

TÜRKİYE CUMHURİYETİ
NECMETTİN ERBAKAN ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

**EL-BİLEK RÖNTGEN GÖRÜNTÜLERİNDEN MATURASYON
DÖNEMİ TAHMİNİ: BİR YAPAY ZEKÂ YAKLAŞIMI**

ARŞ. GÖR. DT. CEMİLE NUR YILDIRIM
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ UZMANLIK PROGRAMI
DİŞ HEKİMLİĞİNDE UZMANLIK TEZİ

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANA BİLİM DALI

TEZ DANIŞMANI
DOÇ. DR. ALİ ALTINDAĞ

KONYA 2025

TÜRKİYE CUMHURİYETİ
NECMETTİN ERBAKAN ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

**EL-BİLEK RÖNTGEN GÖRÜNTÜLERİNDEN MATURASYON
DÖNEMİ TAHMİNİ: BİR YAPAY ZEKÂ YAKLAŞIMI**

ARŞ. GÖR. DT. CEMİLE NUR YILDIRIM
AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ UZMANLIK PROGRAMI
DİŞ HEKİMLİĞİNDE UZMANLIK TEZİ

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANA BİLİM DALI

TEZ DANIŞMANI
DOÇ. DR. ALİ ALTINDAĞ

KONYA 2025

TEZ ONAY SAYFASI

Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı Uzmanlık Öğrencisi Cemile Nur YILDIRIM'ın “**EL-BİLEK RÖNTGEN GÖRÜNTÜLERİNDEN MATURASYON DÖNEMİ: BİR YAPAY ZEKÂ YAKLAŞIMI**” başlıklı tezi tarafımızdan incelenmiş; amaç, kapsam ve kalite yönünden Diş Hekimliğinde Uzmanlık Tezi olarak kabul edilmiştir.
Konya, Türkiye 28/02/2025

Tez Danışmanı	Doç. Dr. Ali ALTINDAĞ Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı	İmza
Jüri Üyesi	Prof. Dr. Güldane MAĞAT Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı	İmza
Jüri Üyesi	Doç. Dr. Ali ALTINDAĞ Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı	İmza
Jüri Üyesi	Dr. Öğr. Üyesi İbrahim Burak YÜKSEL Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Ana Bilim Dalı	İmza

Yukarıdaki tez, Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Yönetim Kurulunun 26/10/2023 tarih ve 2023/34 sayılı kararı ile onaylanmıştır.

Prof. Dr. Ali Rıza TUNÇDEMİR
Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Dekanı
İmzası

APPROVAL

We certify that we have read this dissertation entitled “**DETERMINATION OF MATURATION STAGE FROM HAND-WRIST X-RAY IMAGES: AN ARTIFICIAL INTELLIGENCE APPROACH**” by “Cemile Nur YILDIRIM” that in our opinion it is fully adequate, in scope ve quality, as dissertation for the degree of Master of Science in the Department of Oral and Maxillofacial Radiology, Faculty of Dentistry University of Necmettin Erbakan
Konya, Turkey 28/02/2025

Principal Advisor Assoc. Prof. Ali ALTINDAĞ Signature
Necmettin Erbakan University Faculty of Dentistry
Department of Oral and Maxillofacial Radiology

Examination Committee Member Prof. Dr. Güldane MAĞAT Signature
Necmettin Erbakan University Faculty of Dentistry
Department of Oral and Maxillofacial Radiology

Examination Committee Member Assoc. Professor Ali ALTINDAĞ Signature
Necmettin Erbakan University Faculty of Dentistry
Department of Oral and Maxillofacial Radiology

Examination Committee Member Assist. Prof. İbrahim Burak YÜKSEL Signature
Necmettin Erbakan University Faculty of Dentistry
Department of Oral and Maxillofacial Radiology

This thesis has approved by the decision of Necmettin Erbakan University Faculty of Dentistry Administrative Board dates 26/10/2023 and numbered 2023/34.

Dean
Prof. Dr. Ali Rıza TUNÇDEMİR
Necmettin Erbakan University Faculty of Dentistry
28/02/2025

BEYANAT

Bu tezin tamamının kendi alıřmam olduėunu, planlanmasından yazımına kadar hibir ařamasında etik dıřı davranıřımın olmadıėını, tezdeki bütun bilgileri akademik ve etik kurallar iinde elde ettiėimi, tez alıřmasıyla elde edilmeyen bütun bilgi ve yorumlara kaynak gösterdiėimi ve bu kaynakları kaynaklar listesine aldıėımı, tez alıřması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranıřımın olmadıėını beyan ederim.

28/02/2025

Dt. Cemile Nur YILDIRIM



BENZERLİK RAPORU

EL-BİLEK RÖNTGEN GÖRÜNTÜLERİNDEN MATURASYON DÖNEMİ TAHMİNİ: BİR YAPAY ZEKÂ YAKLAŞIMI

ORIGINALITY REPORT

6%

SIMILARITY INDEX

PRIMARY SOURCES

1	acikbilim.yok.gov.tr Internet	430 words — 3%
2	Unver, Tugba. "El-Bilek Kemikleri, Servikal Vertebra Ve Dislerin Gelisimdonemlerine Gore Kronolojik Yas Evrelerinin El-Bilek Grafileri Ve Dental Volumetrik Tomografi Ile Karsilastirmali Olarak Degerlendirilmesi", Marmara Universitesi (Turkey) ProQuest	52 words — < 1%
3	dergipark.org.tr Internet	38 words — < 1%
4	www.odmfr.org Internet	35 words — < 1%
5	hascoding.com Internet	32 words — < 1%
6	Özder, Mustafa Kerem. "Motor Takozları Bağlantı Elemanlarının Yapısal Tasarımı ve Yapay Sinir Ağları Ile Analiz Tahmini", Bursa Uludag University (Turkey), 2023 ProQuest	28 words — < 1%
7	e-biblio.univ-mosta.dz Internet	17 words — < 1%

TEŞEKKÜR

Uzmanlık eğitimim boyunca her daim destekleyici tavrıyla, gülen yüzüyle yanımda olan, hem akademik hem de sosyal hayatta yol gösteren çok değerli danışman hocam Doç. Dr. Ali ALTINDAĞ'a

Uzmanlık eğitimim boyunca hem klinik hem de akademik bilgi ve tecrübelerinden çok şey öğrendiğim, desteklerini her zaman hissettiğim değerli bölüm hocalarım Prof. Dr. Güldane MAĞAT, Doç. Dr. Melek TAŞSÖKER BULUT ve Dr. Öğr.Üyesi İbrahim Burak YÜKSEL'e

Tez sürecimdeki katkılarından ötürü Prof. Dr. Özkan MİLOĞLU, Dr. Öğr. Üyesi Mücahid YILDIRIM, Dr. Öğr. Üyesi Sümeyye ÇELİK ÖZSOY ve Dr. Öğr. Üyesi Cengiz EVLİ'ye,

Uzmanlık için geldiğim bu şehirde, ilk günden itibaren harika dostluğuyla hayatımda hep var olan ve tez sürecinde yaşadığım her talihsiz sorunda bana çözümlerle koşup gelen, canım arkadaşım Uzm. Dt. Dilşah DEMİRAY'a

Hayatıma neşesiyle giren, hayatıma güzellikler katan, tez sürecimin olmazsa olmaz motivasyon kaynağı canım arkadaşım Uzm. Dt. Sinem ALKURT KAPLAN'a

Uzmanlık hayatımızın ilk gününden beri yan yana olduğumuz, beraber çalışmaktan keyif aldığım, tez sürecinde de desteklerini esirgemeyen Uzm. Dt. Taha ZİREK, Uzm. Dt. Ayşe Hanne SARI, Uzm. Dt. Sultan UZUN, Dr. Öğr. Üyesi Rabia KARAKUŞ, Dt. Mediha ERTÜRK'e ve bölümdeki diğer asistan arkadaşlarıma, sevgili abim Faruk KARAKUŞ'a ve diğer personellerimize,

Diş hekimliği eğitimine beraber başladığım, uzmanlığa başlama ve devam ettirme motivasyonu her daim yanımda olduklarını hissettiren, farklı şehirlerde olsak bile hepsiyle uzmanlık süreçlerimizi devam ettirdiğimiz sevgili arkadaşlarım Selin YAZICI GÜÇLÜ, Saodat RAUPOVA, Elçin YENER, Yasemin YAMAN, Elif YILMAZ BİÇER, Zeynep Gamze ŞANOĞLU, Ege TÜRKMEN, Eyaan ÇETİNSOY, Aybüke YOLCU, Ebrar UZUNPINAR NALBANT'a

Hayatımın her anında yanı başımda olan ve her daim de olmasını istediğim canlarım Asya Duru UYSAL, Zeynep Merve AYDIN UYSAL, Fatma AYDIN, Sıla ÖZAL, Mehmet Fatih UYSAL ve sevgili aileme

sonsuz teşekkürlerimi sunarım...

İÇİNDEKİLER

TEZ ONAY SAYFASI	iii
APPROVAL	iv
BEYANAT	v
BENZERLİK RAPORU	vi
TEŞEKKÜR	vii
SİMGE VE KISALTMALAR	x
ŞEKİLLER LİSTESİ	xi
TABLolar LİSTESİ	xii
ÖZET	xiii
ABSTRACT	xiv
1.GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER	3
2.1. <i>El Bilek Embriyolojisi</i>	3
2.2. <i>El Bilek Anatomisi</i>	4
2.3. <i>Kemik Gelişim Süreci</i>	6
2.4. <i>Büyüme Ve Gelişme</i>	11
2.4.1 <i>Büyüme ve Gelişimin Belirlenmesi:</i>	11
2.4.2. <i>Yaş Tayini</i>	13
2.4.3. <i>Puberte</i>	24
2.5. <i>Yapay Zekâ</i>	28
2.5.1. <i>Yapay Zekânın Tanımı ve Tarihsel Gelişimi</i>	28
2.5.2. <i>Yapay Zekânın Temelleri</i>	29
2.5.3. <i>Yapay Zekâ Türleri</i>	30
2.5.4. <i>Yapay Zekâ Algoritmaları</i>	31
2.5.5. <i>Yapay Zekâ Tabanlı Meta Sezgisel Yöntemler</i>	31
2.6. <i>Makine Öğrenmesi</i>	33
2.7. <i>Derin Öğrenme</i>	36
2.8. <i>Nesne Tespit ve Tanımlama Algoritmaları</i>	37
3.GEREÇ VE YÖNTEM	41
3.1. <i>Gereç</i>	41
3.1.1. <i>Örneklem Büyüklüğünün Belirlenmesi</i>	41
3.1.2. <i>El-Bilek Radyografilerinden Veri Setinin Oluşturulması</i>	41
3.1.3. <i>Birey Seçimi</i>	42
3.1.4. <i>Görüntü İşleme ve El-Bilek Radyografilerinin Değerlendirilmesi</i>	42
3.2. <i>Yöntem</i>	45
3.2.1. <i>Model Eğitimi</i>	45

3.2.2. Modellerin Performans ve Başarısının Değerlendirilmesi	46
4.BULGULAR.....	48
4.1. YOLOv8 Eğitim ve Test Sonuçları	48
4.2. Birleşim Üzerinden Ortalama Kesişme (IoU) ve Alıcı İşlem Karakteristiği (ROC) Eğrisi.....	53
5. TARTIŞMA.....	55
6. SONUÇ VE ÖNERİLER	64
7. KAYNAKLAR	65
8. ÖZGEÇMİŞ.....	76
9. EKLER	77



SİMGE VE KISALTMALAR

2B	İki boyutlu
3B	Üç boyutlu
AS0-AS3	Adduktör sesamoid kemik gelişim aşamaları
AUC	Area Under Curve (Eğri Altındaki Alan)
BT	Bilgisayarlı tomografi
CNN	Convolutional Neural Networks
DÖ	Derin öğrenme
GPU	Grafik İşlem Birimi
IoU	Intersection over Union
KSA	Konvolüsyonel Sinir Ağları
MP3	El bilek olgunluk belirteçlerinden biri
PP, MP, DP	Falanks isimlendirmeleri
Pisi	Pisiform kemiği
R	Radius kemiği
ROC	Receiver Operating Characteristic
TPU	Tensor İşlem Birimi
TW-2/TW-3	Tanner-Whitehouse Metodu 2 ve 3
U	Ön kol kemiği, ulna
YZ	Yapay zeka

ŞEKİLLER LİSTESİ

Şekil 1. El bilek anatomisi	6
Şekil 2. Epifizyal büyüme plağının gelişim aşamaları	10
Şekil 3. Chapman olgunlaşma safhaları.....	19
Şekil 4. Büyüme atılımı dönemleri.....	21
Şekil 5. El-bilek radyografilerinde büyüme göstergeleri ve iskelet maturasyonu ile ilişkisi	22
Şekil 6. Hägg ve Taranger 5 aşamalı maturasyon değerlendirme	23
Şekil 7. Fishman maturasyon değerlendirme	24
Şekil 8. Lamparski metodunun 6 safhada sınıflandırılması.....	25
Şekil 9. Çocuklarda yıllık boy artışının takibi	27
Şekil 10. Yapay zekâ, makine öğrenmesi ve derin öğrenmenin birbirleriyle ilişkisi .	31
Şekil 11. A) İnsan sinir hücresinin diyagramı B) Yapay nöron temsili C) İnsan sinir hücrelerinde bulunan sinaps D) İnsan sinapslarını taklit etmek için geliştirilen yapay sinapslar.....	33
Şekil 12. Makine öğrenmesi türleri	35
Şekil 13. Pre-pik dönemine ait bir el-bilek radyografisi	45
Şekil 14. Pik dönemine ait bir el-bilek radyografisi.....	46
Şekil 15. Post-pik dönemine ait bir el-bilek radyografisi	47
Şekil 16. Eğitim sırasındaki epoch ilerleyişine göre performans metrikleri.....	53
Şekil 18. Öğrenme oranının epochlara göre değişimi	56
Şekil 19. Konfüzyon matrisi.....	57
Şekil 21. ROC (Receiver Operating Characteristic) Eğrisi	59

TABLolar LİSTESİ

Tablo 1. Eğitim, doğrulama ve test veri setlerinin dağılımı	52
Tablo 2. Öğrenme oranını gösteren lr/pg0, lr/pg1 ve lr/pg2 değerleri	55
Tablo 3. YOLOv8 modelinin %50 IoU eşik değeri kullanılarak hesaplanan performans metrikleri.....	58



ÖZET

T.C. NECMETTİN ERBAKAN ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

EL-BİLEK RÖNTGEN GÖRÜNTÜLERİNDEN MATURASYON DÖNEMİ TAHMİNİ: BİR YAPAY ZEKÂ YAKLAŞIMI

DT. CEMİLE NUR YILDIRIM

AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ UZMANLIK PROGRAMI DİŞ HEKİMLİĞİNDE UZMANLIK TEZİ/KONYA-2025

El-bilek radyografileri, iskelet maturasyonunun belirlenmesinde önemli bir tanısal araç olup, özellikle ortodontik tedavi planlaması ve pediatrik büyüme değerlendirmelerinde yaygın olarak kullanılmaktadır. Bu çalışma, bireylerin iskeletsel gelişim süreçlerini belirlemek amacıyla prepik, pik ve postpik olmak üzere üç farklı olgunluk evresini derin öğrenme yöntemleriyle sınıflandırmayı hedeflemektedir. Bu doğrultuda, nesne tespiti ve sınıflandırma konusunda yüksek doğruluk oranlarına sahip ileri seviye bir algoritma olan YOLOv8 modeli kullanılarak, el-bilek radyografileri üzerinde otomatik sınıflandırma gerçekleştirilmiştir.

Bu amaçla bu çalışmada 3268 adet toplanan el-bilek radyografisi Björk, Grave ve Brown sınıflandırma sistemine göre sırasıyla 1060, 1073, 1135 prepik, pik ve postpik görüntü elde edilmiştir. Görüntüler oral radyologlar tarafından sınıflandırılmıştır. Kullanılan derin ağ mimarisi ile 2668 görüntü eğitim seti için, 300 görüntü test ve 300 görüntü de doğrulama veri seti olarak kullanılmıştır.. Sonuçlar kesinlik, duyarlılık ve F-1 skorunu içeren performans kriterlerine göre değerlendirilmiştir.

Modelin kesinlik değerleri postpik sınıfında 1.00, prepik sınıfında 0.95 ve pik sınıfında 0.90 olarak hesaplanmıştır. Postpik sınıfında modelin tahmin ettiği her örnek doğru çıkarken, pik sınıfında yanlış pozitif oranı diğer sınıflara göre biraz daha yüksektir. Duyarlılık değerleri prepik sınıfında 0.96, pik sınıfında 0.95 ve postpik sınıfında 0.94 olarak belirlenmiştir. Model, prepik sınıfında en yüksek duyarlılığa sahip olup, bu sınıfa ait örnekleri en iyi şekilde tespit etmiştir. F1 skoru postpik için 0.97, prepik için 0.95 ve pik için 0.92 olarak hesaplanmıştır. Modelin genel sınıflandırma başarısı yüksek olup, tüm sınıflarda 0.90'ın üzerinde performans göstermiştir.

Anahtar Kelimeler: Derin Öğrenme; El-Bilek Radyografisi; Yapay Zeka; YOLO

ABSTRACT

NECMETTIN ERBAKAN UNIVERSITY

FACULTY OF DENTISTRY

DETERMINATION OF MATURATION STAGE FROM HAND-WRIST X-RAY IMAGES: AN ARTIFICIAL INTELLIGENCE APPROACH

DT. CEMİLE NUR YILDIRIM

MASTER OF SCIENCE IN THE DEPARTMENT OF ORAL AND
MAXILLOFACIAL RADIOLOGY/KONYA-2025

Hand-wrist radiographs are an important diagnostic tool for determining skeletal maturation and are widely used, especially in orthodontic treatment planning and pediatric growth assessment. This study aims to classify individuals' skeletal development stages into three different maturity phases: prepeak, peak, and postpeak, using deep learning methods. Accordingly, an advanced algorithm with high accuracy in object detection and classification, the YOLOv8 model, was employed for the automatic classification of hand-wrist radiographs.

For this purpose, a total of 3,268 hand-wrist radiographs were collected in this study, and based on the Björk, Grave and Brown classification system, 1,060 prepeak, 1,073 peak, and 1,135 postpeak images were obtained. The images were classified by oral radiologists. Using the deep neural network architecture, 2,668 images were allocated for the training set, while 300 images were used for the test set and 300 images for the validation set. The results were evaluated based on performance criteria, including precision, recall, and F1-score.

The precision values of the model were calculated as 1.00 for the postpeak class, 0.95 for the prepeak class, and 0.90 for the peak class. While every sample predicted in the postpeak class was correct, the false positive rate in the peak class was relatively higher than in other classes. The recall values were determined as 0.96 for the prepeak class, 0.95 for the peak class, and 0.94 for the postpeak class. The model exhibited the highest recall in the prepeak class, indicating its strong ability to identify examples from this category. The F1-score was calculated as 0.97 for the postpeak class, 0.95 for the prepeak class, and 0.92 for the peak class. The model demonstrated high overall classification performance, with all classes achieving an F1-score above 0.90.

Keywords: Deep Learning; Hand-Wrist Radiograph; Artificial Intelligence; YOLO.

1. GİRİŞ VE AMAÇ

El-bilek röntgen görüntülerinden maturasyon dönemi tahmini, özellikle ortodonti ve pediatri alanlarında büyük önem taşımaktadır. Bireylerin iskeletsel olgunluk seviyesini belirlemek için kullanılan el-bilek radyografileri, büyüme gelişim analizlerinde yaygın bir yer tutmaktadır (Greulich ve Pyle 1959; Tanner ve ark. 1997). Bu görüntüler, kemik gelişimini izleyerek büyüme dönemi ve pubertal atılım gibi kritik süreçleri değerlendirmek için kullanılır (Hägg ve Taranger 1980; Lamparski ve Nanda 2002). Kemik yaşı tayini için Greulich-Pyle Atlası, Tanner-Whitehouse Metodu ve Fels Metodu gibi yöntemler yaygın olarak uygulanmaktadır (Greulich ve Pyle 1959; Roche ve Johnson 1969; Tanner ve ark. 1997).

El-bilek radyografileri, uzun süreli araştırmalarda doğrulanmış olması, küçük bir alanda çok sayıda kemikleşme merkezi içermesi ve geleneksel röntgen teknolojisiyle kolayca görüntülenebilmesi sayesinde yaygınlığını korumaktadır (Mincer ve ark. 1993; Cameriere ve ark. 2006). Ancak, kemik yaşı tayininde çevresel ve genetik faktörler, etnik köken ve beslenme alışkanlıkları dikkate alınmalıdır (Häusler ve Lussi 1983). Dolayısıyla farklı popülasyonlarda atlasların geçerliliğinin değişebileceği düşünülmektedir (Nur ve ark. 2012; Jayaraman ve ark. 2013).

Son yıllarda yapay zekâ (YZ) uygulamaları bu alanda yeni bir boyut kazandırmıştır (Mupparapu ve ark. 2018; Haenlein ve Kaplan 2019). Makine ve derin öğrenme teknikleri, büyük veri setlerinde insan hatasını en aza indirerek hızlı ve doğru analizler yapabilmektedir (LeCun ve ark. 2015; Goodfellow 2016). YZ tabanlı modeller, hekimin değerlendirme sürecini hızlandırarak subjektif hataları azaltmaktadır (Mahesh 2020; Li ve ark. 2021). Derin öğrenme temelli konvolüsyonel sinir ağları (KSA) ve diğer gelişmiş ağ mimarileri, geleneksel yöntemlere kıyasla daha yüksek doğruluk oranları elde edebilmektedir (Özkan ve Ülker 2017; Pouyanfar ve ark. 2018).

Yapay zekâ ile el-bilek radyografileri üzerinde otomatik sınıflandırma yapılabilir (Mincer ve ark. 1993; Awad ve Khanna 2015). Bu sınıflandırma, büyüme atağının zamanlamasını tahmin ederek ortodontik tedavi planlamasını optimize edebilir (Björk ve Helm 1967; Fishman 1982). Büyüme potansiyelinin doğru

belirlenmesi, iskeletsel bozuklukların ve ortodontik tedavilerin başarısını artırmaktadır (Bench 1963; Lamparski ve Nanda 2002).

Derin öğrenme modelleri, biyolojik sinir sistemlerinden esinlenerek çok katmanlı ağlar kullanır (Haykin 1998). Bu modeller, geniş veri setlerinde detaylı özellik çıkarımı yaparak sınıflandırma doğruluğunu artırır (Bengio ve ark. 2013; Schmidhuber 2015). Onvolüsyon katmanları sayesinde kemikleşme süreçleri daha iyi analiz edilebilir (LeCun ve ark. 2015). Böylece, insan gözünün kaçırabileceği detaylar tespit edilebilir (Öztemel 2012).

Derin öğrenme, klasik istatistiksel yöntemlere kıyasla verideki örüntüleri daha kapsamlı inceleyebilir (Li ve ark. 2017). Bu yöntem, büyüme süreçlerinin farklı etnik gruplar ve çevresel faktörler ışığında değerlendirilmesini kolaylaştırır (Hägg ve Taranger 1980). Modern donanımların yüksek işlem gücü sayesinde büyük veri setleri üzerinde daha hızlı eğitim süreçleri sağlanabilmektedir (Gers ve ark. 2000; Mikolov ve ark. 2010).

Sonuç olarak, el-bilek röntgen görüntülerinden maturasyon dönemi tahmini, hem geleneksel atlas yöntemleri hem de yapay zekâ tabanlı yaklaşımlarla gerçekleştirilmektedir (Greulich ve Pyle 1959; Tanner 1978). Yapay zekâ, süreçleri otomatikleştirerek süreyi kısaltmakta ve doğruluğu artırmaktadır (Mahesh 2020; Li ve ark. 2021). Bu gelişmeler, iskeletsel büyüme süreçlerinin daha etkin izlenmesini sağlayarak tedavi planlamalarının daha hassas yapılmasına katkıda bulunmaktadır (Bench 1963; Fishman 1982).

Bu çalışmada, el-bilek röntgenlerinden bireylerin maturasyon dönemlerini tahmin etmek için yapay zekâ modeli geliştirilmesi ve performansının değerlendirilmesi amaçlanmıştır. Derin öğrenmeye dayalı sınıflandırma yaklaşımı kullanılarak bireylerin pik, postpik ve prepik maturasyon dönemlerinin doğru bir şekilde sınıflandırılması hedeflenmiştir. Modelin başarısı; doğruluk, kesinlik (precision), duyarlılık (recall), F1 skoru ve AUC değerleri açısından değerlendirilmesi planlanmıştır. Elde edilen bulguların, iskeletsel maturasyon değerlendirmesinin otomasyonuna katkı sağlayarak klinik ve araştırma ortamlarında verimliliği ve nesnelliği artırması beklenmektedir.

2. GENEL BİLGİLER

2.1. El Bilek Embriyolojisi

Ekstremitte gelişimi, embriyonik dönemin erken evrelerinde lateral mezoderimde yer alan özel mezenkimal hücre gruplarının aktivasyonu ile başlar. Bu süreçte önemli bir rol üstlenen Homeobox (Hox) genleri, ekstremitelerin gelişimini düzenleyen genler olarak işlev görür. Süreç boyunca mezenkimal hücrelerin çoğalması ve farklılaşması, ekstremitte tomurcuklarının uzamasını ve iskelet yapısının şekillenmesini sağlar. Mezenkimal hücreler, kondroblastlar ve osteoblastlar gibi hücre tiplerine farklılaşarak kıkırdaklaşma ve kemikleşme merkezlerini oluşturur. Bu süreç, ekstremitte iskeletin temel yapı taşlarının yerleşmesi açısından kritik bir öneme sahiptir ve ekstremitte organogenezinin karmaşık yapısını ortaya koyar. (Roche ve Johnson 1969; Gülyurt 1989; Persaud ve Moore 2002).

Ekstremitte tomurcukları, apekslerindeki ektodermal kenarların büyümesiyle gelişir ve kondroblastlar ile osteoblastlara dönüşecek hücrelerden oluşan bir tabaka oluşturur. İntrauterin dönemde sert dokuların ilk gelişimi, mezenkimdeki hücre yoğunlaşmasıyla başlar. Bu yoğunlaşma alanlarına skleroblastem denir ve kemik dokusunun oluşumu buradan başlar (Wadsworth 1983).

Kemikleşme iki şekilde gerçekleşir:

- **Endokondral Kemikleşme:** Önce kıkırdak taslağı oluşur, ardından bu taslak kemikleşir. Bu süreç, uzun ve kısa kemiklerin (ör. kol, bacak, parmak kemikleri) gelişiminde etkilidir.
- **İntramembranöz Kemikleşme:** Kıkırdak taslağı oluşmadan kemik doğrudan gelişir. Bu yöntem yassı kemiklerin (ör. alın, parietal, çene kemikleri) oluşumunda etkilidir.

Her iki süreç de kemik dokusunun gelişiminde ve organ oluşumunda önemli bir rol oynar ve doğru zamanlama ile koordinasyonu gerektirir (Erkoç 1967; Gülyurt 1989; Ünver 2013).

2.2. El Bilek Anatomisi

Uzun kemikler, diafiz ve epifiz olmak üzere farklı bölgelere ayrılır. Diafiz, kemiğin gövdesini oluşturur ve kemikleşmenin başladığı "primer kemikleşme merkezi"ni içerir. Epifiz, kemiğin bir veya iki ucunda bulunur ve "sekonder kemikleşme merkezleri" ile doğumdan sonra gelişir (Drake ve ark. 2005).

El iskeleti, 27 kemikten oluşur ve üç gruba ayrılır:

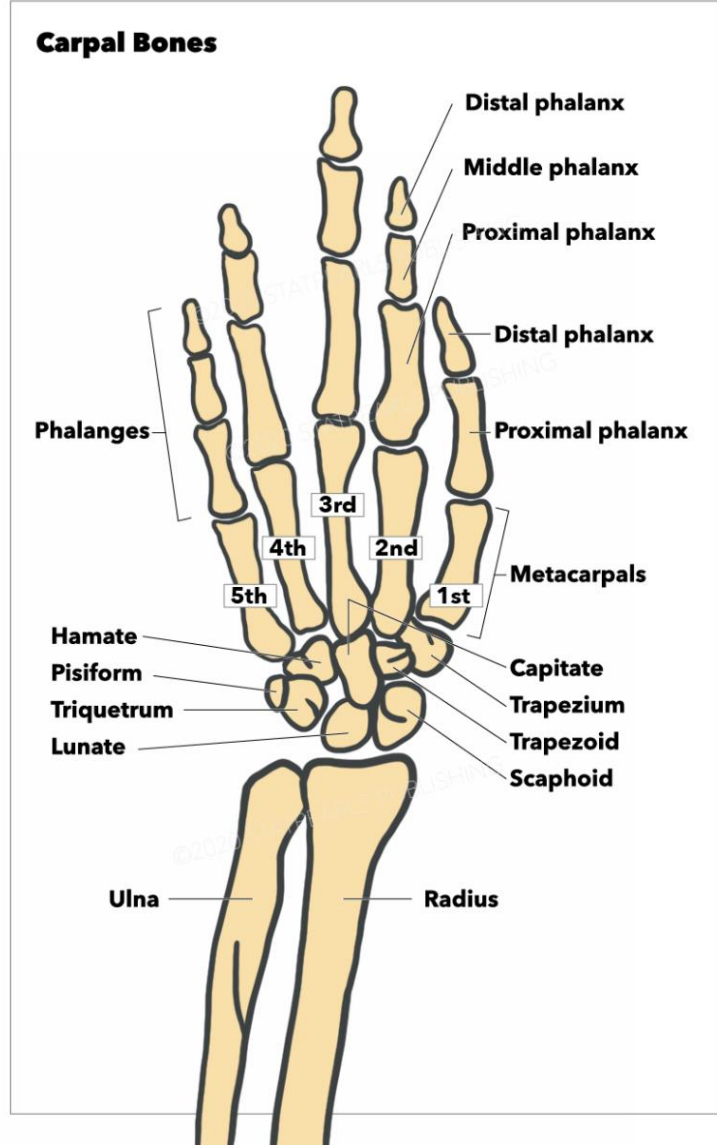
- **El Bilek Kemikleri (Ossa Carpi):** Sekiz kısa kemikten oluşur. Bu kemikler distal ve proksimal sıralar halinde düzenlenmiştir. Proksimal sırada skafoid, lunatum, triquetrum ve pisiform; distal sırada trapezium, trapezoid, capitatum ve hamatum bulunur.
- **El Tarak Kemikleri (Ossa Metacarpi):** Beş uzun kemikten oluşur ve avuç içinin iskeletini oluşturur. Her metakarpal kemiğin basis, corpus ve caput adı verilen üç ana bölgesi vardır.
- **Parmak Kemikleri (Ossa Digitorum):** Her elde toplam 14 kemik bulunur. Baş parmakta iki, diğer parmaklarda ise üç falanks bulunur. Her falanksın proksimal, gövde ve distal bölümleri vardır.

Bu dört grup kemik elin yapısal bütünlüğünü oluşturur ve elin kompleks işlevlerini sağlar (Wadsworth 1983).

El Bileği Kemikleri (Ossa Carpi)

El bileği kemikleri toplamda 8 kısa kemikten oluşur, proksimal ve distal olmak üzere iki sıraya ayrılır. Bu kemikler birbirlerine ligamentlerle bağlanarak sınırlı hareket eder ve el bileğinin hareketliliği ile stabilitesini sağlar.

- **Proksimal Sıra Kemikleri:** Skafoid, Lunatum, Triquetrum, Pisiform
- **Distal Sıra Kemikleri:** Trapezium, Trapezoid, Capitatum, Hamatum



Şekil 1. El bilek anatomisi

El Tarak Kemikleri (ossa metacarpi)

Avuç içinde ve el sırtında yer alan beş uzun ve ince kemikten oluşur. Her metakarpal kemiğin üç ana bölgesi vardır: Basis (el bileğine yakın üst uç), corpus (uzun ve ince orta kısım) ve caput (parmaklara uzanan alt uç).

Bu kemikler, baş parmandan serçe parmağa doğru sıralanır ve Romen rakamlarıyla I'den V'ye kadar numaralandırılır:

- **Os metacarpale I:** Baş parmağın kemiği,
- **Os metacarpale II:** İşaret parmağın kemiği,
- **Os metacarpale III:** Orta parmağın kemiği,

- **Os metacarpale IV:** Yüzük parmağın kemiği,
- **Os metacarpale V:** Serçe parmağın kemiği.

Genellikle en uzun metakarpal kemik işaret parmağıninki (II. metakarpal), en kısa ise baş parmağıninki (I. metakarpal) olarak kabul edilir.

El Parmak Kemikleri (ossa digitorum, phalanges)

El kemiklerinin gelişim süreci, yapısal organizasyonları ve yaşa bağlı değişimleri anlamak açısından önem taşır. Her elde toplam 14 parmak kemiği (falanks) bulunur: baş parmakta 2 adet (proksimal falanks ve distal falanks), diğer parmaklarda ise üçer adet (proksimal, medial ve distal falanks). Proksimalden distale doğru falankslar sırasıyla 1., 2., ve 3. falanks olarak adlandırılır veya falanks proksimalis, falanks media ve falanks distalis şeklinde isimlendirilir.

Ön Kol Kemikleri (Ossa Antebrachii)

- **Radius:** Ön kolun dış tarafında bulunur ve el bileğinde skafoid ile lunatum kemikleriyle eklem yapar.
- **Ulna:** Ön kolun iç tarafında yer alır ve radius ile birlikte hareket ve destek sağlar.

Bu kemikler, elin ve ön kolun hareketliliğini ve dayanıklılığını sağlayarak işlevselliği artırır (Lewis ve ark. 1970).

2.3. Kemik Gelişim Süreci

Embriyonik dönemde kemik gelişimi intramembranöz ossifikasyon ve endokondral ossifikasyon şeklinde iki ana süreçle gerçekleşir.

İntramembranöz Ossifikasyon:

Mezenkimal hücrelerin doğrudan kemik hücrelerine dönüşmesiyle gerçekleşen bu süreç, özellikle düz ve kısa kemiklerin oluşumunda rol oynar. Süreç şu şekilde ilerler:

1. Mezenkimal hücreler belirli bölgelerde toplanır ve yoğunlaşır.

2. Mezenkimal hücreler osteoblastlara dönüşerek kemik matriksi (osteoid) üretir, kemikleşme merkezleri oluşur.
3. Osteoid üzerinde kalsiyum ve fosfat birikerek matriks sertleşir. Sertleşmiş matriks, kemik dokusunu oluşturur.
4. Başlangıçta gevşek olan yapı, zamanla düzenli bir hal alarak olgunlaşır ve düzenlenir.

Kraniyal kemikler, mandibula ve maksilla ile klavikula bu şekilde oluşur. Intramembranöz ossifikasyon, iskeletin temel yapı taşlarının hızla oluşmasını sağlar (Berendsen ve Olsen 2015).

Endokondral Ossifikasyon

Daha karmaşık olan bu süreç, uzun kemiklerin (ör. kol ve bacak kemikleri) gelişimini sağlar. Kemikleşme, bir kıkırdak modelinin oluşumu ve bu modelin kemik dokusuna dönüşümüyle gerçekleşir:

1. Mezenkimal hücreler kondrositlere dönüşerek kıkırdak matriksini oluşturur.
2. Kıkırdak büyüdükçe kondrositler büyür ve hipertrofiye uğrar.
3. Kondrositler, matriksin mineralizasyonunu başlatır ve kan damarları kıkırdağa girer.
4. Mineralize olmuş bölgelerde osteoblastlar, kıkırdağı kemik dokusuna dönüştürür.
5. Kan damarları ve osteoblastlar, kemik iliği boşluğunu oluşturur.

Endokondral ossifikasyon sırasında, perikondrium adı verilen bağ dokusu, osteoblast oluşumunu destekleyerek kemikleşmeyi başlatır. Kıkırdak modeline kan damarlarının girmesi, kemik iliği boşluğunun ve kemikleşme süreçlerinin temel adımıdır (Kronenberg 2003; Long ve Ornitz 2013; Berendsen ve Olsen 2015).

Ossifikasyon Merkezleri

- **Primer Ossifikasyon Merkezi:** Kemiklerin gövdesinde (diafiz) oluşur ve embriyonik dönemde kemikleşmenin başlangıcını temsil eder.

- **Sekonder Ossifikasyon Merkezleri:** Kemik uçlarında (epifiz) doğumdan sonra, özellikle ergenlikte gelişir ve kemiklerin boyca uzamasını sağlar.

Primer ossifikasyon merkezi, kemiklerin gövdesinde temel yapıyı oluşturarak kemikleşme sürecini başlatır. Kan damarları ve osteoblastlar aracılığıyla kemik dokusu gelişir. Sekonder ossifikasyon merkezleri ise epifizlerde doğumdan sonra, özellikle ergenlik döneminde ortaya çıkar ve kemiklerin büyümesini ve şeklini belirler (Maes ve Kronenberg 2012).

Büyüyen kemikler üç ana bölüme ayrılır:

Epifiz, kemik uçlarında spongiyöz dokudan oluşur ve eklem yüzeyleriyle birleşir.

Diyafiz, kompakt kemikten oluşan uzun gövde kısmıdır.

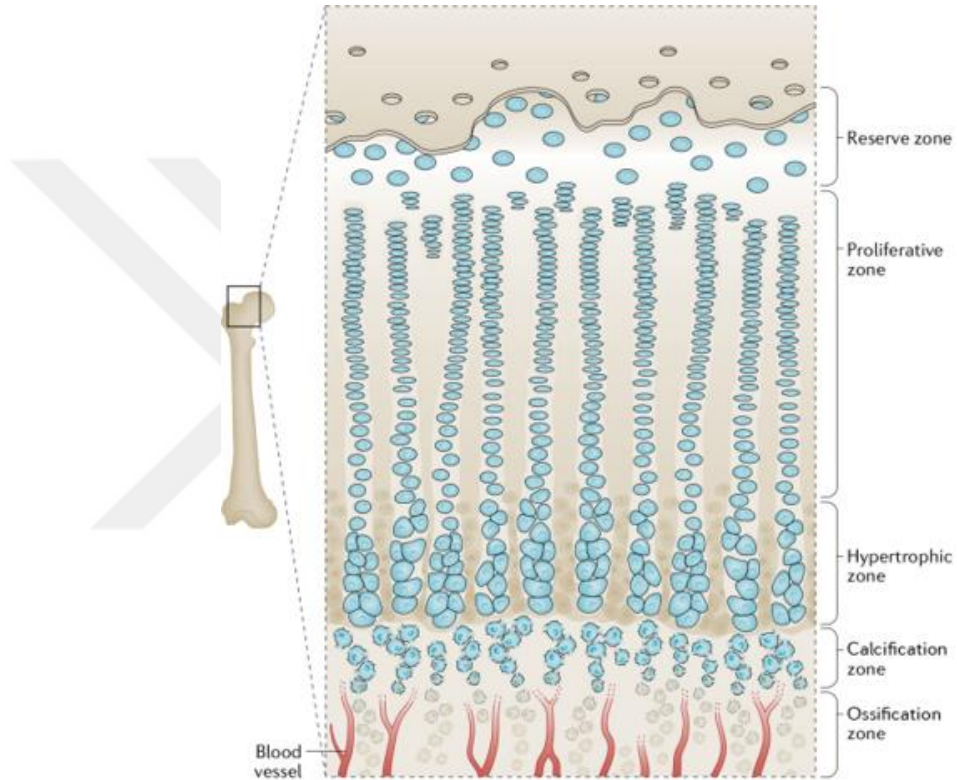
Metafiz, epifiz ve diyafiz arasında yer alır, büyüme plakası içerir ve kemik uzamasında rol oynar (Maes ve Kronenberg 2012)

Epifizyal büyüme plağı, metafiz içinde yer alır ve beş gelişim bölgesine ayrılır.

1. Dinamik Bölge (Reserve Zone): Kondrositlerin durağan olduğu tampon bölgedir.
2. Kıkırdak Üretim Bölgesi (Proliferative Zone): Hücrelerin hızla bölünüp kıkırdak ürettiği alandır.
3. Hipertrofik Bölge (Hypertrophic Zone): Kondrositlerin büyüyerek mineralizasyonu başlattığı bölgedir.
4. Mineralizasyon Bölgesi (Calcification Zone): Kıkırdak matriksinin sertleştiği ve kemikleşme için hazırlandığı aşamadır.
5. Osteojenik Bölge (Ossification Zone): Kemik matriksinin oluştuğu ve kıkırdak dokunun kemik dokusuna dönüştüğü son aşamadır. (Maes ve Kronenberg 2012; Long ve Ornitz 2013; Berendsen ve Olsen 2015)

Damarların kemik kavitesine invaze olması kalsifiye olan kıkırdak matrisini rezorbe etmek üzere osteoklastların ve yeni mineralize kemik dokusu oluşturmak için osteoblastların görevlendirilmesini sağlar, bu da yeni oluşan kemiğin özellikle

kalsiyum ve fosfat ile ossifikasyonunu teşvik eder. Doğumdan sonra, kemiklerin uzunluğu ve hacmi büyümeye devam eder. Bu süreç, çocukluk ve ergenlik dönemini kapsar. Ergenlik döneminde kemiğin remodelasyon süreci tamamlanır. Bu süreç, eski kıkırdak dokusunun kemik dokusuna dönüşmesi ve kemik yapısının olgunlaşmasını içerir. Büyüme plakası (epifizyal plak), kemiklerin uzunluğunu artıran kıkırdak tabakasıdır. Olgunlaşma sürecinde, bu plak kapanır. Epifiz ve diafiz birleşir. Bu, kemik uzunluğunun artışının durduğu ve kemiklerin olgunlaştığı anlamına gelir (Berendsen ve Olsen 2015).



Şekil 2. Metafiz, longitudinal kemik büyümesinin gerçekleştiği epifizyal büyüme plağını içerir. Bu bölge beş ana zona ayrılır: Rezerv, proliferatif, hipertrofik, kalsifikasyon ve ossifikasyon zonları. Rezerv zonu, epifiz ucuna yakın, durağan kondrositler içerir. Proliferatif zon, hızla bölünen kondrositleri barındırır. Hipertrofik zon, bölünmeyi durduran ve hızla büyüyen kondrositlerden oluşur. Kalsifiye zon, hücrelerin apoptoza girdiği ve matriksin kalsifiye olduğu bölgedir. Ossifikasyon zonu, olgun osteoblastların mineralize kemik dokusunu oluşturduğu son aşamadır (Salhotra ve ark. 2020)

El İskeletinin Kemikleşme Süreci

El Bileği Kemiklerinin (Ossa Carpi) Ossifikasyonu: Doğumda kıkırdak yapıya sahip olan bu kemiklerin her birinin kendine ait bir kemikleşme merkezi bulunur (Palanstanga ve ark. 2000; Ellis 2005). Os Capitatum ve Os Hamatum'da intrauterin dönemde kemikleşme başlayabilir. Kemikleşme en erken Os Capitatum'da, en geç ise Os Pisiforme'de başlar. Diğer karpal kemiklerin kemikleşme süreci, beslenme, ırk ve cinsiyet gibi faktörlere bağlı olarak farklılık

gösterebilir. Kemikleşme Os Capitatum ve Os Hamatum'da birinci yaşta, Os Triquetrum'da 2-4 yaşlarında, Os Lunatum'da 3-5 yaşlarında, Os Scaphoideum, Os Trapezium ve Os Trapezoideum'da ise 4-6 yaşlarında başlar. Os Pisiforme'nin kemikleşmesi ise diğer karpal kemiklerden 4-5 yıl sonra gerçekleşir (Dere 2010). Hamulus ossis hamati ayrı bir kemik olarak kemikleşebilir. Hamulus ossis hamati, hamatum kemiğinin bir çıkıntısıdır ve genellikle hamatum kemiği ile birlikte gelişir. Ancak, bazı durumlarda bu yapının ayrı bir kemik olarak erken dönemlerde ya da normalden farklı bir kemikleşme süreci geçirebileceği görülmektedir (Palanstanga ve ark. 2000).

Bilekte yer alan 8 karpal kemiğin kemikleşme süreçleri belirli yaş aralıklarında başlar:

1. yıl: Os capitatum, Os hamatum

3. yıl: Os triquetrum

5. yıl: Os lunatum, Os trapezium

6. yıl: Os scaphoideum

8. yıl: Os trapezoideum

12. yıl: Os pisiforme (Erkoç 1967; Arıncı ve Elhan 1997; Drake ve ark. 2005).

Metakarpal Kemiklerin (Ossa Metacarpi) Ossifikasyonu: Ossa metacarpide primer ossifikasyon merkezleri corpus ossis metacarpide bulunur. Sekonder ossifikasyon merkezleri ise os metacarpal II-IV'te caput ossis metacarpide, os metacarpal I'de ise basis ossis metacarpide yer alır. Os metacarpal I'in kemikleşme süreci falankslarınkine benzediği için, bazı kaynaklarda falanks olarak da değerlendirilmektedir (Arıncı ve Elhan 1997; Ellis 2005). Primer ossifikasyon merkezleri, intrauterin dönemin 9. haftasında ortaya çıkar. Sekonder ossifikasyon merkezleri, os metacarpal II-V'te 1,5-2,5 yaşları arasında, os metacarpal I'de ise biraz daha geç ortaya çıkar. Os metacarpal I'deki sekonder merkezler 15-17 yaşlarında, os metacarpal II-V'teki sekonder merkezler ise 15-19 yaşlarında birinci ve ikinci merkezlerle kaynaşır. Bazen, sekonder merkez caput ossis metacarpide'de görülebilir (Palanstanga ve ark. 2000).

El Parmak Kemiklerinin (ossa digitorum, phalanges) Ossifikasyonu:

Ossa digitorum: Biri gövdede ve diğeri proksimal uçta olmak üzere iki ayrı kemikleşme merkezinden gelişir (Arıncı ve Elhan 1997). İntrauterin dönemin 8-9. haftalarında distal falankslarda kemikleşme başlar. Bunu intrauterin 10. haftada proksimal falanks, ardından ise medial falankslar izler. Sekonder kemikleşme merkezleri 2-4 yaşlarında ortaya çıkar ve bu merkezler 15-18 yaşlarında birincil merkezlerle kaynaşır. Bazen sekonder merkez, caput ossis phalangis'te de görülebilir (Palanstanga ve ark. 2000). Kemikleşme süreci kızlarda genellikle daha erken tamamlanır (Krogman ve Işcan 1986).

Proksimal uçlarda kemikleşme:

- Birinci sıra falankslar: 3-4 yaşlarında,
- İkinci ve üçüncü sıra falankslar: 4-5 yaşlarında başlar.

Her üç sıradaki falanksın kemikleşme merkezleri genellikle 18-20 yaşlarında kaynaşır. Distal falankslar, el kemikleri arasında ilk kemikleşmeye başlayan yapılardır. Diğer falanksların aksine, gövdede değil distal uçlarda kemikleşme görülür (Erkoç 1967; Arıncı ve Elhan 1997; Drake ve ark. 2005).

2.4. Büyüme Ve Gelişme

2.4.1 Büyüme ve Gelişimin Belirlenmesi:

Bireyin büyüme ve gelişiminin değerlendirilmesi, birçok faktörün dikkate alındığı karmaşık bir süreçtir. Bu süreç, genellikle bireyin fizyolojik ve iskelet gelişimini belirlemeye yönelik çeşitli kriterler kullanılarak analiz edilir. Özellikle epifizyal büyüme plağının durumu, kemik olgunlaşma evreleri ve hücrenel değişimler, büyümenin takibinde önemli göstergeler arasında yer alır (Günay 1973; Gülyurt 1989)

1. Kronolojik ve Biyolojik Yaş: Kronolojik yaş, bireyin doğumundan itibaren geçen süreyi ifade eder ve yıl, ay, gün cinsinden ölçülür. Büyüme ve gelişimin değerlendirilmesinde temel bir referans noktasıdır. Çocukluk ve ergenlik dönemlerinde gelişim aşamalarının takibinde önemli bir kriter olarak kullanılır (Günay 1973; Gülyurt 1989).

Bununla birlikte, her bireyin biyolojik yaşı da vardır. Biyolojik yaş, vücudun fizyolojik durumunu yansıtır ve genetik, yaşam tarzı, sağlık durumu ile çevresel faktörler gibi birçok değişkenden etkilenir. Biyolojik yaş, bireyin organ ve dokularının durumu üzerinden değerlendirilir ve bazen kronolojik yaşından daha genç veya yaşlı olabilir. Bu farklılıklar, bireyin büyüme ve gelişim sürecinin daha kapsamlı bir şekilde analiz edilmesini gerektirir (İşcan ve Loth 1989; Garvin ve ark. 2012).

2. Boy ve Ağırlık Artışı: Bireyin boy ve ağırlık ölçümleri, büyüme sürecinin izlenmesinde önemli göstergelerdir. Bu parametreler, yaşa bağlı büyüme eğilimlerini değerlendirmek için kullanılır ve normal büyüme eğrileriyle karşılaştırılarak analiz edilir. Boy ve kilo artışıdaki anormallikler, büyüme bozuklukları veya sağlık sorunlarının habercisi olabilir.

3. Cinsiyet: Büyüme ve gelişim süreçleri cinsiyete bağlı olarak farklılık gösterebilir. Erkekler ve kızlar arasında büyüme hızları ve gelişimsel aşamalar değişkenlik gösterir. Örneğin, kız çocukları ergenlik dönemine daha erken girerken, erkeklerde büyüme atılımı genellikle daha geç başlar ancak daha uzun sürer.

4. Menarş Yaşı: Menarş yaşı, kız çocuklarında ilk adet kanamasının gerçekleştiği dönemi ifade eder ve ergenlik başlangıcının önemli bir göstergesidir. Kemik olgunlaşması ve genel büyüme süreciyle doğrudan ilişkili olan menarş yaşı, bireyin gelişimsel evresini değerlendirmede kullanılan temel kriterlerden biridir.

5. Diş Gelişim Dönemleri: Diş gelişimi, doğumdan yetişkinliğe kadar belirli aşamalardan geçerek ilerler. Süt dişlerinin çıkışı ve kalıcı dişlerin erüpsiyonu gibi süreçler, bireyin yaş tahmininde ve genel gelişim analizinde önemli bir rol oynar. Diş gelişimi, genetik ve çevresel faktörlerin etkilerini yansıtarak büyüme ve olgunlaşma sürecine dair önemli veriler sunar (Günay 1973; Gülyurt 1989).

6. Kemik Yaşı: İskelet yaşının belirlenmesinde, genellikle her iki el ve bileğin röntgen görüntüleri kullanılır. Bu görüntüler, kemiklerin olgunlaşma seviyelerini analiz ederek iskelet gelişiminin değerlendirilmesini sağlar. Homolog parçalar, vücudun her iki tarafında bulunan benzer yapılar olarak tanımlanır. Örneğin, sol ve sağ elin parmak kemikleri homolog kabul edilir. İki el arasındaki

gelişimsel farklılıklar genellikle minimal olduğundan, pratikte belirgin bir sorun oluşturmaz. Kemikleşme süreçleri belirli bölgelerde başlar ve bu merkezlerin sayısı ile büyüklüğü iskelet yaşının belirlenmesinde kritik rol oynar. Karpal kemikler ve sekonder epifizler, yaş ilerledikçe farklı gelişim aşamalarından geçer ve bu süreç bireyin iskelet yaşını değerlendirmek için kullanılır. İskelet yaşı, bireyin fiziksel gelişiminin kronolojik yaşıyla ne kadar uyumlu olduğunu gösterir. Greulich ve Pyle atlası, Tanner yöntemi gibi teknikler, iskelet yaşının belirlenmesinde yaygın olarak kullanılan yöntemlerdir. Kemik yaşı, büyüme sürecindeki bireysel farklılıkları anlamada önemli bir araçtır. Kronolojik yaş, cinsiyet, boy ve ağırlık artışı, diş gelişimi ve kemik yaşı gibi kriterlerin birlikte değerlendirilmesi, çocukların ve ergenlerin normal büyüme eğilimlerini anlamak ve olası sağlık sorunlarını tespit etmek açısından büyük önem taşır (Dreizen ve ark. 1957; Gülyurt 1989).

2.4.2. Yaş Tayini

İskelet yaşının belirlenmesi, kemiklerin morfolojik değişimlerinin yaşla ilişkilendirilmesine dayanır. 1920'de Todd'un çalışmasıyla temelleri atılan bu yöntemler, zamanla gelişmiş ve özellikle iskelet ile diş gelişimi üzerine yoğunlaşmıştır. Ergenlik döneminde yaş tahmini daha kesin yapılabilirken, ergenlik sonrası bireysel farklılıklar ve çevresel etkenler nedeniyle doğruluk oranı düşmektedir. Bu yüzden, yaş tahmin yöntemleri sürekli olarak geliştirilmekte ve yeni bilimsel tekniklerle desteklenmektedir (Krogman ve Isçan 1986).

İskelet olgunlaşmasını değerlendirme yöntemleri, ilk olarak Rochlin ve Todd tarafından geliştirilmiş, ardından Greulich ve Pyle tarafından genişletilmiştir. Bu yöntemler, eklem yüzeyleri, epifizlerin kemikleşmesi ve subepifizyal değişimler gibi anatomik detaylara dayanır. İskelet olgunlaşma evreleri, kemik merkezlerindeki morfolojik değişimlere göre belirlenir ve kronolojik yaş ile karşılaştırılır. Todd'un muayene tekniği ve Kırmızı-Çizelge yöntemi, el ve bilek olgunlaşmasını simetrik olarak analiz ederek daha güvenilir yaş tahminleri yapılmasını sağlar. (Dreizen ve ark. 1957).

Yaş tahmini yöntemleri radyolojik, morfolojik ve histolojik olmak üzere üç ana grupta incelenir. Her yöntemin avantajları ve sınırlamaları bulunmakla birlikte, uygulanma sıklığı ve tercih edilme durumu belirli kriterlere göre değişir. Genel

olarak, radyolojik ve morfolojik yöntemler yaş tayininde daha yaygın olarak kullanılmaktadır. Radyolojik yöntemler, geniş yaş aralıklarında etkili ve pratik bir çözüm sunarak iskelet gelişiminin değerlendirilmesinde tercih edilir. Morfolojik yöntemler ise, özellikle postmortem analizlerde yaygın olarak kullanılır. Histolojik yöntemler, ayrıntılı mikroskopik analizler gerektirdiği ve doku bütünlüğüne zarar verebildiği için daha invaziv bir yöntemdir. Bu nedenle, histolojik incelemeler genellikle zorunlu durumlarda ve özel analizlerde uygulanır (Banerjee ve Agarwal 1998; Davidson ve Rodd 2001).

1. Morfolojik Yöntemler: Morfolojik yöntemler, bireyin büyüme ve gelişim sürecini değerlendirmek için fiziksel ve anatomik özelliklere dayanır. Boy uzaması, ağırlık artışı, kronolojik yaş ve cinsiyet belirteçleri, gelişim aşamalarının belirlenmesinde temel kriterlerdir.

- **Boy Uzaması ve Ağırlık Artışı:** Büyüme eğrileriyle takip edilen bu parametreler, genel sağlık durumu ve gelişimi yansıtır.
- **Kronolojik Yaş:** Doğum tarihine göre hesaplanır ancak tek başına yeterli olmadığından, kemik yaşı gibi diğer kriterlerle desteklenmelidir.
- **Cinsiyet Belirteçleri:** Ergenlikte ses kalınlaşması, kıllanma artışı, bel genişlemesi ve menarş yaşı gibi değişimler, bireyin gelişim düzeyi hakkında bilgi sağlar.

Bu yöntemler birlikte değerlendirildiğinde, iskelet gelişimi ve kemik yaşı daha doğru şekilde belirlenebilir (Günay 1973; Gülyurt 1989).

2. Histolojik Yöntemler: Histolojik yöntemler, yaş tayininde mikroskopik incelemelere dayanır ve iki ana gruba ayrılır:

- **Histomorfolojik Yöntemler:** Kas ve kemik dokularının mikroskopik yapısını analiz ederek yaş tahmini yapar. Miyozin ağır zincirleri, kas lifleri ve hormonların dokular üzerindeki etkileri değerlendirilir.
- **Histokimyasal Yöntemler:** Dokuların kimyasal bileşenleri ve enzim aktiviteleri incelenerek yaş belirlenir. Hormonların kemik gelişimine etkisi ve hücre proliferasyonu gibi faktörler analiz edilir.

İnvaziv ve zaman alıcı bir yöntem olduğundan, histolojik incelemeler genellikle zorunlu durumlarda tercih edilir (Ganong 1995; Isır ve ark. 2004; Dulger ve ark. 2005).

3. Radyolojik Yöntemler: Radyolojik teknikler, kemik ve diş gelişimini görselleştirerek yaş tahmininde yaygın olarak kullanılır. Non-invaziv ve hızlı olmaları, bu yöntemleri pratik hale getirir. Geniş yaş aralıklarını kapsayan veriler sunarak gelişim süreçlerinin takibini sağlarlar. Ancak, radyasyon maruziyeti özellikle çocuklarda minimum seviyede tutulmalıdır. Ayrıca, bazı yaşa bağlı değişimler görüntülerde net olmayabilir, bu da tahmin doğruluğunu etkileyebilir. Sağlık ve güvenilirlik açısından bu faktörlerin dikkatle değerlendirilmesi gereklidir (Greulich ve Pyle 1959; Akkoyun 2013; White ve Pharoah 2013).

Panoramik Radyografi: çene ve diş yapısını geniş bir perspektifte görüntüleyerek ortodontik değerlendirme ve yaş tahmini için kullanılır.

- **Demirjian Metodu:** Diş mineralizasyon aşamalarına dayanarak çocuk ve ergenlerde yaş tahmini yapar. Bölgesel ve bireysel farklılıklar doğruluğu etkileyebilir (Nur ve ark. 2012; Jayaraman ve ark. 2013).
- **Mincer Metodu:** Panoramik radyografilerde dişlerin mineralizasyon seviyelerini inceleyerek yaş belirler (Mincer ve ark. 1993).
- **Häusler ve Lussi Metodu:** Diş köklerinin uzunluğu ve gelişim aşamalarına göre yaş tahmini yapar (Häusler ve Lussi 1983).
- **Nolla Metodu:** Süt ve daimi dişlerin gelişim evrelerini analiz ederek erüpsiyon süreçlerine dayalı yaş tahmini sunar (Nolla 1952).
- **Cameriere Metodu:** Diş kök gelişimi ve diş uzunluklarını ölçerek yaş belirlemede kullanılır (Cameriere ve ark. 2006).

El-bilek radyografileri: El-bilek radyografilerinin temeli, Wilhelm Conrad Röntgen'in 1895'te X ışınlarını keşfetmesiyle atılmıştır. İlk X-ray görüntülerinden biri, Röntgen'in eşinin elinin görüntülenmesiyle elde edilmiştir. Zamanla, geleneksel film bazlı sistemler, daha hızlı, detaylı ve düşük doz radyasyon içeren dijital radyografilerle yer değiştirmiştir. Bu gelişmeler, iskelet yaşı tayini, büyüme ve gelişim analizleri gibi tıbbi alanlarda el-bilek radyografilerinin yaygın kullanımını sağlamıştır (Singer 1980).

El-bilek radyografileri, iskelet gelişimini değerlendirmek ve kemik yaşını belirlemek için yaygın olarak kullanılan bir yöntemdir. Çocuk ve ergenlerde büyüme sürecinin takibinde önemli bir rol oynar. Bu alandaki öncü çalışmalar Ralph Ranke ve Greulich-Pyle tarafından gerçekleştirilmiştir. Ralph Ranke, kemik yaşı değerlendirme prensiplerini geliştiren ilk araştırmacılardan biridir. W. Greulich ve S. Pyle ise Greulich-Pyle Atlasını oluşturarak çocukların kemik yaşını belirlemeye yönelik standart bir referans kaynağı sunmuştur. Greulich-Pyle Atlası, farklı yaş gruplarına ait el ve bilek radyografilerini içerir ve erkekler ile kızlar için ayrı gelişim evreleri sunar. Bireyin el bilek radyografisi, atlasta yer alan yaş gruplarıyla karşılaştırılarak kemik yaşı tespit edilir. Bu yöntem, pediatri, ortopedi, endokrinoloji ve diş hekimliği gibi birçok tıbbi alanda pratik ve hızlı bir değerlendirme sunmaktadır. Ancak, cinsiyet ve etnik farklılıklar bireysel gelişim hızlarını etkileyebileceğinden, kemik yaşı değerlendirmesinde genetik ve bireysel faktörler de göz önünde bulundurulmalıdır (Greulich ve Pyle 1959).

Flory, adduktör sesamoidin kalsifikasyonunun pubertenin başlangıcını belirlemede bir gösterge olabileceğini öne sürmüştür. Daha sonraki araştırmalar, adduktör sesamoidin röntgen görüntülerinde belirgin hale gelmesinden yaklaşık bir yıl sonra büyümenin en yüksek hızına ulaşıldığını göstermiştir. Bu bulgu, iskeletsel olgunlaşma göstergeleri arasında önemli bir kriter olarak kabul edilmekte ve büyüme sürecinin değerlendirilmesine katkı sağlamaktadır (Flory 1936)

Tanner ve ark. (1962), büyüme ve gelişimi değerlendirmek amacıyla İngiliz çocuklardan alınan el-bilek radyografilerini kullanarak Tanner-Whitehouse Atlası'nı oluşturmuştur. İskelet yaşının belirlenmesi için geliştirilen bu atlas, daha sonra Tanner-Whitehouse 2 (TW-2) ve Tanner-Whitehouse 3 (TW-3) olarak iki kez revize edilmiştir. TW-3, önceki versiyonlara kıyasla daha geniş bir veri seti ve güncellenmiş kriterler içermektedir (Tanner ve ark. 1997).

El-bilek bölgesi, iskeletsel maturasyon değerlendirmesinde yaygın olarak kullanılan bir bölgedir. El-bilek radyografilerinin kemik yaşı tayininde tercih edilmesi bazı avantajlar sunar:

- Küçük bir alan olması ve radyografik tekniklerle net görüntülenebilmesi sayesinde değerlendirme kolaydır.

- Tek bir film genellikle yeterli olup, maliyet düşük ve uygulama hızlıdır.
- Kemiklerin süperpozisyon oranı düşük olduğundan analiz daha güvenilirdir.
- Uzun bir dönem boyunca kalsifikasyon gösteren birçok kemik bulunması, gelişim sürecinin detaylı takibini mümkün kılar (Gülyurt 1989).

El-bilek radyografileri uzun yıllardır sol el üzerinden alınmaktadır. Bunun temel nedeni, çoğu bireyin sağ elini aktif olarak kullanması nedeniyle travma ve yaralanmalara daha açık olmasıdır. Ayrıca, sık kullanılan elin kemik gelişiminin yaklaşık üç ay daha ileride olduğu belirtilmektedir. Bu farklılık, iskelet yaşı değerlendirmelerinde standart bir yaklaşım oluşturmak amacıyla sol elin tercih edilmesini sağlamıştır (Greulich ve Pyle 1959).

Kemikleşme ve epifiz kaynaşmasını değerlendirmek için kullanılan yapılar:

- Ulnar sesamoid kalsifikasyonu
- Falanks ve falanks epifizleri
- Metakarpal ve metakarpal epifizleri
- Bilek kemiklerinin kalsifikasyon zamanları
- Radius ve ulnanın epifiz ve diyafizleri

Yaş tayini ve büyüme-gelişim değerlendirilmesinde iki temel yöntem bulunmaktadır:

- **Atlas yöntemi:** Bireyin el-bilek radyografisi, önceden oluşturulmuş bir atlas içindeki yaş gruplarına ait radyografilerle karşılaştırılarak kemik yaşı belirlenir.
- **Kemikleşme analizi yöntemi:** Falanks epifiz ve diyafizlerinin kaynaşma durumu, ulnar sesamoid ve hamatum gibi kemiklerin kalsifikasyonu incelenerek bireyin büyüme-gelişim sürecinin hangi aşamada olduğu belirlenir.

Bu yöntemler, iskelet olgunlaşmasının değerlendirilmesi, yaş tayini ve büyüme süreçlerinin izlenmesi açısından önemli bir rehber sunmaktadır (Gülyurt 1989).

Chapman ve ark., 10 yaşından büyük dental veya ortodontik tedavi başvurusu yapan bireylerin başparmak radyografilerini analiz ederek addüktör sesamoid kemiğin gelişim sürecini dört aşamada sınıflandırmıştır:

- **AS0:** Radyografide henüz sesamoid kemiğin kemikleşme belirtileri gözlemlenmez.
- **AS1:** İlk kez radyografide kemikleşme görülür, sesamoid kemiğin boyutu yaklaşık 1 mm çapında, iğne ucu büyüklüğündedir. Pubertal büyüme atılımının başlangıcı ile ilişkilidir ve yaklaşık 3 ay sürer.
- **AS2:** Ossifikasyon ilerlemiş ancak kemiğin sınırları hala belirsizdir. Bu evre yaklaşık 6 ay devam eder.
- **AS3:** Sesamoid kemiğin sınırları belirginleşmiş, şekli tohum benzeri bir görünüme ulaşmıştır. Erkek bireylerde genellikle daha büyük olarak gözlemlenir.

Bu sınıflandırma, büyüme ve gelişim sürecinin değerlendirilmesinde önemli bir kriter olarak kabul edilmekte olup, ortodonti, pediatri ve endokrinoloji alanlarında yaş tayini ve büyüme analizlerinde kullanılmaktadır (Chapman 1972).



Şekil 3. Chapman olgunlaşma safhaları (Chapman 1972)

Björk ve Helm, 9-17 yaş arasındaki çocukların el-bilek gelişimini inceleyerek sesamoid kemiklerin pubertal büyüme ile ilişkisini araştırmıştır. Sesamoid kemiklerin radyografide görünmesi, büyüme atağının maksimum seviyesine yaklaşmakta olduğunu gösteren önemli bir belirteçdir. Bu kemikler, büyüme atağının zirve noktasından yaklaşık bir yıl önce veya bu süreçte radyografide gözlemlenir. Görüldükten yaklaşık bir yıl sonra ise büyüme atağının en yüksek seviyeye ulaştığı bildirilmiştir. Sesamoid kemiklerin varlığı, pubertal büyümenin değerlendirilmesine yardımcı olur ve büyüme bozuklukları ile gelişimsel anormalliklerin teşhisinde yol gösterici olabilir. Büyüme atağının zamanlamasını doğru belirlemek, tedavi

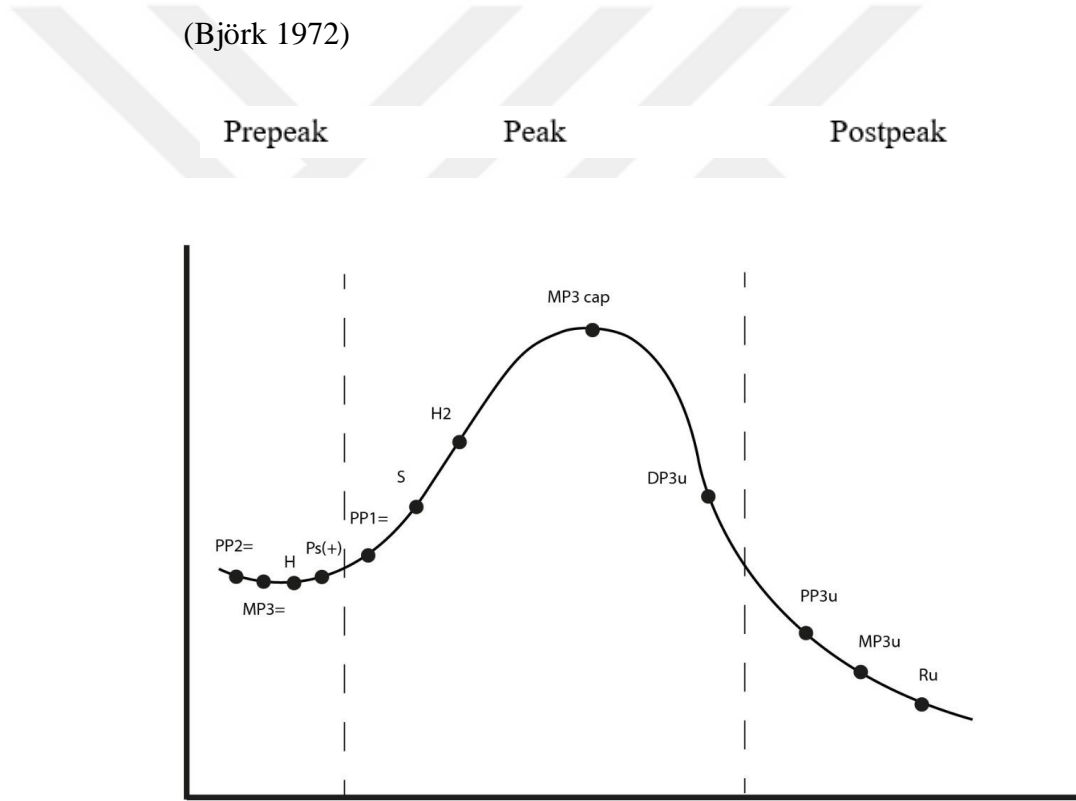
planlaması ve büyüme-gelişim sürecinin takibi açısından önemli bir avantaj sağlamaktadır (Björk ve Helm 1967; Grave 1973; Hassel ve Farman 1995).

Hamatum kemiği, büyüme atılımının değerlendirilmesinde önemli bir gösterge olarak kullanılır. İlk aşamada radyografide kalsifikasyonun başlaması, büyüme atılımının başlangıcını gösterirken, ikinci aşamada hamatum çengeli belirginleşir ve kalsifikasyon artar, bu da büyüme atılımının zirve noktasına ulaşıldığını işaret eder. Bu süreç, iskelet maturasyonunun takibinde önemli bir kriter olup büyüme-gelişim döneminin değerlendirilmesine katkı sağlar (Björk ve Helm 1967; Atasaral 2007). El-bilek bölgesinde kalsifikasyon gösteren kemiklerin yanı sıra, uzun kemik kategorisine giren metakarpal kemikler de büyüme-gelişim değerlendirmelerinde önemli bir yere sahiptir. Başparmak, ilk metakarpal kemik olarak kabul edilir ve bir elde toplam beş adet metakarpal kemik bulunur. Her metakarpal kemiğin diyafizi ve epifizi mevcuttur. Büyüme sürecinde epifiz, önce diyafiz ile eşit genişliğe ulaşır, ardından diyafize doğru kapaklanır, kaynaşmaya başlar ve sonunda tam kaynaşma gerçekleşir. Bu aşamalar, bireyin büyüme-gelişim sürecini izlemek ve iskelet yaşını belirlemek için önemli göstergeler olarak kullanılmaktadır (Grave ve Brown 1976).

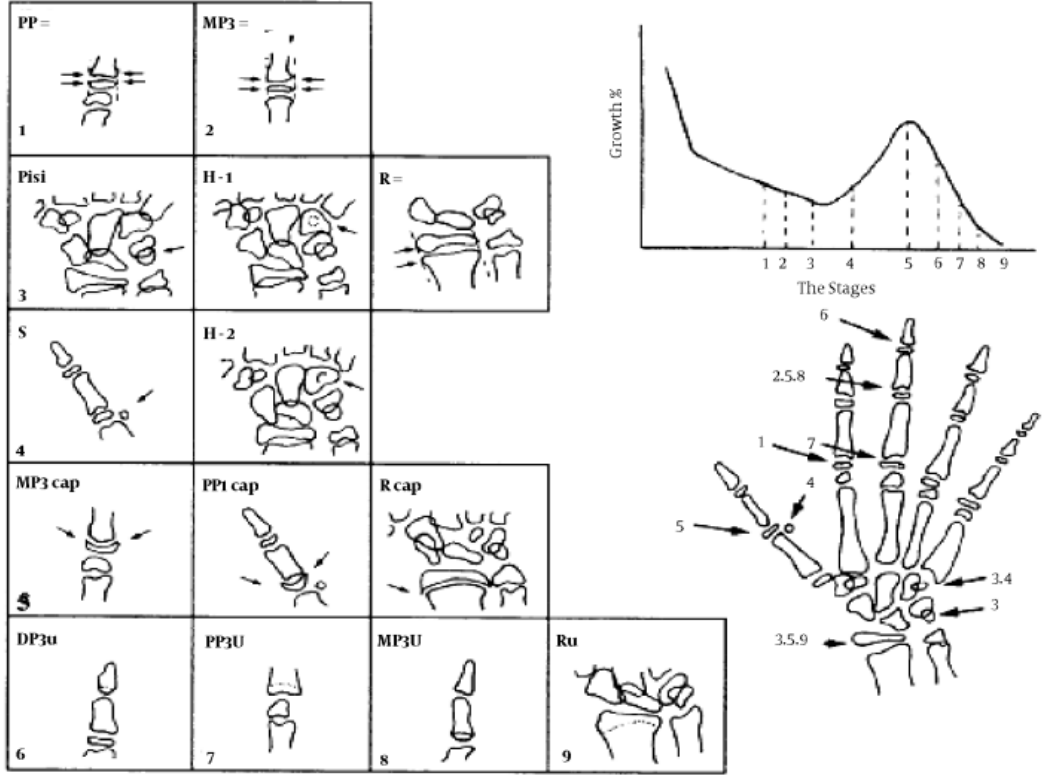
Björk, epifiz ile diyafiz arasındaki ilişkiyi temel alarak büyüme sürecini dokuz aşamada tanımlamıştır. Bu süreç, iskeletsel olgunlaşmanın değerlendirilmesi ve ortodontik planlamalar için önemli bir referans olarak kullanılmaktadır:

- PP2= Evresi: 2. parmağın proksimal falanksında epifiz ile diyafiz eşit genişliktedir.
- MP3= Evresi: 3. parmağın medial falanksında epifiz ile diyafiz eşit genişliktedir.
- Pisi, H1, R= Evresi: Pisiform kemiğin kalsifikasyonu başlamış, hamatum çengeli görünür hale gelmiş ve radius epifiz-diyafiz eşitliği sağlanmıştır. Bu evre, büyüme atılımının başlangıcına işaret eder.
- S-H2 Evresi: Addüktör sesamoid kemik radyografide görünür hale gelmiş ve hamatum çengeli belirginleşmiştir. Bu dönem, büyüme atılımının zirvesine yaklaşıldığını gösterir.

- MP3-Cap, R Cap, PP1 Cap Evresi: 3. parmak medial falanksı, başparmak proksimal falanksı ve radius epifizi, diyafize doğru kapaklanma yapmıştır. Büyüme atılımının zirve noktasına ulaşılmıştır.
- DP3U Evresi: 3. parmak distal falanksında epifiz ile diyafiz kaynaşmıştır. Bu evre, büyüme hızının yavaşlamaya başladığını gösterir.
- PP3U Evresi: 3. parmak proksimal falanksında epifiz ile diyafiz kaynaşmıştır.
- MP3U Evresi: 3. parmak medial falanksında epifiz ile diyafiz kaynaşmıştır.
- RU Evresi: Radius epifizi ile diyafizi kaynaşmıştır ve büyüme süreci tamamlanmıştır. Bu evrede, bireyin artık büyüme potansiyeli kalmamıştır (Björk 1972)



Şekil 4. Büyüme atılımı dönemleri



Şekil 5. El-Bilek radyografilerinde büyüme göstergeleri ve iskelet maturasyonuyla ilişkisi (Björk 1972)

Hägge ve Taranger tarafından geliştirilen MP3 olgunluk belirteçlerine dayanan yöntem, ergenlik dönemindeki iskelet gelişimini değerlendirmek için kullanılan bir metottur. El-bilek radyografileri üzerinden MP3 epifiz ve diyafiz bölgelerindeki değişimler analiz edilerek bireyin büyüme süreci belirlenir.

MP3-F: Pubertal büyümenin başlangıcıdır, epifiz ve metafiz genişlikleri eşittir, ancak belirgin bir sınıır yoktur.


MP3-FG: Büyüme atağı hızlanmaktadır, epifizde belirgin bir demarkasyon hattı oluşur.

MP3-G: Büyüme atağının zirve noktasıdır, epifiz köşeleri kalınlaşmış ve çıkıntılar oluşmuştur.

MP3-H: Büyüme hızı azalmaktadır, epifiz ve metafiz arasındaki kaynaşma süreci başlamıştır.

MP3-I: Pubertal büyüme tamamlanmıştır, epifiz ve metafiz tamamen kaynaşmıştır.

Bu aşamalar, bireyin iskelet olgunlaşmasını değerlendirmek ve büyüme sürecini takip etmek için önemli göstergeler sunmaktadır (Hägg ve Taranger 1980; Hägg ve Taranger 1982).




Şekil 6. Hägg ve Taranger 5 aşamalı maturasyon değerlendirme yöntemi (Hägg ve Taranger 1980)

Fishman'ın büyüme ve gelişim tespit yöntemi, el-bilek radyografileri kullanılarak iskeletsel maturasyonun objektif ve sistematik bir şekilde değerlendirilmesini sağlayan bilimsel bir yaklaşımdır. Bu yöntem, falanks ve radius kemiğindeki belirli anatomik noktaların kemik gelişim evrelerine göre sınıflandırılmasına dayanarak adolesan bireylerin büyüme süreçlerini izlemeye olanak tanır. Her gelişim safhası, kemik olgunluğunun belirli bir aşamasını yansıtmakta ve iskeletsel maturasyonun değerlendirilmesine katkı sağlamaktadır. Fishman metodu, özellikle büyüme hızının belirlenmesi, ortodontik ve ortopedik tedavi planlamalarının optimize edilmesi, iskeletsel olgunlaşmanın değerlendirilmesi ve büyüme atağı zamanlamasının tespit edilmesi gibi klinik uygulamalarda yaygın olarak kullanılmaktadır. Büyüme süreçlerinin bilimsel olarak analiz edilmesine imkan tanıyan bu yöntem, kemik yaşı tayini ve gelişimsel değerlendirmeler için güvenilir ve sistematik bir araç olarak kabul edilmektedir (Björk ve Helm 1967; JM ve ark. 1975).

1. Üçüncü parmağın proksimal falanksında epifiz ve diyafiz eşittir.
2. Üçüncü parmağın orta falanksında epifiz ve diyafiz eşittir.
3. Beşinci parmağın orta falanksında epifiz ve diyafiz eşittir.
4. Addüktör sesamoid kemiği radyografide görünmeye başlar.
5. Üçüncü parmağın distal falanksında epifiz, diyafizi sarmaya başlamıştır.
6. Üçüncü parmağın orta falanksında epifiz, diyafizi sarmaya başlamıştır.


7. Beşinci parmağın orta falanksında epifiz, diyafizi sarmaya başlamıştır.
8. Üçüncü parmağın distal falanksında epifiz ile diyafiz kaynaşmıştır.
9. Üçüncü parmağın proksimal falanksında epifiz ile diyafiz kaynaşmıştır.
10. Üçüncü parmağın orta falanksında epifiz ile diyafiz kaynaşmıştır.
11. Radius epifizi ile diyafizi kaynaşmış, büyüme süreci tamamlanmıştır (Björk ve Helm 1967; JM ve ark. 1975).



Şekil 7. Fishman maturasyon değerlendirme yöntemi (Fishman 1982)

Sefalometrik Radyografiler: Servikal vertebraların büyüme sürecinin değerlendirilmesi üzerine yapılan araştırmalar, sefalometrik radyografilerin iskelet maturasyonunu belirlemede önemli bir yöntem olduğunu ortaya koymuştur. Ruel ve Bench, servikal vertebraların gelişimsel değişimlerini inceleyerek, özellikle atlas (C1) ve aksis (C2) dışındaki vertebraların daha hızlı büyüdüğünü ve bu sürecin belirli yaş aralıklarında takip edilebileceğini vurgulamıştır. Ancak, çalışmalar bireysel vertebraların spesifik büyüme evrelerinden çok, genel gelişim sürecine odaklanmıştır. (Bench 1963).

Lamparski, servikal vertebra analizlerinin kemik yaşı tayini için el-bilek radyografileri kadar güvenilir bir alternatif olabileceğini ileri sürerek, bu alandaki çalışmalara yön vermiştir. Lateral sefalometrik radyografiler yardımıyla C2-C6 vertebralarının büyüme aşamalarını incelemiş ve iskeletsel olgunluk sürecini belirlemek için kullanılacak standartlar geliştirmiştir. Bu yöntem, kemik yaşı belirleme ve büyüme-gelişim süreçlerinin izlenmesi açısından önemli bir değerlendirme aracı olarak kabul edilmiştir. Lamparski'nin çalışmaları, servikal vertebra analizlerinin ortodontik ve ortopedik tedavi planlamalarında da kullanılmasına zemin hazırlamış ve bu alandaki bilimsel araştırmaların gelişimine katkı sağlamıştır (O'Reilly ve Yanniello 1988; Garcia-Fernandez ve ark. 1998; Román ve ark. 2002).



Şekil 8. Lamparski metodunun 6 safhada sınıflandırılması (Lamparski ve Nanda 2002)

2.4.3. Puberte

Puberte, sekonder cinsiyet karakterlerinin geliştiği, büyüme hızının arttığı, üreme kapasitesine ulaşıldığı ve psikolojik değişimlerin yaşandığı çocukluktan yetişkinliğe geçiş sürecidir. İnsanlarda somatik büyüme doğumdan yaklaşık 20 yaşına kadar dört ana dönemde incelenmektedir: bebeklik dönemi (doğumdan 3 yaşa kadar), çocukluk dönemi (3-12 yaş), ergenlik dönemi (12-18 yaş) ve yetişkinlik dönemi (18 yaş ve sonrası). Bu süreçte, özellikle ergenlik döneminde görülen pubertal büyüme atılımı, başlangıç, süre ve miktar açısından bireyler arasında büyük farklılıklar gösterebilmektedir. Yapılan araştırmalar, bu büyüme atılımının genetik, çevresel ve hormonal faktörlere bağlı olarak değiştiğini ortaya koymaktadır (Tanner 1978; Silveira ve ark. 1992).


Sağlıklı bireylerde puberteyi etkileyen faktörler, temel olarak genetik ve çevresel faktörler olmak üzere iki gruba ayrılmaktadır.

Puberteyi Etkileyen Genetik Faktörler

Büyüme ve gelişimi etkileyen genetik faktörler arasında ailesel faktörler, etnik köken ve cinsiyet yer almaktadır. Pubertenin başlangıcını belirleyen genlerin tanımlanması, bu dönemin genetik ve çevresel faktörlerin karmaşık etkileşimine bağlı olması nedeniyle zorluk taşımaktadır (Seminar ve ark. 2003). Etnik farklılıklar açısından yapılan çalışmalar, el-bilek radyografileri, sefalometrik radyografiler ve boy ölçümleri karşılaştırıldığında, pubertal büyüme atağının başlangıcı, süresi, yoğunluğu ve sonlanma zamanı bakımından farklı etnik gruplar arasında belirgin değişiklikler olduğunu göstermektedir. Aynı zamanda dişlerin sürme paternlerinde de bu farklılıkların mevcut olduğu belirlenmiştir (Chertkow 1980; Girgis 1994). Cinsiyetle ilişkili olarak puberte boyunca belirgin hormonal değişimler görülmektedir (Burstone 1963). Erkeklerde androjen sekresyonları testis ve adrenal bezlerden sağlanırken, kızlarda ağırlıklı olarak adrenal bezlerden kaynaklanmaktadır. Bu hormonlar, kemik büyümesini tetikleyerek primer ve sekonder cinsiyet karakterlerinin gelişimini sağlamaktadır (Coutinho ve ark. 1993).

Ergenlik süresince üreme sistemi önemli gelişim gösterirken, sekonder cinsiyet özellikleri belirginleşmektedir. Erkeklerde pubertal büyüme atağının başlangıcında sesin kalınlaşması, bıyık ve sakal çıkması gözlenirken; pubik ve aksiller kıllanma ile dış genital organların büyümesi daha ileri evrelerde gerçekleşmektedir. Kızlarda ise pubik ve aksiller kıllanma ile göğüs gelişimi, üreme sisteminin olgunlaşmakta olduğunu gösterirken, menarşın gerçekleşmesiyle birlikte pubertal büyüme atağı tamamlanmaktadır (Burstone 1963). Menarşın ardından yaklaşık bir yıl sonra boy uzama hızı en yüksek seviyeye ulaşmakta ve bu süreç, kızlarda cinsiyet karakterlerinin olgunlaşmasını değerlendirmede önemli bir gösterge olmaktadır. Genel olarak kızlar, erkeklere kıyasla yaklaşık iki yıl daha erken pubertal büyüme atağına girmektedir. Erkeklerde pubertenin daha geç başlamasına rağmen büyüme hızı, kızlara oranla belirgin şekilde daha fazladır (Greulich ve Pyle 1959; Burstone 1963; Demirjian ve ark. 1985).

Çocukluk Döneminde Normal Büyüme Hızı Deseni



Şekil 9. Çocuklarda yıllık boy artışının takibi

Puberteyi Etkileyen Çevresel Faktörler

Puberteyi etkileyen çevresel faktörler arasında intrauterin gelişim, beslenme, iklim, fiziksel ve psikolojik stres, endokrin bozucu kimyasallar, kronik hastalıklar ve göç gibi etkenler bulunmaktadır. Düşük doğum ağırlığı ve intrauterin büyüme geriliği olan kız çocuklarında menarşın daha erken başladığı ve pubertenin hızlandığı gözlemlenmiştir (Ibáñez ve ark. 2000). Bebeklik döneminde hızlı kilo artışı ve yüksek kalorili diyetler, leptin hormonunun artışıyla birlikte puberte başlangıcını etkileyebilir (Dunger ve ark. 2006). İklim ve etnik köken pubertenin zamanlamasında rol oynamakta olup, soğuk iklimde menarş yaşının daha yüksek olduğu ancak etnik kimliğin belirleyici bir faktör olduğu gösterilmiştir (Bayat ve ark. 2012). Işık maruziyeti, hipotalamik-pituiter-gonadal fonksiyonları etkileyerek üreme sistemini düzenlerken, görme engelli bireylerde erken puberte görülme olasılığı artmaktadır (Bahrami ve ark. 2014). Erken yaşta profesyonel spor yapan kız çocuklarında ise menarşın geciktiği rapor edilmiştir (Łagowska ve Kapczuk 2016). Çevresel toksinler de pubertenin zamanlamasını etkileyebilir. DDT gibi endokrin bozucu kimyasalların hipotalamik olgunlaşmayı hızlandırarak erken puberteye yol açtığı ve göçmen çocuklarda bu maddelere maruziyetin erken puberte riskini artırdığı tespit edilmiştir. Bu faktörler, puberte sürecinin yalnızca genetik değil, aynı zamanda çevresel

etkilerle de şekillendiğini ortaya koymaktadır (Parent ve ark. 2003; Parent ve ark. 2005).

Kemik Yaşının Başlıca Kullanım Alanları

- **Antropoloji:** İnsan kalıntılarında diş gelişimi, kemik yaşı ve cinsiyet tayini için el-bilek ve pelvis kemikleri incelenmekte, Greulich-Pyle, Tanner-Whitehouse ve Fels metodları kullanılmaktadır (Shapland ve Lewis 2014).
- **Adli Tıp:** Kimlik tespiti, cezai sorumluluk, evlilik, askerlik gibi durumlarda yaş belirleme amacıyla kemik yaşı analizleri yapılmaktadır (Arslan ve ark. 2008).
- **Endokrinoloji:** Kemik yaşı, büyüme bozuklukları, obezite ve çölyak gibi hastalıkların takibinde kullanılırken, Greulich-Pyle ve Tanner-Whitehouse atlaslarıyla karşılaştırma yapılmaktadır (Önder ve ark. 2010; Costacurta ve ark. 2012).
- **Ortopedi:** Skolyoz, bacak uzunluğu farkı ve ekstremitelerde kemik yaşı, boy, kilo ve puberte dönemi değerlendirilerek tedavi planlanmaktadır (Heyworth ve ark. 2013).
- **Atletizm:** Spor müsabakalarında kronolojik yaşın doğrulanması ve adil rekabetin sağlanması için kemik yaşı belirlenmekte, yaygın olarak Greulich-Pyle ve Tanner-Whitehouse metodları kullanılmaktadır (Heyworth ve ark. 2013).

Diş Hekimliğinde Kemik Yaşının Kullanımı

Ortodontik Tedavi Planlamasında: Kemik yaşı değerlendirmesi, ortodontik tedavi planlamasında bireyin yüz ve iskelet gelişim sürecini belirlemek amacıyla kullanılmaktadır. Puberte döneminden sonra ortodontik tedavi ile belirgin iskeletsel değişiklikler sağlanamadığından, büyüme modifikasyonu için en uygun zaman pubertal büyüme atağı dönemidir (Alkhal ve ark. 2008; Chen ve ark. 2010). Fonksiyonel apanelerin en etkili olduğu dönem pubertal büyüme atılımı öncesi olup, özellikle sınıf II maloklüzyon tedavisinde puberte dönemi daha iyi sonuçlar vermektedir (Baccetti ve ark. 2002; Franchi ve ark. 2013). Sınıf III olgularda ise palatal ekspansiyonun geç puberte öncesinde yapılmasının daha stabil sonuçlar sağladığı bildirilmiştir (Kluemper ve Spalding 2001). Ortognatik cerrahi

uygulamalarında iskelet gelişiminin tamamlanması beklenmekte olup, büyüme modifikasyonu tedavilerinde kemik yaşının belirlenmesi optimal tedavi zamanlaması açısından önemlidir (Kamal ve Goyal 2006; Joshi ve ark. 2010).

İmplant Planlamasında: Genç bireylerde travmaya bağlı veya konjenital diş eksikliklerinde implant uygulamaları için kesin bir kronolojik yaş sınırı bulunmamaktadır. Ancak, iskelet gelişimi tamamlanmadan yapılan implant uygulamalarında, implantlar ankiloze diş gibi hareket ederek infraoklüzyona neden olabilir ve kötü bir estetik görünüme yol açabilir. Bu nedenle, implant yerleştirilmeden önce dentoalveoler büyümenin tamamlanmasının beklenmesi önerilmektedir (Sharma ve Vargervik 2006; Kumar ve ark. 2011).

2.5. Yapay Zekâ

2.5.1. Yapay Zekânın Tanımı ve Tarihsel Gelişimi

YZ, antik mühendislik harikalarından ve bilimsel kurgudan ilham alarak şekillenmiştir. Leonardo da Vinci'nin 1495'te tasarladığı insansı robot eskizleri ve antik Yunan'daki Antikythera mekanizması, YZ'nin erken dönem fikirlerine zemin hazırlamıştır. Ancak, modern anlamda yapay zekâ, 20. yüzyılda bilgisayarların ve algoritmaların gelişimiyle bilimsel bir alan olarak ortaya çıkmıştır (Chartrand ve ark. 2017; Miladinović ve ark. 2017). YZ, bilgisayarların insan zekâsına benzer şekilde düşünme, öğrenme ve problem çözme yetenekleri kazanmasını sağlayan bir teknoloji alanıdır. YZ, yalnızca önceden programlanmış komutları çalıştırmakla kalmaz, aynı zamanda yeni verilerle öğrenerek kendini geliştirebilir (Mupparapu ve ark. 2018). Alan Turing, 1950'de yayımladığı "Computing Machinery and Intelligence" adlı makalesinde yapay zekâyı teorik olarak ele almış ve Turing Testi ile makinelerin insan benzeri zekâyı sahip olup olmadığını değerlendirme fikrini ortaya atmıştır (Teuscher 2004). 1956 yılında, Marvin Minsky ve John McCarthy tarafından Dartmouth Konferansı'nda ilk kez "yapay zekâ" terimi kullanılmış ve YZ, akademik bir disiplin olarak şekillenmeye başlamıştır (Haenlein ve Kaplan 2019).

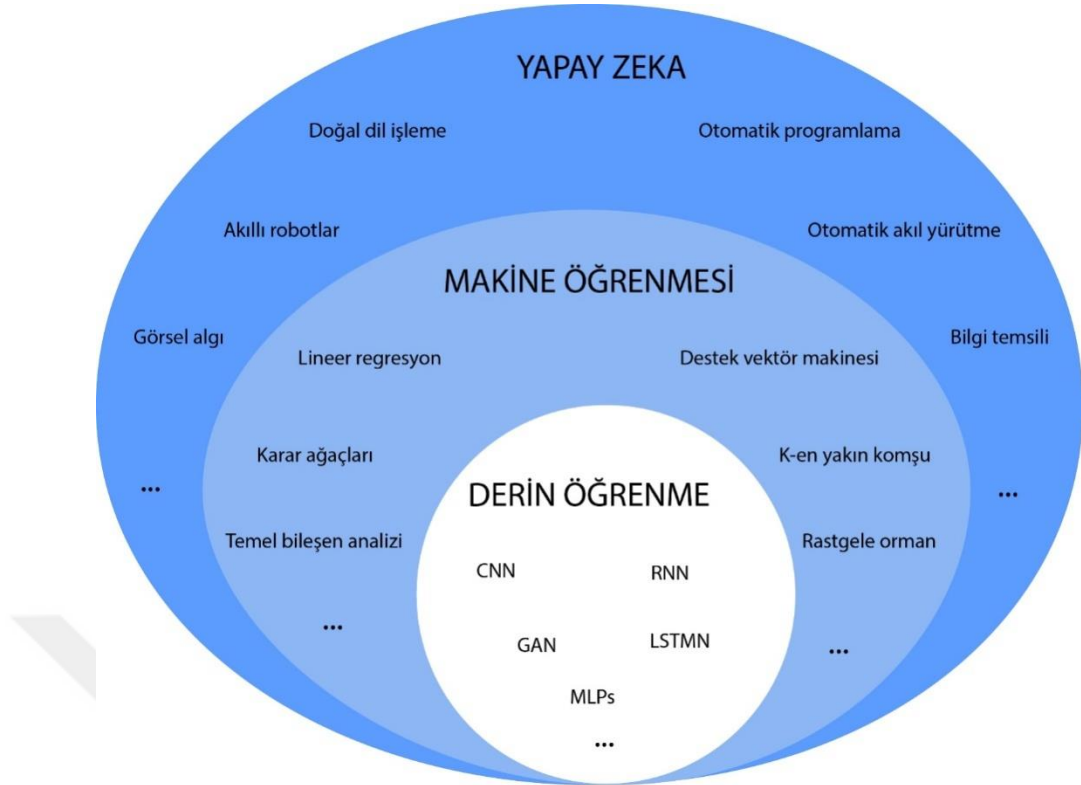
YZ'nin tarihsel gelişimi, 1964'te Joseph Weizenbaum tarafından geliştirilen ELIZA adlı ilk doğal dil işleme programıyla hız kazanmış, 1972'de Japonya'da geliştirilen WABOT-1 ile ilk insansı robot üretilmiştir. 1974-1980 ve 1987-1993 yılları arasında teknik sınırlamalar nedeniyle "Yapay Zekâ Kışları" yaşanmış, ancak

1980'lerde uzman sistemlerin geliştirilmesiyle YZ yeniden popülerlik kazanmıştır. IBM'in geliştirdiği Deep Blue'nun 1997'de Garry Kasparov'u yenmesi, YZ'nin yeteneklerini sergileyen önemli bir dönüm noktası olmuştur (Mijwel 2015; Point 2020).

YZ'nin tanımı zaman içinde değişmiş, McCarthy (1956) tarafından "akıllı makineler yaratma bilimi ve mühendisliği" olarak tanımlanırken, Bellman (1978) bunu "öğrenme, karar verme ve problem çözme gibi insan düşünme yeteneklerinin otomatikleştirilmesi" olarak ifade etmiştir (Bellman 1978; McCarthy 2007). Günümüzde YZ, sağlık, finans, otomotiv ve eğitim gibi birçok alanda devrim niteliğinde ilerlemeler sağlamış ve teknolojik yeniliklerle gelişmeye devam etmektedir (McCarthy 2007; Hassabis 2017; Miladinović ve ark. 2017).

2.5.2. Yapay Zekânın Temelleri

YZ, makinelerin algoritmalar aracılığıyla insan benzeri işlevleri yerine getirmesini sağlayan bir teknolojidir. Makine öğrenmesi, geçmiş verilerden öğrenerek sistemlerin kendini geliştirmesine olanak tanırken, derin öğrenme çok katmanlı sinir ağları kullanarak daha karmaşık analizler yapar. Özellikle görüntü tanıma, doğal dil işleme ve büyük veri analizi gibi alanlarda etkili olan bu yöntemler, yapay zekâ destekli sistemlerin öğrenme ve karar verme süreçlerini sürekli geliştirmektedir (Baduge ve ark. 2022).



Şekil 10. Yapay zekâ, makine öğrenmesi ve derin öğrenmenin birbirleriyle ilişkisi

2.5.3. Yapay Zekâ Türleri

YZ, geliştirilmiş modellerin kapasitelerine göre üç ana gruba ayrılır. Şu an sadece zayıf YZ türü mevcuttur; diğer iki tür üzerinde ise çalışmalar sürmektedir.

Zayıf Yapay Zekâ: Belirli görevleri yerine getirmek için tasarlanmış ve öğrenme kapasitesi sınırlı sistemlerden oluşmaktadır. Finans, üretim, müşteri hizmetleri ve veri analizi gibi alanlarda yaygın olarak kullanılmakta olup, günümüzde mevcut olan tüm YZ sistemleri bu kategoride yer almaktadır (Rawat ve ark. 2023).

Genel Yapay Zekâ: İnsan zekâsına eşdeğer bir sistem geliştirmeyi amaçlamakta ve yeni durumlara uyum sağlayarak öğrenme yeteneğine sahip olmayı hedeflemektedir. Ancak, henüz geliştirilmemiş olup, etik ve güvenlik riskleri ile ilgili çeşitli tartışmalar devam etmektedir (McLean ve ark. 2023).

Süper Yapay Zekâ: İnsan zekâsını her alanda aşabilecek teorik bir konsepttir. Potansiyel olarak küresel sorunları çözebileceği savunulsa da, kontrol edilemez hale gelme ve etik sorunlar yaratma ihtimali nedeniyle ciddi endişeler doğurmaktadır. Günümüzde yapay zekâ yalnızca zayıf yapay zekâ seviyesinde

faaliyet göstermekte olup, genel ve süper yapay zekâ hâlâ araştırma aşamasındadır (Popescu 2019; Ahmed ve ark. 2020).

2.5.4. Yapay Zekâ Algoritmaları

YZ, klasik yöntemlerle çözülemeyen problemlerin çözümünde farklı teknikler ve yaklaşımlar sunar (Çelebi 2021).

Bulanık Mantık: Bulanık mantık, kesin sınırlar yerine belirsizlikleri matematiksel olarak modelleyerek bilgisayarların daha esnek ve insana benzer kararlar almasını sağlar. Bu yöntem, yüz tanıma, hava tahmini ve güç sistemleri gibi çeşitli alanlarda kullanılmaktadır (Zadeh 1984; Isikli 2008; Singh ve ark. 2013).

Uzman Sistemler: Uzman sistemler, insan zekâsının karar verme yeteneğini simüle eden bilgi tabanlı yazılımlardır. Edward Feigenbaum tarafından 1960'ların sonunda geliştirilen bu sistemler, tıbbi teşhis, arıza tespiti ve karar destek mekanizmaları gibi birçok alanda uygulanmaktadır (Lindsay ve ark. 1993; Liao 2005; Russell ve Norvig 2016).


2.5.5. Yapay Zekâ Tabanlı Meta Sezgisel Yöntemler

Optimizasyon süreçlerinde doğadan ilham alan sezgisel ve meta-sezgisel yöntemler kullanılır (Çelebi 2021). Genetik algoritmalar, biyolojik evrim süreçlerini taklit ederek optimizasyon problemlerine çözüm sunar (Thrun 1994; Bäck ve ark. 1997).

Yapay Sinir Ağları

Yapay sinir ağları(YSA), öğrenme süreciyle bilgileri edinin bağlantılarında depolayan ve ağırlıklı bağlantılarla çalışan sistemlerdir (Haykin 1998). 1990'lı yıllarda teorik ve laboratuvar düzeyinde geliştirilen YSA, güçlü işlemciler ve büyük veri işleme kapasitesinin artmasıyla önemli ilerlemeler kaydetmiş ve günümüzde yüz tanıma, sesli asistanlar, otonom araçlar ve sağlık teşhis sistemleri gibi birçok alanda yaygın olarak kullanılmaktadır (Öztemel 2012). İnsan beyninin yapısını taklit eden YSA, nöron adı verilen işlem birimlerinden oluşur ve biyolojik sinir sisteminden esinlenerek öğrenme süreçlerini modellemeyi amaçlar (Van Gerven ve Bohte 2017). YSA, giriş katmanı, gizli katman (ara katman) ve çıkış katmanı olarak üç katmandan

oluşmaktadır (Nguyen ve ark. 2021; Ossowska ve ark. 2022). YSA, girdi olarak verilen matematiksel desenleri çıktılara dönüştürebilmektedir. En çok kullanılan YSA çeşitleri, evrimsel sinir ağları (ESA) ve tekrarlayan sinir ağlarıdır. YSA sayesinde matematiksel anlamda modellenmesi mümkün olmayan kompleks problemlerin modellenmesi yapılmaktadır. Modeller ve aralarındaki ilişkileri öğrenebilen YSA değişen şartlara ayak uydurabilmektedir ve yeniden eğitilebilmektedir (Khanagar ve ark. 2021).



Şekil 11. A) İnsan sinir hücresinin (nöron) diyagramı B) Yapay nöron temsili C) İnsan sinir hücrelerinde bulunan sinaps D) İnsan sinapslarını taklit etmek için geliştirilen yapay sinapslar <http://www.intechopen.com/source/html/39067/media/image1.png> Erişim tarihi 10 Şubat 2025

Yapay sinir ağı modelleri dört ana grupta incelenir:

- Tek Katmanlı Algılayıcılar: Yalnızca girdi ve çıktı katmanlarından oluşur, doğrusal olayları öğrenemez (Öztemel 2012).
- Çok Katmanlı Algılayıcılar: Doğrusal olmayan aktivasyon fonksiyonlarına sahip nöronlar kullanarak daha karmaşık problemlere çözüm sunar (Öztürk ve Şahin 2018).
- İleri Beslemeli Ağlar: Geri besleme döngüsü olmadan, yalnızca önceki birimlerden bilgi alarak çalışır (Al-Zewairi ve ark. 2017).
- Geri Beslemeli Ağlar: Çıktı ile istenen sonuç arasındaki farkı kullanarak öğrenme sürecini gerçekleştirir (Al-Zewairi ve ark. 2017)

Bu modeller, konuşma tanıma, görüntü işleme, örüntü tanıma, risk analizi ve kredi riski tahmini gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. Ayrıca, endüstriyel kontrol, hata yönetimi, ses tanıma, üç boyutlu nesne algılama, hepatit tespiti, uzaktan bilgi alma, üç boyutlu nesne algılama, el yazısı ve yüz tanıma gibi sektörlerde de etkin şekilde uygulanmaktadır (Li ve ark. 2017).

2.6. Makine Öğrenmesi

Makine öğrenmesi, bilgisayar sistemlerinin deneyimlerden öğrenerek büyük veri setlerini analiz etmesini ve değişen koşullara uyum sağlamasını sağlar (Mahesh 2020). Sinir ağları, makine öğrenmesinin bir alt dalı olup, konuşma tanıma, görüntü işleme ve metin/görüntü sınıflandırması gibi birçok alanda yaygın olarak kullanılmaktadır (Li ve ark. 2017). Uygulama alanları oldukça geniştir ve şunları içerir:

Makine öğrenmesi algoritmaları üç ana gruba ayrılmaktadır: denetimli öğrenme, etiketlenmiş verilerle çalışarak tahmin yapma yeteneğine sahiptir; denetimsiz öğrenme, etiketlenmemiş verilerde gizli kalıpları keşfetmeye odaklanır; pekiştirmeli öğrenme ise ödül-ceza mekanizmasıyla en iyi stratejiyi belirler (Hiran ve ark. 2021). Makine öğrenmesi, öneri sistemleri, müşteri segmentasyonu, otonom araçlar ve oyun oynayan yapay zekâlar gibi birçok uygulama alanında kullanılmakta olup, modern teknolojinin temel taşlarından biri olarak gelişmeye devam etmektedir (Mahesh 2020).



Şekil 12. Makine öğrenmesi türleri (Hiran ve ark. 2021)

Denetimli Öğrenme: Denetimli öğrenme, girdi-çıkıtı çiftlerine dayanarak bir fonksiyon öğrenen ve etiketlenmiş verilerle model oluşturan bir makine öğrenimi tekniğidir. Eğitim verisi modelin öğrenmesini sağlarken, test verisi tahmin veya sınıflandırma amacıyla kullanılır. Bu yöntem, sistemlerin öğrendiklerini yeni verilere uygulayarak doğru sonuçlar üretmesine olanak tanır. Denetimli öğrenme, regresyon ve sınıflandırma olmak üzere iki temel kategoriye ayrılır. Regresyon, sayısal verilerle çalışarak sürekli değerler tahmin ederken, sınıflandırma kategorik verileri gruplara ayırır. Örneğin, e-posta filtreleme sistemleri spam ve normal e-postaları ayırt edebilir, kredi risk analizi finans sektöründe kullanılabilir ve hastalık tahmini sağlık alanında uygulanabilir. Günümüzde denetimli öğrenme, makine öğreniminin en yaygın kullanılan yöntemlerinden biridir (Mahesh 2020).

• **Regresyon:** Regresyon, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi analiz eden bir istatistiksel yöntem olup, denetimli öğrenme kapsamında etiketlenmiş verilerle çalışır. Temel amacı, değişkenler arasındaki bağıntıyı en iyi temsil eden fonksiyonu belirleyerek yeni veriler üzerinde tahminler yapmaktır. Maaş, ağırlık ve fiyat tahmini gibi sürekli değişkenlerin öngörülmesi gereken problemlerde yaygın olarak kullanılmaktadır (Goodfellow 2016).

○ **Lineer Regresyon:** Değişkenler arasındaki doğrusal ilişkiyi modelleyerek, örneğin bir ürünün fiyatını üretim maliyetine göre tahmin etmek için kullanılır(Suguna ve Rani 2020).

○ **Polinomal Regresyon:** Doğrusal olmayan ilişkileri modelleyerek talep ve fiyat değişimlerinin etkisini analiz eder (Suguna ve Rani 2020)

○ **Destek Vektör Regresyonu (DVR):** Destek vektör makineleri temelinde çalışarak tahmin hatalarını minimize eden bir hiper düzlem oluşturur (Awad ve Khanna 2015).

○ **Karar Ağacı Regresyonu:** Veri noktaları arasındaki ilişkileri düğüm ve dallardan oluşan bir yapı ile belirler(Abdulhafedh 2022).

○ **Ridge Regresyonu:** Aşırı uyumu önlemek amacıyla modelin karmaşıklığını düzenleyerek daha genelleştirici tahminler yapmasını sağlar (Suguna ve Rani 2020).

○ **Rastgele Orman Regresyonu:** birden fazla karar ağacını bir araya getirerek tahmin doğruluğunu artırır ve daha güvenilir sonuçlar sunar (Abdulhafedh 2022).

• **Sınıflandırma:** verileri belirli sınıflara ayıran bir makine öğrenimi tekniğidir ve etiketlenmiş verilerle model eğiterek yeni verileri doğru kategorilere yerleştirmeyi amaçlar. E-posta filtreleme, tıbbi teşhis ve dolandırıcılık tespiti gibi birçok alanda yaygın olarak kullanılmaktadır.

○ **İkili sınıflandırma:** Veriyi iki sınıftan birine atar (örneğin, spam veya spam değil).

○ **Çoklu sınıflandırma:** Birden fazla sınıftan yalnızca birine atar (örneğin, haber kategorileri).

○ **Çok etiketli sınıflandırma:** Bir veri noktası birden fazla sınıfa ait olabilir (örneğin, bir hayvan fotoğrafının "kedi" ve "evcil hayvan" olarak etiketlenmesi).

○ **Dengesiz sınıflandırma:** Veri setinde bazı sınıfların az temsil edildiği durumları ele alır (örneğin, nadir hastalıkların teşhisi) (Singh ve Aakansha 2017).

Denetimsiz Öğrenme: Etiketlenmemiş verilerde desenleri ve ilişkileri keşfetmek için kullanılır ve özellikle veri analizi ve keşif süreçlerinde önemlidir.

• **Veri gruplama:** Benzer özelliklere sahip veri noktalarını gruplandırır (örneğin, müşteri segmentasyonu).

• **Boyut indirgeme:** Veriyi daha düşük boyutlu bir temsile dönüştürerek işlenmesini kolaylaştırır (örneğin, PCA yöntemi).

• **Anomali tespiti:** Normalden sapmalar gösteren verileri belirler (örneğin, dolandırıcılık tespiti veya ağ güvenliği).

• **Öznitelik öğrenme:** Verilerden daha anlamlı öznitelikler çıkararak analiz süreçlerini iyileştirir (Bonaccorso 2018).

Pekiştirmeli Öğrenme: bir ajanın çevresine tepki vererek ödül/ceza mekanizmasıyla en iyi stratejiyi öğrenmesini sağlayan bir makine öğrenimi yöntemidir. Deneme-yanılma süreciyle çalışan bu yöntem, oyunlar, robotik kontrol, otonom araçlar ve optimizasyon problemlerinde yaygın olarak kullanılmaktadır. Ajan, ödülleri analiz ederek uzun vadede en iyi sonuçları elde etmeye çalışır.

- Pozitif pekiştirme: Doğru eylemlerin ödüllendirilmesiyle teşvik edilir.
- Negatif pekiştirme: Yanlış eylemlerin cezalandırılmasıyla daha iyi stratejilerin bulunmasını amaçlar (Sutton 2018).

2.7. Derin Öğrenme

Derin öğrenme, makine öğreniminin bir alt dalı olup, çok katmanlı sinir ağları aracılığıyla veri içerisindeki üst düzey soyutlamaları modellemeye odaklanır. Özellikle görüntü sınıflandırma, veri işleme ve analiz gibi alanlarda yaygın olarak kullanılmaktadır (Bengio 2009; Bengio ve ark. 2013; LeCun ve ark. 2015; Schmidhuber 2015). YSA, biyolojik sinir sistemlerinden esinlenerek geliştirilen ve yapay nöronlardan oluşan matematiksel modellerdir. Giriş, gizli ve çıktı katmanlarından oluşan bu yapı, veri işleme sürecinde önemli bir rol oynar. Giriş katmanı verileri alırken, gizli katmanlar doğrusal olmayan dönüşümler yaparak karmaşık ilişkileri öğrenir ve çıktı katmanı, modelin nihai tahminini üretir. Nöronlar arasındaki bağlantılar, öğrenme sürecinde güncellenen ağırlıklarla çalışır ve aktivasyon fonksiyonları sayesinde belirli eşik değerleri aşıldığında sinyaller işlenir (Bishop ve Nasrabadi 2006; Goodfellow 2016).

Derin Öğrenme Algoritmaları

Derin öğrenme, sinir ağlarını eğitmek ve optimize etmek için kullanılan algoritmalarla büyük ve karmaşık veri kümelerini işleyebilme kapasitesini artıran bir yaklaşımdır. Geleneksel modeller az sayıda katmana sahipken, derin öğrenme yüzlerce katman kullanarak daha karmaşık yapıları öğrenebilir. Bu çok katmanlı yapı, görüntü işleme, doğal dil işleme ve otonom sistemler gibi alanlarda daha etkili sonuçlar elde edilmesini sağlar (Pouyanfar ve ark. 2018). Derin öğrenme, geleneksel makine öğrenimi algoritmalarının sınırlamalarını aşarak yapılandırılmamış verileri işleyebilme yeteneğine sahiptir. Bu sayede, görüntü, metin ve ses gibi farklı veri türlerinde geniş bir uygulama alanı sunar (Bonaccorso 2018).

Derin Öğrenme Mimarileri

Derin öğrenme mimarileri, farklı veri türlerini işleyebilmek için çeşitli sinir ağı yapıları kullanır ve her model belirli bir problem türüne özel olarak geliştirilmiştir.

Konvolüsyonel Sinir Ağları (KSA) , görüntü tabanlı verilerin işlenmesi ve sınıflandırılması için geliştirilmiş çok katmanlı bir modeldir. Giriş, konvolüsyon, ReLU, havuzlama, tam bağlantılı, DropOut ve sınıflandırma katmanları aracılığıyla özellik çıkarımı ve veri işleme süreçlerini optimize eder (Srivastava ve ark. 2014; O'Shea 2015; Özkan ve Ülker 2017; Silvestrini ve Lavagna 2022)

Tekrarlayan sinir ağları (TSA), sıralı veriler üzerinde çalışmak için geliştirilmiş olup, geri besleme döngüleri sayesinde önceki zaman adımlarını hatırlayarak öğrenmeyi optimize eder. Doğal dil işleme, konuşma tanıma ve zaman serisi tahmini gibi alanlarda yaygın olarak kullanılır (Haykin 1998; Mikolov ve ark. 2010).

Uzun kısa vadeli hafıza (LSTM) ağları, TSA'nın geliştirilmiş bir versiyonu olup, uzun vadeli bağımlılıkları öğrenmeye odaklanarak dil modelleri, biyomedikal analizler ve ses tanıma gibi uygulamalarda kullanılır (Gers ve ark. 2000).

Sınırlı Boltzmann makineleri (SBM), görünür ve gizli nöronlardan oluşan olasılık temelli bir modeldir ve özellikle boyut indirgeme ve öznitelik çıkarma süreçlerinde kullanılır (Hinton 2007).

Derin inanç ağları (DİA), çoklu gizli katmanlardan oluşan, olasılıklı hesaplama yöntemleriyle öğrenme gerçekleştiren üretken bir model olup, görüntü işleme ve doğal dil işleme gibi alanlarda başarılı sonuçlar verir (Hinton 2009)

Derin oto-kodlayıcılar (DOK), denetimsiz öğrenme yöntemiyle çalışan ve boyut indirgeme ile öznitelik öğrenme süreçlerinde kullanılan bir modeldir. Veriyi sıkıştırarak önemli özellikleri korur ve gereksiz bilgileri filtreler (Hosseini ve ark. 2016).

2.8. Nesne Tespit ve Tanımlama Algoritmaları

Nesne tespiti, dijital görüntülerde belirli nesnelere algılama ve tanımlama sürecidir. Bu işlem, nesnenin konumunu belirleme, sınıflandırma ve istatistiksel özelliklerini analiz etme aşamalarını kapsar. Son yıllarda yüz tanıma, otonom araç sistemleri ve güvenlik uygulamaları gibi birçok alanda yaygın olarak kullanılmaktadır (Zou ve ark. 2023). Nesne tespitinin temel amacı, görüntülerde

bulunan nesnelere belirleyerek konumlarını saptamak ve uygun kategorilere ayırmaktır. Geleneksel nesne tespiti yöntemleri, geometrik ve istatistiksel özellikleri kullanırken, derin öğrenme tabanlı algoritmalar daha yüksek doğruluk oranları sunarak bu yöntemlerin yerini almaktadır. Derin öğrenme destekli nesne tespit algoritmaları, karmaşık sahnelerde ve büyük veri setlerinde daha hızlı ve hassas sonuçlar sağlayarak gelecekte yaygın olarak kullanılmaya adaydır (Li ve ark. 2021).

Derin Öğrenmeye Dayalı Yöntemler

Derin öğrenmeye dayalı nesne algılama yöntemleri iki aşamalı ve tek aşamalı modeller olarak ikiye ayrılır (Shetty ve ark. 2021).

İki Aşamalı Nesne Algılama Modelleri

İki aşamalı modellerde nesne algılama süreci, bölge önerisi çıkartma ve sınıflandırma olmak üzere iki aşamada gerçekleşir (Li ve Cao 2020).

- R-CNN (Regional Convolutional Neural Network): R-CNN, Ross Girshick tarafından önerilen bir model olup, görüntüde belirgin özelliklere sahip bölgeleri seçer ve bunları kutularla sınırlar (Kumar ve ark. 2019). Daha sonra, evrişimli sinir ağı (CNN) kullanılarak bu bölgelerden öznelikler çıkarılır ve nesne sınıflandırması yapılır (Li ve Cao 2020)

- Fast R-CNN: Orijinal R-CNN'nin geliştirilmiş versiyonudur. Seçici arama algoritmasıyla önerilen bölgeler oluşturularak nesne algılama süreci hızlandırılmıştır. Evrişimli ve havuzlama katmanları ile dönüşüm özellik haritası çıkarılır (Li ve Cao 2020).

- Faster R-CNN: Fast R-CNN'in düşük hızına sebep olan seçici arama algoritmasının yerine, Bölgesel Öneri Ağı (Region Proposal Network - RPN) kullanılarak nesne algılama süreci hızlandırılmıştır. Böylece daha hızlı ve doğru nesne tespiti sağlanmaktadır (Shetty ve Jogi 2019).

- Mask R-CNN: Faster R-CNN'in bir uzantısı olup, piksel seviyesinde segmentasyon gerçekleştirir. "Mask" adı verilen ek bir adımla, her pikselin nesneye ait olup olmadığını tahmin eder. Eğer eğitim verisi nesnelerin piksel düzeyindeki konumlarını içeriyorsa, modelin doğruluğu artar (Li ve Cao 2020).

Tek Aşamalı Nesne Algılama Modelleri

Tek aşamalı modeller, sinir ağı üzerinden yalnızca tek bir geçişle tüm sınırlayıcı kutuları aynı anda tahmin eder. Bu sayede hesaplama maliyeti azalırken, işlem hızı artar (Redmon ve ark. 2016; Shetty ve Jogi 2019; Adarsh ve ark. 2020).

- SSD (Single-Shot Detector): Tek aşamalı bir nesne algılama modeli olup, nesne tespitini tek bir ardışık süreçte gerçekleştirir. SSD modeli, nesne algılama gerektiren sistemlerde çoğaltılabilir ve özellikle küçük nesnelerin algılanmasını sağlayan yüksek çözünürlüklü katmanlara sahiptir. SSD'nin uçtan uca eğitilebilir olması avantajlarından biridir (Shetty ve Jogi 2019; Li ve Cao 2020).

- YOLO (You Only Look Once): YOLO, tek aşamalı nesne algılamada en popüler algoritmalarından biridir (Sultana ve ark. 2020). İlk olarak 2015 yılında Redmon ve ark. tarafından tanıtılmıştır. YOLO modeli, görüntüyü bir ızgaraya bölerek her bölgenin nesne içerip içermediğini tahmin eder ve nesne sınıflandırmasını aynı anda gerçekleştirir. (Zhiqiang ve Jun 2017).

- RetinaNet: RetinaNet, YOLO ve SSD gibi tek aşamalı modellerin düşük doğruluk oranlarını iyileştirmek için Focal Loss ve Feature Pyramid Network (FPN) gibi yeni teknikler kullanarak hata oranlarını azaltır. Bu sayede, hızdan ödün vermeden iki aşamalı dedektörlerin performansına yaklaşır (Coelho ve ark. 2021). RetinaNet, omurga ağı ve iki görev bazlı alt ağdan (sınıflandırma ve sınırlayıcı kutu regresyonu) oluşan birleşik bir modeldir (Chahyati ve Arymurthy 2020).

YOLO (You Only Look Once)

YOLO, nesne algılama için hızlı ve doğru sonuçlar sağlayan bir algoritmadır. Regresyon tabanlı çalıştığı için karmaşık bir veri tabanına ihtiyaç duymaz ve sınırlayıcı kutular ile ilişkili sınıf olasılıklarını öngörür. Bu sayede yüksek hız ve verimlilik sunar. Evrensel akıl yürütme yeteneği ve nesnelerin genelleştirilebilir temsillerini öğrenmesi önemli avantajları arasındadır (Redmon ve ark. 2016; Jiang ve ark. 2017).

YOLO serisi farklı sürümlerle geliştirilmiştir:

YOLOv1: Tespit işlemi üç aşamadan oluşur: Görüntü ön işleme, sinir ağına giriş ve nesne olasılıklarının belirlenmesi (Shetty ve Jogi 2019).

YOLOv2: Darknet-19 mimarisine dayanır ve COCO ile ImageNet veri kümeleri kullanılarak eğitilmiştir (Redmon ve Farhadi 2017).

YOLOv3: Çok etiketli sınıflandırıcı kullanır ve sigmoid çapraz entropi kaybı ile tahmin doğruluğunu artırır (Redmon 2018).

YOLOv4: Paralel işlemeye uygun şekilde optimize edilmiştir ve önceki sürümlere göre daha yüksek hız ve hassasiyet sunar (Bochkovskiy ve ark. 2020).

YOLOv5: 2020 yılında Ultralytics tarafından tanıtılmıştır. Darknet çerçevesinden PyTorch gibi popüler bir derin öğrenme kütüphanesine geçiş yaparak daha erişilebilir ve özelleştirilebilir bir hale getirilmiştir. Kademeli evrişim katmanları ve Spatial Pyramid Pooling Fast (SPPF) gibi yenilikler ile hesaplama yükü azaltılmış ve bellek kullanımı optimize edilmiştir (Li ve ark. 2021; Wang ve ark. 2023; Jegham ve ark. 2024).

YOLOv6: RepVGG tabanlı EfficientRep omurgasını kullanarak önceki sürümlere kıyasla hız ve doğrulukta iyileştirmeler sunar (Atrey ve ark. 2024).

YOLOv7: Hız ve doğruluğu artıran mimari reformlar içerir ve COCO veri kümesi ile eğitilmiştir (Wang ve ark. 2023).

YOLOv8: 2023 yılında Ultralytics tarafından geliştirilmiştir. Nesne algılama, görüntü sınıflandırma ve segmentasyon görevlerinde kullanılır. Ölçeklenebilir sürümleri farklı uygulama ihtiyaçlarını karşılar. YOLOv8n en hızlı ve en küçük, YOLOv8x ise en yüksek doğruluğa sahip ancak daha yavaş bir modeldir (Rath 2023; Solawetz 2023; Jegham ve ark. 2024).

YOLOv11: 2024 yılında Ultralytics tarafından tanıtılmış olup, Örnek Bölümlendirme, Poz Tahmini ve Yönlendirilmiş Nesne Algılama gibi ek yetenekler sunmaktadır. YOLOv8'den farklı olarak C2f bloğunu daha verimli C3k2 bloğuyla değiştirerek gelişmiş performans sağlamaktadır. Ayrıca, küçük ve üst üste binen nesnelere için doğruluğu artıran C2PSA (Mekansal Dikkatli Kısmi Sahne Çapraz) modülü ile donatılmıştır (Jegham ve ark. 2024).

3.GEREÇ VE YÖNTEM

Bu çalışma, Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Kliniği'nde gerçekleştirilmiş olup, Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi İlaç ve Tıbbi Cihaz Dışı Araştırmalar Etik Kurulu tarafından 26.10.2023 tarih 2023/344 sayılı izni alınarak gerçekleştirilmiştir. Tüm revizyonlar, Helsinki Bildirgesi ilkelerine uygun biçimde yapılmıştır.

3.1. Gereç

3.1.1. Örneklem Büyüklüğünün Belirlenmesi

Tek taraflı bağımsız örneklem t-testi analizi, %95 güven aralığı (1- α), %95 test gücü (1- β) ve $d=0,518$ etki büyüklüğü kullanılarak gerçekleştirilen hesaplamada, her grup için minimum 85 örneğin yeterli olduğu belirlenmiştir. Bu hesaplama, istatistiksel olarak anlamlı bir farkın belirlenebilmesi için gerekli örneklem büyüklüğünü ortaya koymaktadır (Geng ve ark. 2024).

3.1.2. El-Bilek Radyografilerinden Veri Setinin Oluşturulması

Çalışmada kullanılan el-bilek radyografiler Ocak 2022 - Ocak 2023 yılları arasında ortodontik tedavi ihtiyacıyla başvuran hastaların Necmettin Erbakan Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Kliniği'nde çekilmiş görüntüleridir. Hastadan alınan el-bilek görüntüleri üzerinden retrospektif olarak gerçekleştirilmiştir. El-bilek görüntüleri, Planmeca ProMax 2D Scara 3 64 Kv 6.3 mA 10.5 s ve 2D Veraviewpocs (J MORITA MFG corp., Kyoto, Japan) 70 kVp, 5 mA, 15 s; Planmeca Promax S3 Panorex with CEPH-DIMAX 4, Planmeca, Finland; Planmeca Proline CC 2002 model, 60-80 kVp, 8-10 mA, 12.8 saniye pozlama süresi, Helsinki, Finlandiya Planmeca Romexis 16 saniye pozlama süresi, 66 kV, 9 mA Helsinki, Finlandiya parametrelerinde oluşturulan görüntülerden toplanmıştır. Görüntüleme işlemleri sırasında kullanılan cihazlar ve protokoller uygun şekilde seçilmiş ve görüntü kalitesini etkileyebilecek teknik faktörlerin en aza indirildiği bir yaklaşımla değerlendirilmiştir.

Radyografilerin çekimi sırasında aşağıdaki kriterlere dikkat edilmiştir:

- Sağ ve sol el-bilek görüntülerinin elde edilmesi,

- Radyografi sırasında el-bilek bölgesinde herhangi bir aksesuarın bulunmaması,

- El parmaklarının hafifçe açık olması,
- Radius ve ulna distal bölümlerinin ve parmak uçlarının filmde taşmaması.

Çalışma kapsamında uygun görüntü kalitesi taşıyan, artefakt içermeyen ve radyografi çekim kurallarına uygun olan 13663 adet el-bilek radyografisi taranmış, 3268 görüntü çalışmaya dahil edilmiştir. Jpeg formatında (.jpeg) alınan iki boyutlu (2B) veriler 3,7 MP, 68 cm, 2560 x 1440 çözünürlük, 27 inç renkli Ultra Sharp LED TFT ekranda (Dell, DellInc. Round Rock, TX, ABD) incelenmiştir.

3.1.3. Birey Seçimi

Dahil edilme kriterleri arasında;

- 8 yaşından büyük olma,
- Yaygın kemik patolojisi içermeme,
- Diagnostik kabul edilebilirlikte radyografiye sahip olma yer almaktadır.

Aşağıdaki kriterlerden herhangi birisini bulduran bireyler tez çalışmasına dahil edilmemiştir:

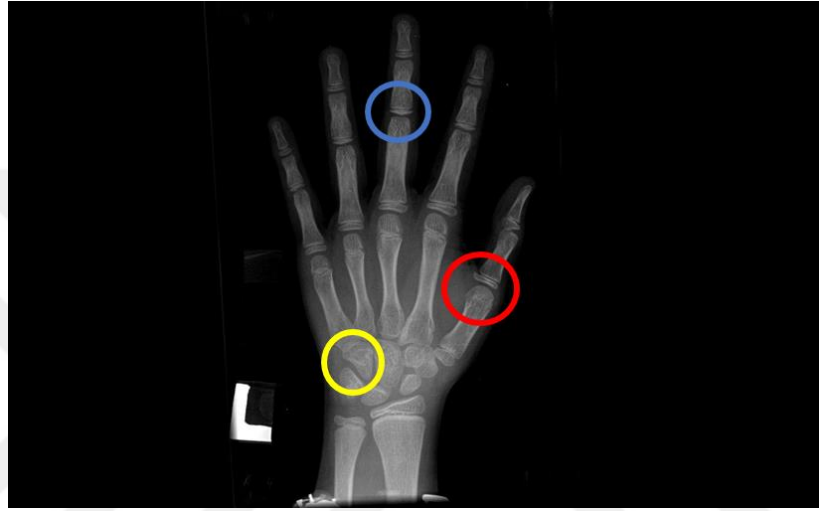
- Görüntü kalitesi düşük, artefaktlı el-bilek görüntüleri,
- El-bilek bölgesinde rezeksiyon, kanser cerrahisi geçiren bireylerin görüntüleri,
- 8 yaşından küçük bireylerin el-bilek görüntüleri
- Büyüme geriliğine sahip olan, anomalisi ya da sendromu bulunan görüntüler

3.1.4. Görüntü İşleme ve El-Bilek Radyograflerinin Değerlendirilmesi


Çalışmada el-bilek görüntüleri üzerinden toplanan görüntülerin satır ve sütun boyutları birbirinden farklıdır. Uygun görselleştirme ve standardizasyonu sağlamak amacıyla görüntü işleme araçları kullanılarak görüntülerin kontrast ve parlaklık değerleri (600) dpi'ye ayarlanarak “.jpeg” formatında kaydedilmiştir. Algoritmaların uygun performansta çalışabilmesi için toplanan tüm görüntülerin boyutları eşitlenmiştir (resize işlemi). Yapay zekâ modelinin standardize olarak test edilmesinin sağlanması ve çalışma başarısının yüksek olması amacıyla tüm

görüntüler 1024 x 640 piksel boyutuna getirilerek kaydedilmiştir. Görüntü boyutları eşitlenen el-bilek görüntülerinde prepik, pik ve postpik olmak üzere üç ayrı gruba sınıflandırılmıştır.


Çalışmaya dahil edilen bireylerin iskeletsel maturasyon evresi el bilek kemiklerinden Björk, Grave ve Brown (Björk 1972; Grave ve Brown 1976) methodu kullanılmıştır. Björk sınıflandırma yöntemine göre bireylerin büyüme-gelişimi değerlendirilerek 3 maturasyon dönemine ayrılmıştır.



Şekil 13. Prepik dönemine ait bir el-bilek radyografisi



Şekil 14. Pik dönemine ait bir el-bilek radyografisi



Şekil 15. Post-pik dönemine ait bir el-bilek radyografisi

Bu sisteme göre toplamda 1060 adet prepik, 1073 adet pik ve 1135 tane postpik görüntü toplanmıştır. Oluşturulan bu gruplarda, YOLOv8x-clc algoritmasının el-bilek radyografisinin ‘bütününe’ odaklanarak maturasyon dönemlerini tespit etmesi amaçlanmıştır ve etiketleme işlemi yapılmamıştır. Modelin eğitim sürecinde aynı veri artırma yöntemleri kullanılmıştır: HSV-Hue, Hue-Saturation, HSV-Value, Mosaic, Flipup, Flipdown, FlipRight, FlipLeft. Bu teknikler modelin performansını artırmada önemli rol oynamıştır. Üç sınıfa ayrılan görüntüler 224x224 piksel olarak yeniden boyutlandırılmıştır. YOLOv8x-clc modeli ile batch büyüklüğü 24 seçilerek 3268 görüntünün 2668’i eğitim, 300 doğrulama ve 300 de test sayısı kullanılarak model eğitimi sağlanmıştır. Öğrenme hızı (learning rate) 0.01 olarak belirlenmiştir. Daha sonra veriler, hastalara ait bilgilerin elde edilemeyeceği şekilde anonimleştirilerek CranioCatch programına (CranioCatch Eskişehir, Türkiye) aktarılmıştır.

Tüm radyograflar karartılmış bir odada aynı bilgisayar monitöründe incelenmiştir. Gözlemcilerin kalibrasyonu için 100 el-bilek görüntüsü üzerinden çalışmaya başlamadan yirmi gün önce Ortodonti uzmanı (MY, 13? yıllık tecrübesi

bulunmaktadır) tarafından eğitim verilmiştir. Ağız Diş ve Çene Radyolojisi alanında çalışan iki gözlemci (Gözlemci 1: CNY 3 yıllık tecrübe, Gözlemci 2: AA. 11 yıllık tecrübe) el-bilek görüntülerini değerlendirip üç sınıfa ayrılmıştır. Gözlemci içi uyum için üç hafta sora değerlendirmeler yapılmıştır. Sonrasında gözlemciler arası uyum için üç hafta sonra el-bilek görüntülerinin %20'si tekrar değerlendirilmiştir. Kararsız kalınan durumlarda konsensusla karar verilerek sınıflandırmalar tamamlanmıştır.

3.2. Yöntem

Çalışmada kullanılan veriler “.jpeg” formatında elde edilip CranioCatch modülüne yüklenmiştir. Gözlemciler arası ve gözlemci içi uyum değerlendirmesinde tutarlılık analizi yapılmış, gözlemci içi uyum katsayısı 0,995; gözlemciler arası uyum katsayısı 0,983 olarak bulunmuştur. Görseller, eğitim, doğrulama ve test olmak üzere üç veri setine ayrılmıştır. Eğitim ve doğrulama veri setleri, yapay zekâ algoritmasının ağırlık faktörlerini tahmin etmesi için kullanılırken, modelin başarısı test setiyle ölçülmüştür.

3.2.1. Model Eğitimi

Veri setleri; eğitim, doğrulama ve test veri setleri olmak üzere 3 bölüme ayrılmıştır. Eğitim ve doğrulama veri setleri optimal yapay zekâ algoritması ağırlık faktörlerini tahmin etmek ve üretmek için kullanılmıştır. Modelin başarısı test veri setiyle kontrol edilmiştir. Yolov8 algoritması, yolov8x-cls modeli kullanılarak model eğitim süreci gerçekleştirilmiştir. Model eğitimi, 500 epoch boyunca devam edecek şekilde planlanmış, ancak erken durdurma (early stopping) stratejisi uygulanmıştır. Erken durdurma için patience değeri 100 olarak belirlenmiştir, yani modelin doğrulama performansında 100 epoch boyunca iyileşme gözlemlenmezse eğitim otomatik olarak sonlandırılmıştır.

Eğitim sürecinde en iyi modelin, 113. epochta elde edildiği belirlenmiş ve ardından patience süresi kadar (yani 100 epoch) ilerleme kaydedilmediği için 223. epochta eğitim süreci sona ermiştir. Bu sayede aşırı uyumun (overfitting) önüne geçilmiş ve gereksiz hesaplama maliyetleri engellenmiştir.

3.2.2. Modellerin Performans ve Başarısının Değerlendirilmesi

Geliştirilen modelin başarı metrikleri bir konfüzyon matrisi ile değerlendirilmiştir. Bir YZ modelinin performansını değerlendirmek için çeşitli ölçütler kullanılmıştır. Modelin belirli bir hedefi doğru şekilde tespit edip etmediğini analiz etmek amacıyla doğruluk ve hata oranları dikkate alınmıştır.

- **Gerçek pozitif (DP)**, gerçekte prepik, pik veya postpik evresine ait olan bir el-bilek röntgeninin YZ modeli tarafından doğru şekilde tespit edilmesini ifade eder. Diğer bir deyişle, modelin “maturasyon dönemi” yönünden doğru sınıflandırdığı örneklere karşılık gelir. DP oranının yüksek olması, modelin gerçekte var olan olgunluk aşamasını yüksek doğrulukla algıladığını ve bu sayede iskeletsel gelişim dönemi tahminlerinde başarılı olduğunu gösterir.

- **Yanlış pozitif (YP)**, gerçekte prepik, pik veya postpik evresine ait olmayan bir el-bilek röntgeninin YZ modeli tarafından bu evrelerden birine dahil edilmesi durumudur. Diğer bir ifadeyle, model gerçekte var olmayan bir maturasyon aşamasını tespit etmiş gibi davranır. YP oranının yüksek olması, modelin gereksiz veya hatalı alarmlar üretme eğiliminin fazla olduğunu ve bu nedenle genel özgüllüğünün düştüğünü gösterir.

- **Yanlış negatif (YN)**, gerçekte prepik, pik veya postpik evresine ait olan bir el-bilek röntgeninin, YZ modeli tarafından hatalı şekilde bu evrelerin dışında kabul edilmesidir. Diğer bir deyişle, model var olan bir maturasyon dönemini saptayamayarak gözden kaçırmıştır. YN değerinin yüksek olması, modelin hassasiyetini (duyarlılığını) olumsuz yönde etkiler; çünkü model, gerçek örneklerin bir kısmını tespit edememekte ve bu da sonuçların doğruluğunu düşürmektedir.

- **Hassasiyet (Sensitivity, Recall)**: Modelin, tespit etmesi gereken toplam alanlardan kaç tanesini doğru şekilde belirlediğini gösteren bir ölçümdür. Modelin eksiksiz bir tespit yapma kapasitesini ifade eder.

$$Hassasiyet = \frac{DP}{DP + YN}$$

- **Kesinlik (Precision)**: Modelin doğru olarak sınıflandırdığı pozitif alanların, tüm pozitif tahminler içindeki oranıdır. Yani modelin verdiği pozitif tahminlerin ne kadarının gerçekten doğru olduğunu gösterir.

$$Kesinlik = \frac{DP}{DP + YP}$$

o **F1 Puanı (F1 Score)**: Hassasiyet ve kesinlik değerlerinin dengeli bir şekilde değerlendirilmesini sağlayan bir ölçümdür. Modelin genel doğruluğunu ve tespit yeteneğini aynı anda göz önünde bulundurur.

$$F1Puanı = \frac{2 \cdot DP}{2 \cdot DP + YP + YN}$$

o **Ortalama Hassasiyet (Mean Average Precision - mAP)**: Nesne algılama modellerinin performansını değerlendirmek için kullanılan bir metriktir. Modelin farklı geri çağırma seviyelerinde ne kadar hassas olduğunu analiz eder.

mAP hesaplamasında birkaç önemli bileşen bulunur:

- **Konfüzyon matrisi**, modelin gerçek pozitif, yanlış pozitif ve yanlış negatif tahminlerini içeren bir yapıdır.
- **IoU (Intersection over Union)**, modelin belirlediği alanların, gerçek etiketli alanlarla ne kadar örtüştüğünü ölçer. Genellikle %50 veya %75 eşik değeri kullanılarak hesaplanır.
- **Geri çağırma (Recall) ve hassasiyet (Precision)** metrikleri de mAP hesaplamasında yer alır.

mAP değeri, modelin genel başarısını belirlemek için kullanılan önemli bir ölçüttür ve değeri ne kadar yüksekse, modelin performansının o kadar iyi olduğu kabul edilir.

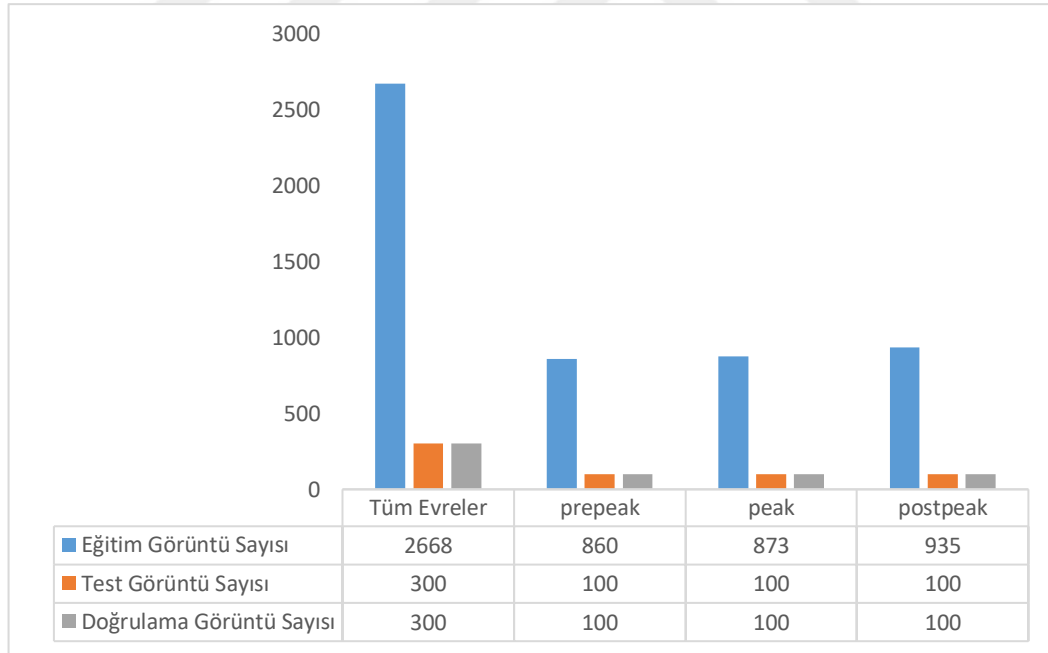
4.BULGULAR

Gözlemciler arası ve gözlemci içi uyum değerlendirilmesinde tutarlılık analizi yapılmış, gözlemci içi uyum katsayısı CNY:0,997, AA:0,991 gözlemciler arası uyum katsayısı 0,983 olarak bulunmuştur.

Bu tez çalışmasında, 8 ile 18 yaş aralığındaki bireylerin sağ ve sol el-bilek radyografileri değerlendirilirken maturasyon yöntemi olarak sadece Björk, Grave ve Brown methodu (Björk 1972; Grave ve Brown 1976) kullanılmıştır ve YOLOv8 derin öğrenme algoritmasının tahmin başarısı ve daha sonraki zamanlarda klinik kullanım için uygunluğu test edilmiştir. Modelin başarısını değerlendirmek için karışıklık matrisi kullanılmıştır.

Eğitim veri seti, modeli eğitmek için kullanılır. Doğrulama veri seti, eğitim aşamasında düzenli olarak hatayı ve modelin uyumunu kontrol etmek için kullanılır. Test veri seti, en son aşamada nihai performansı ölçmek için kullanılır.

Tablo 1. Eğitim, doğrulama ve test veri setlerinin dağılımı



4.1. YOLOv8 Eğitim ve Test Sonuçları

Bu çalışmada, el-bilek röntgen görüntülerinden maturasyon dönemlerinin tahmini için YOLOv8x-cls modeli kullanılmıştır. Modelin eğitimi, farklı maturasyon evrelerindeki bireylerin el-bilek röntgen görüntülerinin sınıflandırılması amacıyla


gerçekleştirilmiştir. Eğitim sürecinde 224x224 piksel çözünürlüğe sahip görüntüler kullanılmış ve model 16 epoch boyunca eğitilmiştir. Modelin performansını artırmak amacıyla batch size 24 olarak belirlenmiştir.

Toplamda 3268 görüntü kullanılmış olup, bu görüntüler Pik, Postpik ve Prepik olmak üzere üç sınıfa ayrılmıştır.

Veri setinin dağılımı şu şekildedir:

- Pik veri sayısı: 1073
- Postpik veri sayısı: 1135
- Prepik veri sayısı: 1060

Modelin genel doğruluk oranı %95 olarak hesaplanmıştır. Test aşamasında 285 gerçek pozitif (TP - True Positive) tespit edilmiştir. Bu sonuçlar, modelin el-bilek röntgenlerinden maturasyon dönemlerini yüksek doğrulukla tahmin edebildiğini göstermektedir.



Şekil 16. Eğitim sırasındaki epoch ilerleyişine göre performans metrikleri verilmiştir

Eđitim Kaybı (train/loss) ve Doğrulama Kaybı (val/loss)

Eđitim kaybı (train/loss) grafiđi, modelin eđitim sırasında yaptıđı hatanın zamanla azaldıđını göstermektedir.

Dođrulama kaybı (val/loss) grafiđi de benzer şekilde düşmektedir, ancak belirli bir noktadan sonra sabit bir seviyede ilerlemektedir.

Sonuç: Model aşırı öğrenme (overfitting) yapmıyor gibi görünmektedir çünkü dođrulama kaybı da eđitim kaybına paralel olarak düşmektedir.

Dođruluk Metrikleri (metrics/accuracy_top1 ve metrics/accuracy_top5)

Top-1 dođruluk (metrics/accuracy_top1), modelin en olası tahmininin dođru olup olmadıđını ölçer. Bu deđer zamanla artmakta ve %90'ın üzerine çıkmaktadır.


Top-5 dođruluk (metrics/accuracy_top5), modelin en olası beş tahmininden birinin dođru olup olmadıđını ölçer. Bu metrik sürekli 1.00 olarak sabit kalmıştır, yani model her zaman dođru tahmin yapmaktadır.

Sonuç: Modelin sınıflandırma başarısı oldukça yüksektir. Top-1 dođruluk oranı %90'ın üzerinde, Top-5 dođruluk ise mükemmeldir (1.00).

Öğrenme oranı (learning rate, lr): Zamanla deđişim göstermektedir, başlangıçta küçükken belirli bir noktada artırmıştır. Öğrenme oranının dinamik olarak ayarlanması, modelin hızlı öğrenme ve optimum noktada stabilizasyon sağlama stratejisini kullandıđını ve modelin adaptif bir eđitim süreci geçirdiđini göstermektedir.


	epoch	train/loss	metric:	metr	val/loss	lr/pg0	lr/pg1	lr/pg2
1	1	0.88348	0.76	1	0.86768	0.0033134	0.0033134	0.0033134
2	2	0.44588	0.89	1	0.68662	0.0066335	0.0066335	0.0066335
3	3	0.29338	0.82 333	1	0.72119	0.0099405	0.0099405	0.0099405
4	4	0.27186	0.86	1	0.68481	0.0099406	0.0099406	0.0099406
5	5	0.236	0.84 667	1	0.69917	0.0099208	0.0099208	0.0099208
6	6	0.2153	0.89 333	1	0.66089	0.009901	0.009901	0.009901
7	7	0.21756	0.92	1	0.64082	0.0098812	0.0098812	0.0098812
8	8	0.17568	0.92 333	1	0.62944	0.0098614	0.0098614	0.0098614
9	9	0.15928	0.93 333	1	0.62754	0.0098416	0.0098416	0.0098416
10	10	0.16692	0.93 333	1	0.61646	0.0098218	0.0098218	0.0098218
11	11	0.15361	0.93 333	1	0.61772	0.009802	0.009802	0.009802
12	12	0.14295	0.94	1	0.62344	0.0097822	0.0097822	0.0097822
13	13	0.14403	0.92 667	1	0.62671	0.0097624	0.0097624	0.0097624
14	14	0.13448	0.93 333	1	0.60957	0.0097426	0.0097426	0.0097426

Tablo 2. Öğrenme oranını gösteren lr/pg0, lr/pg1 ve lr/pg2 değerleri



Şekil 18. Öğrenme oranının epochlara göre değişimi

Öğrenme oranı başlangıçta düşük bir seviyede başlayıp, hızla yükselmekte ve 3. epoch itibariyle stabil hale gelerek zamanla azalmaktadır. Farklı parametre grupları (lr/pg0, lr/pg1, lr/pg2) benzer bir öğrenme oranı eğilimi göstermekte ve birbirine paralel ilerlemektedir. Bu durum, modelin erken aşamalarda hızlı öğrenmesini, ilerleyen süreçte ise daha kararlı hale gelmesini sağlamak için kullanılan bir teknik olduğunu göstermektedir.



Şekil 19. Konfüzyon matrisi

Matristeki satırlar modelin tahmin ettiği sınıfları, sütunlar ise gerçek sınıfları temsil etmektedir. Köşegen üzerindeki hücreler modelin doğru tahmin ettiği örnekleri gösterirken, köşegen dışındaki hücreler yanlış sınıflandırılan örnekleri ifade eder.

Prepik sınıfında model 95 doğru tahmin yaparken, 5 örneği pik sınıfına yanlış atamıştır. Modelin pik sınıfındaki tahminlerinde 91 örnek doğru sınıflandırılmış, ancak 5 örnek yanlışlıkla prepik olarak tahmin edilmiştir. Postpik sınıfında ise model

en iyi performansı göstermiş ve 100 örneğin tamamını doğru tahmin etmiştir, ancak 4 örnek yanlışlıkla pik olarak tahmin edilmiştir.

Genel olarak model oldukça başarılı bir sınıflandırma gerçekleştirmiştir ve en yüksek doğruluk postpik sınıfında gözlemlenmiştir. Yanlış tahminler ağırlıklı olarak pik ve prepik sınıfları arasında gerçekleşmiştir. Arka plan (background) sınıfında herhangi bir yanlış sınıflandırma gözlemlenmemiştir. Bu sonuçlar, modelin yüksek doğruluk oranına sahip olduğunu ancak pik ve prepik sınıfları arasında zaman zaman karışıklık yaşadığını göstermektedir.

4.2. Birleşim Üzerinden Ortalama Kesişme (IoU) ve Alıcı İşlem Karakteristiği (ROC) Eğrisi

IoU (Birleşim Üzerinden Ortalama Kesişme): IoU, bir modelin belirlediği nesne tespit alanı ile gerçek nesnenin örtüşme oranını ifade etmektedir. 0 ile 1 arasında değişen bu değer, 1'e yaklaştıkça modelin doğruluğunun arttığını gösterir. Genellikle %50'nin üzerindeki IoU değerleri başarılı tespit olarak kabul edilmektedir.

ROC Eğrisi (Alıcı İşlem Karakteristiği Eğrisi): Modelin yaptığı tahminlerin doğruluğunu daha geniş bir açıdan değerlendiren bir yöntemdir. ROC eğrisi, modelin prepik, pik ve postpik sınıflarını tahmin ederken yaptığı doğruları ve hataları görselleştiren bir değerlendirme yöntemidir. X eksenini yanlış pozitif oranını, Y eksenini ise doğru pozitif oranını temsil etmektedir.

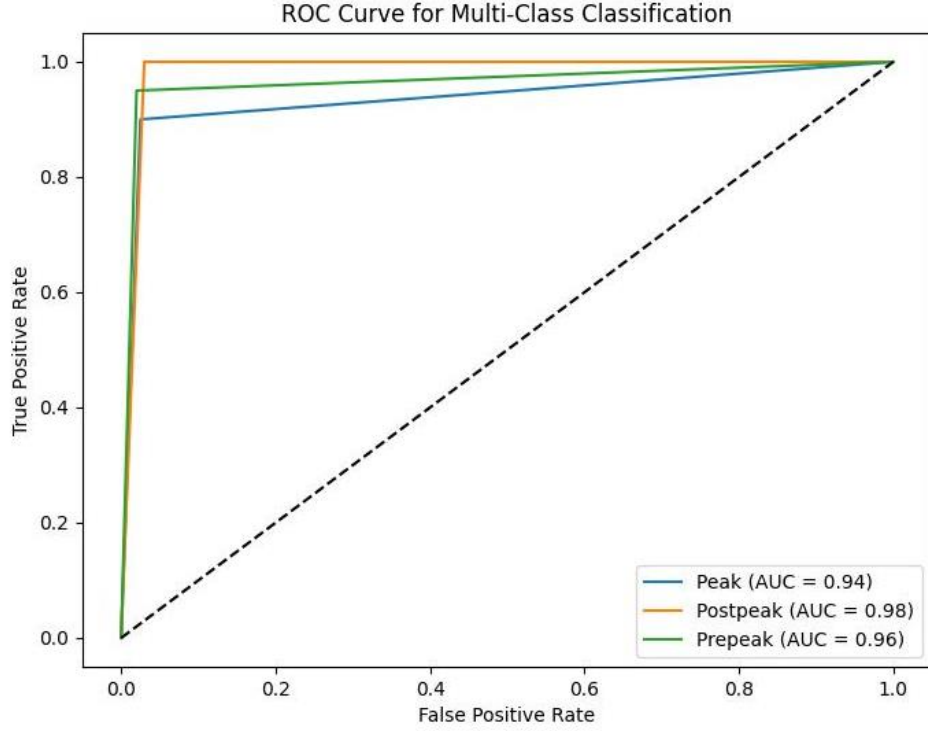
ROC eğrisinin altında kalan alan (AUC - Eğri Altındaki Alan): modelin genel doğruluk performansını özetlemektedir. AUC değeri 1'e ne kadar yakınsa, modelin sınıflandırma başarısı o kadar yüksektir.

ROC Eğrisi (Alıcı İşlem Karakteristiği Eğrisi) ise, modelin yaptığı tahminlerin doğruluğunu daha geniş bir açıdan değerlendiren bir yöntemdir.

Bu analizler, el-bilek röntgenlerinden yapay zeka ile maturasyon dönemlerini tahmin etme modelimizin başarısını ölçmek için kullanılmıştır.

Tablo 3. YOLOv8 modelinin %50 IoU eşik değeri kullanılarak hesaplanan performans metrikleri

Sınıf	Gerçek (n)	Sınıflandırılan (n)	Doğruluk (%)	Keskinlik (Precision)	Duyarlılık (Recall)	F1 Skoru
Pre Peak	99	100	97	0.95	0.96	0.95
Peak	85	100	95	0.9	0.95	0.92
Post Peak	106	100	98	1.0	0.94	0.97



Şekil 21. ROC (Receiver Operating Characteristic) Eğrisi

X eksenini yanlış pozitif oranını (False Positive Rate), Y eksenini ise doğru pozitif oranını (True Positive Rate) göstermektedir. Eğri ne kadar sol üst köşeye yakınsa, modelin performansı o kadar yüksektir. Kesikli siyah çizgi ($y = x$), rastgele tahmin yapan bir modelin başarısını temsil etmektedir; modelin eğrisinin bu çizginin üzerinde olması, öğrenme başarısını göstermektedir.

Bu çalışmada, modelin prepik, pik ve postpik sınıflarını doğru tahmin etme başarısı ROC eğrisi ile analiz edilmiştir. AUC (Eğri Altındaki Alan) değerleri sırasıyla pik için 0.94, postpik için 0.98 ve prepik için 0.96 olarak hesaplanmıştır.

AUC değeri 1'e ne kadar yakınsa, modelin sınıflandırma performansı o kadar yüksektir. Bu sonuçlar, modelin tüm sınıfları yüksek doğrulukla ayırt edebildiğini ve özellikle postpik sınıfı için en yüksek performansı sergilediğini göstermektedir. Genel olarak, AUC değerlerinin 0.90'ın üzerinde olması, modelin başarılı bir sınıflandırma sağladığını kanıtlamaktadır.

5.TARTIŞMA

YZ, diş hekimliği alanında devrim niteliğinde değişikliklere yol açarak teşhis, tedavi planlaması ve hasta takibi süreçlerini yeniden şekillendirmektedir. Gelişmiş algoritmalar ve derin öğrenme teknikleri sayesinde, YZ uygulamaları diş hekimliğinin çeşitli dallarında daha hızlı, hassas ve kişiselleştirilmiş hizmetler sunulmasına olanak tanımaktadır. Özellikle ağız, diş ve çene radyolojisi alanında, YZ destekli görüntü işleme sistemleri, radyografilerin otomatik yorumlanması ve anormalliklerin tespitinde önemli avantajlar sağlamaktadır. Bu teknolojiler, diş çürükleri, periapikal lezyonlar ve kemik yoğunluğu değişikliklerinin erken teşhisinde yüksek doğruluk oranları sunarak, klinik karar verme süreçlerini iyileştirmektedir (Yüce ve Taşöker).

YZ'nin ortodonti ve implantoloji gibi alanlardaki uygulamaları, tedavi sürecinin her aşamasında hekimlere rehberlik ederek, hasta memnuniyetini ve tedavi başarısını artırmaktadır. YZ destekli analizler, iskeletsel olgunluğun belirlenmesi ve tedavi sonuçlarının tahmin edilmesi gibi konularda da önemli katkılar sunmaktadır. Bu bağlamda, YZ'nin diş hekimliğinde kullanımının giderek yaygınlaştığı ve gelecekte daha da entegre bir hale geleceği öngörülmektedir (Koca Ünsal ve Orhan 2022).

Ortodontik tedavi sonrası maksillomandibuler kompleksin büyüme potansiyelinin belirlenmesi, tedavi sonrası relaps riskini değerlendirmek açısından önemli bir faktördür (Flores-Mir ve ark. 2004). Özellikle çeneler arası iskeletsel uyumsuzluğu olan ve büyüme modifikasyonu gerektiren hastalarda, tedavinin doğru zamanlaması tedavi sonuçlarını doğrudan etkilemektedir. Çene büyümesi yalnızca belirli gelişim aşamalarında yönlendirilebildiği için, iskeletsel olgunluk değerlendirmesi ortodontik tanı, tedavi planlaması ve sürecin takibi açısından kritik bir unsurdur (Proffit 2006). Ayrıca, iskeletsel olgunluğa dayalı yaş tahmini, büyüme hormonu tedavisi gören hastaların gelişiminin izlenmesi ve kimliği belirsiz bireylerin yaş tespitinde kullanılmaktadır (Pinchi ve ark. 2014; Darmawan ve ark. 2015). Bunun yanı sıra, farklı ülkelerde cezai ehliyet yaşının değişiklik göstermesi nedeniyle, hukuki süreçlerde yaş doğrulamasının yapılması gerekebilir (Pinchi ve ark. 2014). Bu bağlamda, el-bilek radyografileri ve diş gelişimine dayalı yaş değerlendirmesi, yaş tespiti için önerilen yöntemler arasında yer almaktadır (Gandini ve ark. 2006).

Geleneksel kemik yaşı tahmin yöntemleri, genellikle el-bilek radyografilerinden manuel ölçümlerle yapılmaktadır. İskeletsel maturasyonun belirlenmesi, büyüme-gelişim sürecinin izlenmesi ve ortodontik tedavi planlaması gibi alanlarda kritik bir öneme sahiptir. Geleneksel yöntemler arasında en yaygın kullanılanlar Fishman Skeletal Maturity Index, Greulich-Pyle Atlası ve Tanner-Whitehouse olarak bilinmektedir. Ancak bu yöntemler, manuel değerlendirme süreçlerine dayalı olup, gözlemciler arası farklılıklar oluşturabilmekte ve tekrarlanabilirlik açısından sınırlamalar içermektedir. Buna karşın, YZ destekli sistemler, hata oranlarını minimize ederek daha hızlı ve objektif tahminler sunma potansiyeline sahiptir (Goto ve ark. 2019).

Ortodontide iskelet yaşının kesin yıl ve ay cinsinden belirlenmesi veya yetişkin boyunun tahmin edilmesi, adli veya tıbbi alanlardaki kadar kritik bir önem taşımaz. Bunun yerine, tedavi sürecini doğrudan etkileyebilecek pubertal büyüme atılımının başlangıç ve bitiş zamanlamasının doğru tespit edilmesi önceliklidir (Kim ve ark. 2023)(120). Çeşitli çalışmalar, ergenlik dönemindeki yüz büyüme hızının, genel boy uzama hızıyla bağlantılı olduğunu göstermektedir (Johnston ve ark. 1965; Hunter 1966). Araştırmalar, pubertal büyüme atılımının başlangıç ve zirve dönemlerinin erkeklerde 12-14, kızlarda ise 10-12 yaş aralığında gerçekleştiğini ortaya koymuştur. Bu süreçlerin doğru belirlenmesi, ortodontik tedavinin en uygun zamanda uygulanmasını sağlayarak tedavi sonuçlarını önemli ölçüde iyileştirebilir (FISHMAN 1979)

YZ, özellikle derin öğrenme ve makine öğrenmesi teknikleri sayesinde radyografik görüntülerden iskelet maturasyonunun belirlenmesine olanak sağlamaktadır (Lee ve Lee 2021). Geleneksel yöntemlere kıyasla YZ, değerlendirme sürecindeki subjektif hataları azaltarak tekrarlanabilirliği artırmaktadır (Yılmaz). Imai ve arkadaşlarının yaptığı çalışmada, el-bilek radyografileri kullanılarak geliştirilen YZ modelinin, Tanner-Whitehouse 3 (TW3) metodu ile benzer doğruluk seviyesine ulaştığı gösterilmiştir (Liang ve ark. 2024). Özellikle, Kluck ve arkadaşları (2023) tarafından yapılan bir çalışmada, epifizyodez uygulanan hastalarda, insan gözlemiyle yapılan kemik yaşı tahminleri ile YZ tabanlı tahminler karşılaştırılmıştır. Çalışmanın sonuçları, YZ modelinin daha tutarlı sonuçlar verdiğini ve bacak uzunluğu tahminlerinde daha az hata içerdiğini göstermiştir (Kluck ve ark.

2023). Benzer şekilde, Ohashi ve arkadaşları (2021), YZ regresyon modelinin önem haritalarını kullanarak, modelin karar verme süreçlerinde hangi görüntü bölgelerine odaklandığını analiz etmişlerdir (Wang 2021).

YZ destekli kemik yaşı belirleme süreçlerinde kullanılan yöntemler arasında makine öğrenmesi ve derin öğrenme modelleri yer almaktadır. Yapılan çalışmalarda, Ridge Regression, Support Vector Regression (SVR), Random Forest ve Derin Sinir Ağları (DNN) gibi modellerin başarılı sonuçlar verdiği rapor edilmiştir (Lee ve Lee 2021). Özellikle Kim ve arkadaşları tarafından geliştirilen modelde, kronolojik yaş ve cinsiyet gibi ek bilgilerin dahil edilmesiyle tahmin doğruluğunun arttığı gösterilmiştir. Li ve arkadaşlarının (2023) çalışmasında, cinsiyet bilgisini de içeren derin öğrenme tabanlı bir model kullanılmış ve bu modelin doğruluk seviyesinin artırıldığı gözlemlenmiştir. Çalışma, cinsiyetin kemik yaşı tahmininde önemli bir faktör olduğunu ve modelin, cinsiyet bazlı farklılıkları dikkate aldığı daha hassas tahminler yapabildiğini göstermektedir (Li ve ark. 2023).

Narin ve arkadaşlarının (2021) çalışmasında, makine öğrenmesi (ML) yöntemlerinin klinik kullanıma uygun olduğu ve geleneksel yöntemlere kıyasla daha yüksek doğruluk sağladığı belirtilmiştir. Özellikle Multilayer Perceptron (MLP) ve Logistic Model Tree (LMT) yöntemleri en başarılı modeller olarak öne çıkmıştır. Çalışmada, ML yöntemlerinin kız çocuklarında kemik yaşı tahmini ile kronolojik yaş arasında güçlü bir ilişki gösterdiği, erkek çocuklarında ise GP yönteminin kemik yaşını genellikle daha düşük tahmin ettiği gözlemlenmiştir. Friedman testi sonuçları, ML modelleri arasında belirgin farklılıklar bulunduğunu ortaya koyarken, ML tabanlı sistemlerin GP yöntemine kıyasla daha güvenilir ve tutarlı tahminler sunduğunu göstermektedir. Bununla birlikte, ML modellerinin daha geniş ve çeşitli popülasyonlarda test edilmesi, veri setlerinin büyütülmesi ve dış validasyon süreçlerinin iyileştirilmesi gerekmektedir. Klinik uygulamalarda, ML tabanlı sistemlerin kemik yaşı tahmininde yaygın kullanımının artması beklenmektedir (Narin ve ark.).

Yapay zekânın el-bilek radyografileri üzerindeki uygulanabilirliği yüksek doğruluk oranlarıyla kanıtlanmış olsa da, klinik kullanımda bazı kısıtlamalar bulunmaktadır. Bu kısıtlamalar arasında veri setlerinin çeşitliliğinin artırılması gerekliliği ve modellerin dış validasyon süreçlerindeki eksiklikler yer almaktadır.

Örneğin, Schwendicke ve arkadaşları (2020), YZ tabanlı uygulamaların rutin dış hekimliği pratiğine entegrasyonunun sınırlı veri mevcudiyeti ve erişilebilirliği gibi engeller nedeniyle kısıtlandığını belirtmiştir (Schwendicke ve ark. 2020). Ayrıca, Terzi ve Demirezen (2022), sadece açık kaynak veri setleriyle eğitilen derin öğrenme modellerinin klinik ortamlarda genelleme kabiliyetinin sınırlı olduğunu ve lezyon türlerine göre performansın çeşitlilik gösterdiğini vurgulamıştır. Bu nedenle, YZ modellerinin daha geniş ve çeşitli veri setleriyle eğitilmesi ve farklı popülasyonlarda dış validasyonlarının yapılması, klinik uygulamalardaki etkinliklerini artırmak için önemlidir (Terzi ve Demirezen 2023).

YZ destekli modellerin kemik yaşı tahminindeki başarısı, literatürde yapılan birçok çalışma ile desteklenmektedir. Örneğin, Kim ve arkadaşlarının (2021) yaptığı çalışmada, el-bilek radyografileri ile eğitilmiş bir YZ modelinin, geleneksel yöntemlere kıyasla %91,5 doğruluk oranına sahip olduğu ve %1,2 mutlak hata oranı ile çalıştığı bildirilmiştir (Kim ve ark. 2017). Li ve arkadaşlarının (2023) yaptığı çalışmada, YZ modeline cinsiyet bilgisinin dahil edilmesiyle doğruluk oranının %93,8'e yükseldiği gösterilmiştir (Li ve ark. 2023).

YZ tabanlı sistemlerin klinik pratikte kullanımı, hız ve doğruluk avantajları nedeniyle giderek yaygınlaşmaktadır. Lee & Lee (2021) tarafından yapılan bir çalışmada, YZ'nin radyologlar ve ortodontistler için bir karar destek aracı olarak kullanılabilmesi ve değerlendirme süresini önemli ölçüde azaltabileceği belirtilmiştir (Lee ve Lee 2021). Kluck ve arkadaşlarının (2023) yaptığı bir çalışmada, epifizyodez uygulanmış hastalar üzerinde YZ tabanlı kemik yaşı tahmininin, insan gözlemcilerden %13 daha düşük hata oranıyla gerçekleştirildiği gösterilmiştir (Kluck ve ark. 2023).

Ancak, klinik kullanımdaki en büyük engellerden biri, YZ modellerinin karar mekanizmalarının tam olarak anlaşılabilmesi ve doktorlar tarafından güvenilir bulunmamasıdır. Wang ve arkadaşlarının (2021) yaptığı çalışmada, saliency maps (önem haritaları) kullanılarak YZ modelinin karar verme süreçleri analiz edilmiştir. Bu yöntemde, modelin el-bilek radyografileri üzerinde en çok hangi kemik yapılarına odaklandığı değerlendirilmiş ve modelin %76 oranında epifiz plaklarını referans aldığı belirlenmiştir (Wang 2021). Bu sonuçlar, YZ tabanlı sistemlerin karar mekanizmalarının anlaşılabilirliğini artırmak için önemlidir. Ancak çalışmada, kas

bölgelerinin de yüksek önem taşıdığı görülmüş, bu durumun modelin öğrenme süreçlerinde yanlış yönlendirmelere sebep olabileceği belirtilmiştir. Bu bulgular, YZ modellerinin daha iyi optimize edilmesi ve daha sağlıklı karar mekanizmalarına sahip olması için ek araştırmalar yapılmasını gerektirmektedir. Bu bağlamda, tezimizde geliştirilen modelin de benzer bir açıklanabilirlik analizi ile değerlendirilmesi önerilmektedir.

Çalışmamızda, mAP (mean Average Precision) değeri, modelin genel başarı oranını değerlendirmede önemli bir ölçüttür. mAP değerimiz %95 olarak hesaplanmış olup, bu sonuç daha önce yapılan çalışmalarla benzer doğruluk seviyelerine sahiptir (Schwendicke ve ark. 2020). F1 skoru açısından ise, modelimiz prepik maturasyon dönemi tahmininde %95 oranında, pik dönemi tahmininde % 92, postpik dönem tahmininde ise %97 başarılı bulunmuştur ki bu, hem hassasiyet (recall) hem de kesinliği (precision) dengeli bir şekilde optimize ettiğimizi göstermektedir.

Modelimizin duyarlılık ve kesinlik değerleri, mevcut literatürde yer alan diğer yapay zeka modelleri ile kıyaslanabilir seviyededir. Çalışmamızda elde edilen precision değeri prepik için %95, recall değeri ise %96; pik dönemi için precision değeri %90, recall değeri ise %95; postpik dönemi için ise precision değeri %100, recall değeri ise %94 olarak hesaplanmıştır. Bu bulgular, modelimizin yanlış pozitif oranını düşük tutarak doğru sınıflandırma konusunda yüksek doğruluk sunduğunu göstermektedir. Ancak, recall oranlarının modelimizin bazen maturasyon dönemi tahmininde eksiklik yaşayabileceğini ortaya koymaktadır. Gelecekte, modelin veri çeşitliliği artırılarak bu oranların optimize edilmesi mümkündür.

Son yıllarda yapılan çalışmalar, derin öğrenme modellerinin kemik yaşı tahmininde başarılı sonuçlar verdiğini göstermektedir. InceptionV3 modeli kullanılarak yapılan bir araştırmada, el bilek radyografilerinden kemik yaşı tahmini gerçekleştirilmiş ve modelin ortalama mutlak hata oranının 0.68 yıl olduğu rapor edilmiştir (Wang 2021). Benzer şekilde, başka bir çalışmada, InceptionV3, EfficientNetB4 ve MobileNetV2 gibi modeller test edilmiş ve modifiye edilmiş InceptionV3 modelinin en yüksek doğruluk oranına sahip olduğu belirlenmiştir (Ozdemir ve ark. 2021). Bu bulgular, derin öğrenme tabanlı sistemlerin kemik yaşı tahmininde etkili olduğunu desteklemekte ve bu modellerin klinik pratikte yaygın

olarak kullanılabilceğini göstermektedir. Ancak, modellerin farklı yaş gruplarında ve popülasyonlarda test edilmesi gerekliliđi devam etmektedir.

Çalışmamızın bulguları, tıbbi görüntüleme evrişimli sinir ağlarının (CNN'ler) etkinliğini vurgulayan literatür ile uyumludur. Örneđin, distal radyo-ulnar kırıklarının tespitinde CNN'lerin kullanımını inceleyen bir çalışma, derin öğrenmenin bilek radyografilerini analiz etmede etkili olduğunu ortaya koymuştur (Kim ve ark. 2021). Çalışmamızın bilek radyografilerine odaklanması, CNN'lerin radyolojideki geniş uygulama alanını desteklemektedir. Periodontal hastalıkların makine öğrenimi algoritmalarıyla sınıflandırılmasına yönelik başka bir araştırma ise bu tür modellerin radyografik verilerle hastalık teşhisinde başarılı bir şekilde kullanılabilceğini göstermektedir (Ertaş ve ark. 2022).

El-bilek radyografileri ile kemik yaşı değerlendirmesinin iskelet olgunluđunu belirlemede altın standart olmaya devam ettiđi sistematik bir inceleme ile doğrulanmıştır (Lucchese ve ark. 2022). Çalışmamızda YOLOv8x-cls modeliyle elde edilen sonuçlar, bu bulgularla benzerlik göstermektedir. Çeşitli çalışmalar arasındaki bu tutarlılık, olgunlaşma aşamalarının belirlenmesinde radyografik yöntemlerin güvenilirliğini pekiştirmektedir. El kırıklarını tespit etmek için derin öğrenme yöntemlerini kullanan bir başka araştırma ise gelişmiş makine öğrenimi tekniklerinin radyografik değerlendirmelerde tanı doğruluđunu artırabileceğini göstermektedir (Üreten ve ark. 2022).

Çalışmamızın sonuçları, her sınıf için yüksek hassasiyet (precision), geri çağırma (recall) ve F1 skorları ile modelin olgunlaşma aşamaları arasında güçlü bir ayırım yapabildiğini ortaya koymaktadır. Bu bulgular, iskelet olgunluđu değerlendirmelerinde kesin sınıflandırmanın önemini vurgulayan başka bir çalışmanın sonuçlarıyla tutarlıdır (Bint-e-Nasir ve ark. 2023). Ayrıca, ROC eğrisi analizi ve AUC değerleri, derin öğrenmenin bilek yaralanmalarını sınıflandırmada sağladığı başarıyı ortaya koyan bir araştırmayla uyumludur (Min ve ark. 2023).

Biyolojik olgunlaşma analizlerinde el ve bilek röntgenlerinin güvenilirliği, son yıllarda giderek daha fazla araştırılmıştır. İskelet yaşını tahmin etmek için kullanılan geleneksel yöntemlerin sınırlamalarını vurgulayan bir çalışma, el-bilek radyografileri ile yapılan analizlerin doğruluđu artırabileceğini göstermiştir (de

Almeida-Neto ve ark. 2022). Çalışmamızda kullanılan YOLOv8x-cls modelinin mimarisi ve eğitim metodolojisi, özellikle bilek radyografilerinin sınıflandırma performansını iyileştirmek için tasarlanmıştır ve böylece önceki araştırmalarda dile getirilen bazı sınırlamaların üstesinden gelmektedir.

Ergenlik evrelerinin doğru sınıflandırılması, erken ergenliğin fiziksel ve psikolojik sağlık üzerindeki etkilerini ele alan bir çalışmada vurgulandığı gibi, klinik açıdan büyük önem taşımaktadır (Lorenzon ve ark. 2024). Çalışmamızın olgunlaşma evrelerinin doğru bir şekilde belirlenmesine odaklanması, bu süreçlerin zamanında tespit edilerek uygun tedavi ve müdahalelerin uygulanmasını destekleyebilir. Modelimizin her sınıf için yüksek hassasiyet ve geri çağırma oranlarına ulaşması, klinik kullanımdaki potansiyel faydasını daha da pekiştirmektedir.

YOLOv8 modelinin kemik patolojilerinin lokalizasyonunda kullanıldığı bir araştırmada, derin öğrenme mimarilerinin tıbbi görüntü analizinde önemli avantajlar sunduğu gösterilmiştir (Wang ve ark. 2024). Bulgulara göre, gelişmiş özellik çıkarma ve sınıflandırma teknikleri tanı doğruluğunu artırmaktadır. Bu durum, çalışmamızda YOLOv8 modelinin bilek radyografilerinde olgunlaşma evrelerini yüksek doğrulukla sınıflandırmasına katkıda bulunmuş olabilir.

İskelet olgunluğu değerlendirmelerinde derin öğrenme uygulamaları yalnızca çalışmamızla sınırlı değildir. X-ışını kemik kırıklarını sınıflandırmak için derin öğrenme modellerini kullanan bir çalışma, CNN tabanlı yaklaşımların tıbbi görüntü analizindeki artan rolünü vurgulamıştır (Tanzi ve ark. 2020). Bulgulara göre, kapsamlı veri kümeleri üzerinde ön eğitim yapılmış modellerin sınıflandırma başarısını önemli ölçüde artırdığı gösterilmiştir.

YOLOv8 modelinin omuz manyetik rezonans görüntülerinde rotator manşet yırtıklarını tespit etmek için kullanıldığı bir araştırmada, modelin farklı görüntüleme düzlemlerinde yüksek doğruluk sağladığı ortaya konmuştur (Lee ve ark. 2023). Bu çalışma, modelin bilek radyografilerinde elde ettiğimiz bulgularla benzer şekilde, geleneksel radyografinin ötesinde karmaşık görüntüleme analizlerini gerçekleştirme potansiyeline sahip olduğunu göstermektedir. YOLOv8'in farklı tıbbi görüntüleme modalitelerine uyum sağlayabilmesi, mimarisinin esnekliğini ve tıbbi görüntü analizinde geniş bir kullanım alanına sahip olduğunu ortaya koymaktadır.

YOLOv8 modelinin fundus görüntülerinde diyabetik retinopati tespiti için kullanıldığı bir çalışmada, modelin tıbbi görüntülerde belirli patolojik özellikleri yüksek doğrulukla tanımlayabildiği gösterilmiştir (Moura ve ark. 2024). Bu bulgular, çalışmamızda bilek radyografilerindeki anatomik özelliklere dayanarak olgunlaşma evrelerinin sınıflandırılmasını hedefleyen yaklaşımımızla paralellik göstermektedir.

Tıbbi görüntüleme YOLOv8 modelinin kullanımını inceleyen kapsamlı bir çalışma, modelin yüksek hassasiyet ve gerçek zamanlı tespit yeteneklerine sahip olduğunu vurgulamaktadır (Widayani ve ark. 2024). Bu inceleme, çalışmamızın gelişmiş derin öğrenme teknikleri ile tanı süreçlerini optimize etmeye yönelik devam eden araştırmaların bir parçası olduğunu göstermektedir. YOLOv8'in hızlı ve doğru sonuçlar sağlaması, özellikle zamanında karar verilmesi gereken klinik ortamlar için büyük avantaj sunmaktadır. Bu bağlamda, çalışmamız YOLOv8 modelinin bilek radyografileri üzerinden iskelet olgunluğu evrelerini doğru bir şekilde sınıflandırma kapasitesini doğrulamakta ve tıbbi görüntü analizindeki gelişmiş derin öğrenme uygulamalarına önemli bir katkı sağlamaktadır.

Mevcut literatürde, YOLO (You Only Look Once) algoritmasının doğrudan iskelet maturasyon dönemi tahmini veya kemik yaşı belirlemede kullanıldığına dair spesifik bir çalışmaya rastlanmamıştır. Ancak, yapay zekâ ve derin öğrenme teknikleri, iskeletsel olgunluk ve kemik yaşı tahmininde yaygın olarak kullanılmaktadır. Örneğin, el bilek radyografilerinin değerlendirilmesinde konvolüsyonel sinir ağları (CNN) ve diğer derin öğrenme modelleri başarıyla uygulanmıştır. Bu çalışmalar, büyüme-gelişim süreçlerinin izlenmesi ve ortodontik tedavi planlamasında önemli katkılar sağlamaktadır.

YOLO algoritması, genellikle nesne tespiti ve sınıflandırma görevlerinde kullanılmaktadır. Tıbbi görüntüleme alanında, özellikle beyin tümörü tespiti ve dental uygulamalarda başarıyla uygulanmıştır. Ancak, iskelet maturasyonunun değerlendirilmesi veya kemik yaşı tahmini konusunda YOLO'nun kullanımına dair spesifik bir uygulama mevcut değildir.

Sonuç olarak, iskelet maturasyon dönemi tahmini için YOLO algoritmasının kullanıldığı bir çalışma bulunmamaktadır. Bu çalışmamızın bulguları, modelin çeşitli tıbbi görüntüleme modaliteleri genelindeki çok yönlülüğünü ve etkinliğini

vurgulayan literatüre katkıda bulunmaktadır. Bu alanda, derin öğrenme ve YZ tekniklerinin entegrasyonu, gelecekte daha doğru ve hızlı değerlendirmeler için potansiyel bir araştırma konusu olabilir.

Çalışmamızda birtakım limitasyonlar mevcuttur. 3268 el-bilek radyografisi kullanılmış olsa da, farklı yaş grupları, cinsiyetler ve etnik kökenlerden daha geniş bir veri setiyle modelin genellenebilirliği artırılabilir. Kullanılan radyografilerin tamamı belirli bir popülasyona ait olduğu için, farklı coğrafi bölgelerden gelen bireyler için modelin doğruluğu test edilmemiştir. Görüntüler oral radyologlar tarafından manuel olarak sınıflandırılmış olup, insan kaynaklı hatalar (interobserver ve intraobserver varyasyonları) oluşma riski taşımaktadır. Özellikle peak ve prepeak sınıfları arasında bazı yanlış tahminler gözlemlenmiş olup, modelin bu iki evreyi zaman zaman zaman karıştırması sınıflar arasındaki farklılıkların yeterince belirgin olmamasından kaynaklanabilir. Çalışmada kullanılan YOLOv8 modeli, hızlı ve yüksek doğruluk oranına sahip olması açısından avantajlıdır, ancak tıbbi görüntüleme için optimize edilmemiş genel bir nesne tespit algoritmasıdır. Bu nedenle, tıbbi görüntüler için daha özelleşmiş modellerin (örneğin Transformer tabanlı modeller) değerlendirilmesi model performansını artırabilir. Ayrıca, büyüme sürecini etkileyebilecek genetik, beslenme ve hormonal faktörler modele dahil edilmemiştir, dolayısıyla bireysel farklılıklar göz ardı edilmiştir. Görüntülerin 512×400 piksele yeniden boyutlandırılması bazı küçük yapısal detayların kaybolmasına neden olabilir ve yüksek çözünürlüklü radyografilerle modelin başarısı artırılabilir. Model eğitildiği veri setinde yüksek doğruluk göstermiş olsa da, gerçek dünya klinik senaryolarında henüz test edilmemiştir. Bu nedenle, modelin daha geniş popülasyonlarda ve farklı cihazlardan elde edilen radyografilerle doğrulanması, klinik uygulanabilirliğinin artırılması açısından önemli bir gereklilik olarak değerlendirilmektedir.

6.SONUÇ VE ÖNERİLER

Gelecekteki gelişmelerle birlikte, YZ destekli sistemlerin ortodonti ve pediatrik endokrinoloji gibi alanlarda rutin klinik karar destek araçları olarak kullanılma potansiyeli bulunmaktadır. Mevcut çalışmalar, derin öğrenme ve makine öğrenmesi tekniklerinin kemik yaşı tahmininde etkili olduğunu göstermektedir. Ancak, bu modellerin klinik doğrulamalarının artırılması ve farklı hasta gruplarında test edilmesi gerekmektedir.

Tezimizde geliştirilen YZ modeli, literatürdeki en güncel ve başarılı modellerle kıyaslandığında yüksek doğruluk oranı ve düşük hata payı ile başarılı bir performans sergilemiştir. Modelimiz, geleneksel yöntemlere kıyasla daha hızlı ve objektif tahminler sunarak klinik süreçleri destekleme potansiyeline sahiptir. Ancak, modelin genişletilmiş veri setleri ile test edilmesi, farklı popülasyonlar üzerinde doğrulanması ve açıklanabilirlik analizleri ile doktorlar için daha güvenilir hale getirilmesi gerekmektedir.

Gelecekte, YZ destekli sistemlerin yalnızca kemik yaşı tahminiyle sınırlı kalmayıp, büyüme-gelişim analizlerinde, ortodontik tedavi planlamasında ve iskeletsel olgunluğun belirlenmesinde karar destek sistemleri olarak yaygın şekilde kullanılabilmesi düşünülmektedir. Özellikle, çok merkezli çalışmalar ve farklı etnik gruplara dayalı veri setleriyle eğitilmiş modeller, YZ'nin klinik uygulamalarda daha güvenilir hale gelmesini sağlayacaktır.

YZ tabanlı sistemlerin etkinliği, geniş ve çeşitli veri setleriyle eğitilmelerine bağlıdır. Geleneksel yöntemler belirli popülasyonlara dayandığından, farklı etnik gruplarda tutarsız sonuçlar ortaya çıkabilir. Tezimizde kullanılan veri setinin ağırlıklı olarak belirli yaş gruplarından oluşması, modelimizin genelleştirilebilirliğini sınırlayabilir. Bu nedenle, modelin farklı yaş ve etnik gruplar üzerinde test edilmesi önemlidir. Tezimizde geliştirilen model, yalnızca radyografik görüntüler ve kronolojik yaş bilgisiyle eğitildiğinden, hormonal değişkenler ve beslenme faktörleri gibi ek parametreler dahil edilmemiştir. Gelecekte, bu tür parametrelerin modele entegre edilmesiyle tahmin doğruluğunun %96'nın üzerine çıkabileceği öngörülmektedir.

7.KAYNAKLAR

- Abdulhafedh A. Comparison between common statistical modeling techniques used in research, including: Discriminant analysis vs logistic regression, ridge regression vs LASSO, and decision tree vs random forest. Open Access Library Journal. 2022; 9(2): 1-19.
- Adarsh P, Rathi P, Kumar M YOLO v3-Tiny: Object Detection and Recognition using one stage improved model. pp. 687-94; pp. 687-94. IEEE.
- Ahmed Z, Mohamed K, Zeeshan S, Dong X. Artificial intelligence with multi-functional machine learning platform development for better healthcare and precision medicine. Database. 2020; 2020: baaa010.
- Akkoyun M. Adli tıp açısından yaş tayini istenen olguların değerlendirilmesi. Uzmanlık Tezi, TC Akdeniz Üniversitesi Tıp Fakültesi Adli Tıp Anabilim Dalı, Antalya. 2013.
- Al-Zewairi M, Almajali S, Awajan A Experimental evaluation of a multi-layer feed-forward artificial neural network classifier for network intrusion detection system. pp. 167-72; pp. 167-72. IEEE.
- Alkhal HA, Wong RW, Rabie ABM. Correlation between chronological age, cervical vertebral maturation and Fishman's skeletal maturity indicators in southern Chinese. The Angle Orthodontist. 2008; 78(4): 591-6.
- Arıncı K, Elhan A. Anatomi, 1. Cilt, Güneş Kitapevi. Ankara. Başaran, M.(1989). Serbest ve Grekoromen Güreş. 1997.
- Arslan MM, Çekin N, Akçan R, Saylak E. Hatay Ağır Ceza ve Asliye Hukuk Mahkemelerine 2007 yılında yansıyan yaş tespiti davalarının incelenmesi. Adli Tıp Dergisi. 2008; 22(2): 8-13.
- Atasaral N (2007) El-Bilek Kemiklerine Göre ve Servikal Vertebra'lara Göre Pubertal Büyüme Atılımı Evreleri Arasındaki Geçiş Sürelerinin Belirlenmesi ve Bunların Karşılaştırılması. Atatürk Üniversitesi Sağlık Bilimleri Enstitüsü, Ortodonti Anabilim Dalı: Doktora tezi, Erzurum.
- Atrey J, Regunathan R, Rajasekaran R. Real-world application of face mask detection system using YOLOv6. International Journal of Critical Infrastructures. 2024; 20(3): 216-40.
- Awad M, Khanna R (2015) *Efficient learning machines: theories, concepts, and applications for engineers and system designers*: Springer nature.
- Baccetti T, Franchi L, McNamara Jr JA. An improved version of the cervical vertebral maturation (CVM) method for the assessment of mandibular growth. The Angle Orthodontist. 2002; 72(4): 316-23.
- Bäck T, Fogel DB, Michalewicz Z. Handbook of evolutionary computation. Release. 1997; 97(1): B1.
- Baduge SK, Thilakarathna S, Perera JS *et al.* Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications. Automation in Construction. 2022; 141: 104440.
- Bahrami N, Soleimani MA, Chan YH, Ghojzadeh M, Mirmiran P. Menarche age in Iran: A meta-analysis. Iranian journal of nursing and midwifery research. 2014; 19(5): 444-50.
- Banerjee K, Agarwal B. Estimation of age from epiphyseal union at the wrist and ankle joints in the capital city of India. Forensic science international. 1998; 98(1-2): 31-9.

- Bayat P, Ghanbari A, Khazaei M *et al.* Age at menarche and related factors in girls of urban areas of Markazi (Central) Province of Iran. *Int J Morphol.* 2012; 30(1): 15-8.
- Bench RW. Growth of the cervical vertebrae as related to tongue, face, and denture behavior. *American Journal of Orthodontics.* 1963; 49(3): 183-214.
- Bengio Y (2009) *Learning Deep Architectures for AI.* Now Publishers Inc.
- Bengio Y, Courville A, Vincent P. Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence.* 2013; 35(8): 1798-828.
- Berendsen AD, Olsen BR. Bone development. *Bone.* 2015; 80: 14-8.
- Bint-e-Nasir Z, Abdullah J, Khalid Z, Zia R, Arshad N. Skeletal Maturity Assessment using Mandibular Canine Calcification Stages. *Pakistan Armed Forces Medical Journal.* 2023; 73(2): 464.
- Bishop CM, Nasrabadi NM (2006) *Pattern recognition and machine learning:* Springer.
- Björk A. Timing of interceptive orthodontic measures based on stages of maturation. *Transactions. European Orthodontic Society.* 1972: 61-74.
- Björk A, Helm S. Prediction of the age of maximum puberal growth in body height. *The Angle Orthodontist.* 1967; 37(2): 134-43.
- Bochkovskiy A, Wang C-Y, Liao H-YM. Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934.* 2020.
- Bonaccorso G (2018) *Machine Learning Algorithms: Popular algorithms for data science and machine learning:* Packt Publishing Ltd.
- Burstone CJ. Process of maturation and growth prediction. *American Journal of Orthodontics.* 1963; 49(12): 907-19.
- Cameriere R, Ferrante L, Cingolani M. Age estimation in children by measurement of open apices in teeth. *International journal of legal medicine.* 2006; 120: 49-52.
- Chahyati D, Arymurthy AM Multiple human tracking using Retinanet features, Siamese neural network, and Hungarian algorithm. pp. 465-75; pp. 465-75.
- Chapman S. Ossification of the adductor sesamoid and the adolescent growth spurt. *The Angle Orthodontist.* 1972; 42(3): 236-44.
- Chartrand G, Cheng PM, Vorontsov E *et al.* Deep learning: a primer for radiologists. *Radiographics.* 2017; 37(7): 2113-31.
- Chen L, Liu J, Xu T, Long X, Lin J. Quantitative skeletal evaluation based on cervical vertebral maturation: a longitudinal study of adolescents with normal occlusion. *International journal of oral and maxillofacial surgery.* 2010; 39(7): 653-9.
- Chertkow S. Tooth mineralization as an indicator of the pubertal growth spurt. *American Journal of Orthodontics.* 1980; 77(1): 79-91.
- Coelho C, Costa MFP, Ferrás LL, Soares AJ Object detection with retinanet on aerial imagery: The algarve landscape. pp. 501-16; pp. 501-16. Springer.
- Costacurta M, Sicuro L, Di Renzo L, Condò R, De Lorenzo A, Docimo R. Childhood obesity and skeletal-dental maturity. *European journal of paediatric dentistry.* 2012; 13(2): 128-32.

- Coutinho S, Buschang PH, Miranda F. Relationships between mandibular canine calcification stages and skeletal maturity. *American Journal of Orthodontics and Dentofacial Orthopedics*. 1993; 104(3): 262-8.
- Çelebi Hİ. Artificial intelligence applications in management information systems: a comprehensive systematic review with business analytics perspective. *Artificial Intelligence Theory and Applications*. 2021; 1(1): 25-56.
- Darmawan M, Yusuf SM, Kadir MA, Haron H. Age estimation based on bone length using 12 regression models of left hand X-ray images for Asian children below 19 years old. *Legal Medicine*. 2015; 17(2): 71-8.
- Davidson LE, Rodd HD. Interrelationship between dental age and chronological age in Somali children. *Community dental health*. 2001; 18(1): 27-30.
- de Almeida-Neto PF, de Medeiros JA, Medeiros RMV *et al*. Reliability of biological maturation analyses performed by equations predicting skeletal age and pik height velocity with hand and wrist X-ray results. *American Journal of Human Biology*. 2022; 34(9): e23775.
- Demirjian A, Buschang PH, Tanguay R, Patterson DK. Interrelationships among measures of somatic, skeletal, dental, and sexual maturity. *American Journal of Orthodontics*. 1985; 88(5): 433-8.
- Dere F (2010) *Anatomi atlası ve ders kitabı*: Nobel Tıp Kitabevleri.
- Drake RL, Vogl W, Mitchell AW (2005) *Gray's anatomy for students*: Elsevier Health Sciences TW.
- Dreizen S, SNODGRASSE RM, WEBB-PEPLOE H, PARKER GS, SPIES TD. Bilateral symmetry of skeletal maturation in the human hand and wrist. *AMA Journal of Diseases of Children*. 1957; 93(2): 122-7.
- Dulger H, Baransel A, Ucak R. Age estimation using agnor and immunohistochemical indicators of abdomen skins. *Anadolu Tıp Dergisi*. 2005; 7(1): 25-30.
- Dunger DB, Ahmed ML, Ong KK. Early and late weight gain and the timing of puberty. *Molecular and cellular endocrinology*. 2006; 254: 140-5.
- Ellis H. *Gray's anatomy*. 37th ed. P. L. Williams, R. Warwick, M. Dyson, L. H. Bannister. 305 × 235mm. Pp. 1598. Illustrated. 1989. Edinburgh: Churchill Livingstone. £70.00. *British Journal of Surgery*. 2005; 76(12): 1359-.
- Erkoç R. İnsan anatomi ve fizyolojisi. Milli Eğitim Basımevi, İstanbul. 1967: 14-28.
- Ertaş K, Pence I, Cesmeli MS, Ay ZY. Determination of the stage and grade of periodontitis according to the current classification of periodontal and peri-implant diseases and conditions (2018) using machine learning algorithms. *Journal of Periodontal & Implant Science*. 2022; 53(1): 38.
- FiSHMAN LS. Chronological versus skeletal age, an evaluation of craniofacial growth. *The Angle Orthodontist*. 1979; 49(3): 181-9.
- Fishman LS. Radiographic evaluation of skeletal maturation: a clinically oriented method based on hand-wrist films. *The Angle Orthodontist*. 1982; 52(2): 88-112.
- Flores-Mir C, Nebbe B, Major PW. Use of skeletal maturation based on hand-wrist radiographic analysis as a predictor of facial growth: a systematic review. *The Angle Orthodontist*. 2004; 74(1): 118-24.

- Flory CD. Osseous development in the hand as an index of skeletal development. *Monographs of the Society for Research in Child Development*. 1936; 1(3): i-141.
- Franchi L, Pavoni C, Faltin Jr K, McNamara Jr JA, Cozza P. Long-term skeletal and dental effects and treatment timing for functional appliances in Class II malocclusion. *The Angle Orthodontist*. 2013; 83(2): 334-40.
- Gandini P, Mancini M, Andreani F. A comparison of hand-wrist bone and cervical vertebral analyses in measuring skeletal maturation. *The Angle Orthodontist*. 2006; 76(6): 984-9.
- Ganong WF. Review of medical physiology. Dynamics of blood and lymph flow. 1995; 30: 525-41.
- Garcia-Fernandez P, Torre H, Flores L, Rea J. The cervical vertebrae as maturational indicators. *Journal of clinical Orthodontics*. 1998; 32(4): 221-6.
- Garvin HM, Passalacqua NV, Uhl NM, Gipson DR, Overbury RS, Cabo LL. Developments in forensic anthropology: age-at-death estimation. *A companion to forensic anthropology*. 2012: 202-23.
- Geng J, Zhao G, Gu Y. Feasibility of spheno-occipital synchondrosis fusion stages as an indicator for the assessment of maxillomandibular growth: A mixed longitudinal study. *Orthodontics & Craniofacial Research*. 2024.
- Gers FA, Schmidhuber J, Cummins F. Learning to forget: Continual prediction with LSTM. *Neural computation*. 2000; 12(10): 2451-71.
- Girgis R. A maturational comparison of racial groups during adolescence. *American Journal of Orthodontics and Dentofacial Orthopedics*. 1994; 105(6): 617-.
- Goodfellow I (2016) *Deep learning*. MIT press.
- Goto H, Morris JG, Nevill ME. Influence of biological maturity on the match performance of 8-to 16-year-old, elite, male, youth soccer players. *The Journal of Strength & Conditioning Research*. 2019; 33(11): 3078-84.
- Grave K. Timing of facial growth: a study of relations with stature and ossification in the hand around puberty. *Australasian Orthodontic Journal*. 1973; 3(4): 117-22.
- Grave K, Brown T. Skeletal ossification and the adolescent growth spurt. *American Journal of Orthodontics*. 1976; 69(6): 611-9.
- Greulich WW, Pyle SI. Radiographic atlas of skeletal development of the hand and wrist. *The American Journal of the Medical Sciences*. 1959; 238(3): 393.
- Gülyurt M. Ortodonti yönünden büyüme ve gelişim. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Yayınları, Erzurum*. 1989: 52-77.
- Günay N. 6-18 yaşlar arasındaki kız ve erkek çocuklarda kronolojik yaş kemik yaşı ilişkileri. *Atatürk Üniversitesi Dişhekimliği Fakültesi Dergisi*. 1973; 1(1): 3-16.
- Haenlein M, Kaplan A. A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California management review*. 2019; 61(4): 5-14.
- Hägg U, Taranger J. Skeletal stages of the hand and wrist as indicators of the pubertal growth spurt. *Acta Odontologica Scandinavica*. 1980; 38(3): 187-200.
- Hägg U, Taranger J. Maturation indicators and the pubertal growth spurt. *American Journal of Orthodontics*. 1982; 82(4): 299-309.

- Hassabis D (2017) Artificial intelligence: chess match of the century. Nature Publishing Group UK London.
- Hassel B, Farman AG. Skeletal maturation evaluation using cervical vertebrae. *American Journal of Orthodontics and Dentofacial Orthopedics*. 1995; 107(1): 58-66.
- Häusler JA, Lussi A. A new method for estimating the age of children based on the development of their teeth. *Forensic Sci Int*. 1983; 21(2): 103-10.
- Haykin S (1998) *Neural networks: a comprehensive foundation*: Prentice Hall PTR.
- Heyworth BE, Osei DA, Fabricant PD *et al*. The shorthand bone age assessment: a simpler alternative to current methods. *Journal of Pediatric Orthopaedics*. 2013; 33(5): 569-74.
- Hinton GE. Boltzmann machine. *Scholarpedia*. 2007; 2(5): 1668.
- Hinton GE. Deep belief networks. *Scholarpedia*. 2009; 4(5): 5947.
- Hiran KK, Jain RK, Lakhwani K, Doshi R (2021) *Machine Learning: Master Supervised and Unsupervised Learning Algorithms with Real Examples (English Edition)*: BPB Publications.
- Hosseini M-P, Soltanian-Zadeh H, Elisevich K, Pompili D Cloud-based deep learning of big EEG data for epileptic seizure prediction. pp. 1151-5; pp. 1151-5. IEEE.
- Hunter CJ. The correlation of facial growth with body height and skeletal maturation at adolescence. *The Angle Orthodontist*. 1966; 36(1): 44-54.
- Ibáñez L, Ferrer A, Marcos MV, Hierro FR, de Zegher F. Early puberty: rapid progression and reduced final height in girls with low birth weight. *Pediatrics*. 2000; 106(5): e72-e.
- Isikli S. Bulanık mantık ve bulanık teknolojiler. Ankara Üniversitesi, DTCF, Felsefe Bölümü, Doktora Öğrencisi Tezi. 2008: 1-19.
- Isır AB, Bakır K, Uçak R, Dülger HE. AgNOR yöntemi ile insan epidermisinden yaş tespiti. *Fırat Tıp Dergisi*. 2004; 9(3): 75-8.
- İşcan M, Loth S. Research strategies in age estimation: the multiregional approach. *Age markers in the human skeleton*. 1989: 325-39.
- Jayaraman J, Wong HM, King NM, Roberts GJ. The French–Canadian data set of Demirjian for dental age estimation: a systematic review and meta-analysis. *Journal of forensic and legal medicine*. 2013; 20(5): 373-81.
- Jegham N, Koh CY, Abdelatti M, Hendawi A. Evaluating the evolution of yolo (you only look once) models: A comprehensive benchmark study of yolo11 and its predecessors. *arXiv preprint arXiv:2411.00201*. 2024.
- Jiang F, Jiang Y, Zhi H *et al*. Artificial intelligence in healthcare: past, present and future. *Stroke and vascular neurology*. 2017; 2(4).
- JM T, RH W, Marshall W. Assessment of skeletal maturity and prediction of adult height. London. UK. Academic. 1975.
- Johnston FE, Paul Hufham Jr H, Moreschi AF, Terry GP. Skeletal maturation and cephalofacial development. *The Angle Orthodontist*. 1965; 35(1): 1-11.
- Joshi VV, Iyengar AR, Nagesh K, Gupta J. Comparative study between cervical vertebrae and hand-wrist maturation for the assessment of skeletal age. *Archives of Oral Research*. 2010; 6(3).

- Kamal M, Goyal S. Comparative evaluation of hand wrist radiographs with cervical vertebrae for skeletal maturation in 10-12 years old children. *Journal of Indian Society of Pedodontics and Preventive Dentistry*. 2006; 24(3): 127-35.
- Khanagar SB, Al-Ehaideb A, Maganur PC *et al*. Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *Journal of dental sciences*. 2021; 16(1): 508-22.
- Kim H, Kim C-S, Lee J-M *et al*. Prediction of Fishman’s skeletal maturity indicators using artificial intelligence. *Scientific reports*. 2023; 13(1): 5870.
- Kim JR, Shim WH, Yoon HM *et al*. Computerized bone age estimation using deep learning based program: evaluation of the accuracy and efficiency. *American Journal of Roentgenology*. 2017; 209(6): 1374-80.
- Kim MW, Jung J, Park SJ *et al*. Application of convolutional neural networks for distal radio-ulnar fracture detection on plain radiographs in the emergency room. *Clinical and experimental emergency medicine*. 2021; 8(2): 120.
- Kluck DG, Makarov MR, Kanaan Y, Jo C-H, Birch JG. Comparison of “Human” and artificial intelligence hand-and-wrist skeletal age estimation in an epiphysiodesis cohort. *JBJS*. 2023; 105(3): 202-6.
- Kluemper GT, Spalding PM. Realities of craniofacial growth modification. *Atlas of the Oral and Maxillofacial Surgery Clinics*. 2001; 9(1): 23-51.
- Koca Ünsal RB, Orhan K. Diş Hekimliğinde Yapay Zeka Uygulamaları. *Journal of Ankara University Faculty of Medicine/Ankara Üniversitesi Tıp Fakültesi Mecmuası*. 2022; 75.
- Krogman WM, İşcan MY. *The human skeleton in forensic medicine*, Charles C. Thomas, Springfield, IL. 1986; 15(2): 202-8.
- Kronenberg HM. Developmental regulation of the growth plate. *nature*. 2003; 423(6937): 332-6.
- Kumar A, Reddy SSS, Kulkarni V An object detection technique for blind people in real-time using deep neural network. pp. 292-7; pp. 292-7. *IEEE*.
- Kumar V, Hegde SK, Bhat SS. The relationship between dental age, bone age and chronological age in children with short stature. *International Journal of Contemporary Dentistry*. 2011; 2(4).
- Łagowska K, Kapczuk K. Testosterone concentrations in female athletes and ballet dancers with menstrual disorders. *European Journal of Sport Science*. 2016; 16(4): 490-7.
- Lamparski DG, Nanda SK. Skeletal age assessment utilizing cervical vertebrae. *Craniofacial growth series*. 2002; 39: 171-84.
- LeCun Y, Bengio Y, Hinton G. Deep learning. *nature*. 2015; 521(7553): 436-44.
- Lee B-D, Lee MS. Automated bone age assessment using artificial intelligence: the future of bone age assessment. *Korean journal of radiology*. 2021; 22(5): 792.
- Lee K-C, Cho Y, Ahn K-S *et al*. Deep-learning-based automated rotator cuff tear screening in three planes of shoulder MRI. *Diagnostics*. 2023; 13(20): 3254.
- Lewis O, Hamshere R, Bucknill T. The anatomy of the wrist joint. *Journal of Anatomy*. 1970; 106(Pt 3): 539.

- Li D, Chen J, Qiu M. Research on population development trend in Huizhou of China forecast based on optimal weighted combination method and fractional grey model. *Journal of Mathematics*. 2021; 2021(1): 3320910.
- Li H, Zhang Z, Liu Z. Application of artificial neural networks for catalysis: a review. *Catalysts*. 2017; 7(10): 306.
- Li K, Cao L A review of object detection techniques. pp. 385-90; pp. 385-90. IEEE.
- Li Z, Chen W, Ju Y *et al*. Bone age assessment based on deep neural networks with annotation-free cascaded critical bone region extraction. *Frontiers in Artificial Intelligence*. 2023; 6: 1142895.
- Liang Y, Chen X, Zheng R *et al*. Validation of an AI-Powered Automated X-ray Bone Age Analyzer in Chinese Children and Adolescents: A Comparison with the Tanner–Whitehouse 3 Method. *Advances in Therapy*. 2024; 41(9): 3664-77.
- Liao S-H. Expert system methodologies and applications—a decade review from 1995 to 2004. *Expert systems with applications*. 2005; 28(1): 93-103.
- Lindsay RK, Buchanan BG, Feigenbaum EA, Lederberg J. DENDRAL: a case study of the first expert system for scientific hypothesis formation. *Artificial intelligence*. 1993; 61(2): 209-61.
- Long F, Ornitz DM. Development of the endochondral skeleton. *Cold Spring Harbor perspectives in biology*. 2013; 5(1): a008334.
- Lorenzon B, Burlo F, Barbi L, Tamaro G, Tornese G. Fifteen-minute consultation: The approach to the child with precocious puberty. *Archives of Disease in Childhood-Education and Practice*. 2024; 109(6): 271-5.
- Lucchese A, Bondemark L, Farronato M *et al*. Efficacy of the cervical vertebral maturation method: a systematic review. *Turkish Journal of Orthodontics*. 2022; 35(1): 55.
- Maes C, Kronenberg HM (2012) Postnatal bone growth: growth plate biology, bone formation, and remodeling. *Pediatric bone*, pp. 55-82: Elsevier.
- Mahesh B. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet]. 2020; 9(1): 381-6.
- McCarthy J (2007) Generality in artificial intelligence. *ACM Turing award lectures*, pp. 1971.
- McLean S, Read GJ, Thompson J, Baber C, Stanton NA, Salmon PM. The risks associated with Artificial General Intelligence: A systematic review. *Journal of Experimental & Theoretical Artificial Intelligence*. 2023; 35(5): 649-63.
- Mijwel MM. History of Artificial Intelligence Yapay Zekânın T arihi. *Computer Science*, (April 2015). 2015: 3-4.
- Mikolov T, Karafiát M, Burget L, Cernocký J, Khudanpur S Recurrent neural network based language model. pp. 1045-8; pp. 1045-8. Makuhari.
- Miladinović M, Mihailović B, Mladenović D *et al*. Artificial intelligence in clinical medicine and dentistry. *Vojnosanitetski pregled*. 2017; 74(3): 267-72.
- Min H, Rabi Y, Wadhawan A *et al*. Automatic classification of distal radius fracture using a two-stage ensemble deep learning framework. *Physical and engineering sciences in medicine*. 2023; 46(2): 877-86.

- Mincer HH, Harris EF, Berryman HE. The ABFO study of third molar development and its use as an estimator of chronological age. *Journal of Forensic Sciences*. 1993; 38(2): 379-90.
- Mincer HH, Harris EF, Berryman HE. Age estimation of children using tooth development. *Journal of Forensic Sciences*. 1993; 38(1): 179-88.
- Moura C, Cortez P, Assis D, Motta P, Silva B (2024) *YOLOv8 Deep Learning Model for Diabetic Retinopathy Fundus Image Segmentation and Disease Classification*.
- Mupparapu M, Wu C-W, Chen Y-C. Artificial intelligence, machine learning, neural networks, and deep learning: Futuristic concepts for new dental diagnosis. *Quintessence International*. 2018; 49(9).
- Narin NG, Yeniçeri İÖ, Yüksel G. Estimation of Bone Age from Radiological Images with Machine Learning. *Muğla Sıtkı Koçman Üniversitesi Tıp Dergisi*. 8(2): 119-26.
- Nguyen TT, Larrivée N, Lee A, Bilaniuk O, Durand R. Use of artificial intelligence in dentistry: current clinical trends and research advances. *J Can Dent Assoc*. 2021; 87(17): 1488-2159.
- Nolla CM (1952) *The development of permanent teeth*: University of Michigan Ann Arbor.
- Nur B, Kusgoz A, Bayram M *et al*. Validity of Demirjian and Nolla methods for dental age estimation for Northeastern Turkish children aged 5–16 years old. *Medicina oral, patologia oral y cirugia bucal*. 2012; 17(5): e871.
- O'Reilly MT, Yanniello GJ. Mandibular Growth Changes and Maturation of Cervical Vertebrae: —A Longitudinal Cephalometric Study. *The Angle Orthodontist*. 1988; 58(2): 179-84.
- O'Shea K. An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458. 2015.
- Ossowska A, Kusiak A, Świetlik D. Artificial intelligence in dentistry—Narrative review. *International journal of environmental research and public health*. 2022; 19(6): 3449.
- Ozdemir C, Gedik MA, Kaya Y. Age Estimation from Left-Hand Radiographs with Deep Learning Methods. *Traitement du Signal*. 2021; 38(6).
- Önder A, Doğanç T, Çetinkaya E, Aycan Z. Çölyak hastalığı olan çocuklarda boy kısalığı ve kemik yaşının değerlendirilmesi. *Türkiye Çocuk Hast Derg*. 2010; 4(4): 197-201.
- Özkan İ, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*. 2017; 6(3): 85-104.
- Öztemel E (2012) *Yapay sinir ağları*: Papatya.
- Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*. 2018; 6(2): 25-36.
- Palanstanga N, Field D, Soames R (2000) *Anatomy&Human Movement's—Structure&functions*. Butterworth Heinemann, Oksford.
- Parent A-S, Rasier G, Gerard A *et al*. Early onset of puberty: tracking genetic and environmental factors. *Hormone research*. 2005; 64(Suppl. 2): 41-7.
- Parent A-S, Teilmann G, Juul A, Skakkebaek NE, Toppari J, Bourguignon J-P. The timing of normal puberty and the age limits of sexual precocity: variations around the world, secular trends, and changes after migration. *Endocrine reviews*. 2003; 24(5): 668-93.

- Perinetti G, Contardo L, Gabrieli P, Baccetti T, Di Lenarda R. Diagnostic performance of dental maturity for identification of skeletal maturation phase. *The European Journal of Orthodontics*. 2012; 34(4): 487-92.
- Persaud M, Moore K. İnsan Embriyolojisi (Klinik yönleri ile). Çeviren: Dalçık H, Yıldırım M, Nobel Tıp Kitapevleri, İstanbul. 2002.
- Pinchi V, De Luca F, Ricciardi F *et al.* Skeletal age estimation for forensic purposes: A comparison of GP, TW2 and TW3 methods on an Italian sample. *Forensic science international*. 2014; 238: 83-90.
- Point T. Artificial Intelligence: Intelligent Systems. Tutorials Point. 2020.
- Popescu A-D. The value of data from an artificial intelligence perspective. *Annals of the University of Craiova for Journalism, Communication and Management*. 2019; 5(1): 172-94.
- Pouyanfar S, Sadiq S, Yan Y *et al.* A survey on deep learning: Algorithms, techniques, and applications. *ACM computing surveys (CSUR)*. 2018; 51(5): 1-36.
- Proffit WR. The timing of early treatment: an overview. *American Journal of Orthodontics and Dentofacial Orthopedics*. 2006; 129(4): S47-S9.
- Rath S. Yolov8 ultralytics: State-of-the-art yolo models. LearnOpenCV–Learn OpenCV, PyTorch, Keras, TensorflowWith Examples and Tutorials. 2023.
- Rawat R, Goyal HR, Sharma S Artificial Narrow Intelligence Techniques in Intelligent Digital Financial Inclusion System for Digital Society. pp. 1-5; pp. 1-5. IEEE.
- Redmon J. Yolov3: An incremental improvement. arXiv preprint arXiv:1804.02767. 2018.
- Redmon J, Divvala S, Girshick R, Farhadi A You only look once: Unified, real-time object detection. pp. 779-88; pp. 779-88.
- Redmon J, Farhadi A YOLO9000: better, faster, stronger. pp. 7263-71; pp. 7263-71.
- Roche A, Johnson JM. A comparison between methods of calculating skeletal age (Greulich-Pyle). *American Journal of Physical Anthropology*. 1969; 30(2): 221-9.
- Román PS, Palma JC, Oteo MD, Nevado E. Skeletal maturation determined by cervical vertebrae development. *The European Journal of Orthodontics*. 2002; 24(3): 303-11.
- Russell SJ, Norvig P (2016) *Artificial intelligence: a modern approach*: Pearson.
- Salhotra A, Shah HN, Levi B, Longaker MT. Mechanisms of bone development and repair. *Nature reviews Molecular cell biology*. 2020; 21(11): 696-711.
- Schmidhuber J. Deep learning in neural networks: An overview. *Neural networks*. 2015; 61: 85-117.
- Schwendicke Fa, Samek W, Krois J. Artificial intelligence in dentistry: chances and challenges. *Journal of dental research*. 2020; 99(7): 769-74.
- Seminara SB, Messenger S, Chatzidaki EE *et al.* The GPR54 gene as a regulator of puberty. *New England Journal of Medicine*. 2003; 349(17): 1614-27.
- Shapland F, Lewis ME. Brief communication: a proposed method for the assessment of pubertal stage in human skeletal remains using cervical vertebrae maturation. *American Journal of Physical Anthropology*. 2014; 153(1): 144-53.
- Sharma AB, Vargervik K. Using implants for the growing child. *Journal of the California Dental Association*. 2006; 34(9): 719-24.

- Shetty AK, Saha I, Sanghvi RM, Save SA, Patel YJ A review: Object detection models. pp. 1-8; pp. 1-8. IEEE.
- Shetty J, Jogi PS Study on different region-based object detection models applied to live video stream and images using deep learning. pp. 51-60; pp. 51-60. Springer.
- Silveira AM, Fishman LS, Subtelny JD, Kassebaum DK. Facial growth during adolescence in early, average and late maturers. *The Angle Orthodontist*. 1992; 62(3): 185-90.
- Silvestrini S, Lavagna M. Deep learning and artificial neural networks for spacecraft dynamics, navigation and control. *Drones*. 2022; 6(10): 270.
- Singer J. Physiologic timing of orthodontic treatment. *The Angle Orthodontist*. 1980; 50(4): 322-33.
- Singh H, Gupta MM, Meitzler T *et al*. Real-life applications of fuzzy logic. *Advances in Fuzzy Systems*. 2013; 2013: 3-.
- Solawetz J. What is yolov8? the ultimate guide. *Roboflow Blog*. 2023; 25.
- Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*. 2014; 15(1): 1929-58.
- Suguna R, Rani RU. on with Data Analytics Various Domains Categorized Machine Learning Algorithms. *Predictive Analytics Using Statistics and Big Data: Concepts and Modeling*. 2020: 1.
- Sultana F, Sufian A, Dutta P. A review of object detection models based on convolutional neural network. *Intelligent computing: image processing based applications*. 2020: 1-16.
- Sutton RS. *Reinforcement learning: An introduction*. A Bradford Book. 2018.
- Tanner J. A correction to the TW2 RUS-based tables for predicting adult height. *Annals of Human Biology*. 1978; 5(5): 491-2.
- Tanner J, Oshman D, Bahhage F, Healy M. Tanner-Whitehouse bone age reference values for North American children. *The Journal of pediatrics*. 1997; 131(1 Pt 1): 34-40.
- Tanzi L, Vezzetti E, Moreno R, Moos S. X-ray bone fracture classification using deep learning: a baseline for designing a reliable approach. *Applied Sciences*. 2020; 10(4): 1507.
- Terzi R, Demirezen MU. Performance Analysis of Artificial Intelligence Models Trained with Open-Source Dataset in Clinical Environment. 2023.
- Teuscher C (2004) *Alan Turing: Life and legacy of a great thinker*: Springer Science & Business Media.
- Thrun S. Learning to play the game of chess. *Advances in neural information processing systems*. 1994; 7.
- Ünver T (2013) El-Bilek Kemikleri, Servikal Vertebra Ve Dişlerin Gelişimdönemlerine Göre Kronolojik Yaş Evrelerinin El-Bilek Grafileleri Ve Dental Volumetrik Tomografi Ile Karşılaştırmalı Olarak Değerlendirilmesi: Marmara Üniversitesi (Turkey).
- Üreten K, Sevinç HF, İğdeli U, Onay A, Maraş Y. Use of deep learning methods for hand fracture detection from plain hand radiographs. *Turkish Journal of Trauma & Emergency Surgery*. 2022; 28(2): 196.

- Van Gerven M, Bohte S (2017) Artificial neural networks as models of neural information processing. pp. 114: Frontiers Media SA.
- Wadsworth CT. Clinical anatomy and mechanics of the wrist and hand. *Journal of Orthopaedic & Sports Physical Therapy*. 1983; 4(4): 206-16.
- Wang C-Y, Bochkovskiy A, Liao H-YM YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. pp. 7464-75; pp. 7464-75.
- Wang R, Zhao J, Liu X, Tang X, Shi Y, Wei L. AdvYOLO: Advanced YOLOv8 Application for Bone Pathology Localization and Classification in Wrist X-ray Images. 2024.
- Wang ZJ. Probing an AI regression model for hand bone age determination using gradient-based saliency mapping. *Scientific reports*. 2021; 11(1): 10610.
- White SC, Pharoah MJ (2013) *Oral radiology: principles and interpretation*: Elsevier Health Sciences.
- Widayani A, Putra AM, Maghriebi AR, Adi DZC, Ridho MHF. Review of Application YOLOv8 in Medical Imaging. *Physics Letters*. 2024; 5(1).
- Yılmaz Y Bulanık mantık ile kemik yaşı tespiti: Bilişim Enstitüsü.
- Yüce F, Taşşöker M. Diş hekimliğinde yapay zeka uygulamaları. *7tepe Klinik Dergisi*. 19(2): 141-9.
- Zadeh LA. Making computers think like people [fuzzy set theory]. *IEEE spectrum*. 1984; 21(8): 26-32.
- Zhiqiang W, Jun L A review of object detection based on convolutional neural network. pp. 11104-9; pp. 11104-9. *IEEE*.
- Zou Z, Chen K, Shi Z, Guo Y, Ye J. Object detection in 20 years: A survey. *Proceedings of the IEEE*. 2023; 111(3): 257-76.

8.ÖZGEÇMİŞ



9.EKLER

EK-1



T.C.

**NECMETTİN ERBAKAN ÜNİVERSİTESİ DİŞ HEKİMLİĞİ
İLAÇ VE TIBBİ CİHAZ DIŞI ARAŞTIRMALAR ETİK KURULU**

Toplantı Sayısı: 34

Toplantı Tarihi: 26.10.2023

Karar Sayısı:2023/344: (Başvuru ID: 16281) N.E.Ü. Sağlık Hizmetleri Meslek Yüksekokulu Dişçilik Hizmetleri Bölümü Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Öğretim Üyesi Dr. Öğr. Üyesi Ali ALTINDAĞ'ın "El-Bilek Röntgen Görüntülerinden Yaş Tahmini: Bir Yapay Zekâ Yaklaşımı" başlıklı uzmanlık tez çalışması ile ilgili başvurusu görüşüldü. Arş. Gör. Cemile Nur YILDIRIM'ın uzmanlık tez çalışmasının N.E.Ü. Sağlık Hizmetleri Meslek Yüksekokulu Dişçilik Hizmetleri Bölümü Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Öğretim Üyesi Dr. Öğr. Üyesi Ali ALTINDAĞ'ın sorumluluğunda yürütülmesinin uygun olduğuna oybirliği ile karar verilmiştir.

Not: Çalışma ile ilgili gerekli izin ve yasal sorumluluk araştırmacıya aittir.

Sorumlu Araştırmacı: Dr. Öğr. Üyesi Ali ALTINDAĞ
Yardımcı Araştırmacılar: Arş. Gör. Cemile Nur YILDIRIM

Prof. Dr. Bozkurt Kubilay IŞIK
Etik Kurulu Başkanı