları ekler başlığında verilmiştir. Bu bölümde, tez çalışmasında kullanılan veri setinin oluşturulması ve uygulanan derin öğrenme metotları açıklanmıştır. Bu bölüm iki aşamadan oluşmaktadır. Birinci bölümde 18 yaş altında ki ve 18 yaş üstünde ki bireylerin kemik yaşı tespitini yapmak için kullanılan veri seti oluşturulma süreci verilmiştir. İkinci aşamada ise toplanan veri setine uygulanan ön işlemler, derin transfer öğrenme modelleri ve bu modellerde kullanılan hiper parametreler, analiz ve değerlendirme süreçleri detaylı olarak anlatılmıştır.

3.1. Materyal

Bu tez çalışması kapsamında 18 yaş altındaki bireyler için el bilek görüntülerinden kemik yaşı tespiti 2 farklı veri seti ile gerçekleştirilmiştir. Literatürde el bilek görüntülerinden kemik yaşı tespitinin 18 yaş altında ki bireyler için yapıldığı, 18 yaş üstü bireylerin kemik yaşı tespitine yönelik yeterli çalışmanın olmadığı tespit edilmiştir. Bu nedenle 18 yaş üstü bireylerin kemik yaşı tespiti için farklı bir veri seti oluşturulmuştur.


18 yaş altı bireylerin kemik yaşı tespiti için 2 farklı veri seti kullanılmıştır. Bu veri setlerinden biri tarafımızca hazırlanmış, diğeri ise 18 yaş altında ki bireylerin el bilek grafiplerinden oluşan halka açık olarak dağıtılan veri setinden oluşmaktadır. 18 yaş üstü bireylerin el bilek grafiplerine ait veri seti tarafımızca oluşturulmuştur. Her iki çalışma için elde edilen görüntüler incelenerek bu görüntüler üzerinde yapılacak görüntü işleme teknikleri belirlenmiştir. Bu aşamada görüntülere ait ayırt edici öz niteliklerin ortaya çıkarılması amaçlanmıştır.

Veri setleri oluşturulduktan sonra bireylerin kemik yaşı tahmini için 18 yaş altı kemik yaşı tahmini ve 18 yaş üstü kemik yaşı tahmini için 2 farklı çalışma yapılmıştır. Her bir çalışma için farklı veri setleri oluşturulmuştur. Bu nedenle bu bölümde 2 farklı veri seti ve bu veri setleri üzerinden uygulanan çalışmalar ayrı ayrı anlatılmıştır.

3.1.1. 18 yaş altı veri seti


18 yaş altı bireylerin kemik yaşının tespiti için iki farklı veri seti kullanılmıştır. Bunlardan ilki tarafımızca oluşturulmuş veri seti (KRV), diğeri ise halka açık olarak dağıtılan RSNA veri setidir.

KRV (Kütahya Radyoloji Veriseti): Bu veri setinde görüntüler Kütahya ilindeki 3 ilçe ve il merkezi olmak üzere 4 farklı hastaneden temin edilmiştir. Kadın ve erkeklerden oluşan yaşları 0-18 aralığında toplam 5305 örnek toplanmıştır. Görüntüler hastane arşivinden (PACS - Picture Archiving and Communication System) 2013-2021 yılları arasında acil servise başvuran hastalarda çekilen sol el bilek grafileri içerisinde seçilmiştir. Görüntü elde edilen Röntgen cihazları CR (kompüterize radyografi) ve DR (dijital radyografi) dir. Farklı merkezlerde ve farklı cihazlardaki çekim nedeniyle görüntülerin bir kısmında parlaklık ve kontrast ayarları birbirinden farklıdır. PACS sisteminden DICOM formatında elde edilen görüntüler uzman bir radyolog tarafından değerlendirilmiş, grafisinde kırık bulunanlar, kronolojik yaşı ile belirgin uyumsuz olanlar elenmiştir. Görüntülerden derin öğrenme metotları ile daha hızlı ve sağlıklı sonuçlar almak için JPEG formatına çevrilmiş ve normalize edilmiştir. Röntgen görüntüleri içerisine gömülü olan hekim veya teknisyen bilgileri kaldırılmıştır. Tüm resimlerde hasta bilgileri anonimize edilmiştir. Tüm resimlerde el bileği resmin solunda, parmaklar sağında olacak şekilde rotasyon işlemi uygulanmıştır. Görüntü ile kronolojik yaş ve cinsiyet bilgileri de kaydedilmiştir. Toplanan görüntülerde 0-7 ay aralığındaki görüntü sayısı çok az olduğundan bu aralıktaki görüntüler veri setine dahil edilmemiştir. KRV veri setindeki yaş dağılımları Şekil 3.1’de gösterilmiştir.



Şekil 3.1. KRV veri setindeki kayıtların yaşlara (aylık) göre dağılımı. (A) Tüm veri seti, (B) Erkeklerle ait dağılım, (C) Kadınlara ait dağılım

RSNA: Kuzey Amerika Radyoloji Derneğinin (RSNA) 2017'de farklı hastanelerden hasta görüntüleri içeren veri setiyle yaptığı yarışmada kullanılan ve halka açık olan veri setidir (Ontell ve ark., 1996). RSNA veri setinde 12611 görüntü bulunmaktadır. RSNA veri setindeki görüntülerin yaşlara ve cinsiyetlerin yaşlara göre dağılımları Şekil 3.2'de verilmiştir.



Şekil 3.2. RSNA veri setindeki kayıtların yaşlara (aylık) göre dağılımı. (A) Tüm veri seti, (B) Erkeklerle ait dağılım, (C) Kadınlara ait dağılım

İki veri setindeki görüntülerin cinsiyetlere göre dağılımları Tablo 3.1’de verilmiştir.


Tablo 3.1. Veri setlerinin cinsiyete göre dağılımları

	KRV	RSNA
Toplam Görüntü	5301	12621
Erkek	2312	6833
Kadın	2989	5778
Ortalama Yaş (ay)	140,33	127,32

Tablo 3.2’de KRV veri setinin cinsiyet ve yaşlara göre dağılımı, Şekil 3.3’te ise bunun görsel dağılımı ise verilmiştir.

Tablo 3.2. KRV veri setindeki görüntülerin cinsiyet ve yaşlara (yıl) göre dağılımı

Yaş	Erkek	Kadın	Toplam
2	22	21	43
3	49	62	111
4	57	68	125
5	89	77	166
6	103	82	185
7	98	98	196
8	115	110	225
9	154	149	303
10	179	184	363
11	206	229	435
12	271	176	447
13	285	176	461
14	266	146	412
15	294	192	486
16	255	195	450
17	286	182	468
18	260	165	425
Toplam	2989	2312	5301




Şekil 3.3. KRV veri setindeki görüntülerin cinsiyet ve yaşlara(yıl) göre dağılımı

Tablo 3.3'te RSNA veri setinin cinsiyet ve yaşlara göre dağılımı ve bunun görsel olarak dağılımı ise Şekil 3.4'te verilmiştir.

Tablo 3.3. RSNA veri setindeki görüntülerin cinsiyet ve yaşlara (yıl) göre dağılımı

Yaş	Kadınlara ait görüntü sayısı	Erkeklerle ait görüntü sayısı	Toplam
1	12	12	24
2	83	61	144
3	78	126	204
4	131	65	196
5	262	249	511
6	272	235	507
7	289	470	759
8	297	608	905
9	366	540	906
10	417	707	1124
11	480	822	1302
12	582	656	1238

13	1377	479	1856
14	1330	396	1726
15	298	230	528
16	262	73	335
17	206	31	237
18	70	18	88
Toplam	6812	5778	12590




Şekil 3.4. RSNA veri setindeki görüntülerin cinsiyet ve yaşlara(yıl) göre dağılımı

3.1.2. 18 yaş üstü veri seti

18 yaş üstündeki bireylerin el bilek grafilerinden kemik yaşı tahminini yapmak için tarafımızca oluşturulan veri seti KYRV (Kütahya Yetişkin Radyoloji Veri seti) kullanılmıştır. KYRV veri setindeki görüntüler Kütahya ilindeki 3 ilçe ve il merkezi olmak üzere 4 farklı hastaneden temin edilmiştir. Yaşları 19-85 arasında olan bireylerden görüntüler toplanmıştır. Bu görüntülerden kadınlardan toplam 4743 adet görüntü, erkeklerden ise toplam 3846 adet görüntü ve toplamda 8589 adet görüntü elde edilmiştir.

Yaklaşık 50000 görüntüden uygun olmayanlar elenerek toplam 8589 görüntü veri setine dahil edilmiştir. Daha sonra JPEG formatına çevrilmiş ve normalize edilmiştir. Röntgen görüntüleri içerisine gömülü olan hekim veya teknisyen bilgileri kaldırılmıştır. Görüntü ile birlikte kronolojik yaş ve cinsiyet bilgileri de kaydedilmiştir. KYRV veri setindeki yaş dağılımları cinsiyetlere göre Şekil 3.5'te gösterilmiştir. Şekil 3.5 ve Şekil 3.6'dan da anlaşılacağı gibi 19-43 yaş aralığında ki görüntülerde erkek bireylere ait görüntü sayısı kadın bireylere ait görüntü sayısından fazladır. Ancak 43-85 yaş aralığında ise kadınlara ait görüntü sayısı erkeklere ait görüntü sayısında fazladır. Tablo 3.4'te 18 yaş üstü görüntülerin cinsiyete göre dağılım tablosu verilmiştir.




Şekil 3.5. KYRV veri setindeki görüntülerin cinsiyetlere göre yaşlarının dağılımı

Tablo 3.4. 18 yaş üstü görüntülerin cinsiyete göre dağılım tablosu

Yaş	Erkek	Kadın	Toplam
19	212	93	305
20	175	99	274
21	176	95	271
22	161	82	243
23	156	60	216
24	139	55	194
25	134	57	191

26	108	69	177
27	112	56	168
28	113	47	160
29	157	61	218
30	116	57	173
31	143	50	193
32	131	97	228
33	117	72	189
34	118	70	188
35	110	80	190
36	106	80	186
37	130	90	220
38	129	109	238
39	106	78	184
40	106	76	182
41	124	69	193
42	113	81	194
43	72	76	148
44	67	81	148
45	69	82	151
46	69	67	136
47	69	85	154
48	63	75	138
49	54	77	131
50	55	64	119
51	59	83	142
52	67	88	155
53	68	97	165
54	66	71	137
55	46	80	126
56	53	68	121
57	58	78	136
58	51	67	118

59	55	60	115
60	41	69	110
61	40	54	94
62	47	57	104
63	35	50	85
64	42	52	94
65	25	53	78
66	39	40	79
67	31	46	77
68	20	37	57
69	20	25	45
70	26	36	62
71	15	23	38
72	19	33	52
73	10	19	29
74	14	20	34
75	14	29	43
76	15	21	36
77	11	15	26
78	11	18	29
79	5	8	13
80	7	17	24
81	6	12	18
83	5	13	18
84	6	7	13
85	6	10	16
Toplam	4743	3846	8589



Şekil 3.6. KYRV veri setinin cinsiyetlere göre yaşlarının dağılımı

3.1.3. Veri setlerine uygulanan ön işlem adımları

Veri artırımı (data augmentation), görüntüler için gerçek zamanlı veri çeşitlendirme yaparak, görüntü sınıflandırma, nesne algılama veya görüntü bölütleme gibi farklı işlemler için belirtilen görüntü kümesinden yeni, farklı ve zengin yeni görüntü kümesi üretme işlemidir. Bu üretici görüntüler üzerinde; kırpma, öteleme, soldurma, doldurma, döndürme, ölçeklendirme, büyütme vb., Ses verileri için; zaman değişimi (time shifting), hızını değiştirme (changing speed), gürültü ekleme (noise addition) işlemleri, Metin verileri için ise; rastgele değiştirme (random swap), eş anlamlısıyla değiştirme (synonym replacement), rastgele silme (random deletion) rastgele ekleme (random insertion) teknikleri kullanılarak benzer bir veri kümesi oluşturulur. Veri artırma, mevcut görüntülerden yapay olarak (sentetik) yeni görüntüler oluşturmaya yönelik bir tekniktir. Bu teknik sayesinde, modeli yeterince görüntü ile besleyerek modelin daha başarılı eğitilmesi amaçlanmaktadır.

Veri artırma yöntemleri; klasik teknikler (Örn., ölçekleme, kaydırma, yakınlaştırma, döndürme vb.) ve gelişmiş teknikler (doku ve stil transferi yapma) olmak üzere iki gruba ayrılır. Gelişmiş teknikler işlem ve zaman maliyetleri açısından maliyetleri yüksek yöntemlerdir. Klasik yöntemler kolay uygulanabilir, işlem ve zaman maliyetleri düşük yöntemlerdir. Bu tez çalışmasında klasik veri artırma yöntemleri kullanılmıştır.


Derin öğrenme modellerinde, büyük veri kümeleri ile çalışmak modelin performansı açısından önemlidir. Az miktarda veya tekdüze veriler (görüntüler, metin vs) ile derin öğrenme işlemlerinin yapılması durumunda, derin öğrenme modelinin ezberleme (overfitting) problemi ortaya çıkabilir. Bu durumu ortadan kaldırmak ve modelin daha doğru bir şekilde öğrenip, modelin performansını artırmak için veri artırma yöntemleri uygulanır.

Bu tez çalışması kapsamında kullanılan, görüntü verileri üzerinde uygulanan klasik veri artırma yöntemleri içerisinde yer alan teknikler anlatılmıştır. Bu işlemler için `tf.keras.preprocessing.image.ImageDataGenerator` sınıfı kullanılmıştır.

Döndürme (rotation_range): Görüntüyü istenilen açılarda döndürme işlemidir. Modelin nesnenin yönüne göre değişmez olmasını sağlar. `ImageDataGenerator` sınıfı, `rotation_range` değişkeni ile döndürme işlemini gerçekleştirir. Bu değişkene atanan değer ile görüntülerin 0 ile 360 arasında herhangi bir derecede rastgele döndürmemize olanak sağlar. Görüntü döndürüldüğünde, bazı pikseller görüntünün dışında kalacak ve doldurulması gereken boş bir alan kalacaktır. Bunu sabit bir değer (constant) veya en yakın piksel değerleri (nearest) gibi farklı şekillerde doldurabiliriz. Doldurma işlemi için `ImageDataGenerator` sınıfında bulunan doldurma modu (`fill_mode`) bağımsız değişkeni kullanılır. Bu değişkenin varsayılan değeri "nearest" dır ve boş alanları en yakın piksel değerleriyle değiştirir.

Şekil 3.7’de görüldüğü gibi 30 derecelik bir açı ile döndürülen bir görüntüye ait 3 farklı sentetik görüntü verilmiştir. Solda ki ilk görüntü orijinal görüntüye ait olup diğer 3 görüntü ise sentetik görüntüleri göstermektedir.

18 yaş altı çalışma da `rotation_range` değeri 5, 18 yaş üstü çalışma da 10 olarak alınmıştır.




Şekil 3.7. Döndürme


Rastgele Kaydırma (Random Shifts): Nesne her zaman görüntünün merkezinde olmayabilir. Bu problemin üstesinden gelmek için görüntünün pikselleri yatay veya dikey olarak kaydırılır. Bu işlem için tüm piksellere belirli bir sabit değer eklenir. ImageDataGenerator sınıfı, görüntünün dikey kayması için height_shift_range ve görüntünün yatay kayması için width_shift_range değişkenlerini kullanılır. Değişkenlere atanan değer bir kayan sayıysa, bu kaydırılacak görüntünün genişlik veya yükseklik yüzdesini gösterir. Şayet bir tamsayı değeri ise, genişlik veya yükseklik bu çok sayıda piksel değeriyle kaydırılır.

Şekil 3.8’de görüldüğü gibi 0.2 değerinde yatay olarak kaydırılan bir görüntüye ait 3 farklı sentetik görüntü verilmiştir. Solda ki ilk görüntü orijinal görüntüye ait olup diğer 3 görüntü ise sentetik görüntüleri göstermektedir. Şekil 3.9’da görüldüğü gibi 0.2 değerinde dikey olarak kaydırılan bir görüntüye ait 3 farklı sentetik görüntü verilmiştir. Solda ki ilk görüntü orijinal görüntüye ait olup diğer 3 görüntü ise sentetik görüntüleri göstermektedir.

18 yaş altı ve üstü her iki çalışma da width_shift_range ve height_shift_range değerleri 0,1 olarak alınmıştır.



Şekil 3.8. Yatay kaydırma




Şekil 3.9. Dikey kaydırma

Rastgele Parlaklık (Random Brightness): Görüntünün parlaklığını rastgele değiştirir. Aynı zamanda çok kullanışlı bir büyütme tekniğidir çünkü çoğu zaman nesnemiz mükemmel ışık koşullarında olmayacaktır. Bu nedenle, modelimizi farklı aydınlatma koşulları altında görüntüler üzerinde eğitmek zorunlu hale gelecektir. Parlaklık, ImageDataGenerator sınıfında Random Brightness bağımsız değişkeni aracılığıyla kontrol edilebilir. İki kayan değerden oluşan bir listeyi kabul eder ve bu aralıktan bir parlaklık kayması değeri seçer. 1.0'dan küçük değerler görüntüyü koyulaştırırken 1.0'ın üzerindeki değerler görüntüyü aydınlatır.

Şekil 3.10'da görüldüğü gibi bir görüntüye ait parlaklık değeri 0.7-1.3 aralığında değiştirilerek 3 farklı sentetik görüntü elde edilmiştir. Şekilden görüleceği üzere her sentetik görüntüye ait parlaklık oranı değişmektedir. Solda ki ilk görüntü orijinal görüntüye ait olup diğer 3 görüntü ise sentetik görüntüleri göstermektedir.

18 yaş üstü ve 18 yaş altı her iki çalışma da brightness_range değeri [1.0, 1.3] olarak alınmıştır.




Şekil 3.10. Rastgele parlaklık

Rastgele Yakınlaştırma (Random Zoom): Rastgele yakınlaştırma görüntüyü rastgele yakınlaştırır veya görüntüyü uzaklaştırır. Yakınlaştırma için ImageDataGenerator sınıfında yer alan zoom_range bağımsız değişkenine verilen bir kayan nokta değeri ile bu işlem gerçekleştirilir. Alt ve üst limiti belirten iki değer içeren bir liste belirlenir. Aksi takdirde, bir kayan değer belirtirseniz, yakınlaştırma $[1-\text{zoom_range}, 1+\text{zoom_range}]$ aralığında yapılacaktır. 1'den küçük herhangi bir değer görüntüyü yakınlaştırır. 1'den büyük herhangi bir değer ise görüntüyü uzaklaştıracaktır.

Şekil 3.11'da görüldüğü gibi bir görüntüye ait yakınlaştırma değeri 0.15 aralığında girilerek 3 farklı sentetik görüntü elde edilmiştir. Şekilden görüleceği üzere her sentetik görüntüye ait yakınlaştırma oranı değişmektedir. Solda ki ilk görüntü orijinal görüntüye ait olup diğer 3 görüntü ise sentetik görüntüleri göstermektedir.

18 yaş altı ve üstü her iki çalışma da range_zoom değeri =0.1 olarak alınmıştır.



Şekil 3.11. Rastgele yakınlaştırma

Yeniden ölçeklendirme (Rescale): Yeniden ölçeklendirme parametresidir. Geçerli değeri “None”dır. Geçerli değeri 0 ya da farklı bir değer ise yeniden ölçeklendirilmez. Görüntümüzün piksel değerlerini ayarlar. Şayet rescale=1./255. olur ise görüntüye ait piksel değerlerini 0–1 aralığında olacak şekilde ayarlanır.


Veri ön işleme fonksiyonu (preprocessing_function): Yeniden ölçeklendirme fonksiyonu ile aynı işlemi yapar. Giriş verileri üzerinde yapılan bir işlemdir. Görüntünün, modelin istediği ve daha başarılı çalıştığı biçime uygun hale getirmek için kullanılır. Bazı modeller 0 ile 1 arasında değişen değerlere sahip görüntüler kullanır. Örneğin rescale=1./255. yapıldığı zaman. Bazı modeller ise -1 ile +1 arasında değişen değerlere sahip görüntüler kullanır. Transfer derin öğrenme modellerinin birçoğu verileri 1./127 yaparak -1 ile +1 aralığına indirger. Bu tez çalışmasında rescale yerine preprocessing_function kullanılmıştır.

3.2. Metot

BBC ile söyleşisinde MIT bilgisayar bilimleri laboratuvar yöneticilerinden Edward Fredkin “Tarihte üç büyük olay vardır. Bunlardan ilki kâinatın oluşumudur. İkincisi yaşamın başlangıcının olması, üçüncüsü de yapay zekanın ortaya çıkışıdır.” ifadelerini kullanmıştır (Pirim, 2006). Yapay zeka, bilgisayar veya bilgisayar destekli bir makinenin, insana özgü özelliklerini kullanarak problemi çözme, anlama ve anlam çıkartma, genelleme veya geçmişteki deneyimlerden öğrenme gibi yüksek mantık süreçlerine ilişkin görevleri yerine getirmesi olarak tanımlanmaktadır (Nabiyev, 2012). Yapay zekanın isim babası olan John McCarthy e göre yapay zekâ: “Zeki bilgisayar programları yapma bilimi ve mühendisliğidir” (Pirim, 2006). Özet olarak yapay zekâ; problemlerin makinalar yoluyla çözülmesini sağlamak için makinaların insan zekasını taklit ederek programlanmasıdır. Yapay zekâ ile makinalara beceri kazandırmak hedeflenmektedir.

Yapay zekanın bir alt kolu olan makine öğrenimi Arthur Samuel'e göre: "makinelere özellikle programlanmadığı sonuçları öğrenebilme kabiliyetidir". Makine öğrenmesinde öznitelik kümelerinin tespiti ve oluşturulması büyük öneme sahiptir. Makineyi programlayan kişinin bu öznitelikleri manuel olarak tespit etmesi ve oluşturması gerekmektedir. Makine öğrenmesinde veriden bilgi çıkarımının yapılması için bu öznitelikler kullanılmaktadır. Bu özniteliklerin doğru ve ayırt edici bir şekilde çıkarılması hayati bir öneme sahiptir. Bu nedenle bu veriler arasındaki farklılıkları ortaya koyan özelliklerin tespit edilmesi ve bu özelliklerin sisteme tanıtılması gerekmektedir.

Öznitelik çıkarma yöntemi maliyetli ve etiketlenilmesi en büyük problemlerden biri olarak görülmektedir. Bu problemin üstesinden gelmek için derin öğrenme modelleri geliştirilmiştir. Derin öğrenme, bir makine öğrenme tekniğidir. Bu yöntemde öznitelik çıkarmak için bir uzmana ihtiyaç yoktur. Ham veri içerisindeki özellikler veriden çıkarılır. Derin öğrenme modellerinde verilere ait öznitelikler Evrimsel sinir ağları (ESA) olarak bilinen yöntem ile çıkarılır. Bu yöntemle ham veriler içerisinde ilgili özelliklerin çıkarılması sağlanır. Şekil 3.12'de el bilek görüntüsünden yaş tahmini yapan makine öğrenmesi ve derin öğrenme arasındaki farklılıklar gösterilmiştir.



Şekil 3.12. Makine öğrenmesi ve derin öğrenme arasındaki farklılıklar

Şekil 3.13'te yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisi görsel olarak ifade edilmiştir.




Şekil 3.13. Yapay zekâ, makine öğrenmesi ve derin öğrenme

3.2.1. Yapay sinir ağları

Beynimiz öğrenme işlemini girdi olarak alınan örneklere ve geri bildirimlere dayanak sağlar. İnsan doğduktan sonra çevresinde gördüğü birçok nesneyi görsel olarak birbirinden ayırt edebilse de yaşadığı coğrafya itibari ile bu nesnelerin isimlerini bilmez. Bu nesnelerin isimlerini ve birbirine benzer nesnelerin ayırt edilmesi sürecini ebeveynlerinin veya çevresinde ki diğer insanların öğretmesi (öğretmen) ile birbirinden ayırt eder ve bu nesneleri tanır. Burada gerçekleşen olay aslında bir geri bildirim olayıdır. Öğretmenlerinden alınan geri bildirimler sayesinde öğrenme süreci gerçekleşir. Bu öğrenme metodunun bilgisayar sistemlerine aktarılması ve bilgisayar sistemlerinin bu yöntemle nesneleri tanınması, birbirinden ayırt etmesi vb. için birçok araştırma yapılmış ve beynin bu öğrenme süreçleri taklit edilmeye çalışılmıştır. Beynin öğrenme yönteminin bilgisayara öğretilmesi işlemine Yapay sinir ağı (YSA) denir.

Beynin işlevlerinin çalışması için, hücreler arasındaki iletişimin sürekli olması ile olur. Sinir (nöron) hücreleri ve glial (glue) hücreler olmak üzere insan beyinde, yaklaşık 1 trilyon hücre vardır. Nöronlar sinir sistemi ve beyin fonksiyonlarının ana gövdesini oluşturur. Nöronlar, üç kısımdan (hücre gövdesi, dendrit, akson) oluşur (Şekil 3.14). Dendrit'ler hücreye gelen girişleri toplar ardından bir çıkış darbesi oluşturup oluşturmaya karar verir. Eğer çıkış darbesi olacağına karar verilir ise çıkış darbesi aksonlar tarafından diğer bütün nöronlarla olan bağlantılara taşınır. Nöronlar arasındaki bağlantılar hücre gövdesinde "sinaps" adı verilen dendritlerde ki geçişlerde olur. Sinyaller

hücrenin etkinliğini (dürtüsünü) belirler. Bir nöron sahip olduğu dürtü miktarınca diğer hücrelerin dürtülerini pozitif veya negatif yönde etkiler. İnsan beyni benzer şekilde işlev gören milyonlarca sinir hücresinin buluşmasıyla oluşur (Ersoy ve Karal, 2012).



Şekil 3.14. Basit bir sinir hücresi (Nöron) (Anonim, 2020)

Yapay sinir ağları, insan beyninde ki sinir ağlarından esinlenerek geliştirilmiş, beynin basit bir nöron modelinin simülasyonudur. Yapay sinir ağlarında, insan sinir ağında bulunan nöronların işleyiş tarzından esinlenerek özneteliği çıkarılmış verilerden modelin öğrenmesi amaçlanmıştır.

Biyolojik sinir sistemini taklit ederek nöronlar arası bağlantılara şekil ve işlev olarak benzeyen yapay sinir ağı, birbiri ile iletişimde olan yapay sinir hücrelerinin oluşturduğu bir yapı ile insan gibi karar verebilmeyi ve değerlendirme yeteneği olan akıllı yapılar geliştirmeyi hedefler.

YSA teorisi 1943 yılında ilk kez nöro-fizyolog Warren McCulloch ve matematikçi Walter Pitts tarafından matematiksel olarak ifade edilmiştir. Psikolog Donald Hebb 1949'da YSA için ilk öğrenme kuralını- Hebb'in kuralı- ortaya atmıştır. Bu kuralın çalışma prensibi, iki nöronun aynı anda aktif ise, nöronlar arasındaki bağlantının kuvvetinin artırılması gerektiğidir. 1960'lı yıllarda güçlü bilgisayarların ortaya çıkması ile ilişkisel ağ mimariler üretilmeye başlanmıştır. YSA, basit birçok sinir hücresini barındıran karmaşık bir sinir ağıdır (Lippmann, 1987).

Walter ve Pitts Denklemi 3.1 numaralı eşitlikteki gibidir.

$$y_i = \psi(g(x)) = \psi(\sum_{j=0}^n w_{ij}x_j - Q_i); x_i = (x_0, x_1, \dots, x_n) \quad (3.1)$$

Denklem 3.2’de, y_i çıkış değerini, $\psi(.)$ aktivasyon fonksiyonunu, $g(.)$ toplama işlemini, w_{ij} ağırlık katsayılarını ve Q_i ise i. sinir hücresinin eşik değerini belirtmektedir.


$$\psi(.) = \begin{cases} 1 & g(.) \geq 0 \\ 0 & g(.) < 0 \end{cases} \quad (3.2)$$

Denklem 3.3’de $g(.)$ toplama fonksiyonu olduğundan x_j gösterimi girişlerin doğrusal bir bileşimini temsil etmektedir.

$$g(.) = \sum_{j=0}^n w_{ij}x_j - Q_i \quad (3.3)$$


Yapay sinir ağları; sinir hücrelerinin çalışma mekanizmasına dayanan ve birbirine bağlı seri düğümlerden oluşur. YSA öğrenebilir, nesneleri kümeleyebilir, örüntüleri tanıyabilir ve özellikleri ayırt edebilir (Brewka, 1996).

Örneklerin eğitilmesi ile veriler arasındaki gizli ilişkinin öğrenilmesi amaçlanır. Böylelikle istenilen görev yerine getirilmiş olur. Benzer durumlarda veri modellerine yanıt verebilmek için ağı girilen değer kendi ağırlıkları ile çarpılması gerekir. Arından bu değerlerin toplanır. Toplanan bu değerler aktivasyon fonksiyonundan geçerek gerçekleşir (ÖZTEMEL, 2008). Şekil 3.15’te bir yapay sinir ağı gösterilmiştir.



Şekil 3.15. Yapay sinir ağı (Uzm. Alpay, 2021)

Şekil 3.16’da bir canlı sinir ağının matematiksel modeli gösterilmiştir. Bu model bir YSA ağında bulunan katmanın matematiksel karşılığıdır.




Şekil 3.16. Bir sinir hücresinin YSA katman karşılığı (Gollapudi, 2019)

YSA birden fazla nörondan oluşan katmanlardan oluşur. Her nöron katmana verilen giriş verilerini alır. Her nöron kendine ait ağırlık ve bias değerini bulundurur. Bu nedenle çıkış verileri genellikle diğer nöronlardan farklı olacaktır.

Şekil 3.17’den görüleceği üzere çok katmanlı bir yapay sinir ağı 3 katmandan oluşmaktadır. Bu katmanlar giriş katmanı, gizli katman ve çıkış katmanıdır.

Şekil 3.16’den görüldüğü üzere her bir nöronun bir ağırlığı vardır (w_0). Bu ağırlık giriş değerine göre eğitilebilir bir değerdir. Tüm giriş (x_0) ve ağırlık değerleri çarpımı nöronda toplanır ($w_0 x_0$) ve bu toplama sonucuna bir başka eğitilebilir değer olan bias değeri eklenir. Bias değeri genel olarak fonksiyonu dengelemek için kullanılır. Elde edilen değer aktivasyon fonksiyonuna gönderilir ve ardından çıkışa aktarılır. Bu çıkış YSA ağının son çıkışı veya bir başka hücrenin girişi olabilir.

Derin öğrenme yönteminde giriş verisi olarak etiketlenmiş olan veriler giriş verisi olarak kullanılır. Bu giriş verileri yapay sinir ağına verilerek model eğitilir. Şekil 3.17’de çok katmanlı bir yapay sinir ağı gösterilmiştir.



Şekil 3.17. Çok katmanlı yapay sinir ağı

Giriş ve çıkış katmanındaki nöron sayısı, bağımlı ve bağımsız değişkenlerin sayısı ile belirlenir. Gizli katmandaki katman sayısı kullanıcı tarafından belirlenmelidir. En optimal gizli katman sayısı en iyi sonuç alınabilir. Giriş katmanı verilerin YSA ağına alınmasını sağlar. Çıkış katmanı ise YSA ağı içerisinde işlenen verinin sonucunu verir. Bir YSA ağına birden çok gizli katman olabilir ve ya hiçbir gizli katman olmayabilir (Fausett, 1990).

3.2.2. Derin öğrenme

Derin öğrenme, denetimli veya denetimsiz özellik çıkarma, sınıflandırma, dönüştürme, örüntü analizi, birçok doğrusal olmayan bilgi işlemenin birçok gizli katmanından yararlanan bir makine öğrenim teknikleri sınıfı olarak tanımlanabilmektedir. Derin öğrenme, birden fazla soyutlama seviyesine sahip verilerin özelliklerinin öğrenilmesini sağlayan, çoklu işleme katmanlarından oluşan hesaplama modelleri bütünüdür (Lecun ve ark., 2015).

Derin öğrenmede, verilerin öğrenilmesine dayanan (piksel başına yoğunluk değerlerinin bir vektörü, kenar kümeleri gibi) bir yapı mevcuttur. Bu özellik seviyesinde üst düzey özellikler, alt düzey özelliklerden türetilir. Bu işlem, soyutlamanın farklı seviyelerinde yapılarak öğrenme işlemi gerçekleştirilir. Bu özelliklerin bazıları veriyi diğer verilerden ayırt etmeyi sağlar. Derin öğrenme yöntemleri, veriye ait özellikleri el

ile çıkarmak yerine veriyi diğer verilerden ayırt etmek için etkin algoritmalar kullanmaktadır (Bengio, 2009; Song ve Lee, 2013). Bu yöntem ile büyük ölçekli verilerin yapısını yakalamak kolaylaşabilir.

2007'de Geoffrey Hinton yayınladığı makalede (Hinton, 2007), derin öğrenmedeki en önemli atılımlardan birini yapmıştır. Kısıtlı Boltzmann Makineleri ile çok katmanlı ileri beslemeli bir sinir ağının her seferinde bir katmanı denetimsiz bir şekilde nasıl etkili bir şekilde eğitebildiğini, ardından denetimli bir geri yayılım yöntemi ile ince ayar yapabileceklerini göstermiştir. Derin öğrenme yöntemleri, Lecun ve arkadaşları tarafından 1998 yılında el ile yazılan rakamları tanımak için önerilen ilk evrimsel sinir ağı modeli (ESA) olan LENET (Szegedy ve ark., 2015) ile popüler olmuştur.

Derin öğrenme makine öğrenmesinin alt alanıdır. Makine öğrenmesi yaklaşımlarının başarısı ham verilerden doğru özniteliklerin çıkarılmasına bağlıdır. Derin öğrenmeyi geleneksel makine öğrenmesi modellerinden ayırt eden özelliği; verilere ait öznitelikleri çıkarmak için öznitelik çıkarma yöntemlerine ihtiyaç duymaz. Bu işlem için önışlemeden geçirilmiş ham veriden öznitelik çıkarmak işlemini otomatik olarak gerçekleştirir. Modele giriş olarak verilen veri setinde etiketlenmiş olan verileri kullanır. Verilere ait özellikler denetimli/denetimsiz özellik öğrenmesi ve hiyerarşik özellik çıkarımı ile çıkartılır. Özellikle doğal dil işleme, görüntü işleme, görüntü sınıflandırma, biyomedikal sinyal sınıflandırma, video işleme, görüntü oluşturma, nesne algılama ve bölütleme, ses analizleri gibi disiplinlerde yoğun olarak kullanılmaktadır.

"Derin" terimi ağıdaki katman sayısını belirtir, yani katman sayısı ne kadar yüksekse ağ o kadar derindir (Batur Dinler ve Aydın, 2020).

Derin öğrenmede özniteliklerin otomatik olarak çıkarılması için evrimsel sinir ağları kullanılır.

3.2.3. Evrimsel sinir ağları

Geleneksel yapay sinir ağlarında (YSA) görüntü veya nesnelere ait öznitelik çıkarım işlemi manuel olarak yapılmaktadır. Öznitelik çıkarımı için veri setine hâkim olmak gerekmektedir. Veri setindeki görüntüleri birbirinden ayırt eden özellikleri bilmek ve buna göre yöntem geliştirmek gerekmektedir. Evrimsel sinir ağları (ESA), manuel olarak yapılan özellik çıkarma yöntemini otomatik olarak gerçekleştirmektedir.

ESA manuel olarak yapılan özellik çıkarma yöntemini otomatize eden bir yapay sinir ağıdır. CNN, girdi olarak ham görüntüler ile ilgilenir. Bu girdiler daha sonra evrişim katmanı, aktivasyon katmanı, havuzlama katmanı, toplu normalizasyon içeren özellik çıkarma katmanı ve tam bağlı çıktı katmanı olan ve farklı katman türlerini içeren çok katmanlı ileri beslemeli bir sinir ağından geçer. CNN, görüntülerdeki kenarlar dahil her türlü bilgiyi, özellikleri tespit edecek şekilde tasarlanmıştır.

Evrişimsel fonksiyonu

$$s(t) = (f * g)(t) \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} f(\tau)g(t - \tau)d\tau \quad (3.4)$$


g:kernel, f: input, t:times, s:result

giriş olarak 2 boyutlu veriler kullanılacak ise

$$s(i,j)=(I*K)(i,j) = \sum_m \sum_n I(i,j)K(i - m,j - n) \quad (3.5)$$

evrişim işlemi sonucunda elde edilecek yeni matrisin konumlarını i ve j terimleri ifade eder.


CNN mimarileri üç ana katmandan oluşur. Evrişimli katman, havuzlama katmanı ve tam bağlı katman (FC). Bu katmanların üst üste gelmesi ile tam bir ESA mimarisi elde edilir. Şekil 3.18’de örnek bir ESA ağ yapısı gösterilmiştir.



Şekil 3.18. Evrişimsel sinir ağı yapısı

Evrişim katmanı: Evrişim işlemi; girişten alınan verinin belirlenen bir kernel ile evrişim işlemi uygulanmasını ve ardından giriş verisinden daha küçük boyutlarda yeni bir giriş verisi elde edilmesini sağlar. Evrişim için kullanılan kernel bir dizi sayıdır. Bu sayılara literatür de ağırlıklar denilmektedir. Evrişim katmanı, giriş verilerini küçük boyutlu konvolüsyon filtreleri yardımıyla dönüştüren birçok katman içermektedir. Matris olarak ifade edilen bir önceki katmandan gelen giriş verisi üzerinde filtre matrisi gezdirilerek evrişim işlemi uygulanır ve yeni bir özellik haritası elde edilir.

Kaydırma sırasında; görüntü piksel değerleri ile filtre değerleri çarpılır. Çarpılan bu değerler toplanır. Bu hesaplama işlemini tüm matrise uyguladığımızda yeni bir görüntü elde etmiş oluruz. Elde edilen görüntüye evrişim özneliği adı verilir (Goodfellow lan, Bengio Yoshua, 2016)



Şekil 3.19. Filtreleme kullanılarak yapılan evrişim işlemi

Evrişim işleminin ardından giriş boyutunda küçülme yaşanır. Şekil 3.19’da verilen 4x3 boyutlu resim filtre uygulandıktan sonra 3x2 boyutuna indirgenmiştir. Evrişim işlemi yapılırken boyutta yaşanan küçülme neticesinde istenmeyen durumlar oluşabilir. Bu durumun önüne geçmek için bazı katmanlarda evrişim sonrasında oluşan giriş verisinin çerçevesine sıfır doldurma işlemi uygulanabilir.

Evrişim katmanında kullanılan parametreler derinlik, adım ve sıfır parametreleridir. Bu parametrelerin değerlerinin verilmesinde bir standart bulunmamaktadır.

Derinlik; her eğitim iterasyonunda giriş verilerine uygulanan filtre sayısı olarak tanımlanabilir. Her bir filtre ayrı ayrı giriş verisine uygulanır. Bununla giriş verileri içerisinde bulunan özelliklerin keşfedilmesi amaçlanır.

Adım; Evrişim esnasında giriş verisi üzerinde filtrenin ne kadarlık kaydırılacağını belirten parametredir. Evrişim işlemi için filtreyi görüntü üzerinde belirlenen adım sayısı kadar kaydırmaya yarar. Küçük seçilen adımlarda kayma esnasında örtüşme fazla olur ve böylece boyutun büyümesine neden olur.


Örneğin adım sayısı 1 seçildiğinde, filtre evrişim işlemi sırasında 1 piksel kayacaktır. Eğer adım sayısı 2 olursa filtre 2 piksel kayacaktır. Bu işlem çıkış verisinin giriş verisinden daha düşük olmasını sağlar.

Şekil 3.20’de birer adımlık kaydırmalar ile $4A = \pi r^2 \times 3$ boyutlu resim üzerinde 2×2 boyutlu kernelin uygulanması ve 3×2 boyutlu matrisin oluşumu gösterilmiştir.

Filtre, en soldan başlayarak en sağa kadar belirlenen adım sayısı kadar ilerlediğinde çıktının genişliği, ilerleme sayısı +1 olmaktadır. Matematiksel olarak; girdi boyutu (g), filtre boyutu (f), adım sayısı 1 ve dolgu değeri 0 ise sonuç (s) değeri denklem 3.6’da belirtilen formül ile hesaplanır.

$$s = (g - f) + 1 \quad (3.6)$$

Girdi genişliği (g) 4, filtre boyutu (f) 3 için, adım sayısı (ss) 1 ve dolgu 0 olduğunda sonuç $oo = (g - f) + 1 = (4 - 3) + 1 = 2$ olur (Dumoulin ve Visin, 2016).




Şekil 3.20. Dolgu kullanılmayan evrişim örneği (Dumoulin ve Visin, 2016)

Dolgu, giriş verileri matrisinin sıfırlar ile doldurulması işlemidir. Evrişim işlemi sonrasında çıkış verisinin boyutu kontrol edilmek isteniyor ise; dolgu kullanılır. Dolgunun çıktı boyutuna etkisini görmek için, denklem (3.7) verilen formül kullanılır (Dumoulin ve Visin, 2016):

$$A = (g - f) + 2d + 1 \quad (3.7)$$

Girdi boyutu (g), filtre boyutu (f), adım sayısı 1 ve herhangi bir dolgu (d) değeridir.

Şekil 3.21’de girdi genişliği (g) 5 ve filtre genişliği (f) 4 için, adım sayısı (a) 1 ve dolgu (d) 2 olduğunda çıktı $A = (g - f) + 2d + 1 = (5 - 4) + 2 \times 2 + 1 = 6$ olur (Dumoulin ve Visin, 2016).



Şekil 3.21. İsteğe bağlı dolgu evrişim örneği (Dumoulin ve Visin, 2016)


Evrişim sonucunda giriş ve çıkış boyutunun aynı olması istendiğinde dolgu değeri 1 olmalıdır. Bu duruma Yarım Dolgu (Half-Padding) denir ve matematiksel olarak denklem 3.8’de gösterildiği gibi ifade edilir. Herhangi bir g ve f değeri için (Dumoulin ve Visin, 2016);

$$f = \{f \text{ değeri tek ise, } 2n + 1, n \in \mathbb{N}\} \quad (3.8)$$

Adım sayısı (a) = 1 ve dolgu $d = \lceil f/2 \rceil = n$ olmak üzere sonuç Denklem (3.9) ile hesaplanır.

$$\begin{aligned} A &= g + 2 \left\lceil \frac{f}{2} \right\rceil - (f - 1) \\ A &= g + 2n - 2n \\ A &= g \end{aligned} \quad (3.9)$$

Şekil 3.22’de giriş genişliği (g) 5 ve filtre genişliği (f) 3 için, adım sayısı (a) 1 ve dolgu (d) 1 olduğunda sonuç $A = g = 5$ olur (Dumoulin ve Visin, 2016).



Şekil 3.22. Yarım dolgu evrişim örneği (Dumoulin ve Visin, 2016)


Evrişim genel olarak çıkış boyutunu giriş boyutuna göre küçültse de bazen bunun tersine de ihtiyaç duyulabilir. Çıkış boyutunu artırmak için uygun dolgu değeri tercih edilmelidir. Herhangi g ve f değeri için adım sayısı 1 ve dolgu $d = f - 1$ olmak üzere sonuç Denklem (3.10) ile hesaplanır (Dumoulin ve Visin, 2016):

$$A = g + 2(f - 1) - (f - 1)$$

$$A = g + (f - 1) \quad (3.10)$$

Şekil 2.25'te girdi genişliği (g) 5 ve filtre genişliği (f) 3 için, adım sayısı (a) 1 ve dolgu (d) 2 olduğunda sonuç $A = g + (f - 1) = 5 + (3 - 1) = 7$ olur (Dumoulin ve Visin, 2016).

Şekil 3.23'te tam dolgulu evrişim örneği şekli verilmiştir.



Şekil 3.23. Tam dolgulu evrişim örneği (Dumoulin ve Visin, 2016)

Yukarıdaki açıklamalar adım sayısı 1 olan evrişimler için geçerlidir. Adım sayısı birden farklı olduğunda Denklem (3.11)'de ki genelleştirilmiş ifade kullanılmalıdır. Herhangi girdi boyutu (g), filtre boyutu (f), dolgu değeri (d) ve adım sayısı (a) için sonuç Denklem (3.11) ile hesaplanır (Dumoulin ve Visin, 2016):

$$A = \left\lceil \frac{g+2d-f}{a} \right\rceil + 1 \quad (3.11)$$

Dolgu parametresinde kullanılan 2 parametre vardır. Bunlardan ilki same padding olarak adlandırılır. Padding parametresine “same” verildiğinde girdi veya özellik haritasının etrafında bir miktar dolgu olduğu anlamına gelir. Bu da çıktı özellik haritasının boyutunu girdininkiyile aynı yapar.


Bunlardan ikincisi valid padding olarak adlandırılır. Padding parametresine “valid” verildiğinde girdi veya özellik haritasının etrafında dolgu olmadığı anlamına gelir.

Havuzlama katmanı: ESA ağlarında boyut azaltmak için havuzlama ya da diğer bir adı ile ortaklama (pooling) işlemi kullanılır. Havuzlama katmanı evrişim katmanından sonra veriye uygulanan aktivasyon fonksiyonundan üretilen sonuçtan hemen sonra uygulanır. Modelin ezberleme (overfitting) probleminden kaçınması sağlanır. Böylelikle sonraki katman için hesap yükünü azaltmak amaçlanır (Dumoulin ve Visin, 2016).

Havuzlama işlemlerinde ortalama ve maksimum değer alma fonksiyonları adında 2 tip fonksiyon kullanılır. Bu fonksiyonlar kullanılarak çıktının boyutu düşürülür. Kayan pencere yöntemiyle girdi verilerine belirlenen havuzlama işlemi uygulanır. Kayan pencere her seferinde girdi alanından bir değer oluşturur ve bunu çıktı katmanına ekler (Dumoulin ve Visin, 2016).


Bir ESA ağında giriş verileri havuzlama katmanları sayesinde, tercih edilen yöntemle göre tek bir sabit değere indirgenmiş olduğundan; havuzlama katmanı hesaplamaları, ESA katmanına göre daha az maliyetlidir. Şekil 3.24’de listelenen havuzlama türlerinden en yaygın olarak kullanılan türü, girdinin parçalara ayrılıp her bir parçadaki en yüksek değer alınmış maksimum havuzlamadır. 3x3'lük maksimum havuzlama işleminin 5x5'lik girdi üzerinde 1x1'lik adım sayısı ile hesaplanması Şekil 3.24’de gösterilmiştir (Dumoulin ve Visin, 2016).

$$\text{Maksimum}(3, 3, 3, 2, 1, 2, 2, 1, 1) = 3$$



Şekil 3.24. Maksimum havuzlama örneği (Kurt, 2018)

Ortalama havuzlamada, girdi parçalarına ayrılır ve her bir parçadaki değerlerin ortalaması alınır. 3x3'lük ortalama havuzlama işleminin 5x5'lik girdi üzerinde 1x1'lik adım sayısı ile hesaplanması Şekil 3.25'de gösterilmiştir (Dumoulin ve Visin, 2016).



Şekil 3.25. Ortalama havuzlama örneği (Kurt, 2018)

Havuzlama katmanının çıktı boyutunun (ς); girdi boyutu (g), işlemin gerçekleştirileceği pencere (parça) boyutu (p) ve adım sayısı (a) ile ilişkisi Denklem (3.12)'da gösterilmektedir (Dumoulin ve Visin, 2016).

$$\varsigma = \left\lceil \frac{g-p}{a} \right\rceil + 1 \quad (3.12)$$

Özet olarak alt örnekleme katmanı olarak da bilinen havuzlama katmanının ana işlevi, ESA çıkışı değiştirme. Bu katmanda genellikle filtre 2x2 boyutunda ve 2 adımlik kaydırmalar kullanılır. Bu filtre ve kaydırma işlemi giriş verisi üzerinde maksimum veya ortalama fonksiyonu kullanılarak gezdirilir. Bu durum parametrelerin birçoğunun yok olmasına ve aşırı öğrenmenin önlenmesine yardımcı olur.

3.2.4. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, YSA veya ESA modellerinde girdi verileri üzerinde belirlenen fonksiyonun kullanılması sonucu bir çıktı elde edilmesini sağlar. Aktivasyon fonksiyonları genellikle doğrusal olmayan verileri tanıtmak için doğrusal olmayan fonksiyonlardan oluşmaktadır. Bu fonksiyonlar sayesinde modelimizin daha başarılı bir şekilde öğrenmesi sağlanarak daha başarılı sonuçların elde edilmesi sağlanır.

Aktivasyon fonksiyonlarının bir diğer işlevi çıktıları belirli değerler arasında sıkıştırır. Aşağıda YSA modellerinden derin ve transfer öğrenme yöntemlerinde özellikle kullanılan aktivasyon fonksiyonları verilmiştir. Aşağıda verilen fonksiyonlardan görüleceği üzere seçilen fonksiyona göre değerleri $[-1,1]$, $[0,1]$ gibi aralıklarda sıkıştırılırlar. Buradan elde ettiğimiz değerlerden 0 veya 0' a yakın değer verenler tahmin değerine çok az etki ederken, 1 veya -1' e yakın değerlerin tahmine katkısı çok daha fazladır. Aktivasyon fonksiyonu sonucu ele edilen değerler nihai çıkış veya bir başka katmanın girişi olabilir.


Sigmoid fonksiyonu: Sigmoid fonksiyonu en fazla kullanılan aktivasyon fonksiyonlarından biridir. Fonksiyona gönderilen değerleri 0 ile 1 arasına sıkıştırır. Gelen değer sıfırdan küçük ise sonucu 0'a, 0' dan büyük ise sonucu 1' e eşitlemektedir. Fonksiyonun uç noktalarına doğru türev değerleri 0 a yaklaşır ve tepki verme azalır, gradient kaybolması yaşanır ve yumuşak bir eğri (gradient) meydana gelir. Bu durumda

ağın öğrenmesi zorlaşır ve doğru tahmin elde etme süresi artar. Böyle durumlarda, sigmoid fonksiyonu yerine hiperbolik tanjant fonksiyonu seçilebilir.

Sigmoid fonksiyonu Denklem 3.13 kullanılarak hesaplanır.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.13)$$

Şekil 3.26’da sigmoid fonksiyon grafiği gösterilmiştir.




Şekil 3.26. Sigmoid fonksiyonu

Hiperbolik tanjant (tanh) fonksiyonu: Sigmoid fonksiyonuna benzer bir yapıya sahiptir. Bu fonksiyonda değerler -1 ile +1 aralığında sıkıştırılmaktadır.

Hiperbolik tanjantın fonksiyonu Denklem 3.13 kullanılarak elde edilir. Şekil 3.26 ile tanh fonksiyon grafiği verilmiştir.

$$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (3.13)$$

Şekil 3.27’de tanh fonksiyon grafiği gösterilmiştir.




Şekil 3.27. Tanh fonksiyonu

Doğrultulmuş Lineer Birim (Rectified Lineer Unit - ReLU) Fonksiyonu: Derin öğrenme uygulamalarında evrişim katmanından sonra uygulanan aktivasyon fonksiyonları arasında çok fazla edilen bir fonksiyondur. Hesaplamalar yapılır iken üstel fonksiyonlar tercih edilmez. Bu durum maliyet açısından ReLU fonksiyonunu diğer fonksiyonlardan daha avantajlı kılar. Fonksiyona gönderilen değerler $[0, +\infty)$ aralığında çıktı üretir. $x < 0$ olduğunda 0, $x \geq 0$ olduğunda x çıktısı üreten doğrusal olmayan bir fonksiyondur. Başarılı sonuç verdiği için doğrusal ve doğrusal olmayan problemlerde sıklıkla kullanılır. Doğrusal yapıya sahiptir. Bu nedenle girdiler sıfıra doğru yaklaştığından ağıda kayıplar meydana gelir.

ReLU fonksiyonu Denklem 3.14 kullanılarak elde edilir. Şekil 3.28 ile ReLU fonksiyon grafiği verilmiştir.

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.14)$$

Şekil 3.28’de ReLU fonksiyon grafiği gösterilmiştir.




Şekil 3.28. ReLu fonksiyonu

Sızıntı ReLu (Leaky ReLu) fonksiyonu: ReLu fonksiyonunda nöron kayıplar meydana gelmekte idi. Bu dezavantajı ortadan kaldırmak için geliştirilmiştir. Bu dezavantajı ortadan kaldırmak için negatif bölgelerde 0 değeri yerine küçük bir eğim kullanılır. Ancak bu durum negatif değerler de tutarsız sonuçlara yol açabilir.

Denklem 3.15'te, sızıntı ReLu formülü verilmiştir.

$$f(x) = \max(a \times x, x), \quad 0 < a < 1 \quad (3.15)$$

Şekil 3.29'de sızıntı ReLu fonksiyon grafiği gösterilmiştir.



Şekil 3.29. Sızıntı ReLu fonksiyonu

Softmax aktivasyon fonksiyonu: Softmax, sigmoid gibi sınıflandırıcı olarak kullanılabilir. Sınıflandırıcı olarak kullanıldığında, her bir çıktı değerinin olasılığı, vektördeki her bir sınıf ile orantılıdır.

Softmax fonksiyonu genellikle makine öğreniminde yaygın bir şekilde kullanılır. Softmax fonksiyonu bir sinir ağı modelinde aktivasyon fonksiyonu olarak kullanılır. Softmax fonksiyonu, sonuçları normalleştirmek için kullanılır. Softmax fonksiyonu, sonuç değerlerinin toplamını bir olan olasılıklara dönüştürür. Softmax fonksiyonunun çıktısındaki her değer, bir sınıf için olasılık değeri olarak yorumlanır.

Denklem 3.16'da, softmax formülü verilmiştir.

$$S_{i,j} = \frac{e^{z_{i,j}}}{\sum_{l=1}^L e^{z_{i,l}}} \quad (3.16)$$


3.2.5. Normalizasyon katmanı

Normalizasyon katmanı (batch normalization) ağ içerisindeki verileri normalize ederek ağı daha kararlı çalışmasını sağlar. Farklı türde normalize yapıları olsa da genelde toplu normalizasyon işlemi ve çapraz normalizasyon (Cross normalization) kullanılmaktadır. Ağı eğitimi sırasında farklılaşan veri dağılımları normalize edilmektedir. Batchnormalization evrişim katmanından sonra kullanılır.


3.2.6. Seyreltme katmanı

Seyreltme katmanı (Dropout) modelin aşırı öğrenmesini engellemek için kullanılır. Modelin eğitimi esnasında gizli katmanlar arasındaki bağlantılar, belirlenen oranda yok edilir ve kalan ağırlıklar yeniden eğitilir. Bu işlem sonucunda modelin nöron sayıları azaltılmış ve eğitim hızı artırılmış olur. Bu işlem de yok edilecek nöronlar rastgele seçilir. 0-1 aralığında bir değer belirlenmelidir. Her katmanda seyreltme oranı farklı verilebilir. Şekil 3.30'da dropout uygulanan bir YSA ağı gösterilmiştir. Şekil 3.30'de soldaki resim YSA modelinin dropout uygulanmadan önceki halini, sağda ki resim ise dropout uygulandıktan sonraki resmi göstermektedir. Sağda ki resimde görüldüğü gibi siyah olan nöronlar YSA ağından silinmiştir. Kalan nöronlar yeniden eğitilecektir. Bu katman sayesinde nöronların modeli ezberlemesini önlemiş olur.

Standart Sinir Ağı




Dropout sonrası Sinir Ağı



Şekil 3.30. Seyreltme katmanı

3.2.7. Derinlik birleştirme katmanı

Derinlik birleştirme katmanı (Depth Concatenation Layer) büyük derin öğrenme modellerinde kullanılmaktadır. Birden fazla katmanın birleştirilmesini sağlar. Birden fazla girdiyi alarak birleştirir ve tek çıktı olarak döndürür. Çalışmamızda modellerimize cinsiyet bilgisi verip modelin eğitilmesini sağlamak için cinsiyet girdisi ve görüntü girdisi birleştirilmiştir. Şekil 3.31’de bu durum görsel olarak ifade edilmiştir. Örnek bir derinlik birleştirme yapısı Şekil 3.31’de görülmektedir.



Şekil 3.31. Derinlik birleştirme yapısı

3.2.8. Hiperparametreler

Makine öğrenmesinde mühendislik daha çok öznelite seçimi üzerine yapılmaktadır. Derin öğrenmede bu mühendislik daha çok mimari mühendisliğine yönelmiş durumda. Derin öğrenme mimarisi seçimi, mimari kullanımında yer alan parametrelere verilen değerlerin performans sonuçları üzerine ciddi etkileri olduğu bilinmektedir. Derin sinir ağlarının eğitiminin yüksek başarımla ve az maliyetle yapılmasını sağlamak için uygun hiperparametre seçimi önemli rol oynar. Bu başlık altında bu tez çalışmasında kullanılan hiperparametreler anlatılmıştır.

3.2.8.1. Döngü sayısı ve yığın büyüklüğü

Bir model eğitilir iken tüm veri seti aynı anda işleme alınmaz. Veri seti belli parçalar halinde eğitim işlemi için alınır. İlk parça alınır ve modelin eğitim süreci başlar. Model eğitimi sonunda modelin başarısına göre geriyeayılım (backpropagation) yöntemi ile modele ait ağırlıklar güncellenir. Bu işlemden sonra veri setinden farklı bir parça veri seti alınıp modele verilir ve model başarısını ölçmek için yeniden model eğitilip test edilir

ve model başarısına göre ağırlıklar yeniden güncellenir. Bu işlem her bir eğitim adımında tekrar edilir. Böylece model için en uygun ağırlıklar gradyan hesaplaması (gradient descent) yöntemi ile tespit edilmeye çalışılır. Bu eğitim adımlarının her birine döngü sayısı (Epoch) denir.

Modelin her bir eğitim adımında (iterasyon) veri seti miktarı ne kadar yüksek ise hesaplama işlemi de yüksek zaman ve yüksek bellek gerektirmektedir. Bu maliyetleri düşürmek için her eğitim adımında veri setinden alınacak veri miktarı gruplara ayrılır ve modelin öğrenme işlemi bu küçük veri seti grupları üzerinde gerçekleştirilir. Bu şekilde veri setinin kaç gruba ayrılacağı yığın büyüklüğü (batch_size) ile belirlenmektedir.

Yüksek yığın büyüklüğü seçilir ise her iterasyon işlemi çok fazla uzun sürelerde gerçekleştirilecektir. Düşük yığın büyüklüğü seçilmesi halinde eğitim işlemleri çok hızlı gerçekleşecek ancak öğrenme başarısı çok zigzaglı olacaktır. Öğrenme başarısının düşük olmasının nedeni veri çeşitliliği olan bir veri seti üzerinde düşük veri seti grupları seçildiğinde her grupta aynı çeşitlilikte veri olmayacağından, modelin bu farklı durumları öğrenmesi yavaş gerçekleşecektir. İşlemler hızlı ancak öğrenme yavaş olacaktır.

Döngü sayısı ve yığın büyüklüğü parametrelerinin kullanımını bir örnekle açıklarsak şayet: 200 örnekten oluşan bir veri kümesi için yığın büyüklüğü 10 ve döngü sayısı 100 olsun. Bu durumda veri kümesi $200/10=20$ adet gruba bölünecektir. Her bir grupta 20 örnek veri seti yer alacaktır. Her bir 20 örnek veri seti için model ağırlıkları hesaplanacak ve ardından hata hesaplanıp, modele ait ağırlık değerleri güncellenecektir. Her bir döngü sayısında modele ait ağırlıklar 20 kez güncellenecektir. Eğitimi için belirlenen 100 döngü sayısı için model tüm veri kümesinden 100 kere yararlanacak ve modelin ağırlıklarında tüm eğitim süreci boyunca toplam 2.000 güncelleme yapılmış olacaktır. Çalışmalarımızda yığın büyüklüğü değeri 32 olarak alınmıştır.

3.2.8.2. Öğrenme hızı

Derin öğrenmede parametrelerin güncellenmesi geriye yayılım ("backpropagation") işlemi ile yapılmaktadır. Geriye yayılım işleminde güncelleme için; geriye doğru türev olarak fark bulunur. Bu fark değeri öğrenme hızı ile çarpılır. Çarpma işlemi sonucunda elde edilen değer ağırlık değerlerinden çıkarılır böylece modele ait yeni ağırlık değerleri hesaplanmış olur. Öğrenme hızı (learning rate) değeri varsayılan değer olarak 0,01 olarak kullanılır. Öğrenme hızı sabit değer olarak belirlenebileceği gibi adım adım artan bir değer olarak da değişken bir değer olarak ta alınabilir. Tez çalışmamız da

öğrenme hızı için her 10 döngü sayısında modele ait performans sonuçlarını iyileştirmek için 0.8 ile çarpılmıştır.

Öğrenme hızını yüksek tutmak salınma sebep olacak ve ayrıca modelin veri setinden çokça etkilenmesine sebep olacaktır. Öğrenme hızını küçük tutmak modelin küçük adımlarla ilerlemesine sebep olacağından öğrenimin çok uzun sürmesine neden olacaktır.

Bu değer her bir döngü sayısından sonra belli kurallara göre düşürülebilir veya sabit bırakılabilir.

3.2.8.3. Düzenleştirme

Düzenleştirme (regularization) yöntemi modelde oluşabilecek aşırı öğrenme (overfitting) problemini engellemek/çözmek için kullanılmaktadır. Model üzerinde değişiklik yaparak modelin performansını iyileştirmeye yarar. Çalışmalarımızda kullandığımız düzenleştirme tekniklerinden L2 düzenleştirme fonksiyonu kullanılmıştır. L2 düzenleştirme, en yaygın kullanılan düzenleştirme türüdür. L2 düzenleştirme, ağırlıkları sıfıra yakın değerlere indirgemeye zorlar. Burada ki amaç döngü sayısı işlemi sonucunda elde edilen hata kareler toplamını minimize eden katsayıların büyüklüğünü azaltmaya çalışmaktır. Bunun için bu katsayılar ceza uygulanır. Bunun için

$$J = \text{Loss} + \lambda * \sum |w|^2 \quad (3.17)$$

Loss hatayı hesaplar. λ düzenleme parametresidir ve >0 olarak ayarlanır. w maliyet fonksiyonu ağırlıklarını ifade eder.

CNN, nesnelerde bazen fark edilmeyen noktaları alarak bu nesneleri birbirinden ayırt etmekte kullanılan popüler bir derin öğrenme teknolojidir. Derin öğrenmenin en belirgin özelliklerinden biri üzerinde çalışılan veri seti miktarının çok olması gerektiğidir. Veri seti miktarı az ise çalışma esnasında aşırı öğrenme problemleri meydana gelebilir. Bu problemin üstesinden gelmek, küçük veri setleri ile çalışmalarda derin öğrenme teknolojilerinden yararlanmak için transfer öğrenme yöntemi kullanılmaktadır.

3.2.9. Transfer öğrenme modelleri

Transfer öğrenme yöntemi ile modeller; ImageNet veri seti üzerinde (1000 kategoride 1,2 milyon görüntü) eğitilmiştir. Transfer öğrenme ile önceden eğitilmiş bu modellerin öğrendikleri özellikleri (ağırlıkları) veri setimizde kullanarak daha verimli ve etkili sonuçlar alabiliriz.

Derin öğrenmenin önemli bir özelliği, büyük miktarda veri gerektirmesidir. Veri miktarı çok küçükse, eğitim sırasında yetersiz uyum (under-fitting) oluşacaktır. Küçük bir veri setinde verileri derin öğrenme modelleri ile eğitmek için bilim adamları transfer öğrenme kavramını önermişlerdir.

Transfer öğrenmenin öğrenme yeteneği sayesinde, sadece küçük bir veri seti ile doğru ve verimli görüntü sınıflandırması yapılabilir.

Yetersiz bir eğitim seti varsa, ImageNet veri seti ile önceden eğitilmiş ve ImageNet veri seti içerisinde yer alan görüntülerin özelliklerini öğrenmiş olan transfer öğrenme yöntemi kullanılır. Uygulamada, ImageNet tarafından önceden eğitilmiş ağırlık parametreleri, kurduğumuz modelde başlatılmalıdır; bu, daha önce öğrenilen özelliklerin modelimize gönderilmesini ve modelimiz ile daha iyi sonuçların alınmasını sağlayabilir.

Morid ve arkadaşları (Morid ve ark., 2021) tıbbi görüntüler üzerinde yapılan 102 araştırmayı incelemiştir. Bu araştırma da tıbbi görüntü analizinde transfer öğreniminin geniş ölçekli bir incelenmesi yapılmıştır. Bu incelemeye göre tıbbi görüntüler üzerinde transfer öğrenme modellerinin yaygın başarısından söz edilmektedir. Bu makaleye göre çeşitli anatomik bölgeler için kullanılan popüler transfer öğrenme modelleri Tablo 3.5'te gösterilmiştir.

Tablo 3.5. Farklı anatomik bölgeler için kullanılan popüler transfer öğrenme modeller

Anatomik bölge	Model mimarisi
Ultrason, endoskopi ve iskelet sistemi	Inception
Göz, cilt, dış röntgenleri için	VGGNet
Beyin MRI'ları ve meme röntgenleri için	AlexNet
Akciğer röntgenleri için	DenseNet

Görüntüleri eğitmek için birçok farklı transfer öğrenme modelleri mevcuttur. Transfer öğrenme modelleri önceden eğitilmiş modeller olduğundan farklı görüntülerin sınıflandırılmasında veya regresyon problemlerinde katkı sağlarlar. Çalışmalarımızda

farklı görüntüler üzerinde eğitilmiş transfer öğrenme modelleri kullanılmıştır. Transfer öğrenme modelleri arasında daha önce kemik yaşı tespiti problemleri ile ilgili yapılan çalışmalarda sıklıkla InceptionV3 (Dong ve ark., 2020) modelinin diğer modellerden daha başarılı sonuçlar aldığı görülmüştür. Tablo 3.5'te verilen bilgilerden görüleceği üzere iskelet sistemleri üzerinde yapılan çalışmalarda ve kemik yaşı tahmini ile ilgili yapılan çalışmalarda InceptionV3 modelinin en başarılı model olduğu görülmüştür. Bu nedenle InceptionV3 ve bu InceptionV3 modeline parametre sayısı bakımından yakın ve hızlı olan modeller tercih edilmiştir. 18 yaş altı bireylerin kemik yaşı tespiti için InceptionV3 modeli ile beraber MobileNetV2 (Sandler ve ark., 2018) ve EfficientNetB4 (Tan ve Le, 2019) modelleri tercih edilmiştir. 18 yaş üstünde ki bireylerin kemik yaşı tespiti için InceptionV3 modeli ile beraber ResNet50V2 ve DenseNet201 modelleri tercih edilmiştir. Tez çalışmasında kullanılan evrişimli sinir ağı modellerinin mimari yapıları Tablo 3.6'da gösterilmiştir. Tez çalışmasında transfer öğrenme modellerinin tercih edilmesinin temel sebebi benzer problemlerde yapılan çalışmalarda transfer öğrenme modellerinin; zaman ve maliyet açısından daha pahalı olan tasarlanan modellere göre daha başarılı olduğunun literatür kısmında tespit edilmiş olmasıdır.


Tablo 3.6. Evrişimli sinir ağı modellerinin mimari yapıları

Model	Boyut (MB)	Parametre Sayısı
InceptionV3	92	23,851,784
MobileNetV2	14	3,538,984
EfficientNetB4	75	19,466,823
ResNet50V2	98	25,613,800
DenseNet201	80	20,242,984

3.2.9.1. InceptionV3


InceptionV3 ağ mimarisi, ImageNet veri seti üzerinde bir milyon verinin üzerinde eğitilmiştir. 42 katman derinliğindedir ve 1.000 kategoriye ayrılabilir. Modelin ana fikri, çok ölçekli gösterimleri öğrenmek ve hesaplama karmaşıklığını ve toplam parametre sayısını azaltmak için büyük çekirdekleri küçük çekirdeklerle değiştirmektir. Sadece ağ parametrelerinin miktarını azaltmakla kalmayıp aynı zamanda ağ derinliğini de artıran Inception ağ yapısını benimser. InceptionV3 ağ mimarisinde evrişim katmanları daha küçük çarpanlara ayrılmış ve verimliliğini düşürmeden parametre sayısını azaltılmıştır.

Inception v3 ağ yapısı, büyük hacimli integralleri küçük evrişimlere bölmek için bir evrişim çekirdeği bölme yöntemi kullanır. Örneğin, bir 3×3 evrişim, 3×1 ve 1×3 evrişimlere bölünür. Bölme yöntemi ile parametre sayısı azaltılabilir; bu nedenle, uzamsal özellik daha etkin bir şekilde çıkarılırken ağ eğitim hızı hızlandırılabilir. Inception v3, üç farklı boyutta alan ızgarası (35×35 , 17×17 ve 8×8) kullanarak Inception ağ yapısı modülünü optimize eder (Dong ve ark., 2020). Bu model GoogLeNet ağını temel alarak geliştirilmiştir. GoogLeNet modelinde paralel olan ağ parçaları “inception” olarak adlandırılmıştır (Szegedy ve ark., 2015). Şekil 3.32’de Temel Inception modülü gösterilmiştir.



Şekil 3.32. Temel Inception Modülü

Parametre sayısı ve çıkış boyutunun büyüklüğünden kaynaklı olarak işlem hesaplamaları çok büyümektedir. Bu sorunu çözmek için boyut azaltma işlemleri uygulanır. Boyut azaltma işlemleri için paralel temel inception konvolüsyon katmanlarının önüne (1×1) konvolüsyon katmanları eklenerek gerçekleştirilir. Giriş matrisi 100 kanallıysa ve buna 70 kanallı bir (1×1) konvolüsyon filtresi hacimsel olarak uygulandığında çıkış matrisinin kanal sayısı filtre sayısına eşit yani 70 olur. Bu durumda (1×1) konvolüsyon katmanı derinlikte boyut azaltmış demektir. Bu çözüm hesaplama karmaşıklığına ve büyüklüğüne hız ve başarıyı getirmiştir. Inception ağ modeli farklı boyutlu konvolüsyon ve maksimum ortaklama işlemlerinden meydana gelmiştir (Kızrak ve Bolat, 2018). Şekil 3.33’te Inception modülü yapısı sunulmuştur. Ağın boyutlarını azaltmak ve daha hızlı hesaplamalar gerçekleştirmek için (3×3) ve (5×5) evrişimsellerden önce, fazladan (1×1) bir evrişimsel eklenerek giriş kanal sayısı sınırlandırılmıştır.



Şekil 3.33. Boyutu azaltılmış Inception modülü


Inception modülünde oluşan büyük bir işlem yükünü hafifletmek için Szegedy ve ekibi her konvolüsyon katmanından önce (1×1) konvolüsyon katmanı kullanmayı önermiştir. Bu (1×1) konvolüsyon işlemi ‘darboğaz’ (bottleneck) olarak tanımlanmıştır. Bu işleme öz nitelik ortaklama (pooling of feature) denir. Aktivasyon fonksiyonu olarak ReLU kullanılmaktadır. Daha karmaşık bir ağ modeli ile daha az hesap ve daha hızlı bir tasarım yapılmaktadır. Tüm ağ, 100’den fazla katmandan oluşan 9 inception modülünden oluşmaktadır. Tüm bağlantı katmanlarında ortalama ortaklama kullanılmaktadır. GoogLeNet 5 milyon parametre ile AlexNet’e göre 12 kat daha az işlem yüküne sahiptir (Szegedy ve ark., 2015, 2016, 2017).

Şekil 3.34’de Inception ağ yapısı ve Tablo 3.7’de InceptionV3 modelinin mimarisi gösterilmiştir.

Tablo 3.7. Inceptionv3 model mimarisi

	Katman Tipi	Filtre Boyutu	Girdi Boyutu	Adım Sayısı
Girdi	Görüntü	-	299x299x3	-
1	Konvolüsyon(Conv)	3x3	299x299x3	2
2	Konvolüsyon (Conv)	3x3	149x149x32	1
3	Konvolüsyon (Conv Padded)	3x3	147x147x32	1
4	Ortaklama (Pool)	3x3	147x147x64	2

5	Konvolüsyon (Conv)	3x3	73x73x64	1
6	Konvolüsyon (Conv)	3x3	71x71x80	2
7	Konvolüsyon (Conv)	3x3	35x35x192	1
8	Inception modülü A (3*Inception)	3 modül	35x35x288	-
9	Inception modülü B (5*Inception)	4 modül	17x17x768	-
10	Inception modülü C (2*Inception)	2 modül	8x8x1280	-
11	Ortaklama (Pool)	8x8	8x8x2048	-
12	Linear	Lojit	1x1x2048	-
Çıktı	Softmax	1000	1x1x1000	-




Şekil 3.34. InceptionV3 ağ yapısı

3.2.9.2. Modifiye edilmiş InceptionV3

Modifiye edilmiş InceptionV3 modelinde Şekil 3.35'te gösterildiği gibi inceptionv3 modelinin sonuna yeni bir blok eklenmiştir. Yeni eklene blok ile öz niteliklerin elde edilmesi amaçlanmıştır. Bunun için InceptionV3 modelinden çıkış katmanı çıkarılıp, bu modelin sonuna ek olarak 2 şer evrişim katmanı ve bu katmanların sonuna maksimum havuzlama katmanı eklenmiştir. Bu eklemelerin sonunda mimariden elde edilen verilerin YSA ağına verilmesi için Global havuzlama katmanı eklenmiştir.

Ayrıca aşırı öğrenmeyi engellemek adına tasarlanan mimarinin sonuna dropout eklenmiştir. Bu yeni eklenen blok ile sonuçların daha başarılı olduğu gözlemlenmiştir.




Şekil 3.35. Modifiye edilmiş InceptionV3 ağ mimarisi

3.2.9.3. MobileNetV2

MobileNetV2 (Sandler ve ark., 2018) tarafından özellikle mobil cihazlar için önerilen bir CNN mimarisidir. MobileNet TensorFlow'a dayalı küçük bir yapıya sahip, daha düşük gecikmeye ve daha düşük güç tüketimine sahip, sınırlı bilgi işlem kaynaklarına sahip küçük cihazlarda uygulanmasına olanak verir. Benzersiz ağ yapısı yüksek doğruluk oranları ile görüntü sınıflandırma, algılama, gömme ve segmentasyonda verimliliğini artırır. Mobil ve gömülü uygulamalarda yüksek doğruluk sağlar. MobileNetV2 CNN mimarisi, ImageNet gibi büyük veri kümelerinde kullanılır. Kaynak kısıtlamalarının olduğu durumları karşılayabilecek şekilde parametrelendirilmiş bir modeldir. Nesne tespiti ve segmentasyonu için etkili bir öznetelik çıkarıcıdır. 3 katman halinde derinden ayrılabilen evrimsel bir yapıya sahiptir. Bunlardan ilki genişleme katmanıdır. Son 2 katman derinlemesine ve noktasal evrişim katmanıdır.


Şekil 3.36'da ayrılabilir ve noktasal evrişim katmanları yapısı görülmektedir.



Şekil 3.36. Sol: Batchnormalization ve ReLU ile standart evrişim katmanı. Sağ: Batchnormalization ve relu tarafından takip edilen derinlik yönünde ve nokta yönünde katmanlarla derinlemesine ayrılabilir evrişimler (Howard ve ark., 2017)

Doğrusal olmayan ve sınıflandırma için bir softmax katmanı ile beslenen son tam bağlı katman hariç tüm katmanları bir Batchnormalization ve ReLU doğrusalsızlığı izler. Ayrılabilir evrişim katmanlarında her bir giriş verisi için tek bir filtre uygulanır. Şekil 3.8’de düzenli evrişimler, Batchnormalization ve ReLU doğrusal olmayan bir katmanla, her bir evrişim katmanından sonra Batchnormalization ve ReLU’nun yanı sıra derinlemesine evrişim, 1×1 noktasal evrişim ile faktörleştirilmiş katmanla karşılaştırır (Howard ve ark., 2017).

MobilenetV2 çıkış ve pooling katmanları hariç 155 katmana sahiptir. MobileNetV2 modeli, geleneksel evrişimsel katmanın iki ayrı katmana bölündüğü, derinlemesine ayrılabilir evrişim modelidir. İlk katman girişin her kanalına uygulanan noktasal evrişim katmanı, ikinci katman gelen veriye evrişim uygulayan derinlemesine evrişim katman olarak adlandırılır. Geleneksel evrişimin evrişim çekirdeği parametreleri $f1*f2*M*N$ ’dir. $f1*f2$ evrişim çekirdeği, M giriş ve N çıkış kanallarının sayısıdır. Noktasal evrişimde çekirdek parametresi $1*1*M*N$ ’dir. Bu katmanda giriş kanallarının doğrusal kombinasyonlarını hesaplayarak yeni öznetelikler oluşturmaktan sorumlu olup 1×1 evrişimdir. Derinlemesine ayrılabilir evrişim katmanı çekirdek parametreleri $f1*f2*1*M$ ’dir. Derinlikli katmanda giriş kanalı tek başına bir evrişim filtresi uygulayarak hafif filtreleme yapar. Şekil 3.37’de MobileNet yapısı gösterilmiştir.



Şekil 3.37. MobileNet yapısı

Tablo 3.8’de ise MobileNetV2’nin farklı mimariler için olası parametreleri verilmiştir. k kanallı bir giriş verisi, noktasal evrişim, derinlemesine ayrılabilir evrişim ve doğrusal evrişim yoluyla verilere dönüştürülür.

Tablo 3.8. MobileNetV2 ağ yapısı (Dang ve ark., 2018)

Giriş	Operatör	t	c	n	s
224*224*3	Conv2d	-	32	1	2
112*112*32	bottleneck	1	16	1	1
112*112*16	bottleneck	6	24	2	2
56*56*24	bottleneck	6	32	3	2
28*28*32	bottleneck	6	64	4	2
14*14*64	bottleneck	6	96	3	1
14*14*96	bottleneck	6	160	3	2
7*7*160	bottleneck	6	320	1	1
7*7*320	conv2d 1*1	6	1280	1	1
7*7*1280	avgpool 7*7	-	-	1	-
1*1*1280	conv2d 1*1	-	k	-	-

t =katmanın genleşme faktörü. Genleşme katmanında verilen t değerine göre kanal sayısı belirlenir.

c =çıkış kanalı sayısı


n = katmanın yinelenen sayısı

s =katmanın adım sayısı

MobileNet modeli Google Öğretilbilir Makine (Google Teachable Machine) projesi ile (Carney ve ark., 2020) makine öğrenimini hızlı, kolay ve erişebilir hale getirmeyi sağlayan web tabanlı olarak geliştirdiği sisteminde arka planda kullandığı derin öğrenme modeli olarak karşımıza çıkmaktadır.

3.2.9.4. EfficientNet


EfficientNet modeli, Google araştırma ekibi tarafından ağın derinlik, genişlik ve çözünürlüğünün tüm boyutlarını eşit olarak ölçekleyen yeni bir boyutlandırma yöntemidir. EfficientNet, model verimliliğini korumak için öğrenme veri setlerini koruyup aktarır ve temel bir ConvNet'in herhangi bir hedef kaynak kısıtlamasına ölçeklenmesini sağlar (Tan ve Le, 2019). EfficientNet B0-B7 arasında 8 tane model içerir ve her modelin boyut ve parametre sayısı farklıdır. EfficientNet B0 modeli boyut ve parametre olarak en küçük modeldir. Model numarası arttıkça boyut ve parametre sayısı artmaktadır. EfficientNet bileşik ölçeklendirme yöntemlerine dayanmaktadır. Bu çalışmamızda kullandığımız transfer öğrenme modellerinin boyut ve parametre sayılarının birbirine yakın olmasına dikkat edildiği için EfficientNetB4 modeli tercih edilmiştir. EfficientNetB4 temel ağ yapısı Şekil 3.38'de verilmiştir.



Şekil 3.38. EfficientNetB4 temel ağ yapısı


3.2.9.5. ResNet50V2

ResNet mimarisi ile birlikte, ağıdaki derinliğin artırılmasının başarından ziyade daha fazla kaynak gereksinimi ve daha düşük başarıma sebep olduğu tespit edilmiştir. Bunların aşılması için artık (Residual) Ağ denilen bloklar kullanılmıştır. Yani ResNet'teki kısayol bağlantıları olarak bu bloklar kullanılmıştır. Katmanlar arası geçişte girdilerin ağırlıkları sıfırlansa bile bu girdiler 2 katman sonra evrişime tekrar dâhil olabilmekte ve etkileri sonraki katmanlara taşınabilmektedir. Bu şekilde gradyanların yok olması engellenmiş olmaktadır (İŞ, 2021). Şekil 3.39'da ResNet mimarisinde kısayol bağlantı işlemi gösterilmiştir. ResNet ile Artık Ağ Evrişimi (Residual Network Convolution) yapısı Şekil 3.39'da verilmiştir.



Şekil 3.39. ResNet ile Artık Ağ Evrişimi

Resnet50V2 modeli Resnet50 modelindeki bloklar arasındaki bağlantıları değiştirerek Resnet50 modelini daha da geliştirmişlerdir. Resnet50V2 50 derin katmandan oluşmaktadır. Bu katmanlar kimlik ve konvolüsyün bloklarına sahip 5 parçadan oluşmaktadır. Kimlik ve konvolüsyün blokları 3 katmana sahiptir (İŞ, 2021). Resnet modelinin diğer modellerden ayıran özelliği, sonraki katmanları artık değerleri (residual value) ile besleyen bloklar mimariye eklenmiştir. Resnet50V2 temel ağ yapısı Şekil 3.40'da verilmiştir.




Şekil 3.40. Resnet50V2 temel ağ yapısı (He ve ark., 2016)

3.2.9.6. DenseNet201

DenseNet her katmanı önceki tüm katmanların özelliklerini her katmana girdi olarak ileri beslemeli bir şekilde bağlar, önceki tüm katmanların özelliklerini her katmana girdi olarak verir. Özellik haritaları da sonraki tüm katmanların girişi olarak kullanılır. Bu özellik ile DenseNet görüntüye ait özelliklerin yeniden kullanımını sağlar. Şekil 3.41’te DenseNet mimarisinin 4 yoğunluk blokundan oluşan modellenmesi gösterilmiştir.


ResNet’ten farklı olarak 2 katmanda bir sisteme eklenen değer DenseNet’te her katmanda eklenmiştir. Bu durum modele pekçok avantaj sağlamıştır. Böylece DenseNet çoğu katmanın işlevsiz olma sorununun olduğu yüksek katmanlı yapıları optimize ederek daha kolay eğitilebilir bir hal almıştır (Huang ve ark., 2017).



Şekil 3.41. DenseNet ağ mimarisi (Huang ve ark., 2017)

DenseNet201 ağ mimarisi şekil 3.42’da gösterilmiştir. 305 katmandan ve 4 yoğun bloktan oluşur. Her blokta 1x1 ve 3x3 filtrelerden 128 ve 32 evrişimli bloklar vardır. Evrişimli ve Maksimum havuzlama (1×1 Evrişim., 2×2 Maksimum havuzlama) yapan iki bitişik blok arasındaki geçiş katmanları, özellik haritalarının boyutlarını küçültür. Bu işlem darboğaz girdi özellik haritalarını azaltmak ve daha büyük evrişimi daha verimli hale getirmek için yapılır.

Özelliklerin bir sonraki katmana aktarılması ile sonraki katmanın özellik çıkarımlarında katkı sunacak şekilde aktarılması parametre kullanımını azaltmaktadır.




Şekil 3.42. DenseNet201 layer mimarisi

3.2.10. Kemik yaşı tespitinde görüntü işleme prosedürü

Bu çalışma için KRV veri seti için elde edilen görüntülerin boyutlarının her birinin farklı boyutlarda olduğu tespit edilmiştir. Yapılan çalışmalarda derin öğrenme transfer metotlarında sıklıkla kullanılan ve tavsiye edilen görüntü boyutlarına göre görüntüler 128,256, 299 olarak küçültüldüğünde görüntü içerisindeki değerli bilgilerin kaybolduğu ve sonuçların istenilen seviyede olmadığı tespit edilmiştir. El bilek grafi görüntülerinin boyutları 300 piksel üzerine boyutlandırıldığında ise bellek (RAM) problemleri ile karşılaşmıştır. Bu çalışmada görüntülerdeki ayırt edici piksellerin kaybolmaması için görüntüler 512*512 olarak boyutlandırılmıştır. Bu ölçekte resimleri RAM’de sorun çıkarmadan tutulup işleyebilmesi için özel veri üreteç metodu (imagedatagenerator) yazılmıştır. Bu metot’ta her adımda 512*512 boyutlarında 32 resim alınıp işlenmiştir. Daha fazla resim alındığında ram hatası alındığı için tüm modeller de yığın büyüklüğü 32 olarak alınmıştır. Her iterasyonda görüntüler rastgele seçilmiştir. Bu özel veri üreteç

metodu ile sisteme tüm görüntüleri yüklemek yerine her epoch'un iterasyonunda yığın büyüklüğü kadar görüntü adedi sisteme yüklenmiştir. Böylelikle görüntülerdeki değerli bilgilerin kaybolması engellenmiş ve karşılaşılan RAM problemi ortadan kaldırılmıştır.

Ön işlem aşamasında KRV, KYRV ve RSNA veri setindeki tüm görüntülere parlaklık ve kontrast farklılıklarını gidermek için gerekli ön işlemler uygulanmıştır. Görüntüler farklı hastanelerde ve farklı açılardan çekildiği için birçok görüntünün parlaklık ve kontrast ayarları birbirinden farklı olduğu tespit edilmiştir. Bu problemi ortadan kaldırmak için kontrast sınırlı uyarlamalı histogram eşitleme yöntemi kullanılmıştır. Şekil 3.43'ta bu yöntem sonucu elde edilen 2 farklı görüntü örneği verilmiştir.




Şekil 3.43. Görüntülere uygulanan otomatik kontrast ve parlaklık işlemi. (A) Orijinal görüntüler (B) Otomatik kontrast ve parlaklık ayarı uygulandıktan sonra elde edilen görüntüler

Önişlem aşamasında görüntülere kontrast ve parlaklık ayarı yapıldıktan sonra ölçeklendirme işlemi yapılmıştır. Derin öğrenme metotları yüksek matematiksel işlemler yaptığı için görüntülerin boyutlarını düşürmek işlemleri hızlandıracaktır. Veri setlerindeki görüntüler farklı boyutlarda ve yüksek çözünürlükte olduğu için bu görüntülerin boyutları yeniden ayarlanmıştır. Görüntülerde ki en boy oranını bozmadan aynı tutarak, görüntüler hedef genişlik ve yüksekliğe göre yeniden boyutlandırılmıştır. Ön işlem aşamasında yapılan diğer işlemler “veri setine uygulanan ön işlem adımları” başlığında detaylı olarak açıklanmıştır.

3.2.11. 18 yaşından küçük bireylerde kemik yaşı tespiti blok diyagramı

Bu bölümde 18 yaş altındaki el bilek grafilerinden yaş tespiti yapmak için kullanılan derin öğrenme mimarisi anlatılmıştır. Önerilen yaklaşım 4 bloktan oluşmaktadır. Önerilen derin öğrenme mimarisi Şekil 3.44’de gösterilmiştir. Her blokta gerçekleştirilen işlemler aşağıda özetlenmiştir.



Şekil 3.44. 18 yaş altı için kemik yaşı tespiti için derin öğrenme yöntemlerinin genel mimarisi

Blok 1: Ön işlem aşamasıdır. Bu aşamada KRV ve RSNA veri setindeki tüm görüntülere parlaklık ve kontrast farklılıklarını gidermek için gerekli ön işlemler uygulanmıştır. Öncelikle görüntülerin kontrast ve parlaklık ayarları yapılmıştır. Görüntüler farklı hastanelerde ve farklı açılardan çekildiği için birçok görüntünün parlaklık ve kontrast ayarları birbirinden farklı olduğu tespit edilmiştir. Bu problemi ortadan kaldırmak için kontrast sınırlı uyarlamalı histogram eşitleme yöntemi kullanılmıştır.


Önişlem aşamasında görüntülere kontrast ve parlaklık ayarı yapıldıktan sonra ölçeklendirme işlemi yapılmıştır. Derin öğrenme metotları yüksek matematiksel işlemler yaptığı için görüntülerin boyutlarını düşürmek işlemleri hızlandıracaktır. Veri setlerindeki görüntüler farklı boyutlarda ve yüksek çözünürlükte olduğu için bu görüntülerin boyutları yeniden ayarlanmıştır. Görüntülerde ki en boy oranını bozmadan aynı tutarak, görüntüler hedef genişlik ve yüksekliğe göre yeniden boyutlandırıldı.

Blok 2: Önişlem aşamasında geçmiş görüntüler CNN bloğuna verilir. Bu blokta görüntülerden görüntülerdeki kenarlar dahil her türlü bilgi ve özellikler tespit edilmektedir.

Blok 3: Bu aşamada önceki bloktan gelen öznitelikler kullanılarak regresyon işlemi gerçekleştirilmektedir. CNN bloğundan gelen öznitelikler ile kişi kemik yaşı arasında neden sonuç ilişkisi belirlenmektedir. Modelin performansını değerlendirmek için MAE, RMSE ve R2 ölçütleri kullanılmıştır.


3.2.12. 18 yaşından büyük bireylerde kemik yaşı tespiti blok diyagramı

Bu bölümde 18 yaşından büyük bireylerin el bilek grafilerinden yaş tespiti yapmak için kullanılan sisteme ait blok diyagram anlatılmıştır. Önerilen yaklaşım 3 bloktan oluşmaktadır. Önerilen kemik yaşı tespit sistem mimarisi Şekil 3.45’de gösterilmiştir.



Şekil 3.45. 18 yaş üstü bireylerde kemik yaşı tespiti için derin öğrenme yöntemlerinin genel mimarisi

Blok 1: Ön işlem aşamasıdır. Bu aşamada KYRV veri setindeki tüm görüntülere parlaklık ve kontrast farklılıklarını gidermek için gerekli ön işlemler uygulanmıştır. Görüntüler farklı hastanelerde ve farklı açılardan çekildiği için birçok görüntünün parlaklık ve kontrast ayarlarının birbirinden farklı olduğu tespit edilmiştir. Öncelikle görüntülerin kontrast ve parlaklık ayarları yapılmıştır. Bu problemi ortadan kaldırmak için kontrast sınırlı uyarlamalı histogram eşitleme yöntemi kullanılmıştır. Ardından farklı boyutlara sahip görüntüler 512*512*3 boyutlarında ölçeklendirilmiştir. Şekil 3.46’da bu yöntem sonucu elde edilen 2 farklı görüntü örneğinin bu aşamalar sonucunda elde edilen görüntüleri verilmiştir.



Şekil 3.46. Görüntülere uygulanan otomatik kontrast ve parlaklık işlemi. (A) Orijinal görüntüler, (B) Otomatik kontrast ve parlaklık ayarı uygulandıktan sonra elde edilen görüntüler, (C) Yeniden ölçeklendirildikten sonra elde edilen görüntüler


Derin öğrenme metotları yüksek matematiksel işlemler yaptığı için görüntülerin boyutlarını düşürmek işlemleri hızlandıracaktır. Veri setlerindeki görüntüler farklı boyutlarda ve yüksek çözünürlükte olduğu için bu görüntülerin boyutları yeniden ayarlanmıştır. Görüntülerdeki küçük ama kıymetli bilgilerin kaybolmaması için görüntüler ölçeklendirilir iken çok küçük boyutlara indirgendiği zaman oluşan bilgi kaybının önüne geçmek için 512*512 olarak ölçeklendirilmiş ve klasik yeniden boyutlandırma yöntemi yerine resize padding yöntemi tercih edilmiştir.

Blok 2: Önilem aşamasında geçmiş görüntüler CNN bloğuna verilir. Bu blokta; görüntülerden görüntülerdeki kenarlar dahil her türlü bilgi ve ayırt edici özellikler keşfedilir ve görüntüye ait öznitelikler ortaya çıkarılır.

Blok 3: Bu aşamada önceki bloktan gelen öznitelikler kullanılarak regresyon işlemi gerçekleştirilmektedir. CNN bloğundan gelen öznitelikler ile kişi kemik yaşı arasında neden sonuç ilişkisi belirlenmektedir. Modelin performansını değerlendirmek için MAE, RMSE ve R2 ölçütleri kullanılmıştır.

3.2.13. 18 yaşından küçük bireyler için önerilen ağ yapısı

El bilek grafilerinden kemik yaşını tespit etmek için önerilen ağ mimarisi Şekil 3.47’te gösterilmiştir.

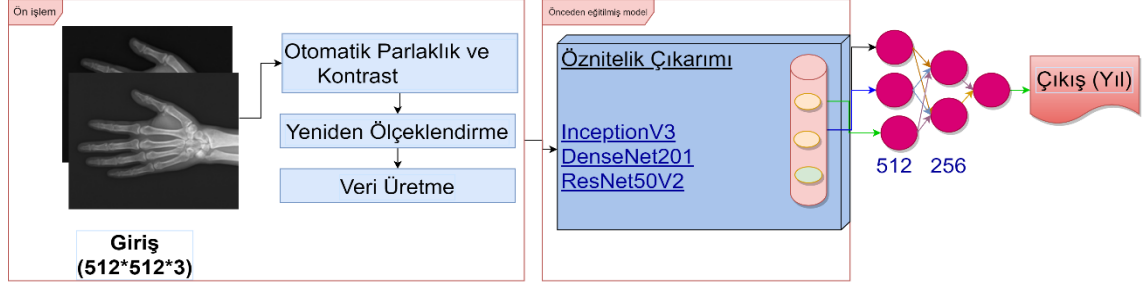


Şekil 3.47. Önerilen kemik yaşı ağ mimarisi

Cinsiyete göre el bilek grafileri farklılık göstermektedir. Bu cinsiyet ayrımının, modelin tanınması ve keşfetmesi için ikili cinsiyet bilgisi alan (erkek için 0, kadın için 1) ve 32 nörondan oluşan bir cinsiyet katmanı eklenmiştir. InceptionV3, MobileNetV2 ve EfficientNetB4 modelinin çıkış katmanı çıkarılmış ve geri kalan modele küresel ortalama havuzlama işlemi uygulanmıştır. Ardından modelin girişine 512*512 girişleri verilmiştir. 2 model (Transfer Learning ve cinsiyet) birbirine bağlandıktan (Concatenate) sonra 256, 128 ve 64 nörondan oluşan 3 katman bu modele eklenmiştir.

3.2.14. 18 yaşından büyük bireyler için önerilen ağ yapısı

Bu çalışmada el bilek grafilerinden kemik yaşını tespit etmek için önerilen ağ mimarisi Şekil 3.48’de gösterilmiştir.



Şekil 3.48. Önerilen kemik yaşı ağ mimarisi

Cinsiyete göre el bilek grafilere farklılık gösterdiği literatürde belirtildiği gibi farklılık göstermektedir. Bu nedenle modeller cinsiyetlere göre ayrı ayrı eğitilmiştir. InceptionV3, DenseNet201 ve ResNet50V2 modelinin çıkış katmanı çıkarılmış ve geri kalan modele global ortalama havuzlama işlemi uygulanmıştır. Ardından modelin girişine 512*512 girişleri verilmiştir. 512 ve 256 nöronlu oluşan 2 katman bu modele eklenmiştir. Bu 2 katmanın başarısını artırmak, çıktıları düzenli hale getirmek ve ağırlıkları düzenlemek için kernel, bias ve activity regularizer yöntemleri ilave edilmiştir.

3.2.15. Performans ölçütleri

Bu çalışmada derin transfer öğrenme modellerin performansları test etmek için hata kareler ortalamasının karekökü (RMSE), hatanın mutlak ortalaması (MAE) ve belirleme katsayısı (R2) gibi istatistiki ölçütler kullanılmıştır. Kemik yaşı tahminleri istatistiksel ölçütler üzerinden karşılaştırılmıştır. Bu ölçütler aşağıdaki eşitlikler ile tanımlanırlar (Ma ve Iqbal, 1983; Akinoğlu ve Ecevit, 1990; Bakirci, 2009; Şahin ve ark., 2013; Dogan ve Keles, 2020)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{Y}_i - Y_i)^2} \quad (3.18)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{Y}_i - Y_i| \quad (3.19)$$

$$R^2 = \frac{\sum_{i=1}^N (Y_i - \bar{Y})^2 - \sum_{i=1}^N ((\hat{Y}_i - Y_i)^2)}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (3.20)$$

Burada Y_i kişilerin ay olarak gerçek yaş değerleridir. $\bar{Y}$ ise bu yaş değerlerin ortalama değerlerini, $\hat{Y}_i$ tahmin edilen kemik yaş değerlerini, N toplam gözlem sayısı belirtir. RMSE ve MAE pozitif değerler olup bu istatistiki ölçütlerin küçük olması tercih edilir. Sıfıra yakın değerler modellerin kişilerin yaş tahminlerinin gerçeğe yakın tahmin ettiğini belirtir. R2 ölçütü ise gerçek kişilerin ay olarak yaş değerleri ile modellerin tahmin ettiği değerler arasındaki ilişkiyi belirtir. Modellerin başarısı için R2'nin 1 yakın olması gerekir. Bu kayıp fonksiyonları fonksiyonların değerlerini en aza indirerek modelin kalitesini en üste çıkarmak için kullanılır.



4. BULGULAR

Tez çalışmasının bulgular bölümünde 3 farklı veri seti üzerinde yapılan 2 farklı yaş tayini çalışmalarının sonuçları verilmiştir. Derin öğrenmede yüksek kaynak ihtiyacına vardır. Yüksek kaynak ihtiyaçlarını karşılamak için Google Colaboratory kullanılmıştır. Google Colaboratory; yapılandırma gerektirmeyen, GPU'lara ücretsiz erişim imkânı sunan Google'ın geliştiricilere sunduğu ücretsiz bulut servisi. Tablo 4.1'de Tez çalışmasında veri seti üzerine uygulanan derin öğrenme modellerinin uygulandığı platformlar ve donanımsal yeterlilikler verilmiştir.

Kaggle Google'ın bir yan kuruluşudur. Veri bilimcileri, makine öğrenimi, derin öğrenme vb alanlarında çalışan toplulukları bir araya getiren, bu konularda çalışan kişilere gerekli donanım alt yapısını sunan çevrimiçi bir topluluktur. Bu alanlarda çalışan kişilere donanım alt yapısı sunmakla beraber kişilerin veri kümelerini yüklemesine ve paylaşmasına olanak tanır. Python ve R dillerinde çevrimiçi kod yazılmasına ve çalıştırılmasına olanak sunar. Bu dillerde ve alanlarda farklı yarışmalar düzenleyerek kullanıcıların öğrenmesine yardımcı olan bir platformdur.

Tablo 4.1. Tez çalışmasında derin öğrenme modellerinin uygulandığı platformlar ve donanımsal yeterlilikler

Donanım	RAM	GPU	Ekran Kartı
Google Colab	13.342 GB	Tesla K80 GPU	NVIDIA T4 GPUs
Kaggle	16 GB	Tesla P100-PCIE	NVIDIA

4.1. 18 Yaş Altı Bireylerde Kemik Yaşı Tespiti Deneysel Sonuçları

Bu çalışma için KRV ve RSNA veri seti için elde edilen görüntülerin boyutlarının her birinin farklı boyutlarda olduğu tespit edilmiştir. Derin öğrenme transfer metotlarında sıklıkla kullanılan ve tavsiye edilen görüntü boyutlarının 128, 256, 299 olduğu görülmektedir. Görüntü boyutlarının bu değerlere küçültüldüğünde görüntü içerisindeki değerli bilgilerin kaybolduğu ve sonuçların istenilen seviyede olmadığı tespit edilmiştir. El bilek grafi görüntülerinin boyutları 300 piksel üzerine boyutlandırıldığında ise bellek (RAM) problemleri ile karşılaşmıştır. Bu çalışmada görüntülerdeki ayırt edici piksellerin kaybolmaması için görüntüler 512*512 olarak boyutlandırılmıştır. Bu ölçekte resimleri RAM'de sorun çıkarmadan tutulup işleyebilmesi için özel veri üreteç metodu (imagedatagenerator) yazılmıştır. Bu metotta her adımda 512*512 boyutlarında en fazla

32 resim alınıp işlenmiştir. Daha fazla resim alındığında ram hatası alındığı için tüm modeller de yığın büyüklüğü 32 olarak alınmıştır. Bu özel veri üretmeç metodu ile RAM'e tüm görüntüleri yüklemek yerine her döngü sayısında (epoch) belirlenen görüntü adedi sisteme yüklenmiştir. Böylelikle görüntülerdeki değerli bilgilerin kaybolması engellenmiş ve karşılaşılan RAM problemi ortadan kaldırılmıştır.


Görüntüler farklı açılardan çekildiği için görüntülere keras kütüphanesinde yer alan imagedatagenerator işlemi uygulanmıştır. imagedatagenerator sınıfı veri üreticidir ve bu sınıf ile veriler çeşitlendirilmektedir. Veri çeşitlendirmesinde eğitim veri seti için; kullanılan transfer öğrenme modelinin normalleştirme metodu, -5, +5 arası döndürme, %10 büyütme ve %10 oranında yatay ve dikey kaydırma, işlemleri uygulanmıştır. Doğrulama ve test veri seti için ayrılan görüntülere sadece transfer öğrenme modelinin normalleştirme metodu işlemi uygulanmıştır. InceptionV3, EfficientNetB4, MobileNetV2 ve modifiye edilmiş InceptionV3 derin transfer yöntemleri ile kemik yaşı tahmini gerçekleştirilmiştir. InceptionV3 modeli, 2017 tarihinde Kaggle tarafından düzenlenen RSNA 2017 Pediatrik Kemik Yaşı makine öğrenimi yarışmasında en başarılı model olarak karşımıza çıkmıştır. Bu çalışmada InceptionV3 modeli modifiye edilerek tarafımızca oluşturulan veri seti için daha başarılı bir model haline getirilmiştir. Modellerin performanslarını değerlendirmek için MAE, RMSE ve R2 ölçütleri kullanılmıştır. KRV veri setindeki 5301 görüntünün 3710 (%70) adedi eğitim, 796 (%15) adedi doğrulama ve 795 (%15) adedi ise test amaçlı kullanılmıştır. RSNA veri seti için ise veri setindeki 12621 adet görüntünün 8835 (%70) adedi eğitim, 1893 (%15) adedi doğrulama ve 1893 (%15) adedi ise test amaçlı kullanılmıştır.

Optimizasyon fonksiyonu olarak ADAM ve aktivasyon fonksiyonu olarak ELU kullanıldığında 4 farklı derin öğrenme modeline ait test veri seti için elde edilen başarı performans değerleri Tablo 4.2'de verilmiştir. Yöntemler KRV ve RSNA veri setlerine ayrı ayrı uygulanmıştır.


Tablo 4.2. Transfer öğrenme modellerine göre sonuçlar

	KRV veri seti üzerinde			RSNA Veri Seti üzerinde		
Modeller	MAE	RMSE	R2	MAE	RMSE	R2
InceptionV3	11,18	14,1	0,970	5,9	8,22	0,974
Modifiye edilmiş InceptionV3	4,3	5,76	0,99	5,75	7,42	0,96
MobileNetV2	6,35	9,12	0,956	8,7	10,31	0,938
EfficientNetB4	5,42	7,15	0,970	9,4	12,44	0,870

Tablo 4.2'ye bakıldığında RSNA veri seti için yapılan yarışmada en başarılı model olan InceptionV3 derin transfer modeli ile MAE=5,9, RMSE=8,22 ve R2=0,974 performans değerleri elde edilmiştir. Aynı modelin KRV veri seti için ise MAE=11,18, RMSE=14,1 ve R2=0,974 değerleri elde ettiği gözlenmiştir. Önerdiğimiz modifiyeli InceptionV3 derin transfer modeli ile RSNA veri seti için MAE=5,75, RMSE=7,42 ve R2=0,96 değerleri elde edilmiştir. KRV veri seti için ise MAE=4,3, RMSE=5,76 ve R2=0,99 değerleri gözlenmiştir. Tablo 4.2'de RSNA ve KRV veri setleri için MobileNetV2 ve EfficientNetB4 derin transfer yöntemlerinin performans başarıları gösterilmiştir. Tablo 4,2'den görüleceği üzere InceptionV3 modelinin diğer modellerden daha başarılı olduğu görülmektedir. Ancak InceptionV3 modelinin farklı veri setine göre başarı sonuçlarının değişkenlik gösterdiği görülmektedir. Bu çalışmada modifiye edilmiş InceptionV3 ile her iki veri seti için diğer yöntemlerin tümünden daha başarılı sonuçlar elde edilmiştir. 4 modelden en kötü performansı MobileNetV2 derin transfer yöntemi göstermiştir. Eğitim aşamasında KRV veri seti için modifiyeli InceptionV3 modelinin kayıp değerlerini (Loss) gösteren grafik Şekil 4.1 ve MAE değerlerinin değişimini gösteren grafik Şekil 4.2'de verilmiştir.



Şekil 4.1. KRV veri seti için Modifiyeli InceptionV3 modeline ait loss grafiği



Şekil 4.2. KRV veri seti için Modifiyeli InceptionV3 modeline ait MAE grafiği

Modifiyeli InceptionV3 modeli için KRV veri setinden rastgele seçilen birkaç örneğe ait görüntülere ait gerçek yaş ve tahmin edilen yaş bilgileri Şekil 4.3'te verilmiştir.

Gerçek Yaşı Aylık : 191
Tahmin Edilen : 194.9
Cinsiyet : Erkek

Gerçek Yaşı Aylık : 202
Tahmin Edilen : 205.7
Cinsiyet : Kadın

Gerçek Yaşı Aylık : 214
Tahmin Edilen : 212.7
Cinsiyet : Kadın




Gerçek Yaşı Aylık : 32
Tahmin Edilen : 32.6
Cinsiyet : Kadın

Gerçek Yaşı Aylık : 81
Tahmin Edilen : 76
Cinsiyet : Kadın

Gerçek Yaşı Aylık : 111
Tahmin Edilen : 104
Cinsiyet : Kadın

Gerçek Yaşı Aylık : 118
Tahmin Edilen : 121
Cinsiyet : Erkek




Şekil 4.3. KRV veri seti için Modifiyeli InceptionV3 yöntemi ile elde edilen tahmin sonuçlarına ait birkaç görüntü

Optimizasyon fonksiyonu olarak SGD kullanıldığında yukarıda ki çalışmada en iyi sonucu veren modifiye edilmiş InceptionV3 modelinin sonuçları Tablo 4.3'te gösterilmiştir.


Tablo 4.3. Optimizasyon fonksiyonu olarak SGD kullanıldığında önerilen modelin başarısı

KRV veri seti üzerinde			
Modeller	MAE	RMSE	R2
Modifiyeli InceptionV3	7,24	10,16	0,91

Modifiye edilmiş InceptionV3 modelinin SGD optimizasyon fonksiyonu ile yapılan çalışmalarında elde edilen MAE ve kayıp fonksiyonlarına ait görseller şekil 4.4 ve şekil 4.5'te gösterilmiştir.




Şekil 4.4. Modifiyeli InceptionV3 modelinde SGD optimizasyon fonksiyonunun kullanımı sonucu MAE grafiği




Şekil 4.5. Modifiyeli InceptionV3 modelinde SGD optimizasyon fonksiyonunun kullanımı sonucu kayıp grafiği

KRV veri seti için Modifiyeli InceptionV3 modelinin SGD optimizasyon fonksiyonunun kullanımı sonucu gerçek ve tahmin ettiği değerlere ait sonuçlar Şekil

4.6’da verilmiştir. Modifiye edilmiş InceptionV3 modelinin SGD optimizasyon fonksiyonu ile yapılan çalışmalarında KRV veri setinden rastgele seçilen birkaç örneğe ait görüntülere ait gerçek yaş ve tahmin edilen yaş bilgileri Şekil 4.7’de gösterilmiştir.



Şekil 4.6. KRV veri seti için Modifiyeli InceptionV3 modelinin SGD optimizasyon fonksiyonunun kullanımı sonucu gerçek ve tahmin ettiği değerlere ait sonuçları



Şekil 4.7. KRV veri seti için Modifiyeli InceptionV3 modelinin SGD optimizasyon fonksiyonunun kullanımı sonucu elde edilen tahmin sonuçlarına ait birkaç görüntü


Optimizasyon fonksiyonu olarak ADAM fonksiyonunun daha iyi olduğu tespit edildikten sonra kullanılan yapay sinir ağlarında kullanılan aktivasyon fonksiyonu olarak daha önce ki çalışmalarda ELU kullanılmıştır. Bundan sonraki çalışmamızda optimizasyon fonksiyonu olarak ADAM, kayıp fonksiyonu olarak MAE kullanılmıştır.

Bu çalışmada KRV veri seti üzerinde ELU yerine RELU kullanılır ise sonuçların ne olacağı görülmeye çalışılmıştır. Önerilen modelde katmanlarda RELU kullanıldığında elde edilen sonuçlar Tablo 4.4'te gösterilmiştir.


Tablo 4.4. Aktivasyon fonksiyonu olarak RELU kullanıldığında önerilen modelin başarısı

KRV veri seti üzerinde			
Modeller	MAE	RMSE	R2
Modifiyeli InceptionV3	4,39	5,56	0,97


Modifiye edilmiş InceptionV3 modelinin yapay sinir katmanlarında aktivasyon fonksiyonu olarak RELU kullanıldığında elde edilen MAE ve kayıp fonksiyonlarına ait görseller şekil 4.8 ve şekil 4.9’da gösterilmiştir. Ayrıca bu modelin test veri seti üzerinde ki başarısı şekil 4.10’da verilmiş olup bu modelin test veri setinde ki birkaç görüntü üzerinde ki gerçek ve tahmin edilen görselleri şekil 4.11’de gösterilmiştir.




Şekil 4.8. Modifiyeli InceptionV3 modelinde RELU aktivasyon fonksiyonu kullanımı sonucu MAE grafiği



Şekil 4.9. Modifiyeli InceptionV3 modelinde RELU aktivasyon fonksiyonu kullanımı sonucu kayıp grafiği



Şekil 4.10. Modifiyeli InceptionV3 modelinin RELU aktivasyon fonksiyonunu kullanması sonucu gerçek ve tahmin ettiği değerlere ait sonuçları



Şekil 4.11. Modifiyeli InceptionV3 modelinin RELU aktivasyon fonksiyonunu kullanması sonucu elde edilen tahmin sonuçlarına ait birkaç görüntü

Model üzerinde yapılan hiperparametre optimizasyonlarından görüleceği gibi optimizasyon fonksiyonu olarak ADAM fonksiyonu ile yapılan çalışma sonuçlarının SGD optimizasyon fonksiyonu ile yapılan çalışma sonuçlarına göre daha etkili ve verimli olduğu tespit edilmiştir.

Aktivasyon fonksiyonu olarak RELU fonksiyonu yaygın olarak kullanılmaktadır. Hiperparametre optimizasyonu yapılırken yapay sinir ağlarında kullandığımız aktivasyon fonksiyonu olarak RELU'ya alternatif olarak önerilen ELU fonksiyonu ile çalışmalar yapılmış ve sonuçlar karşılaştırılmıştır. Buna göre aktivasyon fonksiyonu olarak RELU ve ELU birbirine çok yakın sonuçları tespit etmemizi sağlamıştır. ELU fonksiyonun çok az bir miktarda RELU fonksiyonundan daha başarılı olduğu gözlemlenmiştir.

Bundan sonra yapılan deneylerde optimizasyon fonksiyonu olarak ADAM, aktivasyon fonksiyonu olarak ELU kullanılmıştır.

En iyi sonucu elde ettiğimiz eğitilmiş modelin KRV veri seti üzerinde yaş gruplarına ve cinsiyetlerine göre farklılık gösterip göstermediğini ölçmek için deneyler yapılmıştır. Buna göre elde edilen sonuçlar Tablo 4.5'te gösterilmiştir.


Tablo 4.5. KRV veri seti için önerilen modelin cinsiyete göre yaş grup performansı

Yaş aralığı	0-5		5-10		10-15		15-18	
Cinsiyet	E	K	E	K	E	K	E	K
MAE	4,51	2,87	5,44	4,97	4,2	4,8	4,7	5,02
RMSE	5,24	3,5	6,8	7,6	6,3	6,34	6,2	6,35
R2	0,76	0,94	0,79	0,8	0,8	0,83	0,55	0,43


Hsieh ve ark. (2007), 9 yaşından küçük bireylerde karpal özelliklerin sınıflandırma hatalarını etkili bir şekilde azaltabileceğini ortaya koymuştur. Karpal özelliklerin, çocuklar 10 yaşına kadar büyüdüğünde KYT'yi değerlendirmek için daha az etkili olacağını, (Liu ve ark., 2008) yaptığı çalışmada karpal kemik sınıflandırmasında 9 yaş altındaki çocuklar için sınıflandırma hatalarının azaldığını, 10 yaşın üzerinde ise sınıflandırma hatalarının azalmadığını belirtilmiştir. Zhang ve ark. (2007), yaptığı çalışmada erkek çocuklar için 5.5 yaşından, kız çocukları için 4 yaşından itibaren kemik yaşı tespitinde tutarsızlıkların olduğunu diğer karpal kemiklerinde dikkate alınmasının başarı oranının arttıracağını ifade etmiştir. Pietka ve ark. (2003), kızlarda kemik yaşı ve kronolojik yaş hatasının ortalama farkının yüksek olmasının nedeninin, epifasal füzyon infalanjları tamamlandıktan sonra (yani 15-16 yaşında) olduğunu ifade etmiştir. Tablo 4.5'ten görüleceği üzere bu tespitlere uygun sonuçların elde edildiği gözlemlenmiştir. 0-5 yaş aralığında kız çocuklarında erkeklere göre daha başarılı sonuçlar elde edilmiştir. 5-10 yaş aralığında her iki cinsiyetin benzer sonuçlar verdiği tespit edilmiştir. 10-15 yaş üzerinde kemik yaşı tespitinde kızlara göre erkeklerde nispeten biraz daha başarılı sonuçlar elde edilmiştir. 15 yaş üzerinde ise erkeklerin yaş tahminin kızlara göre daha az hata payı ile tespit edildiği gözlemlenmiştir.

Şekil 4.12'de KRV veri seti ile erkeklere ait görüntülerden modifiye edilmiş InceptionV3 modelinin performans ölçütlerine göre sonuçları grafik üzerinde gösterilmiştir. Şekil 4.13'te KRV veri seti ile kızlara ait görüntülerden modifiye edilmiş

InceptionV3 modelinin performans ölçütlerine göre sonuçları grafik üzerinde gösterilmiştir.




Şekil 4.12. KRV veri setinde erkeklere ait performans sonuçlarının grafiği




Şekil 4.13. KRV veri setinde kızlara ait performans sonuçlarının grafiği

Şekil 4.14'te RSNA veri seti ile yapılan çalışmalarda modifiyeli InceptionV3 modeline ait MAE grafiği ve şekil 4.15'te RSNA veri seti ile yapılan çalışmalarda modifiyeli InceptionV3 modeline ait kayıp grafiği gösterilmiştir.




Şekil 4.14. RSNA veri seti için modifiyeli InceptionV3 modeline ait MAE grafiği



Şekil 4.15. RSNA veri seti için modifiyeli InceptionV3 modeline ait loss grafiği

Modifiyeli InceptionV3 modeli için RSNA veri setinden rastgele seçilen birkaç örneğe ait görüntülere ait gerçek yaş ve tahmin edilen yaş bilgileri Şekil 4.16'da verilmiştir.




Şekil 4.16. RSNA veri seti için modifiyeli InceptionV3 yöntemi ile elde edilen tahmin sonuçlarına ait birkaç görüntü

KRV veri seti üzerinde yaş gruplarına göre yapılan çalışma RSNA veri seti üzerinde de yapılmıştır. Buna göre Tablo 4.6’da görüleceği üzere 0-5 yaş aralığında erkek çocuklarında kızlara göre daha başarılı sonuçlar elde edilmiştir. 5-10 yaş aralığında kız çocuklarında erkek çocuklara göre daha başarılı sonuçlar elde edilmiştir. 10-15 yaş üzerinde kemik yaşı tespitinde önerilmiş Inception modelinin erkek veri seti üzerinde ki başarısı kızlara göre daha başarılı sonuçlar elde edilmiştir. 15 yaş üzerinde ise erkeklerin kızlara göre daha az hata payı ile sonuçları tespit ettiği gözlemlenmiştir.


Şekil 4.17’de RSNA veri seti üzerinde erkeklere ait görüntülerden modifiye edilmiş InceptionV3 modelinin performans ölçütlerine göre sonuçları grafik üzerinde gösterilmiştir. Şekil 4.18’de RSNA veri seti üzerinde kızlara ait görüntülerden modifiye edilmiş InceptionV3 modelinin performans ölçütlerine göre sonuçları grafik üzerinde gösterilmiştir.

Tablo 4.6. RSNA veri seti için önerilen modelin cinsiyete göre yaş grup performansı

Yaş aralığı	0-5		5-10		10-15		15-18	
Cinsiyet	E	K	E	K	E	K	E	K
MAE	4,88	5,26	5,99	5,46	4,13	4,46	4,64	6,0
RMSE	6,42	7,02	8,14	7,27	5,86	6,2	6,32	7,5
R2	0,61	0,43	0,76	0,75	0,86	0,84	0,7	0,43



Şekil 4.17. RSNA veri setinde erkeklere ait performans sonuçlarının grafiği




Şekil 4.18. RSNA veri setinde kızlara ait performans sonuçlarının grafiği


18 yaş altında ki bireylerin kemik yaşlarının gruplara göre performanslarına bakıldığında RSNA veri seti için Modifiye edilmiş Inception modelinin erkek veri seti üzerinde ki performansının kızlara ait veri setine göre daha başarılı sonuçlar elde ettiği tespit edilmiştir.

Grad-CAM yöntemi; CNN mimarilerinde, eğitilmiş modelin görüntüler üzerinde tahmin yaparken modelin ilgilendiği önemli bölgeleri göstermek amacıyla kullanılmaktadır. CNN'nin son evrişim katmanındaki değerleri kullanarak tahminleme yapılır. Böylelikle son katmandaki özellik haritalarından ısı haritası oluşturularak modelin yoğun olarak ilgilendiği bölgeler görselleştirilir. Bu aşamada tahminleme yaparken en iyi sonucu elde ettiğimiz modifiye edilmiş InceptionV3 modelinin veri seti üzerinde en iyi sonuçları bulurken elde ettiği başarıyı Grad-CAM (Gradientweighted Class Activation Mapping) yöntemi kullanılarak görselleştirilmiştir

Şekil 4.19 ve şekil 4.20'de El bilek grafilerine göre eğitilmiş modifiyeli IncepitonV3 modelinin tahminleme yaparken odaklandığı bölgelerin ısı haritası gösterilmiştir.



Şekil 4.19. KRV veri seti için modifiye edilmiş Inception V3 Modeline ait ısı haritası örneği (Grad-CAM)




Şekil 4.20. RSNA veri seti için modifiye edilmiş Inception V3 Modeline ait ısı haritası örneği

Yukarıda verilen çalışmalarda ki tüm modellere cinsiyet olarak adlandırdığımız 32 filtreden oluşan bir katman eklenmiştir. Bu katmanın temel amacı görüntülerde ki cinsiyetlerin model tarafından ayırt edilmesi ve öğrenmesini sağlamaktır. Bu katmanın olmaması durumunda modelin başarısını ölçmek için çalışmalar yapılmıştır. İki farklı veri seti üzerinde en başarılı sonuçları elde ettiğimiz modifiyeli InceptionV3 modelimizden cinsiyet katmanını çıkarıp deneysel sonuçlara bakıldığında sonuçların önceki sonuçlara göre çok fazla etkilendiği ve önceki sonuçlara göre performansın bir hayli düştüğü tespit edilmiştir. Tablo 4.7’de RSNA veri seti için önerilen modelin cinsiyet katmanı olmadan ve daha önce cinsiyet katmanı eklenerek elde ettiği performans sonuçları verilmiştir.


Tablo 4.7. Önerilen modelin cinsiyet katmanına göre performans sonuçları

	Cinsiyet katmanı eklendiğinde	Cinsiyet katmanı olmadan
MAE	5,75	7,93
RSNA	7,42	10,76
R²	0,96	0,93

Şekil 4.21 ve şekil 4.22’de modifiyeli InceptionV3 modelinin cinsiyet katmanı olmadan elde ettiği MAE ve loss değerlerine ait grafikler gösterilmiştir.




Şekil 4.21. Cinsiyet katmanı olmadan modifiyeli InceptionV3 modelinin MAE grafiği




Şekil 4.22. Cinsiyet katmanı olmadan modifiyeli InceptionV3 modelinin loss grafiği

Şekil 4.23'te cinsiyet katmanı olmadan modifiyeli InceptionV3 modelinin gerçek yaşlara ve tahmin ettiği yaşlara ait performans grafiği verilmiştir.




Şekil 4.23. Cinsiyet katmanı olmadan modifiyeli InceptionV3 modelinin gerçek ve tahmin ettiği değerlere ait başarı grafiği

Şekil 4.24’te cinsiyet katmanı olmadan Modifiyeli InceptionV3 modelinin RSNA veri seti üzerinde ki birkaç görüntüye ait gerçek değerler ile tahmin ettiği değerlere ait sonuçları görüntüler üzerinde vermiştir.




Şekil 4.24. Cinsiyet katmanı olmadan modifiyeli InceptionV3 modelinin gerçek ve tahmin ettiği değerlere ait sonuçlar


Bu çalışmada modifiyeli InceptionV3 modelinin her iki veri setine uygulandıktan sonra eğitim, doğrulama ve test setleri için elde edilen performans grafikleri Şekil 4.25 - 4.27’de gösterilmiştir. Grafikler gerçek yaş bilgisi ile tahmin edilen yaş bilgisi arasındaki hata ve hata dağılımlarını göstermektedir. Şekil 4.28’de ise eğitim, doğrulama ve test setleri için gerçek yaş değerleri ile tahmin edilen yaş değerleri arasındaki regresyon grafikleri gösterilmiştir. Regresyon belirleme katsayısı grafikleri tahmin değerlerinin gerçek değerlere ne kadar yakın tahmin edildiğini belirtmektedir.




Şekil 4.25. KRV Eğitim seti için performans değerleri



Şekil 4.26. KRV doğrulama seti için performans değerleri



Şekil 4.27. KRV Test seti için performans değerleri



Şekil 4.28. KRV Eğitim, doğrulama ve test setleri için regresyon grafikleri


Literatürde kemik yaşı tahmini için birçok çalışmanın yapıldığı gözlemlenmiştir. Son yıllarda derin öğrenme tabanlı yaklaşımların kullanıldığı görülmektedir. Yapılan çalışmalarda modellerin başarısı genellikle MAE ölçütü üzerinden değerlendirilmiştir. Yapılan bir kısım çalışmalar Tablo 4.8’de verilmiştir. Yapılan çalışmalara ait sonuçlar ile bu çalışmada önerilen yaklaşım ile elde edilen sonuçlar karşılaştırıldığında önerilen yaklaşım ile başarılı sonuçlar elde edildiği görülmektedir.

Tablo 4.8. Kemik yaşı tahmini ile ilgili yapılan çalışmalar

Yazarlar	Metot	Veri Seti	MAE
(Iglovikov ve ark., 2017)	U-Net	RSNA	7,52
(Spampinato ve ark., 2017)	BoNet	DHA	9,6
(Castillo ve ark., 2018)	VGG-16	RSNA	9,82 – 10,75
(Pan ve ark., 2020)	U-Net	RSNA	8,59
(Chen ve ark., 2021)	Xception	RSNA	7,3
(Lee ve Kim, 2018)	CaffeNet	RSNA	18,9
(Zhao ve ark., 2020)	DenseNet	RSNA	5,78±1,3
(Cao ve ark., 2019)	U-Net	RSNA	6,24±3
(Lee ve ark., 2017)	InceptionV3	XRBAE	RMSE =0,82 – 0,93
(Mutasa ve ark., 2018)	VGG-16	Mabal	6,43 ± 7,64
(Chen ve ark., 2020)	ResNet	China Medical University	Accuracy=%78
(Son ve ark., 2019)	VGGNet	Korean children	5,52
(Bui ve ark., 2019)	InceptionV4	DHA	7,44
Bu çalışma	Modifiyeli InceptionV3	RSNA KRV	5,75 4,3


Tablo 4.8’e bakıldığında bu çalışmada kullanılan RSNA veri seti üzerinde yapılan çalışmalar arasında önerdiğimiz modelin en başarılı sonuçları elde eden modellerinden biri olduğu görülmektedir. Ayrıca önerdiğimiz modelin ülkemizde ki hastalardan temin edilen veri seti üzerinde çok başarılı sonuçlar elde ettiği gözlemlenmiştir.

Şekil 4.29’da verilen grafikten görüleceği üzere Modifiyeli InceptionV3 modelinin KRV test verileri üzerindeki başarısı eğri üzerinde gösterilmiştir. Grafikten görüleceği üzere gerçek değerler ve modelin tahmin ettiği değerler birbirine yakındır.



Şekil 4.29. Modifiye edilmiş InceptionV3 modelinin KRV test verileri üzerinde başarısı

Şekil 4.30'da verilen grafikten görüleceği üzere Modifiyeli InceptionV3 modelinin RSNA test verileri üzerindeki başarısı eğri üzerinde gösterilmiştir. Grafikten görüleceği üzere gerçek değerler ile modelin tahmin ettiği değerler birbirine yakın derecede seyir göstermiştir.



Şekil 4.30. Modifiye edilmiş InceptionV3 modelinin RSNA test verileri üzerinde başarısı

4.2. 18 Yaş Üstü Bireyler İçin Deneysel Sonuçlar

Bu çalışmada kemik yaşı tahmini (KYT) için Kütahya ilindeki 3 ilçe ve il merkezi olmak üzere 4 farklı hastaneden görüntüler temin edilmiştir. Bu veri seti, kadın ve erkeklerden oluşan yaşları 19-85 aralığında değişen toplam 8589 örnek görüntü içermektedir. Görüntüler derin öğrenme modellerine verilmeden önce belirli bir ön işleminden geçirilmiştir. Öncelikle görüntülerin her biri farklı boyutlarda olduğu için bu görüntülerin tamamı aynı boyutlara getirilmiştir. Derin öğrenme transfer metotlarında görüntü boyutları genellikle derin transfer metotlarına göre farklılık gösterse de genel olarak 128,256 ve 299 olarak ölçeklendirilmesi tavsiye edilmektedir. Bu çalışmada görüntüler tavsiye edilen boyutlara indirildiğinde sonuçların istenilen düzeyde olmadığı tespit edilmiştir. El bilek grafi görüntülerinin boyutları 300 piksel üzerine ölçeklendirildiğinde ise bellek (RAM) problemleri ile karşılaşmıştır. Bu çalışmada görüntülerdeki ayırt edici piksellerin kaybolmaması için görüntüler 512x512 olarak boyutlandırılmıştır. Bu ölçekte resimleri RAM’de sorun çıkarmadan tutup işleyebilmek için özel veri üreteç metodu yazılmıştır. Bu özel veri üreteç metodu ile sisteme tüm görüntüleri yüklemek yerine her epoch’ta belirlenen görüntü adedi kadar görüntü sisteme yüklenmiştir. Böylelikle görüntülerdeki değerli bilgilerin kaybolması engellenmiş ve karşılaşılan RAM problemi ortadan kaldırılmıştır. Fakat bu yöntemin de dezavantajı modelin eğitim süresinin uzun sürmesidir.

Görüntüler farklı hastanelerden, farklı açılardan çekildiği için ve bu görüntülerin aynı standartlarda işlenmesi için görüntülere veri artırma işlemi uygulanmıştır. Veri artırmada eğitim veri seti için; kullanılan transfer öğrenme modelinin normalleştirme metodu (preprocess_input), -10, +10 arası döndürme, %10 büyütme ve %10 oranında yatay ve dikey kaydırma, parlaklık değeri [0.8, 1.2] ve büyütme değeri %10 olacak şekilde işlemler uygulanmıştır. Doğrulama ve test veri seti veri seti için; ayrılan görüntülere sadece transfer öğrenme modelinin normalleştirme metodu (preprocess_input) işlemi uygulanmıştır. InceptionV3, DenseNet201 ve ResNet50V2 derin transfer yöntemlerin performanslarını değerlendirmek için MAE, RMSE ve R2 ölçütleri kullanılmıştır. KYRV veri setindeki görüntüler cinsiyete bağlı olarak farklı derin öğrenme metotları ile eğitilmiştir. 3 farklı derin transfer modelinin eğitim, doğrulama ve test veri seti için elde ettiği başarı performans değerleri Tablo 4.9 - 4.11’de verilmiştir.

Tablo 4.9. Eğitim veri seti için transfer öğrenme modellerin başarı oranları

	InceptionV3		DenseNet201		ResNet50V2	
	Erkek	Kadın	Erkek	Kadın	Erkek	Kadın
MAE	1,387	2,016	1,381	1,819	1,899	2,065
RMSE	2,002	2,819	1,992	2,575	2,692	2,957
R²	98,36	97,25	98,40	97,83	97,72	96,85

Tablo 4.9’da eğitim veri seti için en uygun modelin DenseNet201 olduğu görülmektedir. Hem erkek hem de kadınlar için kişinin yaşını tahmin etmede DenseNet201 modelinin diğer modellere (InceptionV3 ve ResNet50V2) göre daha başarılı performans sonuçları göstermiştir. Erkekler için DenseNet201 ile MAE=1,381, RMSE=1,992, R²=98,40 ve kadınlar için MAE=1,389, RMSE=2,575, R²=97,83 başarı oranları gözlenmiştir. Erkekler için elde edilen performans değerlerinin kadınlara göre daha yüksek olduğu görülmüştür. DenseNet201 modelinin kişilerin yaşını tahmin etmede en başarılı model olduğu ancak InceptionV3 modelinin de DenseNet201 modelinin başarısına yakın bir performans başarısı gösterdiği gözlemlenmiştir. Eğitim veri seti üzerinde yapılan çalışmalarda derin transfer modelleri arasında ResNet50V2 modelinin en kötü performansı gösterdiği gözlemlenmiştir.

Tablo 4.10. Doğrulama veri seti için transfer öğrenme modellerin başarı oranları

	InceptionV3		DenseNet201		ResNet50V2	
	Erkek	Kadın	Erkek	Kadın	Erkek	Kadın
MAE	1,698	2,360	1,667	2,195	2,112	2,573
RMSE	2,493	3,369	2,463	3,180	2,979	3,482
R²	97,48	96,14	97,45	96,60	96,64	96,06

Tablo 4.10’da doğrulama veri seti için en başarılı modelin DenseNet201 olduğu görülmüştür. Hem erkek hem de kadınlar için kişinin yaşını tahmin etmede DenseNet201 modelinin, diğer modellere göre daha başarılı performans sonuçları elde edilmiştir. Erkekler için DenseNet201 modeli ile MAE=1,667, RMSE=2,463, R²=97,45 ve kadınlar için MAE=2,195, RMSE=3,180, R²=96,60 başarı oranları gözlemlenmiştir. Erkekler için elde edilen performans değerleri kadınlara göre daha başarılı bulunmuştur. Doğrulama

veri seti için Densenet201 modeli ile kişilerin yaşını tahmin etmede InceptionV3 modeli ile ResNet50V2 modeline göre daha başarılı sonuçlar elde edilmiştir.

Tablo 4.11. Test veri seti için transfer öğrenme modellerin başarı oranları


	InceptionV3		DenseNet201		ResNet50V2	
	Erkek	Kadın	Erkek	Kadın	Erkek	Kadın
MAE	1,686	2,113	1,666	2,044	2,128	2,289
RMSE	2,640	3,225	2,665	3,069	3,104	3,442
R²	97,28	96,09	97,32	96,84	96,71	95,42

Tablo 4.11’de test veri seti için en uygun modelin DenseNet201 olduğu görülmektedir. Hem erkek hem de kadınlar için kişinin yaşını tahmin etmede DenseNet201 modelinin diğer modellere (InceptionV3 ve ResNet50V2) göre daha başarılı sonuçlar gösterdiği görülmüştür. Erkekler için DenseNet201 modeli ile MAE=1,666, RMSE=2,665, R²=97,32 ve kadınlar için MAE=2,044, RMSE=3,104, R²=96,84 başarı oranları gözlemlenmiştir. Erkekler için elde edilen performans değerleri kadınlara göre daha başarılı bulunmuştur. DenseNet201 modelinin kişilerin yaşını tahmin etmede en başarılı model olduğu bununla birlikte InceptionV3 modelinin de gayet başarılı olduğu tespit edilmiştir. Test veri seti üzerinde yapılan çalışmalarda derin transfer modelleri arasında ResNet50V2 modelinin en kötü performansı gösterdiği gözlemlenmiştir.


Tablo 4.9 – 4.11’den görüldüğü gibi eğitim, doğrulama ve test veri setlerinde kemik yaşı tespiti için en başarılı modelin DenseNet201 olduğu görülmüştür. Ancak diğer modellerin de kabul edilebilir başarılı sonuçlar elde edilmiştir. Tüm modellere ait eğitim, doğrulama ve test setleri için regresyon grafikleri Şekil 4.31 – 4.33’te verilmiştir. Regresyon belirleme katsayısı grafikleri tahmin değerlerinin gerçek değerlere ne kadar yakın tahmin edildiğini belirtmektedir.

Test veri seti için gerçek yaş değerleri ile tahmin edilen değerler arasındaki serpmeye grafikleri Şekil 4.31 – 4.36’da verilmiştir. Grafikler erkek ve kadınlar için ayrı ayrı verilmiştir. Grafiklerden görüldüğü gibi DenseNet201, InceptionV3 ve ResNet50V2 modelleri ile kişilerin yaşını tahmin etmede çok yüksek başarılı sonuçların elde edildiği görülmektedir. El bilek grafilerinden kemik yaşının tespiti için literatürde yapılmış çalışmaya rastlanmamıştır. Tablo 4.11’den görüleceği üzere 18 yaş üstü hastalarda kemik


yaşı tespiti için DenseNet201 modeli hem kadın hem de erkeklerde en iyi performans sonucu göstermiştir. Tercih edilen modeller arasında en kötü performansı ResNet50V2 derin transfer yöntemi göstermiştir.




Şekil 4.31. DenseNet201 için erkek ve kadınlara ait regresyon grafikleri




Şekil 4.32. InceptionV3 için erkek ve kadınlara ait regresyon grafikleri




Şekil 4.33. ResNet50V2 için erkek ve kadınlara ait regresyon grafikleri



Şekil 4.34. DenseNet201 ile test seti için erkek ve kadınlara ait gerçek yaş değerleri ile tahmin edilen yaş değerleri




Şekil 4.35. InceptionV3 ile test seti için erkek ve kadınlara ait gerçek yaş değerleri ile tahmin edilen yaş değerleri



Şekil 4.36. ResNet50V2 ile test seti için erkek ve kadınlara ait gerçek yaş değerleri ile tahmin edilen yaş değerleri


Veri setinden rastgele seçilen erkek ve kadınlara ait birkaç örnek görüntüye ait gerçek yaş değerleri ile DenseNet201 modelin tahmin ettiği yaş değerleri Şekil 4.37’de gösterilmiştir.



Şekil 4.37. Cinsiyete göre bazı örneklerle ait gerçek yaşlar ve DenseNet201 modelinin tahmin ettiği yaşlar

Şekil 4.38’de erkek ve kadın bireylere ait örnek görüntüler için eğitilen DenseNet201 modelinin görüntülerde odaklandığı noktaların ısı haritası (Grad-CAM) gösterilmiştir. Grad-CAM yöntemi transfer derin öğrenme mimarilerinde, eğitilmiş modelin görüntüler üzerinde tahmin yaparken modelin ilgilendiği önemli bölgeleri göstermek amacıyla kullanılmaktadır. CNN’nin son evrişim katmanındaki değerleri kullanarak tahminleme yapılır. Böylelikle son katmandaki özellik haritalarından ısı haritası oluşturularak modelin yoğun olarak ilgilendiği bölgeler görselleştirilir. Bu

aşamada tahminleme yaparken en iyi sonucu elde ettiğimiz DenseNet201 modelinin veri seti üzerinde en iyi sonuçları bulurken elde ettiği başarısı Şekil 4.38’de Grad-CAM yöntemi kullanılarak görselleştirilmiştir.



Şekil 4.38. Erkek ve Kadın hastalar için DenseNet201 modelinin ısı haritası

Erişkin yaş tahmininde manuel ve otomatik yöntemler kullanılmaktadır. Tablo 4.12’de yapılan çalışmalarda kullanılan manuel yöntemler ve başarı performansları gösterilmiştir.

Tablo 4.12. Erişkin yaş tayininde dental grafilerden manuel yöntemlerle başarı oranları

Yazar(lar)	Veri seti	N	Yaş Aralığı		Metot	AE Years	Anatomic Region
(Kvaal ve ark., 1995)	Private	100	20	87	manuel	9	Dental x-rays
(Drusini, 2008)	Private	433	9	76	manuel	5	Dental x-rays
(Hatice ve ark., 2017)	Private	200	20	75	manuel	9,23	Dental x-rays
(Akay ve ark., 2020)	Private	800	18	60	manuel	5,64	Dental x-rays

Erişkin yaş değerlendirmesinde kullanılan, manuel yöntemlerin başarı oranları daha düşüktür, her bir birey için değerlendirme zamanı çok daha fazladır, ayrıca tahmini yaşı yıl olarak değil dekadlar olarak aralık halinde verirler. El bilek grafisinde alınan radyasyon dozu, OPG grafilere oranla çok daha düşüktür.

Tablo 4.13'te ise derin öğrenme modellerinin kullanıldığı farklı yöntem ve başarı performansları verilmiştir.

Tablo 4.13. Erişkin yaş tayininde derin öğrenme yöntemleri başarı oranları

Yazar(lar)	Veri seti	Anatomic Region	N	Yaş Aralığı	En iyi sonucu veren Model	MAE(Yıl)
(Vila-Blanco ve ark., 2020)	Private-OPG	Teet	2289	4-89	DASNet	2,83
(Othmani ve ark., 2020)	Public-CASIA-Web face dataset.	Face	494	1-74	Xception	2,01
(Xing ve ark., 2017)	Public-MORPH II-face dataset	Face	55134	16-77	NET VCGhybrid	2,96
Bu Çalışma	Original KYRV	Hand x-rays	8677	19-85	DenseNet201	1,666

18 yaş üzeri yaş tayininde derin öğrenme yöntemleri ile genellikle halka açık yüz görüntülerine ait veri setleri üzerinde çalışılmıştır. OPG grafileri ile yapılmış bir çalışma mevcuttur. El bilek grafisi ile yapılan çalışma ise bildiğimiz kadarıyla literatürde mevcut değildir. Tablo 4.13'ten görüldüğü üzere bu çalışmada kullandığımız DenseNet201 modeli ile çalışmamız en düşük MAE değerleri ile en başarılı sonuçları vermiştir.

Osteoporoz (Kemik erimesi) kemiklerde mikro yapıda bozulmaya ve bunun sonucunda etkilenen hastalarda kırıklara neden olabilen kemik yoğunluğundaki

azalmaz. Dünya apında yaklaşık 200 milyon insanı etkileyen, metabolik hastalıkların en sık g r len formudur. Yaşlanma osteoporoz ve osteopeni (d ş k kemik yoğunluęu) iin ana risk fakt rlerinden biridir. Erkekler ve kadınlar yaşılanmayla kemik yoğunluęu kaybetme eęilimindedir, ancak bu s re kadınlar daha gen yaşıta ve erkeklere g re daha hızlıdır. Osteoporoz kadınlarda erkeklerden 4 kat daha sık g r l r.  zetle 50 yaşıını geen kadınlarda erkeklere oranla osteoporoz 4 kat osteopeni 2 kat daha sık g r l r (Alswat, 2017). 18 yaşı  st  alıřmamızda erkeklerin kemik yaşıının tespitinin kadınlara g re daha bařarılı olmasının sebebi olarak kadınlarda kemik yaşı erimesinin erkeklere oranla daha fazla olması olabilirlięidir.



5. TARTIŞMA VE SONUÇ

Kişinin nüfus cüzdanında ki doğum tarihi ile hesaplanan yaşı kronolojik yaşıdır. Kemik yaşı, kişinin biyolojik ve kemiksel gelişiminin göstergesidir. Kemik yaşı kronolojik yaştan farklıdır. Kemik yaşı, çocuklarda uzun veya kısa boy ile sonuçlanan hastalıkların teşhisi için kronolojik yaşla karşılaştırılarak bu problemi teşhis etmek için çocuk doktorları ve endokrinologlar tarafından sıklıkla istenir. Pediyatrik hastalarda büyümeyi değerlendirmek, çok sayıda endokrin bozukluğu ve pediatrik sendromu teşhis etmek ve yönetmek için kemik yaşı değerlendirmesi sıklıkla yapılmaktadır.

Adli tıp uygulamalarında cezai sorumluluğun tespiti, hukuki ehliyeteye haiz olup olmadığı, işlediği eylemin hukuksal manasını ve önemini kavrama, maruz kalınan cinsel saldırı olaylarına karşı kendini ruhsal yönden koruyup koruyamayacağının tespiti, suç işleme fiilinde bulunmuş zanlılarda, şüpheli ölümler, bebek cesetleri, kendini ifade edemeyecek durumdaki kişiler ve kimliği belirsiz kişilerde yaş tespitinin yapılması gerekebilmektedir. Askere alınma, memuriyete girme, evlenme, emeklilik, okula çağında, sürücü belgesine başvuru durumlarında kişinin yaşının bilinmesi gerekmektedir. Yaş tayinine ülkemizin kırsal kesimlerde özellikle sağlıklı doğum ve nüfus kayıtlarının olmamasından kaynaklı başvurular sıklıkla yapılmaktadır. Özetle kişilerin yargıya yansıyan olaylarda ve insanların sosyal ilişkilerinde yaş tespiti büyük öneme sahiptir (Gök ve ark., 1985b; Aykaç, 1987; Çöloğlu, 1987; Schmeling ve ark., 2000; Koc ve ark., 2001; Bilgin ve ark., 2003; Büken ve ark., 2003; Isır ve Dulger, 2007). Bireysel olarak gerçek yaşını öğrenme isteği gibi durumlarda, tedavi uygulanacak hastanın tedavi protokolünün seçilmesinde, uygulanacak ameliyat yönteminin belirlenmesinde, ilaçların belli yaşlara uygun olarak başlanmasında, hasta onayı alınırken kişinin 18 yaşından büyük olması gibi tıbbi uygulamalarda ayrıca bireyin yaşı önemli olduğundan yaş tahminin yapılması da önemli bir duruma gelmiştir (DAŞ, 2019). Çocuk hastalarda büyüme gelişimin takip edilmesi önemlidir. Kronolojik yaşa göre çocuğun bilinç derecesi, ağırlığı, boyu ve dişlerinin sayısı değerlendirilmektedir. Aynı ırk, cinsiyet ve yaştaki bireyler arasında fizyolojik farklılıklar olabilir. Bu nedenle bazı bireylerin biyolojik yaşı kronolojik yaşına göre farklılık gösterebilir. Çocuğun gelişim durumunun belirlenmesi, normal gelişimden farklılıkların tespitine varılması, tedavi seçimi, tedaviye zamanında başlama gibi konularda biyolojik yaş temel alınmaktadır (Hägg ve Taranger, 1980; Saini, 2013).

Onlarca yıldır, yaygın olarak kemik olgunluğunun belirlenmesi için Greulich ve Pyle, Tanner-Whitehouse, Gök atlası vb atlaslar kullanılarak, el ve bileğin iskelet gelişiminin görsel bir değerlendirmesine dayanıyordu.

Medikal görüntülerde ve yapay zekada ki teknolojik gelişmeler ile birlikte, iskelet olgunluğu değerlendirmelerine daha etkili, verimli ve objektif bir yaklaşım sağlamak için el bilek kemiklerindeki kemikleşmenin temel morfolojik özelliklerini otomatik olarak çıkaran görüntü işleme teknikleri geliştirmek için çok sayıda girişimde bulunulmuştur. Bunların bir kısmı literatür bildirişleri kısmında anlatılmıştır. Bununla birlikte, kemik yaşını otomatik olarak gösterebilen bilgisayar algoritmalarının tasarımı, el ve el bileğindeki çok sayıda kemikleşme merkezinde ki kemik gelişiminin temposu, şekli ve boyutundaki geniş varyasyonları değerlendirmenin karmaşıklığı yüzünden zora girmiştir. Evrişimsel sinir ağları (ESA) bu problemlerin giderilmesinde önemli katkılar sağlamıştır.

Bu çalışmada ESA teknolojisini kullanan transfer öğrenme modelleri kullanılarak el bilek görüntülerinden kemik yaşının tespitine yönelik karar destek sistemi geliştirilmiştir.

Tez çalışmasında 2 farklı kemik yaşı tespiti yapılmıştır. Birincisi literatürde var olan ve üzerinde çalışmalar yapılan 18 yaş altında ki kişilerin kemik yaşı tespitine dönük olarak yapılmış çalışmadır. Diğer ise tarafımızca oluşturulan veri setidir. Bu çalışmanın ana katkısı ülkemizde ki 18 yaş altında ki bireylerin görüntülerinin toplanması ve bu görüntüler üzerinde yapılan ilk derin öğrenme çalışmalardan biri olmasıdır. Bununla ülkemizde ki ve açık kaynak olarak dağıtılan ABD'ye ait el bilek görüntülerinin kıyaslanması sağlanmıştır.

İkinci olarak yapılan çalışma ise; 18 yaş üzerinde ki bireylerin kemik yaşının tespitine yönelik olarak yapılan çalışmadır. Bu çalışma;18 yaş üzerinde ki bireylerin kemik yaşının derin öğrenme modelleri ile tespit edilmesine yönelik olarak yapılan ilk çalışma özelliğini barındırmaktadır. Bu iki çalışmanın sonuçları aşağıda verilen 2 farklı başlıkta detaylı olarak verilmiştir.

5.1. 18 Yaş Altı

Tıbbi görüntülerde yenilikçi teknolojiler sıklıkla kullanılmaktadır. Bu teknolojiler kişilerin görüntülerdeki problemleri daha doğru tespit etmede ve zamandan kazanmalarına yardımcı olmaktadır. Bu tez çalışmasında yenilikçi teknolojilerden olan derin öğrenme yöntemleri kullanılarak el bilek grafiplerinden yaş tespitinin yapılması için

uzmanlara yardımcı olacak bir karar destek sistemi geliştirilmiştir. Çalışmada el bilek grafilerinden 18 yaşın altındaki kişilerin yaş tespitini yapacak bir karar destek sistemi geliştirmek için Kütahya ilinde bulunan 4 hastaneden elde edilen 5301 görüntü kullanılmıştır. Görüntülerin eğitilmesi için derin öğrenme metotlarından InceptionV3, EfficientNetB4, MobileNetV2 ve modifiye edilmiş InceptionV3 transfer öğrenme modelleri kullanılmıştır. Çalışmamızda kullandığımız modellerin ve önerdiğimiz modelin performansını ölçmek için daha önce el bilek grafileri üzerine yapılan bir yarışmada kullanılan ve halka açık olarak dağıtılan 12621 görüntüden oluşan RSNA veri seti ve tarafımızca oluşturulmuş KRV veri seti üzerinde yapılan çalışmalar sonucunda elde edilen performans sonuçları değerlendirilmiş ve modellerin performansları kıyas yapılmıştır. Her iki veri seti ile yapılan çalışmalarda önerdiğimiz derin öğrenme modeli ile en başarılı sonuçlar elde edilmiştir. KRV veri setinde bulunan görüntüler üzerinde modifiyeli InceptionV3 modeli ile MAE=4,3, RMSE=5,76 ve R2=0,99 (Tablo 4.2), RSNA veri seti için modifiyeli InceptionV3 modeli ile MAE=5,75, RMSE=7,42 ve R2=0,96 (Tablo 4.2) değerleri elde edilmiştir. Bu tez çalışması; ülkemiz özelinde toplanan ilk el bilek grafileri ile yapılan çalışma özelliğini taşımaktadır. Elde ettiğimiz veri seti üzerinde ki modelimizin başarısını test etmek için public olarak dağıtılan RSNA veri seti kullanılmış ve önerilen modelin bu veri seti üzerinde de Tablo 4.8'ten görüleceği üzere literatürde yapılan çalışmalar arasında ki en iyi sonuçlardan birini gösterdiği tespit edilmiştir. Bu sonuçlar bize önerdiğimiz modelin her iki veri seti için kullanılabileceği ve en optimal değerlere yakın sonuçlar elde edebileceğimizi göstermiştir.

Ayrıca iki farklı veri seti üzerinde eğitilmiş modellerin cinsiyetlere göre farklı yaş grupları üzerinde ki etkileri araştırılmıştır. Cinsiyetlerin yaş gruplarına göre farklı performans gösterdikleri tespit edilmiştir. KRV veri seti için 0-5, 5-10, 10-15 ve 15-18 yaş grupları üzerinde yapılan çalışmalarda (Tablo 4.5);

- ✓ 0-5 yaş aralığında kız çocuklarında erkeklere göre daha başarılı sonuçlar elde edilmiştir.
- ✓ 5-10 yaş aralığında her iki cinsiyetin benzer sonuçlar verdiği ancak kız çocuklarının daha az hata ile yaşlarının tespit edildiği gözlenmiştir.
- ✓ 10-15 yaş aralığında kemik yaşı tespitinde erkek çocukların yaşlarının kız çocuklara göre biraz daha az hata ile tespit edildiği gözlenmiştir.
- ✓ 15 yaş üzerinde ise erkeklerin kızlara göre nispeten daha az hata ile yaşlarının tespit edildiği gözlemlenmiştir.

RSNA veri seti ile 0-5, 5-10, 10-15 ve 15-18 yaş grupları üzerinde yapılan çalışmalarda (Tablo 4.6);

- ✓ 5-10 yaş aralığında kız çocukların erkek çocuklarına göre daha başarılı sonuçlar elde edilmiştir.
- ✓ Diğer yaş gruplarının tamamında erkek çocukların performansı kız çocuklarına göre daha başarılı olduğu gözlemlenmiştir.

18 yaş altında KRV ve RSNA veri setleri ile yapılan çalışmalarda özellikle yaş gruplarına göre cinsiyetlere göre modellerin farklı veri setlerinde farklı sonuçlar gösterdiği tespit edilmiştir. Özellikle 0-5 yaş aralığında iki farklı veri setinin çok farklı sonuçlar verdiği tespit edilmiştir. 5-18 yaş aralığında ki çocukların yaş tespiti her iki veri setinde benzer olduğu gözlemlenmiştir. Farklı veri setlerinde aynı yaş gruplarında modellerin farklı sonuç vermesinin sebebi olarak çocukların özellikle farklı coğrafyalarda olmalarından kaynaklı olarak, beslenme alışkanlıkları, gelişim süreçleri, coğrafya vb sebeplerden dolayı olduğu düşünülmektedir.

İnsan gelişiminde çevresel faktörlerin etkilediği şekillenmenin sonucu olarak bireylerin el bilek grafilerinin farklı olduğu bilinmektedir. Bu çalışma ile derin öğrenme yöntemlerinin bu farklılığı giderebileceği veya yakınlaştıracabileceği görüşü ele alınmış ve bu tez çalışması yapılmıştır. Modellerin farklı veri setleri üzerinde ki başarılarına bakıldığında farklı bölgelerde/çevrelerde yetişen bireylerin el bilek grafilerinden derin öğrenme yöntemleri ile kemik yaşının tespit edilebileceği görülmüştür. Bu sonuçlar ışığında kemik yaşı tespitinde derin öğrenme metodlarının; farklı çevresel faktörlerden kaynaklı ortaya çıkan problemlerin çözümünde en optimal değerleri elde edebileceği gözlemlenmiştir.

Ülkemizde yoğun olarak yaşanan göç olaylarından kaynaklı olarak bir ihtiyaç haline gelen kemik yaşı tespiti için bir atlasın oluşturulması ve bu atlas üzerinde yapılan eğitilmiş bir modelin uzmanlara yardımcı olması için bir karar destek sistemi geliştirilmiştir. Bu çalışma ile birlikte yoğun olarak yapılan kemik yaşı tespitinde hekimlerin ve adli tıp uzmanlarının harcadığı zamanı azaltmak ve günümüz şartlarına uygun, hızlı, ekonomik, mekândan bağımsız her yerden ulaşılabilen ve daha doğru sonuçlar üreten bir karar destek sistemi geliştirilmiştir.

5.2. 18 Yaş Üstü

Tıbbi görüntülemede birçok yeni teknolojiler kullanılmaktadır. Bu teknolojiler özellikle karar destek sistemi olarak doğru tanıyı arttırmakta ve iş yükünü azaltıp zamandan kazanmalarına yardımcı olmaktadır. Bu tez çalışmasında derin öğrenme yöntemleri kullanılarak el bilek grafilerinden 18 yaş üstündeki kişilerin yaş tespiti için uzmanlara yardımcı olacak bir karar destek sistemi geliştirilmiştir. Bunun için Kütahya ilinde bulunan 4 hastaneden elde edilen 8589 görüntü kullanılmıştır. Görüntülerin eğitilmesi için derin transfer öğrenme metotlarından InceptionV3, DenseNet201 ve ResNet50V2 transfer öğrenme modelleri kullanılmıştır. Bu modellerin tercih edilmesinin nedeni ise daha önce yapılan çalışmalarda başarılı sonuçlar elde edilen modeller olması ve bu modellerin parametre sayısına yakın olan diğer modellerin başarılarını ölçmek için tercih edilmiştir. Çalışmada el bilek grafilerinden yaş tespiti erkek ve kadınlar için ayrı ayrı gerçekleştirilmiştir. Çalışmamızın performansını ölçmek için kullanılan derin transfer öğrenme yöntemlerinden DenseNet201 modeli ile en yüksek sonuçlar elde edilmiştir. Test seti için erkeklere ait görüntülerden MAE=1,666, RMSE=2,665, R2=97,32 (Tablo 4.11) performans sonuçları gözlemlenmiştir. Kadınlara ait görüntüler için ise MAE=2,044, RMSE=3,069, R2=96,84 (Tablo 4.11) sonuçları elde edilmiştir. 18 yaş üstündeki hastalardan toplanan görüntülerden elde edilen veri seti üzerinde kemik yaşı tespiti için 3 farklı model ile yapılan çalışmada sol el bilek grafilerinin, çalışma ortamına ve cinsiyete göre farklılık gösterdiği ve bu farklılığın model üzerinde farklı sonuçların elde edilmesine neden olduğu tespit edilmiştir. Tez çalışmasının bu kısmında yapılan çalışmanın literatürde ilk kez yapıldığı, erişkinlerde sol el bilek grafisi ile kemik yaşının tespitine dönük daha önce benzer bir çalışmanın yapıldığı literatür taramasından tespit edilememiştir. Tez çalışmasının bu kısmının uzun yaş aralıkları içeren atlas ve dental skorlama yöntemlerinden çok daha başarılı olduğu gözlemlenmiştir. Özellikle 18 yaş üzerinde kemik yaşı tespitinde yeni bir yöntem olabileceği düşünülmektedir. Çalışmanın karar destek sistemine evrilmesiyle erişkin bireylerde kemik yaşı tespiti yapan tüm hekimlere önemli bir yardımcı araç olacağı, iş gücü kaybını önleyeceği, yaş tespitinde çok daha başarılı sonuçların almasına yardım sağlayacağı aşikardır.

18 yaş üstü modellerde erkeklerin kemik yaşı tahmin sonuçları, kadınların kemik yaşı tespit sonuçlarına göre daha başarılı sonuçlar ortaya çıkardığı tespit edilmiştir. Bunun nedenlerine bakıldığında kadınların özellikle 40 yaş üzerinde menapoza girmiş

olabileceği ve menapoza giren kadınların el bilek kemiklerinin birbirine yaklaştığı ve kaynadığı bilindiğinden buna sebep olabileceği düşünülmektedir. Bu durum ispat etmek için bazı araştırmaların yapılması gerektiğine inanıyoruz.

Bu heyecan verici çalışma, yetişkinler için kemik yaşı tespitinde el bilek grafilerinin kullanılabilmesini göstermektedir. Bu yeni keşfin uygulanabilirliği için gidilecek uzun bir yol var, örneğin çalışmanın sosyoekonomik olarak farklı şartlarda yetişen kişiler, farklı ırklar ve coğrafyalar üzerinde çalışmalar yapılması ve sonuçlarının paylaşılması gerekmektedir. Yetişkinlerin kemik yaşı tespiti için uzman radyolog arkadaşımız ile sürekli ortaklık içinde tespit ettiğimiz bu yeni keşif ile Kemik yaşı tespitinin herkes için daha erişilebilir hale getirerek radyologların kullanımına sunmuş bulunmaktayız.

Tez çalışmasında kullanılan modellerin sonuçlarına bakıldığında; InceptionV3 ve DenseNet modellerinin daha yeni olan modellere (EfficientNetB4, MobileNetV2) göre daha başarılı sonuçlar elde ettiği tespit edilmiştir. Bunun sebebinin yeni ve modern olan modellerin ImageNet görüntüleri üzerinde daha uyumlu olduğu düşünülmektedir. Mevcut sonuçlar bize eski derin öğrenme modellerinin tıp alanında ki veriler üzerinde daha başarılı sonuçlar verebileceğini göstermektedir.

KAYNAKÇA

- Akay, G., Karataş, M. S., Karadağ, Ö., Gungor, K. and Üçok, C. Ö., 2020. An application for Olze's method and tooth coronal index for age estimation of a Turkish adult population, *Australian Journal of Forensic Sciences*, 52(6), 699–710.
- Akinoğlu, B. G. ve Ecevit, A., 1990. A further comparison and discussion of sunshine-based models to estimate global solar radiation, *Energy*, 15(10), 865–872.
- Alswat, K. A., 2017. Gender Disparities in Osteoporosis, *Journal of Clinical Medicine Research*, 9(5), 382–387.
- Anonim, 2020. *Anonim*. <https://webders.net/908/noron-nedir.html> [Ziyaret Tarihi: 25 Mart 2021].
- Aykaç, M., 1987. Adli tıp ders kitabı 1. baskı, *İstanbul Tıp Fakültesi*, İstanbul, 1-471.
- Bakirci, K., 2009. Correlations for estimation of daily global solar radiation with hours of bright sunshine in Turkey, *Energy*, 34(4), 485–501.
- Baransel Isır, A., 2009. Adli Hekimlikte Yaş Tayini, *Klinik Gelişim*, 22(18), 114–121.
- Batur Dinler, Ö. and Aydın, N., 2020. An optimal feature parameter set based on gated recurrent unit recurrent neural networks for speech segment detection, *Applied Sciences (Switzerland)*, 10(4).
- Bengio, Y., 2009. Learning deep architectures for AI, *Foundations and Trends in Machine Learning*, 2(1), 1–27.
- Bilgin, N., Çekin, N., Korkut, M. K. ve Alper, B., 2003. Çukurova Üniversitesi Tıp Fakültesi Adli Tıp Anabilim Dalı'na başvuran yaş tayini olgularının retrospektif değerlendirilmesi, *Mersin Üniv. Tıp Fak. Dergisi*, (2), 140–144.
- Black, S., Aggrawal, A. ve Payne-James, J., 2010. Age Estimation in the Living: The Practitioner's Guide, *Wiley Blackwell*, 1–299.
- Boyunağa, Ö., 2002. Radyolojik Olarak Kemik Yaşı Tayini, *Klinik Pediatri*, 1(2), 81–85.
- Brewka, G., 1996. Artificial intelligence—a modern approach by Stuart Russell and Peter Norvig, Prentice Hall. Series in Artificial Intelligence, Englewood Cliffs, NJ., *The Knowledge Engineering Review*, 11(1), 78–79.
- Bui, T. D., Lee, J. J. and Shin, J., 2019. Incorporated region detection and classification using deep convolutional networks for bone age assessment, *Artificial Intelligence in Medicine*, 97, 1–8.
- Büken, B., Demir, F. ve Büken, E., 2003. 2001-2003 yılları arasında Abant İzzet Baysal üniversitesi düzce tıp fakültesi adli tıp anabilim dalı'na gönderilen yaş tayini olgularının analizi ve adli tıp pratiğinde karşılaşılan güçlükler, *Düzce Tıp Fakültesi Dergisi*, 2(5), 18–23.
- Büken, B., Erzen, Ö. U., Büken, E., Şafak, A. A., Yazici, B. ve Erkol, Z., 2009.

- Comparison of the three age estimation methods: Which is more reliable for Turkish children?, *Forensic Science International*, 183(1–3), 103.e1-103.e7.
- Büken, B., Şafak, A. A., Büken, E., Yazici, B., Erkol, Z. ve Erzengin, Ö. U., 2010. Is the tanner-whitehouse (TW3) method sufficiently reliable for forensic age determination of Turkish children?, *Turkish Journal of Medical Sciences*, 40(5), 797–805.
- Büken, B., Şafak, A. A., Yazici, B., Büken, E. and Mayda, A. S., 2007. Is the assessment of bone age by the Greulich-Pyle method reliable at forensic age estimation for Turkish children?, *Forensic Science International*, 173(2–3), 146–153.
- Cao, F., Huang, H. K., Pietka, E. and Gilsanz, V., 2000. Digital hand atlas and web-based bone age assessment: System design and implementation, *Computerized Medical Imaging and Graphics*, 24(5), 297–307.
- Cao, S., Chen, Z., Li, C., Lv, C., Wu, T. and Lv, B., 2019. Landmark-based multi-region ensemble convolutional neural networks for bone age assessment, *International Journal of Imaging Systems and Technology*, 29(4), 457–464.
- Carney, M., Webster, B., Alvarado, I., Phillips, K., Howell, N., Griffith, J., Jongejan, J., Pitaru, A. and Chen, A., 2020. Teachable machine: Approachable web-based tool for exploring machine learning classification, *Conference on Human Factors in Computing Systems - Proceedings*.
- Castillo, J. C., Tong, Y., Zhao, J. ve Zhu, F., 2018. RSNA Bone-age Detection using Transfer Learning and Attention Mapping, http://noiselab.ucsd.edu/ECE228_2018/Reports/Report6.pdf, [Ziyaret Tarihi: 25 Ocak 2021].
- Chang, C.-H., Hsieh, C.-W., Jong, T.-L. and Tiu, C.-M., 2003. A fully automatic computerized bone age assessment procedure based on phalange ossification analysis, *Proc IPPR*, 16(October), 463–468.
- Chen, C., Chen, Z., Jin, X., Li, L., Speier, W. F. and Arnold, C., 2021. Attention-Guided Discriminative Region Localization and Label Distribution Learning for Bone Age Assessment, *IEEE Journal of Biomedical and Health Informatics*, 26(3), 1208-1218, doi: 10.1109/JBHI.2021.3095128
- Chen, X., Li, J., Zhang, Y., Lu, Y. and Liu, S., 2020. Automatic feature extraction in X-ray image based on deep learning approach for determination of bone age, *Future Generation Computer Systems*, 110, 795–801.
- Çöloğlu, A. S., 1987. Kemik ve diş gelişimini etkileyen faktörler yaş tayini çalışmalarındaki önemi, *Adli Tıp Dergisi*, 3(1–4), 117–122.
- Cunningham, C., Scheuer, L. and Black, S., 2016. Developmental Juvenile Osteology: Second Edition, *Developmental Juvenile Osteology: Second Edition*, Academic press
- Dallora, A. L., Berglund, J. S., Brogren, M., Kvist, O., Ruiz, S. D., Dübbel, A. ve Anderberg, P., 2019. Age assessment of youth and young adults using magnetic

- resonance imaging of the knee: A deep learning approach, *JMIR Medical Informatics*, 7(4).
- Dang, T. D. Q., Che, H. V. G. and Dinh, T. B., 2018. Mobile multi-scale vehicle detector and its application in traffic surveillance, *ACM International Conference Proceeding Series*, 265–272.
- Daş, V., 2019. Suriyeli mülteci 18 yaş altı evlilerde kemik yaşının tespitinde gök, greulich-pyle ve tanner-whitehouse atlaslarının kullanılabilirliğinin değerlendirilmesi ve sosyodemografik özellikleri, Uzmanlık Tezi, *Gaziantep Üniversitesi Tıp Fakültesi*, Gaziantep, 1-101.
- Demirel, P., 2005. El Antropometrik Ölçümleri ve El Kavrama Kuvvetinin Farklı Spor Branşlarında Karşılaştırılması, Yüksek Lisans Tezi, *Zonguldak Karaelmas Üniversitesi Sağlık Bilimleri Enstitüsü*, Zonguldak.
- Devecioğlu, J., Arslan, S. G., Dar, O. ve Özer, T., 2006. Erkek Bireylerde Servikal Vertebra Kemik Yaşının Kronolojik ve İskelet Yaş ile Karşılaştırılması, *Dicle Tıp Dergisi*, 33(1), 36–41.
- Dogan, Y. ve Keles, H. Y., 2020. Semi-supervised image attribute editing using generative adversarial networks, *Neurocomputing*, 401.
- Dong, N., Zhao, L., Wu, C. H. ve Chang, J. F., 2020. Inception v3 based cervical cell classification combined with artificially extracted features, *Applied Soft Computing*, 93, 106311.
- Drusini, A. G., 2008. The coronal pulp cavity index: A forensic tool for age determination in human adults, *Cuadernos de Medicina Forense*, (53–54), 235–249.
- Dumoulin, V. and Visin, F., 2016. A guide to convolution arithmetic for deep learning, 1–31. arXiv preprint *arXiv:1603.07285*
- Ersoy, E. ve Karal, Ö., 2012. Yapay sinir ağları ve insan beyni, *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2), 188–205.
- Fausett, L., 1990. Fundamentals of Neural Networks Architectures, Algorithms, and Applications, Pearson Education, India
- Garn, S. M. and Rohmann, C. G., 1960. Variability in the order of ossification of the bony centers of the hand and wrist, *American Journal of Physical Anthropology*, 18(3), 219–230.
- Garn, S. M. ve Tanner, J. M., 1986. Assessment of Skeletal Maturity and Prediction of Adult Height (TW2 Method), *WB Saunders, Man*, London.
- Gertych, A., Zhang, A., Sayre, J., Pospiech-Kurkowska, S. ve Huang, H. K., 2007. Bone age assessment of children using a digital hand atlas, *Computerized Medical Imaging and Graphics*, 31(4–5), 322–331.
- Giordano, D., Leonardi, R., Maiorana, F., Scarciofalo, G. and Spampinato, C., 2007. Epiphysis and metaphysis extraction and classification by adaptive thresholding and

- DoG filtering for automated skeletal bone age analysis, *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, 6551–6556.
- Gök, Ş., Erölçer, N. ve Özen, C., 1985a. Adli Tıpta yaş tayini, *Adli Tıp Müessesesi Yayınları no 1*, İstanbul.
- Gök, Ş., Erölçer, N. ve Özen, C., 1985b. Adli tıpta yaş tayini. 2. baskı, *Adli Tıp Müessesesi Yayınları no 1*, İstanbul.
- Gollapudi, S., 2019. Deep Learning for Computer Vision, *Learn Computer Vision Using OpenCV*. Berkeley, CA, 51–69.
- Goodfellow I., Bengio Y., Courville, A., 2016. Deep Learning - Ian Goodfellow, Yoshua Bengio, Aaron Courville - Google Books, *MIT Press*, 800.
- Greulich, W. W., 1950. The Rationale of Assessing the Developmental Status of Children from Roentgenograms of the Hand and Wrist, *Child Development*, 21(1), 33.
- Greulich, W. W. and Pyle, S. I., 1959. Radiographic Atlas of Skeletal Development of the Hand and Wrist, *The American Journal Of The Medical Sciences*, 238(3), 393.
- Güllüpinar, F., 2012. Göç Olgusunun Ekonomi-Politigi ve Uluslararası Göç Kuramları Üzerine Bir Değerlendirme, *Yalova Sosyal Bilimler Dergisi*, Nisan-Eylül(4), 53–85.
- Gungor, O. E., Celikoglu, M., Kale, B., Gungor, A. Y. and Sari, Z., 2015. The reliability of the Greulich and Pyle atlas when applied to a Southern Turkish population, *European Journal of Dentistry*, 9(2), 251–254.
- Gurses, M. S., Inanir, N. T., Soylu, E., Gokalp, G., Kir, E. and Fedakar, R., 2017. Evaluation of the ossification of the medial clavicle according to the Kellinghaus substage system in identifying the 18-year-old age limit in the estimation of forensic age—is it necessary?, *International Journal of Legal Medicine*, 131(2), 585–592.
- Hägg, U. and Taranger, J., 1980. Skeletal stages of the hand and wrist as indicators of the pubertal growth spurt, *Acta Odontologica Scandinavica*, 38(3), 187–200.
- Haiter-Neto, F., Kurita, L. M., Menezes, A. V. and Casanova, M. S., 2006. Skeletal age assessment: A comparison of 3 methods, *American Journal of Orthodontics and Dentofacial Orthopedics*, 130(4), 435.e15-435.e20.
- Han, Y. and Wang, G., 2020. Skeletal bone age prediction based on a deep residual network with spatial transformer, *Computer Methods and Programs in Biomedicine*, 197.
- Hao, P., Chokuwa, S., Xie, X., Wu, F., Wu, J. and Bai, C., 2019. Skeletal bone age assessments for young children based on regression convolutional neural networks, *Mathematical Biosciences and Engineering*, 16(6), 6454–6466.
- Harmsen, M., Fischer, B., Schramm, H., Seidl, T. and Deserno, T. M., 2013. Support vector machine classification based on correlation prototypes applied to bone age assessment, *IEEE Journal of Biomedical and Health Informatics*, 17(1), 190–197.

- Hasaltın, E. ve Beřtok, E., 2004. El – bilek röntgen görüntülerinden radyolojik kemik yaşı tespitinde yapay sinir ağıları kullanımı, *Elektrik-Elektronik ve Bilgisayar Mühendisliğı Sempozyumu*. Bursa, 8–12.
- Hatice, B. D., Nihal, A., Nursel, A., Humeyra Ozge, Y. and Goksuluk, D., 2017. Applicability of Cameriere's and Drusini's age estimation methods to a sample of Turkish adults, *Dento maxillo facial radiology*, 46(7), 20170026.
- He, K., Zhang, X., Ren, S. and Sun, J., 2016. Identity mappings in deep residual networks, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 630–645.
- Hinton, G. E., 2007. Learning multiple layers of representation, *Trends in Cognitive Sciences*, 428–434.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. and Adam, H., 2017. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications.
- Hsieh, C. W., Jong, T. L. and Tiu, C. M., 2007. Bone age estimation based on phalanx information with fuzzy constrain of carpals, *Medical and Biological Engineering and Computing*, 45(3), 283–295.
- Hsieh, C. W., Liu, T. C., Jong, T. L. and Tiu, C. M., 2010. A fuzzy-based growth model with principle component analysis selection for carpal bone-age assessment, *Medical and Biological Engineering and Computing*, 48(6), 579–588.
- Huang, G., Liu, Z., Van Der Maaten, L. and Weinberger, K. Q., 2017. Densely connected convolutional networks, *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, 2261–2269.
- Iglovikov, V., Rakhlin, A., Kalinin, A. A. and Shvets, A., 2017. Pediatric bone age assessment using deep convolutional neural networks, *bioRxiv*.
- İř, H., 2021. Sosyal ağlarda etkileřime dayalı davranıř analizi ile karakter tespiti, Doktora Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, 1-130.
- Isır, A. B. ve Dulger, H. E., 2007. 1998-2005 Yılları Arasında Gaziantep Üniversitesi Adli Tıp Anabilim Dalında Raporlandırılan Yař Tayini Olgularının İrdelenmesi, *Türkiye Klinikleri Dergisi*, 4, 1–6.
- Jantan, S., Hussain, A. and Mustafa, M. M., 2010. Distal radius bone age estimation based on fuzzy model, *Proceedings of 2010 IEEE EMBS Conference on Biomedical Engineering and Sciences, IECBES 2010*, 427–432.
- Kashif, M., Deserno, T. M., Haak, D. and Jonas, S., 2016. Feature description with SIFT, SURF, BRIEF, BRISK, or FREAK? A general question answered for bone age assessment, *Computers in Biology and Medicine*, 68, 67–75.
- Kim, H. J. and Kim, W. Y., 2007. Computerized bone age assessment using DCT and LDA, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 440–448.

- King, D. G., Steventon, D. M., O’Sullivan, M. P., Cook, A. M., Hornsby, V. P. L., Jefferson, I. G. and King, P. R., 1994. Reproducibility of bone ages when performed by radiology registrars: An audit of Tanner and Whitehouse II versus Greulich and Pyle methods, *British Journal of Radiology*, 67(801), 848–851.
- Kızrak, M. A. ve Bolat, B., 2018. Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma, *Bilişim Teknolojileri Dergisi*, 263–286.
- Koc, A., Karaoglanoglu, M., Erdogan, M., Kosecik, M. and Cesur, Y., 2001. Assessment of bone ages: Is the Greulich-Pyle method sufficient for Turkish boys?, *Pediatrics International*, 43(6), 662–665.
- Korkut, M., Tüzün, B., Korkut, S. ve Çakmak, Y., 2001. Ülkemizde Adli Tıp Uygulamalarında Karşılaşılan Güçlükler ve Çözüm Önerileri, *Klinik Adli Tıp*, (1), 9–21.
- Kurt, F., 2018. 17. Evrişimli sinir ağlarında hiper parametrelerin etkisinin incelenmesi, Yüksek Lisans Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, 1-130.
- Kvaal, S. I., Kolltveit, K. M., Thomsen, I. O. and Solheim, T., 1995. Age estimation of adults from dental radiographs, *Forensic Science International*, 74(3), 175–185.
- Larson, D. B., Chen, M. C., Lungren, M. P., Halabi, S. S., Stence, N. V. and Langlotz, C. P., 2018. Performance of a deep-learning neural network model in assessing skeletal maturity on pediatric hand radiographs, *Radiology*, 287(1), 313–322.
- Lecun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning, *Nature*, 521(7553), 436–444.
- Lee, H., Tajmir, S., Lee, J., Zissen, M., Yeshiwas, B. A., Alkasab, T. K., Choy, G. and Do, S., 2017. Fully Automated Deep Learning System for Bone Age Assessment, *Journal of Digital Imaging*, 30(4), 427–441.
- Lee, J. H. ve Kim, K. G., 2018. Applying deep learning in medical images: The case of bone age estimation, *Healthcare Informatics Research*, 24(1), 86–92.
- Lee, K. C., Lee, K. H., Kang, C. H., Ahn, K. S., Chung, L. Y., Lee, J. J., Hong, S. J., Kim, B. H. and Shim, E., 2021. Clinical validation of a deep learning-based hybrid (Greulich-pyle and modified tanner-whitehouse) method for bone age assessment, *Korean Journal of Radiology*, 22(12), 2017–2025.
- Li, Y., Huang, Z., Dong, X., Liang, W., Xue, H., Zhang, L., Zhang, Y. and Deng, Z., 2019. Forensic age estimation for pelvic X-ray images using deep learning, *European Radiology*, 29(5), 2322–2329.
- Liang, B., Zhai, Y., Tong, C., Zhao, J., Li, J., He, X. and Ma, Q., 2019. A deep automated skeletal bone age assessment model via region-based convolutional neural network, *Future Generation Computer Systems*, 98, 54–59.
- Lippmann, R. P., 1987. An Introduction to Computing with Neural Nets, *IEEE ASSP Magazine*, 4(2), 4–22.

- Liu, J., Qi, J., Liu, Z., Ning, Q. and Luo, X., 2008. Automatic bone age assessment based on intelligent algorithms and comparison with TW3 method, *Computerized Medical Imaging and Graphics*, 32(8), 678–684.
- Liu, Y., Zhang, C., Cheng, J., Chen, X. and Wang, Z. J., 2019. A multi-scale data fusion framework for bone age assessment with convolutional neural networks, *Computers in Biology and Medicine*, 108, 161–173.
- De Luis-García, R., Martín-Fernández, M., Arribas, J. I. and Alberola-López, C., 2003. A fully automatic algorithm for contour detection of bones in hand radiographs using active contours, *IEEE International Conference on Image Processing*, 421–424.
- Ma, C. C. Y. and Iqbal, M., 1983. Statistical comparison of models for estimating solar radiation on inclined surfaces, *Solar Energy*, 31(3), 313–317.
- Malina, R. M. and Beunen, G. P., 2002. Assessment of skeletal maturity and prediction of adult height (TW3 method), *American Journal of Human Biology*, 14(6), 788–789.
- Mansour, H., Fuhrmann, A., Paradowski, I., van Well, E. J. and Püschel, K., 2017. The role of forensic medicine and forensic dentistry in estimating the chronological age of living individuals in Hamburg, Germany, *International Journal of Legal Medicine*, 131(2), 593–601.
- Martín-Fernández, M. Á., Cárdenes, R., Muñoz-Moreno, E., de Luis-García, R., Martín-Fernández, M. and Alberola-López, C., 2009. Automatic articulated registration of hand radiographs, *Image and Vision Computing*, 27(8), 1207–1222.
- Mehta, C., Ayesha, B., Sotakanal, A., Nirmala, S. R., Desai, S. D., K, V. S., Ganguly, A. D. and Shetty, V., 2021. Deep Learning Framework for Automatic Bone Age Assessment, 3093–3096.
- Mentzel, H. J., Vilser, C., Eulenstein, M., Schwartz, T., Vogt, S., Böttcher, J., Yaniv, I., Tsoref, L., Kauf, E. and Kaiser, W. A., 2005. Assessment of skeletal age at the wrist in children with a new ultrasound device, *Pediatric Radiology*, 35(4), 429–433.
- Mettler, F. A., Huda, W., Yoshizumi, T. T. and Mahesh, M., 2008. Effective doses in radiology and diagnostic nuclear medicine: A catalog, *Radiology*, 248(1), 254–263.
- Morid, M. A., Borjali, A. and Del Fiol, G., 2021. A scoping review of transfer learning research on medical image analysis using ImageNet, *Computers in Biology and Medicine*, 128, 104115.
- Morris, L. L., 2003. Assessment of Skeletal Maturity and Prediction of Adult Height (TW3 Method), *Australasian Radiology*, 47(3), 340–341.
- Mutasa, S., Chang, P. D., Ruzal-Shapiro, C. ve Ayyala, R., 2018. MABAL: a Novel Deep-Learning Architecture for Machine-Assisted Bone Age Labeling, *Journal of Digital Imaging*, 31(4), 513–519.
- Nabiyev, V. V., 2012. Yapay zeka insan-bilgisayar etkileşimi, *Seçkin yayınları*, Ankara

- Neyzi, O. and Ertuğrul, T., 2000. *Pediatric (cilt 1 - 2), Adli Tıp Der Yayınları*. İstanbul.
- Ontell, F. K., Ivanovic, M., Ablin, D. S. ve Barlow, T. W., 1996. Bone age in children of diverse ethnicity, *American Journal of Roentgenology*, 167(6), 1395–1398.
- Othmani, A., Taleb, A. R., Abdelkawy, H. and Hadid, A., 2020. Age estimation from faces using deep learning: A comparative analysis, *Computer Vision and Image Understanding*, 196.
- Özel, H. C., Kirangil, B. ve Fidancı, K. Ş., 1988. Kimlik Belirtimi, *Adli Tıp Dergisi*, 4(3–4), 173–181.
- Öztemel, P. D. E., 2012. Yapay Sinir Ağları, *Papatya Yayıncılık*, İstanbul
- Pan, X., Zhao, Y., Chen, H., Wei, D., Zhao, C. and Wei, Z., 2020. Fully Automated Bone Age Assessment on Large-Scale Hand X-Ray Dataset, *International Journal of Biomedical Imaging*, 2020, <https://doi.org/10.1155/2020/8460493>
- Panchbhai, A. S., 2011. Dental radiographic indicators, a key to age estimation, *Dentomaxillofacial Radiology*, 40(4), 199–212.
- Payne-James, J., Busuttil, A., Smock, W. and Smock, W. S. (Eds.), 2003. Forensic medicine: clinical and pathological aspects, *Cambridge University Pres*.
- Pietka, E., 2003. Computer-assisted bone age assessment—database adjustment, *International Congress Series*, 1256(C), 87–92.
- Pietka, E., Pospiech-Kurkowska, S., Gertych, A. and Cao, F., 2003. Integration of computer assisted bone age assessment with clinical PACS, *Computerized Medical Imaging and Graphics*, 27(2–3), 217–228.
- Pietka, E., Witko, K. and Gertych, A., 2005. Remotely accessible e-atlas for bone age assessment, *International Congress Series*, 1281, 260–265.
- Pirim, H., 2006. Yapay Zeka, *Journal of Yaşar University*, 1(1), 81–93.
- Reddy, N. E., Rayan, J. C., Annapragada, A. V., Mahmood, N. F., Scheslinger, A. E., Zhang, W. and Kan, J. H., 2020. Bone age determination using only the index finger: a novel approach using a convolutional neural network compared with human radiologists, *Pediatric Radiology*, 50(4), 516–523.
- Ren, X., Li, T., Yang, X., Wang, S., Ahmad, S., Xiang, L., Stone, S. R., Li, L., Zhan, Y., Shen, Di. and Wang, Q., 2019. Regression Convolutional Neural Network for Automated Pediatric Bone Age Assessment from Hand Radiograph, *IEEE Journal of Biomedical and Health Informatics*, 23(5), 2030–2038.
- Van Rijn, R. R., Lequin, M. H. and Thodberg, H. H., 2009. Automatic determination of Greulich and Pyle bone age in healthy Dutch children, *Pediatric Radiology*, 39(6), 591–597.
- Şahin, M., Kaya, Y. and Uyar, M., 2013. Comparison of ANN and MLR models for estimating solar radiation in Turkey using NOAA/AVHRR data, *Advances in Space*

- Research*, 51(5), 891–904.
- Saini, P., 2013. Master dentistry. Volume 2: restorative dentistry, paediatric dentistry and orthodontics, 3rd edition, *British Dental Journal*, 215(11), 597–597.
- De Sanctis, V., Di Maio, S., Soliman, A., Raiola, G., Elalaily, R. and Millimaggi, G., 2014. Hand X-ray in pediatric endocrinology: Skeletal age assessment and beyond, *Indian Journal of Endocrinology and Metabolism*, S63–S71.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L. C., 2018. MobileNetV2: Inverted Residuals and Linear Bottlenecks, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 4510–4520.
- Satoh, M., 2015. Bone age: Assessment methods and clinical applications, *Clinical Pediatric Endocrinology*, 143–152.
- Schmeling, A., Grundmann, C., Fuhrmann, A., Kaatsch, H. J., Knell, B., Ramsthaler, F., Reisinger, W., Riepert, T., Ritz-Timme, S., Rösing, F. W., Röttscher, K. and Geserick, G., 2008. Criteria for age estimation in living individuals, *International Journal of Legal Medicine*, 122(6), 457–460.
- Schmeling, A., Reisinger, W., Loreck, D., Vendura, K., Markus, W. and Geserick, G., 2000. Effects of ethnicity on skeletal maturation: Consequences for forensic age estimations, *International Journal of Legal Medicine*, 253–258.
- Şen, Y. F. ve Özkorul, G., 2016. Türkiye – Avrupa Birliği İlişkilerinde Yeni Bir Eşik : Sığınmacı Krizi Bağlamında Bir Değerlendirme [A New Threshold in Turkey - European Union Relationships : A Review Within The Context of Refugee Crisis], *Göç Araştırmaları Dergisi*, 2(2), 86–119.
- Shin, N. Y., Lee, B. D., Kang, J. H., Kim, H. R., Oh, D. H., Il Lee, B., Kim, S. H., Lee, M. S. and Heo, M. S., 2020. Evaluation of the clinical efficacy of a TW3-based fully automated bone age assessment system using deep neural networks, *Imaging Science in Dentistry*, 50(3), 237–243.
- Somkantha, K., Theera-Umpon, N. and Auephanwiriyakul, S., 2011. Bone age assessment in young children using automatic carpal bone feature extraction and support vector regression, *Journal of Digital Imaging*, 24(6), 1044–1058.
- Son, S. J., Song, Y., Kim, N., Do, Y., Kwak, N., Lee, M. S. and Lee, B. D., 2019. TW3-Based Fully Automated Bone Age Assessment System Using Deep Neural Networks, *IEEE Access*, 7, 33346–33358.
- Song, H. A. and Lee, S. Y., 2013. Hierarchical representation using NMF, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 466–473.
- Spampinato, C., 1995. Skeletal bone age assessment, *University of Catania, Viale Andrea Doria*, 6, 95125.
- Spampinato, C., Palazzo, S., Giordano, D., Aldinucci, M. and Leonardi, R., 2017. Deep learning for automated skeletal bone age assessment in X-ray images, *Medical*

Image Analysis, 36, 41–51.

- Van Steenkiste, T., Ruyssinck, J., Janssens, O., Vandersmissen, B., Vandecasteele, F., Devolder, P., Achten, E., Van Hoecke, S., Deschrijver, D. and Dhaene, T., 2018. Automated Assessment of Bone Age Using Deep Learning and Gaussian Process Regression, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 674–677.
- Štern, D., Payer, C., Lepetit, V. and Urschler, M., 2016. Automated age estimation from hand MRI volumes using deep learning, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 194–202.
- Štern, D., Payer, C. and Urschler, M., 2019. Automated age estimation from MRI volumes of the hand, *Medical Image Analysis*, 58.
- Szegedy, C., Ioffe, S., Vanhoucke, V. and Alemi, A. A., 2017. Inception-v4, inception-ResNet and the impact of residual connections on learning, *31st AAAI Conference on Artificial Intelligence, AAAI 2017*, 4278–4284.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A., 2015. Going deeper with convolutions, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1–9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z., 2016. Rethinking the Inception Architecture for Computer Vision, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2818–2826.
- Tajmir, S. H., Lee, H., Shailam, R., Gale, H. I., Nguyen, J. C., Westra, S. J., Lim, R., Yune, S., Gee, M. S. and Do, S., 2019. Artificial intelligence-assisted interpretation of bone age radiographs improves accuracy and decreases variability, *Skeletal Radiology*, 48(2), 275–283.
- Tan, M. and Le, Q. V., 2019. EfficientNet: Rethinking model scaling for convolutional neural networks, *36th International Conference on Machine Learning, ICML 2019*, 10691–10700.
- Tanner, 1962. A new system for estimating skeletal maturity derived from study of 2600 healthy british children, *Centre International de l'enfance*. Paris.
- Tong, C., Liang, B., Li, J. and Zheng, Z., 2018. A Deep Automated Skeletal Bone Age Assessment Model with Heterogeneous Features Learning, *Journal of Medical Systems*, 42(12).
- Tuncel, E., 2008. Klinik Radyoloji, *Nobel Tıp Kitabevleri*, Ankara.
- Türk ceza kanunu, 2004. *Kanun No. 5237*.
- Uğur Ersoy, Ö., 2003. Kemik Yaşının Değerlendirilmesi.0-18 Yaş Arası Popülasyonda Kesitsel Çalışma, Uzmanlık Tezi, *T.C. Adalet Bakanlığı Adli Tıp Kurumu*, İstanbul.

- Üzel, M., 2002a. Kemik yaşı belirlenmesi, sosyoekonomik faktörler ve beslenme ilişkilerinin incelenmesi, Doktora Tezi, *İstanbul Üniversitesi Sağlık Bilimleri Enstitüsü*, İstanbul.
- Üzel, M., 2002b. Türk Populasyonunda Puberte Dönemi Kemik Gelişimi ve Yaş Tayini Üzerine Anatomik ve Radyolojik Araştırma, Doktora Tezi, *İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi*, İstanbul.
- Uzm. Alpay, 2021. Anonim. <https://www.psikolojik.gen.tr/yapay-sinir-aglari.html> [Ziyaret Tarihi: 25 Mart 2021].
- Vila-Blanco, N., Carreira, M. J., Varas-Quintana, P., Balsa-Castro, C. and Tomas, I., 2020. Deep Neural Networks for Chronological Age Estimation from OPG Images, *IEEE Transactions on Medical Imaging*, 39(7), 2374–2384.
- Wang, S., Shen, Y., Shi, C., Yin, P., Wang, Z., Cheung, P. W. H., Cheung, J. P. Y., Luk, K. D. K. and Hu, Y., 2018. Skeletal Maturity Recognition Using a Fully Automated System with Convolutional Neural Networks, *IEEE Access*, 6, 29979–29992.
- Wibisono, A. and Mursanto, P., 2020. Multi Region-Based Feature Connected Layer (RB-FCL) of deep learning models for bone age assessment, *Journal of Big Data*, 7(1).
- Wu, E., Kong, B., Wang, X., Bai, J., Lu, Y., Gao, F., Zhang, S., Cao, K., Song, Q., Lyu, S. and Yin, Y., 2019. Residual attention based network for hand bone age assessment, *Proceedings - International Symposium on Biomedical Imaging*, 1158–1161.
- Xing, J., Li, K., Hu, W., Yuan, C. and Ling, H., 2017. Diagnosing deep learning models for high accuracy age estimation from a single image, *Pattern Recognition*, 66, 106–116.
- Yarimoğlu, B. H., Alper, B., Meral, D. and Çekin, N., 2005. Yaş Tayini Uygulamalarında Epifiz Plağı Kapanma Derecelerinin İncelenmesi, *The Bulletin of Legal Medicine*, 10(3), 84–89.
- Yi, P. H., Wei, J., Kim, T. K., Shin, J., Sair, H. I., Hui, F. K., Hager, G. D. and Lin, C. T., 2021. Radiology “forensics”: determination of age and sex from chest radiographs using deep learning, *Emergency Radiology*, 28(5), 949–954.
- Yılmaz, Ö., 2006. Adli Tıp Kurumu’nda Yaş Tayininde Kullanılan Yöntemin Verimlilik Açısından Değerlendirilmesi. *T.C. Adalet Bakanlığı*.
- Zhang, A., Gertych, A. and Liu, B. J., 2007. Automatic bone age assessment for young children from newborn to 7-year-old using carpal bones, *Computerized Medical Imaging and Graphics*, 31(4–5), 299–310.
- Zhao, X. X., Li, D. Y., Li, J., Kang, J. and Yang, L., 2020. Research on the Intelligent Assessment Algorithm of Bone Age Based on Attention Mechanism, *Journal of Physics: Conference Series*.

EKLER

EK 1: Kütahya Sağlık Bilimleri Üniversitesi Rektörlüğü Etik Kurulu Karar Formu Üst Yazı

Evrak Tarih ve Sayısı: 22.04.2021-10381



T.C.
KÜTAHYA SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
REKTÖRLÜĞÜ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu Başkanlığı

Sayı : E-41997688-050.99-10381
Konu : Etik Kurul Karar Formu

Sayın Uzm.Dr. Mehmet Ali GEDİK

Üniversitemiz Girişimsel Olmayan Klinik Araştırmalar Etik Kurulunun 15/04/2021 tarih ve 2021/07 sayılı toplantısında başvuru dosyanız incelenmiş olup karar formu ekte gönderilmiştir. Gereğini rica ederim.

Prof. Dr. Duygu PERÇİN RENDERS
Başkan

Ek: Karar Formu (2 Sayfa)

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu :BEKR507H7 Pin Kodu :20581

Belge Takip Adresi :
https://ebys.ksbu.edu.tr/en/Vision/validate_doc.aspx?V=BEKR507H7

Adres: Evliya Çelebi Yerleşkesi Tavşanlı Yolu 10. km KÜTAHYA
Telefon: 0 (274) 260 00 43 / 1139
e-Posta: etik.gir.olmayan@ksbu.edu.tr
Kep Adresi: kutahyasaglikbilimleriuniversitesi@hs01.kep.tr

Bilgi için: F.Gergin
Unvan: Hemşire



Bu belge, güvenli elektronik imza ile imzalanmıştır.

EK 2: Kütahya Sağlık Bilimleri Üniversitesi Rektörlüğü Etik Kurulu Karar Formu (18 yaş altı bireyler için)

**T.C
KÜTAHYA SAĞLIK BİLİMLERİ ÜNİVERSİTESİ REKTÖRLÜĞÜ
GİRİŞİMSSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU
KARAR FORMU**

ARAŞTIRMANIN AÇIK ADI		18 Yaş Altı Bireylerde Sol El Bilek Grafisi Veri Seti Oluşturma Ve Yapay Zeka İle Kemik Yaş Tayini
ETİK KURUL BİLGİLERİ	ETİK KURULUN ADI	Kütahya Sağlık Bilimleri Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu
	KURUL ADRESİ	Kütahya Sağlık Bilimleri Üniversitesi Evliya Çelebi Yerleşkesi Tavşanlı Yolu 10. Km KÜTAHYA
	TELEFON	(0 274) 260 00 43 / 1112
	FAKS	(0 274) 265 22 85
	E-POSTA	etik.gir.olmayan@ksbu.edu.tr
BAŞVURU BİLGİLERİ	KOORDİNATÖR/SORUMLU ARAŞTIRMACI UNVANI/ADI/SOYADI	Uzm.Dr.Mehmet GEDİK
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ UZMANLIK ALANI	Radyoloji Uzmanı
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ BULUNDUĞU MERKEZ	KSBÜ Evliya Çelebi Eğitim ve Araştırma Hastanesi
	YARDIMCI ARAŞTIRMACI VE BÖLÜMÜ	Doç.Dr.Yılmaz KAYA-Bilgisayar Mühendisi, Siirt Üniversitesi/Mühendislik-Mimarlık Fakültesi/Bilgisayar Mühendisliği Bölümü/Bilgisayar Yazılımı Anabilim Dalı Öğretim Görevlisi Cüneyt ÖZDEMİR- Bilgisayar Mühendisi, Siirt Üniversitesi/Mühendislik-Mimarlık Fakültesi/Bilgisayar Mühendisliği Bölümü/Bilgisayar Yazılımı Anabilim Dalı İntern Dr. Mehmet SABANCI- KSBÜ Tıp Fakültesi
	ARAŞTIRMANIN TÜRÜ	Kesitsel, Tanımlayıcı
KARAR BİLGİLERİ	Karar No: 2021/07-20	Tarih: 15.04.2021
	Başvuru dosyası ile ilgili belgeler araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve uygun bulunmuş olup araştırmanın başvuru dosyasında belirtilen merkezde gerçekleştirilmesinde etik ve bilimsel sakınca bulunmadığına oy birliği ile karar verilmiştir.	

Prof.Dr.Duygu PERÇİN RENDERS
Etik Kurul Başkanı
Tarih: 19.04.2021

EK 3: Kütahya Sağlık Bilimleri Üniversitesi Rektörlüğü Etik Kurulu Karar Formu (18 yaş üzeri bireyler için)

**T.C
KÜTAHYA SAĞLIK BİLİMLERİ ÜNİVERSİTESİ REKTÖRLÜĞÜ
GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU
KARAR FORMU**

	ARAŞTIRMANIN AÇIK ADI	18 Yaş Üzeri Bireylerde Yapay Zekâyla Sadece Sol El Bilek Grafisi Yaş Tayininde Yeterli Olabilir mi?
ETİK KURUL BİLGİLERİ	ETİK KURULUN ADI	Kütahya Sağlık Bilimleri Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu
	KURUL ADRESİ	Kütahya Sağlık Bilimleri Üniversitesi Evliya Çelebi Yerleşkesi Tavşanlı Yolu 10. Km KÜTAHYA
	TELEFON	(0 274) 260 00 43 / 1112
	FAKS	(0 274) 265 22 85
	E-POSTA	etik.gir.olmayan@ksbu.edu.tr
BAŞVURU BİLGİLERİ	KOORDİNATÖR/SORUMLU ARAŞTIRMACI UNVANI/ADI/SOYADI	Uzm.Dr.Mehmet GEDİK
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ UZMANLIK ALANI	Radyoloji Uzmanı
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ BULUNDUĞU MERKEZ	KSBÜ Evliya Çelebi Eğitim ve Araştırma Hastanesi
	YARDIMCI ARAŞTIRMACI VE BÖLÜMÜ	Doç.Dr.Yılmaz KAYA-Bilgisayar Mühendisi, Siirt Üniversitesi/Mühendislik-Mimarlık Fakültesi/Bilgisayar Mühendisliği Bölümü/Bilgisayar Yazılımı Anabilim Dalı Öğretim Görevlisi Cüneyt ÖZDEMİR- Bilgisayar Mühendisi, Siirt Üniversitesi/Mühendislik-Mimarlık Fakültesi/Bilgisayar Mühendisliği Bölümü/Bilgisayar Yazılımı Anabilim Dalı İntern Dr. Mehmet SABANCI- KSBÜ Tıp Fakültesi
	ARAŞTIRMANIN TÜRÜ	Kesitsel, Tanımlayıcı
KARAR BİLGİLERİ	Karar No: 2021/07-21	Tarih: 15.04.2021
	Başvuru dosyası ile ilgili belgeler araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve uygun bulunmuş olup araştırmanın başvuru dosyasında belirtilen merkezde gerçekleştirilmesinde etik ve bilimsel sakınca bulunmadığına oy birliği ile karar verilmiştir.	

Prof.Dr.Duygu PERÇİN RENDERS
Etik Kurul Başkanı
Tarih: 19.04.2021

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Cüneyt ÖZDEMİR

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Atatürk Lisesi, Mersin	1998
Üniversite	: Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği	2004
Yüksek Lisans	: Fırat Üniversitesi, Bilgisayar Mühendisliği	2013
Doktora	: Siirt Üniversitesi, Elektrik-Elektronik Mühendisliği A.B.D.	2022

UZMANLIK ALANI: Bilgisayar Yazılımı, Derin Öğrenme, Makine Öğrenmesi, Görüntü işleme, İşaret işleme

YABANCI DİLLER: İngilizce

YAYINLAR

Uluslararası Hakemli Dergilerde (SCI) Yayınlanan-Baskıda Makaleler

1. Ozdemir, C., Gedik, M.A., Kaya, Y., 2021. Age estimation from left-hand radiographs with deep learning methods. *Traitement du Signal*, Vol. 38, No. 6, pp. 1565-1574. <https://doi.org/10.18280/ts.380601>

Uluslararası Hakemli Dergilerde (Alan İndeksli) Yayınlanan Makaleler

1. Ozdemir, C., Kaya, Y., 2021. Ray Bileşenlerinde Meydana Gelen Arızaların Görüntü İşleme Teknikleri ile Tespit Edilmesi. *Bilişim Teknolojileri Dergisi*, 14(1), 105-113.
2. Kaya, Y., Ozdemir, C., 2018. Spam SMS'lerin filtrelenmesinde yeni bir yaklaşım: Motif örüntüler. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 6(2), 436-450., Doi: 10.29109/http-gujsc-gazi-edu-tr.372880
3. Ozdemir, C., 2012. XML Web Servisleri ile Oracle ve SQL Server Veri Tabanları Arasında Veri Transferi. *Gazi Üniversitesi Bilişim Teknolojileri Dergisi*, 5(1), 7-12., Doi: 2147-0715

Uluslararası Bilimsel Toplantılarda Sunulan Ve Bildiri Kitabında (Proceedings) Basılan Bildiriler

1. Kaya Y., Ozdemir, C., 2019. Sinyallerin Benzerlikleri Kullanılarak 3 Farklı Yeni Öznitelik Çıkarım Yöntemi. International Engineering and Science Symposium 2019 (Tam Metin Bildiri/Sözlü Sunum)(Yayın No:5251617)
2. Kaya Y., Ozdemir, C., 2019. Yeni Öznitelik Çıkarım Yöntemi ile Duygu Analizi. International Engineering and Science Symposium 2019 (Tam Metin Bildiri/Sözlü Sunum)(Yayın No:5251623)
3. Ozdemir, C., Kaya, Y., 2018. Motif Örüntüler Yöntemi ile Spam E-Postaların Filrelenmesi. 1st International Engineering and Technology Symposium (Tam Metin Bildiri/Sözlü Sunum)(Yayın No:4609378)
4. Ozdemir, C., Kaya, Y., Minaz M.R., 2018. Motif Örüntüler Yöntemi ile Spam E-Postaları Filtreleme. International Engineering and Technology Symposium (IETS'xx18) (Tam Metin Bildiri/Sözlü Sunum)(Yayın No:5611103)
5. Kaya, Y., Ertuğrul, Ö. F., Ozdemir, C., 2016. A New Approach for Spam Filtering. International Conference on Natural Science and Engineering (Tam Metin Bildiri/Sözlü Sunum)(Yayın No:5611083)

Ulusal Bilimsel Toplantılarda Sunulan ve Bildiri Kitabında Basılan Bildiriler

1. Ozdemir, C., 2011. Panik Değerli Tıbbi Tahlil Sonuçlarının Analizi İçin Klinik Karar Destek Sisteminin Geliştirilmesi. Tıp Bilişim Kongresi (8), 35 (Tam Metin Bildiri/)(Yayın No:303689)
2. Ozdemir, C., Kaya, Y., 2016. Spam filtrelemek için kaydırmalı ikili örüntüler tabanlı yeni bir yaklaşım. XVIII. Akademik Bilişim Conference (Tam Metin Bildiri/Sözlü Sunum)
3. Dogan, Y., Atas, M., Ozdemir, C., 2014. A new approach for plotting raster based image files. 2014 22nd Signal Processing and Communications Applications Conference (SIU), 1-4., Doi: 10.1109/SIU.2014.6830407 (Tam Metin Bildiri/)
4. Ozdemir, C., Atas, M., 2014. A novel similarity algorithm for fixing erroneous turkish text and detection of roots. 2014 22nd Signal Processing and Communications Applications Conference (SIU), 830-833., Doi: 10.1109/SIU.2014.6830358 (Tam Metin Bildiri/)
5. Ozdemir, C., Atas, M., Ozer, A. B., 2013. Classification of Turkish spam e mails with artificial immune system. 2013 21st Signal Processing and Communications Applications Conference (SIU), 1-4., Doi: 10.1109/SIU.2013.6531457 (Tam Metin Bildiri/)

Ulusal & Uluslararası Akademik Projeler

1. Siirt Üniversitesi BAP (2013-SİÜMÜH-M6) "Bilgisayarlı Görü Tekniği Kullanılarak Siirt Fıstığında Aflatoksin Tespiti Üzerine Bir Araştırma" isimli proje, Araştırmacı, (2013-2016).