



RECEP TAYYİP
ERDOĞAN
ÜNİVERSİTESİ

T.C.

SAĞLIK BAKANLIĞI

RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ TIP FAKÜLTESİ

RADYOLOJİ ANABİLİM DALI

MANYETİK REZONANS GÖRÜNTÜLEMEDE SAPTANAN
VERTEBRA KORPUS LEZYONLARININ AYIRICI TANISINDA
DERİN ÖĞRENME TABANLI YAPAY ZEKANIN ETKİNLİĞİNİN
DEĞERLENDİRİLMESİ

UZMANLIK TEZİ

Dr. Hüseyin Er

RİZE, 2025



RECEP TAYYİP
ERDOĞAN
ÜNİVERSİTESİ

T.C.

SAĞLIK BAKANLIĞI

RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ TIP FAKÜLTESİ

RADYOLOJİ ANABİLİM DALI

MANYETİK REZONANS GÖRÜNTÜLEMEDE SAPTANAN
VERTEBRA KORPUS LEZYONLARININ AYIRICI TANISINDA
DERİN ÖĞRENME TABANLI YAPAY ZEKANIN ETKİNLİĞİNİN
DEĞERLENDİRİLMESİ

UZMANLIK TEZİ

Dr. Hüseyin Er

TEZ DANIŞMANI

Doç. Dr. Mehmet Beyazal

RİZE, 2025

TEZ ETİK BEYANNAMESİ

Tarafımdan hazırlanan “**Manyetik Rezonans Görüntülemede Saptanan Vertebra Korpus Lezyonlarının Ayırıcı Tanısında Derin Öğrenme Tabanlı Yapay Zekanın Etkinliğinin Değerlendirilmesi**” başlıklı bu tezin, Recep Tayyip Erdoğan Üniversitesi Sağlık Bilimleri Enstitüsü Tez Hazırlama ve Yazım Kılavuzu standartlarına uygun olarak yazıldığını, tezin akademik ve etik kurallara bağlı kalınarak gerçekleştirilmiş özgün bir bilimsel araştırma eseri olduğunu, tezde yer alan ve bu tez çalışmasıyla elde edilmeyen bilgi ve yorumlara kaynak gösterildiğini ve kullanılan kaynak listesinde yer aldığını, tezin çalışılması ve yazımı aşamasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Dr. Hüseyin Er

Ocak, 2025

ÖNSÖZ

Başta, radyolojinin gri tonları arasında, bilgi ve tecrübeleriyle yolumuzu aydınlatan değerli hocam, bölüm başkanımız Prof. Dr. Fatma Beyazal Çeliker'e,

Eğitim hayatımın bu aşamasında, girişimsel radyolojinin tüm uygulamalarını ve inceliklerini öğrenmemde her türlü kolaylığı sağlayan, çözüm odaklı yaklaşımıyla tez oluşturma sürecinde de değerli katkılarını esirgemeyen kıymetli hocam ve tez danışmanım Doç. Dr. Mehmet Beyazal'a,

Uzmanlık eğitimim boyunca desteklerini, bilgi ve tecrübelerini aktaran sevgili hocalarım Doç. Dr. Gülen Burakgazi, Doç. Dr. Filiz Taşçı ve Dr. Öğr. Üyesi Hande Melike Bülbül'e,

Asistanlığım süresince, yoğun çalışma temposu içerisinde eğitim sorumluluğunu büyük bir özveriyle üstlenen, iyi bir hekimden öte örnek bir insan olan ve bir radyolog olarak kendime rol model aldığım çok sevgili hocam Dr. Öğr. Üyesi Nur Hürsoy'a,

Artık aramızda olmasalar da birlikte çalışma imkanı yakaladığım hocalarım Doç. Dr. Hasan Gündoğdu ve Doç. Dr. Tuğba Eldeş'e,

Bu süreçte, tezimin hazırlanmasında değerli katkılarıyla büyük rol oynayan Doç. Dr. Murat Tören ve Berkutay Asan'a,

Tüm radyoloji serüvenimde, tez çalışmamda ve kişisel yaşantımda her türlü konuda yardımcı olup kendisinden çok şey öğrendiğim, ileride mesleki olarak çok iyi yerlere geleceğine inandığım, değerli dostum Uzm. Dr. Esat Kaba'ya,

Kliniğimizde her zaman keyif ve uyum içinde çalıştığımız tüm sekreter, teknisyen, hemşire ve personel arkadaşlarıma,

Başta sevgili dostlarım Uzm. Dr. Sümeyye Sekmen ve Uzm. Dr. Lütfullah Sağır olmak üzere, birlikte çalışmaktan, öğrenmekten, öğretmekten ve beraber olmaktan her zaman mutluluk duyduğum tüm asistan arkadaşlarıma,

Hayatımın her anında, maddi ve manevi anlamda desteklerini esirgemeyen, geldiğim noktada ben olabilmeyi kendilerine borçlu olduğum annem Havva Er ve babam Kadir Er'e,

Karşıma çıktığı andan itibaren hayatımı güzelleştirip anlamlandıran, her anımda yanımda olarak bana güç veren, aynı zamanda çok iyi bir hekim ve anne olan sevgili eşim Uzm. Dr. Kübra Uyar Er'e ve en değerli varlığım, biricik oğlum Ömer Merih Er'e,

Sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖNSÖZ	iii
İÇİNDEKİLER.....	iv
TABLolar DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	vi
KISALTMALAR	viii
ÖZET	ix
ABSTRACT.....	xi
1. GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER.....	3
2.1. ANATOMİ.....	3
2.1.1. Vertebral Kolonun Anatomisi	3
2.1.2. Vertebra Anatomisi	4
2.2. SIK GÖRÜLEN VERTEBRA KORPUS LEZYONLARI	6
2.2.1. Benign Tümörler.....	7
2.2.1.1. Hemanjiom.....	7
2.2.2. Malign Tümörler.....	9
2.2.2.1. Metastaz.....	9
2.2.3. Enfeksiyonlar	14
2.2.3.1. Spondilodiskit (Diskit- Osteomyelit).....	14
2.3. YAPAY ZEKA	15
2.3.1. Makine Öğrenmesi.....	16
2.3.1.1. Denetimli Makine Öğrenmesi.....	16
2.3.1.2. Denetimsiz Makine Öğrenmesi.....	17
2.3.1.3. Yarı Denetimli Makine Öğrenmesi.....	17
2.3.2. Derin Öğrenme	17
2.3.2.1. YOLO (You Only Look Once):.....	20
3. GEREÇ VE YÖNTEM.....	23

3.1. HASTALARIN BELİRLENMESİ.....	23
3.2. MRG ÇEKİM PROTOKOLÜ	24
3.3. GÖRÜNTÜ ÖN İŞLEME	24
3.4. ÇALIŞMA TASARIMI	25
3.5. DERİN ÖĞRENME	25
3.6. İSTATİSTİK	27
4. BULGULAR.....	30
5. TARTIŞMA	40
6. SONUÇ	47
7. KAYNAKLAR.....	48

TABLolar DİZİNİ

Tablo 1: Çalışmaya dahil edilen hasta/lezyon sayısı	23
Tablo 2: YOLOv8 eğitim parametreleri	26
Tablo 3: Hastaların yaş ortalaması, cinsiyet ve radyolojik tanı dağılımları	30
Tablo 4: Lezyon gruplarına göre cinsiyet dağılımı	31
Tablo 5: Tüm tanı gruplarının yaş ortalamaları	31
Tablo 6: Metastaz tanı grubunun primer hastalık bölgeleri	32
Tablo 7: Metastaz tanı grubunun diğer epidemiyolojik, klinik ve radyolojik özellikleri	32
Tablo 8: Metastaz alt grubunda malignite alt grubu ile patolojik kırık varlığı ilişkisi	33
Tablo 9: YOLOv8 modelinin T1 ve T2 veri setinde test performansı	34

ŞEKİLLER DİZİNİ

Şekil 1: Vertebral kolonun farklı yönlerden görünüşü	4
Şekil 2: Tipik bir vertebranın temel yapısal bileşenleri	6
Şekil 3: Vertebral hemanjiom MRG özellikleri	8
Şekil 4: Vertebral atipik hemanjiom MRG özellikleri	9
Şekil 5: Vertebra korpus metastazı MRG özellikleri	13
Şekil 6: Akut çökme kırığı MRG özellikleri	13
Şekil 7: Spondilodiskit MRG özellikleri	15
Şekil 8: Yapay zeka hiyerarşisinin diyagramı	16
Şekil 9: Yapay sinir ağı	18
Şekil 10: Evrişimli sinir ağı	19
Şekil 11: YOLO ve diğer modellerin karşılaştırma grafikleri	20
Şekil 12: YOLOv8 mimarisi	21
Şekil 13: Çalışma planı	26
Şekil 14: YOLOv8'in sınırlandırıcı kutular ile tespit ve sınıflandırma örneği	27
Şekil 15: Karışıklık matrisinin şematik gösterimi	29

Şekil 16: YOLOv8 modelinin eğitim-doğrulama metrikleri ve kayıp değerleri analizi	33
Şekil 17: T1 veri setine göre sınırlayıcı kutu (bounding box) ve yapılan sınıflandırma grafikleri.....	35
Şekil 18: T2 veri setine göre sınırlayıcı kutu (bounding box) ve yapılan sınıflandırma grafikleri.....	36
Şekil 19: YOLOv8 modelinin T1 veri seti için karışıklık matrisi	37
Şekil 20: YOLOv8 modelinin T2 veri seti için karışıklık matrisi	38
Şekil 21: T1 test setinin ve T2 test setinin ROC eğri analizi.....	39

KISALTMALAR

AUC: Eğri Altındaki Alan (Area Under Curve)

BT: Bilgisayarlı Tomografi

CNN: Evrişimli Sinir Ağı (Convolutuonal Neural Network)

COCO: Common Objetscs in Context

DICOM: Tıpta Dijital Görüntüleme ve İletişim

FN: Yalancı negatif

FOV: Görüş Alanı (Field Of View)

FP: Yalancı pozitif

IoU: Birleşim Üzerinden Kesişim (Intersection Over Union)

mAP: Ortalama Doğruluk Skoru (Mean Average Precision)

MRG: Manyetik Rezonans Görüntüleme

NEX: Uyarım Sayısı

PACS: Görüntü Saklama ve İletişim Sistemleri (Picture Archiving and Communication Systems)

PET-BT: Pozitron Emisyon Tomografisi ve Bilgisayarlı Tomografi

ROC: Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)

ROI: İlgi Alanı Bölgesi (Region Of Interest Coding)

STIR: Short Tau Invertion Recovery

TE: Eko Zamanı (Time to Echo)

TN: Gerçek negatif

TP: Gerçek pozitif

TR: Tekrar Süresi (Time to Repeat)

TSE: Turbo Spin Eko

T1A: T1 Ağırlıklı

T2A: T2 Ağırlıklı

VH: Vertebral Hemanjiom

YOLO: You Only Look Once

ÖZET

Manyetik Rezonans Görüntülemeye Saptanan Vertebra Korpus Lezyonlarının Ayırıcı Tanısında Derin Öğrenme Tabanlı Yapay Zekanın Etkinliğinin Değerlendirilmesi

Giriş ve Amaç: Omurga (vertebra) hastalıkları insan ömrünün uzamasıyla birlikte oldukça yaygın olarak görülmektedir. Vertebra korpusunda, metastazlar, en sık görülen malign hastalık grubudur. Hemanjiomlar, en sık izlenen benign tümörlerdir. Bunun dışında çökme kırıkları ve spondilodiskit oldukça sık görülmektedir. Bu hastalıkların tanısında MRG altın standarttır ancak lezyonların benzer görüntüleme özellikleri gösterebilmesi ayırıcı tanıda güçlük oluşturabilmektedir. Biz bu çalışmamızda, tedavi yaklaşımları ve prognozu birbirlerinden oldukça farklı olan bu antitelerin ayırıcı tanısında MRG kullanarak derin öğrenme modellerinin etkinliğini değerlendirmeyi amaçlamaktayız.

Gereç ve Yöntem: Recep Tayyip Erdoğan Üniversitesi Tıp Fakültesi Eğitim ve Araştırma Hastanesinde Ocak 2019- Mart 2024 tarihleri arasındaki hastalar geriye dönük olarak incelendi. Herhangi bir klinik gerekçeyle, 1.5 T (Tesla) MR cihazında torakal ve lomber spinal MRG çekimi yapılan hastaların görüntüleri taranarak toplamda 235 hastaya ait 392 vertebra korpus lezyonu çalışmaya dahil edildi. Çalışma için uygun görüntü verileri sagittal planda çekimi yapılmış T1 ve T2 ağırlıklı sekanslardan elde edilip kaydedildi. Tüm görüntüler standart boyutta düzenlendi. Standartize edilmiş görüntülerden T1 ve T2 ağırlıklı görüntüler için iki ayrı veri seti oluşturuldu. Patoloji grupları metastaz, akut çökme kırığı, hemanjiom, atipik hemanjiom ve spondilodiskit olarak sınırlayıcı kutu ile işaretlenerek belirlendi. 181 hastanın görüntülerinden oluşturulan veri seti %80 eğitim ve %20 doğrulama olarak ikiye ayrıldı. Ek olarak test amacıyla 54 hastanın görüntüleri kullanıldı. Görüntü ön işleme aşamalarının ardından YOLOv8 derin öğrenme modeli kullanılarak tespit ve sınıflandırma işlemi gerçekleştirildi.

Bulgular: Test seti sonuçlarına göre; T1 ve T2 ağırlıklı görüntülerden elde edilen veri setleri için mAP (B) değeri sırasıyla 0,82 , 0,86, mAP (M) değeri sırasıyla 0,83, 0,85'tir. Kesinlik (B) değeri sırasıyla 0,85 ve 0,86, kesinlik (M) değeri sırasıyla 0,81 ve 0,82 elde edilmiştir. Geri çağırma (B) değeri sırasıyla 0,82, 0,84 ve geri çağırma (M) değeri 0,84 ve 0,82 olarak bulunmuştur. F1 skoru sırasıyla 0,82 ve 0,83 olarak tespit edilmiştir. Doğruluk oranı T1 veri seti için 0,84 ve T2 veri seti için 0,85'tir.

Sonuç: Derin öğrenme modelleri vertebra korpus lezyonlarının ayırıcı tanısında yüksek başarı performansı göstermektedir. Bu sonuçlar derin öğrenme mimarilerinin, görüntüleme analizleri gerçekleştirerek tanısal süreçlerde değerli bir araç olarak kullanılabileceğini göstermektedir. Derin öğrenme yaklaşımları, vertebra korpus lezyonlarının tespitinde ve ayırıcı tanısında klinik uygulamalar için güçlü bir destek sunarak hasta bakımını iyileştirme potansiyeline sahiptir.

Anahtar Kelimeler: Vertebra korpus lezyonları, manyetik rezonans görüntüleme, derin öğrenme, tespit, sınıflandırma, ayırıcı tanı

ABSTRACT

Evaluation of the Effectiveness of Deep Learning in the Differential Diagnosis of Vertebral Body Lesions Detected by Magnetic Resonance Imaging

Introduction and Objective: Spinal diseases have become increasingly common with the extension of human life expectancy. Metastases are the most frequently observed malignancies in the vertebral body, while hemangiomas are the most common benign tumors. Furthermore, compression fractures and spondylodiscitis are also frequently encountered. Although MRI is the gold standard for diagnosing these conditions, the similar imaging characteristics of the lesions can pose challenges in the differential diagnosis. In this study, we aim to evaluate the effectiveness of deep learning models in the differential diagnosis of these conditions using MRI.

Materials and Methods: Between January 2019 and March 2024, images of patients who underwent thoracic and lumbar spinal MRI using a 1.5 T MR device at Recep Tayyip Erdoğan University Medical Faculty Training and Research Hospital were scanned. A total of 392 vertebral body lesions from 235 patients were included in the study. Suitable image data were obtained from sagittal plane T1 and T2-weighted sequences and recorded. All images were standardized to a uniform size. Two separate datasets were created from the standardized images for T1 and T2 weighted images. Pathology groups were defined using bounding boxes to identify metastasis, acute compression fractures, hemangiomas, atypical hemangiomas, and spondylodiscitis. The images in the created dataset were divided into 80% for training and 20% for validation. Additionally, images from 54 patients were used for external testing purposes. Following the image preprocessing stages, detection and classification were performed using the YOLOv8 deep learning model.

Findings: According to the results of the test set, the mAP(B) value for T1 and T2 datasets were 0.82 and 0.86, respectively, and the mAP(M) values were 0.83 and 0.85. The precision(B) values were 0.85 and 0.86, while the precision(M) values were 0.81 and 0.82. The recall(B) values were 0.82 and 0.84, and the recall(M) values were found

to be 0.84 and 0.82. The F1 scores were 0.82 and 0.83, respectively. The accuracy rates were 0.84 for the T1 dataset and 0.85 for the T2 dataset.

Conclusion: Deep learning models demonstrate high performance in the differential diagnosis of vertebral body lesions. These results indicate that deep learning architectures can be valuable tools in diagnostic processes by performing imaging analyses. Deep learning approaches provide strong support for clinical applications in the detection and differential diagnosis of vertebral body lesions, thereby contributing to the improvement of patient care.

Keywords: Vertebral body lesions, magnetic resonance imaging, deep learning, detection, classification, differential diagnosis

1.GİRİŞ VE AMAÇ

Omurga (vertebra), vücudun aksiyel iskeletini oluşturur. Görevi omurilik ve sinir köklerini korumak, vücut ağırlığını taşıyarak postürü stabil tutmaktır [1]. Yapısı esas olarak vertebral cisim (korpus), intervertebral disk, vertebral ark ve posterior eklemlerden oluşur [2]. Malignite ve diğer hastalık gruplarının görülme sıklığı, yaşın ilerlemesiyle birlikte belirgin şekilde artmaktadır [3].

Omurga hastalıklarının tanısında direkt grafi, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) temel olarak kullanılan görüntüleme yöntemleridir [3]. MRG, radyasyon içermeyen ve diğer modalitelere göre daha iyi bir rezolüsyon gösteren görüntüleme yöntemidir. MRG, intervertebral diskler, vertebral kemik iliği ve spinal kanal içeriği gibi yumuşak dokuların daha net olarak görüntülenmesini sağlar [4]. Ayrıca, lezyonların anatomik yerleşimini ve yumuşak doku yayılımını belirlemede önemli bir rol oynar [5]. Bu nedenle MRG, günümüzde omurga hastalıklarının teşhisinde altın standart görüntüleme yöntemidir [6].

Vertebra korpusunda (gövdesinde); metastazlar, benign tümörler, enfeksiyonlar ve çökme kırıkları sık görülen lezyonlardır. Manyetik rezonans görüntüleme (MRG), yüksek tanısal doğruluğa sahiptir. Ancak görüntülemelerin değerlendirilmesinde, hata veya yorum farklılıkları gözlenebilmektedir [7]. Ayrıca, vertebra korpus lezyonlarının morfolojik benzerlikleri, ayırıcı tanıyı zorlaştıran önemli bir faktör olmaktadır [8]. Lezyonların kesin tanısının konulabilmesi için patolojik doku biyopsisi gerekli olabilir. Ancak, biyopsi invaziv bir işlem olduğundan, işlem sonrası komplikasyon gelişme riski bulunmakta, hastanın semptomlarında artış gözlemlenebilmekte ve hastalığın daha geniş bir alana yayılma riski oluşabilmektedir [9]. Biyopsi uygulanmasına rağmen, malign ve metastatik lezyonların tanısında doğruluk oranı yaklaşık %85-90, benign tümörlerde ise %75-80 seviyesinde kalmaktadır [10]. Bu nedenlerle invaziv olmayan tanı yöntemlerinin geliştirilmesi ve iyileştirilmesi, omurga hastalıklarının yönetiminde büyük önem taşımaktadır.

Günümüzde tıp biliminde yapay zekâ alanındaki çalışmalar büyük bir hız kazanmaktadır. Çalışmaların büyük çoğunluğu görüntüleme yöntemleri üzerinde

yoğunlaşmıştır. Bu çalışmalar, tanı süreçlerini iyileştirmek, daha hızlı tanı koyup daha etkili tedavi yöntemleri geliştirmeyi hedeflemektedir. Bu amaç doğrultusunda derin öğrenme modelleri yaygın bir şekilde kullanılmaktadır. Derin öğrenme, insan beynindeki nöral ağlara benzer şekilde çalışan, birden fazla katman içeren ve karmaşık yapıların modellenmesine olanak sağlayan yapay sinir ağlarını ifade etmektedir [11]. Görüntü sınıflandırmada, görüntü verileri üzerinde çalışmak için özel olarak tasarlanmış derin öğrenme modellerinden biri olan evrişimli sinir ağları (CNN) kullanılmaktadır [12]. CNN tabanlı modeller, lezyonların veya hastalıklı bölgelerin tespiti, sınıflandırılması ve segmentasyonu gibi farklı görevlerde başarılı şekilde kullanılmaktadır [12, 13].

Bu bağlamda, çalışmamızda YOLOv8 derin öğrenme modeli kullanarak, vertebra korpus patolojilerinin hem tespiti hem de sınıflandırılması işlemi gerçekleştirilmiştir. Çalışmanın amacı, vertebra korpus patolojilerinin ayırıcı tanısında yüksek doğruluk ve etkinlik sunabilen bir model geliştirmek ve derin öğrenme algoritmalarının bu alandaki potansiyelini değerlendirmektir. Çalışmanın sonuçlarının, klinik tanı süreçlerine katkıda bulunacak önemli bulgular sunması amaçlanmaktadır.


2. GENEL BİLGİLER

2.1. ANATOMİ

2.1.1. Vertebral Kolonun Anatomisi

Omurga, vertebral kolon ya da spinal kolon olarak bilinir ve vücudun boyun, sırt ve aksiyel iskelet (kranyum, spinal kolon, kaburgalar ve sternum) yapısının temelini oluşturur. Kranyumdan başlayıp koksikse dek uzanan bu yapı, erişkinlerde genellikle 7 servikal, 12 torasik, 5 lomber, 5 sakral ve 4 koksigeal olmak üzere beş bölgeye ayrılan 33 omur ve 23 intervertebral diski içerir. Hareketin büyük bir kısmı yalnızca üstteki 25 omur arasında gerçekleşir. Sakral bölgede bulunan beş omur, yetişkinlikte kaynaşarak sakrumu, koksigeal bölgedeki dört omur ise yaklaşık 30 yaşında birleşerek koksiksi oluşturur. Bu nedenle, yetişkin bir omurgada yaklaşık 72-75 cm uzunluğunda, dördte biri intervertebral disklerden oluşan ve 24 omur içeren bir yapı bulunur [14, 15].

Vertebral kolon ya da omurga , omurilik ve spinal sinirlerin korunmasını sağlar, aynı zamanda pelvisin üstünde vücut ağırlığını destekler. Vücuda hem sağlamlık hem de esneklik kazandırarak başın üzerinde dönebileceği geniş bir taban oluşturur. Ayrıca, omurga, postürün korunmasında ve hareketlerin gerçekleştirilmesinde önemli bir rol oynar [15, 16].



Şekil 1: Vertebral kolonun farklı yönlerden görünüşü (Sobotta, 2013)

2.1.2. Vertebra Anatomisi

Omurgayı oluşturan vertebraların boyutları ve özellikleri, omurganın farklı bölgelerinde değişiklik gösterir, ancak temel yapıları aynıdır. Her bir vertebra, vertebra gövdesi (korpus), vertebral ark ve çeşitli çıkıntılardan (proses) meydana gelir [17].

Vertebra gövdesi, omurganın ön kısmında yer alan silindirik bir yapıdır ve temel olarak vücut ağırlığını taşır. Gövde, sağlam bir dış kompakt kemik tabakası ve içte vasküler, trabeküler kemikten oluşur. İç kısımda, kısa yatay trabeküllerle kesişen uzun dikey trabeküllerden oluşan bir ağ bulunmaktadır. Bu trabeküller arasındaki

boşluklar, erişkin bir bireyin en aktif hematopoietik dokularından biri olan kırmızı kemik iliği ile doludur. Vertebra gövdesinin üst ve alt yüzeyleri, kemiğin geliştiği kıkırdak modelin kalıntıları olan hiyalin kıkırdak diskleriyle (vertebral ‘endplate’) kaplıdır [15].

Anüler epifizler ve onların kıkırdak kalıntıları, hem büyüme bölgeleri olarak görev yapar hem de vertebra gövdelerine belli bir koruma sağlar. Bu yapılar, intervertebral disk ile vertebra gövdesi arasındaki sıvı difüzyonunu da sağlar. Üst ve alt epifizler, genellikle yetişkinliğin erken döneminde (yaklaşık 25 yaşında) vertebra gövdesinin merkez kısmı olan sentrum ile birleşir [18].

Vertebral ark, vertebra gövdesinin arkasında yer alır ve iki pedikül ile orta hatta birleşen geniş, düz laminalardan oluşur. Pediküller, vertebra gövdesinden arkaya doğru kısa ve kalın silindirik çıkıntılar şeklinde uzanır ve laminalarla birleşerek vertebral arkı tamamlar. Vertebral ark ile vertebra gövdesinin arka yüzeyi birlikte vertebral foramenlerin duvarlarını oluşturur. Bu foramenler, omuriliği, omurilik sinir köklerini, onları çevreleyen zarları (meninksler), yağ dokusunu ve damarları içerir. Böylece, vertebral foramenler spinal kanalı meydana getirir ve bu yapılar için koruyucu bir geçit oluşturur [19].


Vertebral çentikler, vertebraların lateral görünümünde pediküllerin üstünde ve altında görülen anatomik yapılardır. Vertebraların üst ve alt çentikleri, bunları birbirine bağlayan intervertebral disklerle birlikte intervertebral foramenleri oluşturur. Bu foramenler spinal sinirlerin spinal kanaldan çıkış noktalarıdır ve spinal (arka kök) ganglionlarını barındırır [15].

Tipik bir vertebradan yedi çıkıntı (proses) uzanır. Bunlardan biri olan spinöz çıkıntı, laminaların birleşim noktasından vertebral arkın arkasına doğru uzanır ve genellikle alttaki vertebrayla örtüşerek aşağı doğru yönelir. Spinöz çıkıntıya interspinöz ve supraspinöz bağlar ile çeşitli kaslar tutunur ve bu yapı, omurganın fleksiyonunu sınırlandırmada önemli bir rol oynar. Pediküller ile laminaların birleşim noktalarından ise posterolateral yönde iki transvers çıkıntı uzanır. Ayrıca, üstte ve altta

ikişer olmak üzere toplam dört eklem çıkıntısı (zigapofizyal eklemler) bulunur. Her biri bir eklem yüzeyi (faset) taşıyan bu çıkıntılar, pediküller ile laminaların birleşim yerinden kaynaklanır. Zigapofizyal eklemler, omurganın hizalanmasını koruyarak hareket aralığını düzenler ve belirli pozisyonlarda yük taşıma görevine katkıda bulunur [15, 20].

Spinöz ve transvers çıkıntılar, derin sırt kaslarının bağlantı noktalarını oluşturarak, vertebraların pozisyonunu sabitleyen veya değiştiren kaslara destek sağlayan kaldıraç görevi görür. Eklem çıkıntıları, üst ve alt vertebraların karşılıklı çıkıntılarının birleşmesiyle zigapofizyal (faset) eklemleri oluşturur. Bu eklemler, her omurga bölgesinde bitişik vertebralar arasındaki hareket çeşitlerini ve sınırlarını belirler. Ayrıca, eklem çıkıntıları bitişik vertebraların hizasını koruyarak, üstteki vertebranın alttaki vertebra üzerinde öne doğru kaymasını engeller [21].

Bu anlatım, vertebralar ve eklem çıkıntılarının omurganın fonksiyonundaki önemini vurgular. Vertebraların sabitlenmesi ve düzgün hareket etmelerinin sağlanması, omurganın bütünlüğünü korur ve hareket yeteneğini destekler [15, 22]. Tipik bir vertebranın temel yapısal bileşenleri şekil 2’de gösterilmiştir.



Şekil 2: Tipik bir vertebranın temel yapısal bileşenleri [23].

2.2. SIK GÖRÜLEN VERTEBRA KORPUS LEZYONLARI

Omurga tümörlerinin yaklaşık %60'ı ekstradural alanda, %40'ı ise dural kese içinde yer alır. Ekstradural alan, aslında büyük ölçüde kemik kısmı temsil eder ve tümörlerin çoğunluğu omurga gövdesinde izlenir. Primer omurga tümörleri nispeten nadirdir ve tüm kemik tümörlerinin %5'inden azını oluşturur. Buna karşılık, sekonder metastatik hastalık, multipl miyelom ve lenfoma daha yaygındır [24]. Benign lezyonlardan en sık hemanjiom görülmektedir [25]. Spondilodiskit, son yıllarda artan insan ömrü ve girişimsel yöntemlerin yaygınlaşmasıyla daha sık görülmektedir. İntervertebral disk ve komşu kemiğin uç platosu etkilenir [26]. Vertebra çökme kırıkları, yaşlı bireylerde sıkça görülmekte olup, osteoporoz ve yaşlanma bu kırıkların başlıca nedenlerindedir [27].

2.2.1. Benign Tümörler


2.2.1.1. Hemanjiom

Hemanjiyomlar, kemik de dahil olmak üzere vücudun her bölgesinde görülebilen, iyi huylu ve yavaş büyüyen vasküler kökenli tümörleridir [28]. Histolojik değerlendirmede, vertebral hemanjiomlar (VH) yağlı ve ödemli bir stroma ile çevrili ince duvarlı ve kanla dolu damarlardan oluşur [29]. Otopsi serilerinde bildirilen verilere göre, omurgaların %11'inde VH'lere rastlanmaktadır ve vakaların %25 ile %30'unda multifokal lezyonlar görülmektedir [30]. Omurganın en sık görülen primer tümörüdür [31]. Bu lezyonlar genellikle vücudun veya omurganın BT ve MR görüntülemelerinde ya da torakolomber omurganın radyografilerinde tesadüfen tespit edilir [32]. Çoğunlukla asemptomatik seyirli olup VH'lerin yalnızca %0.9-1.2'si hayatın herhangi bir döneminde semptomatik hale gelebilirler [33].

VH'ler, radyografilerde "bal peteği" benzeri dikey trabeküller göstererek klasik olarak "kadife çizgisi işareti" (corduroy sign) olarak bilinen bir görünüm oluştururlar. Aksiyel BT görüntülerinde ise "polka-dot veya tuz-biber" işaretleri oluşturacak şekilde çok sayıda küçük skleroz alanları içerirler. Bu görünüm VH tanısı için patognomoniktir. MRG'de, lezyonlar genellikle kontrastsız T1 ve T2 ağırlıklı incelemelerde yüksek sinyal özelliğinde izlenmektedirler [34]. Tipik VH'ler, T1

ağırlıklı görüntülerde çevre kemik iliğine kıyasla yağ içeriğinin yoğunluğuna bağlı olarak hiperintens izlenirler. T2 ağırlıklı görüntülerdeki hiperintensite ise hemanjiyomların içindeki su ve yavaş akışlı kan içeriğini yansıtır.


Yağ içeriği düşük olan VH'ler T1 ağırlıklı görüntülerinde izointens veya hipointens görülebilir; bu tür lezyonlar atipik hemanjiyom olarak adlandırılır [35]. Atipik VH'ler, malign tümörler veya metastazlar gibi daha ciddi patolojik durumları taklit edebilir ve bu nedenle tanıda zorluklar yaratabilir. Bu benzerlik invaziv tanı prosedürlerine ve tedaviye başlama sürecinde gecikmelere neden olabilir. Tipik ve atipik VH'lerin radyolojik bulgularının tanınması, gereksiz invaziv tetkiklerin önlenmesine ve tedavi gecikmelerinin azaltılmasına yardımcı olur [36].



Şekil 3: Vertebral hemanjiom MRG özellikleri; a) sagittal yağ baskısız T1A ve b) sagittal yağ baskısız T2A MR görüntüsü

a)

b)



Şekil 4: Vertebral atipik hemanjiom MRG özellikleri; sagittal yağ baskısız T1A ve b) sagittal yağ baskısız T2A MR görüntüsü

Diğer sık görülen benign tümörler; enostosis (kemik adacığı), osteoid osteoma, osteoblastom, anevrizmal kemik kisti, osteokondrom, dev hücreli tümör, nörofibrom ve eozinofilik granülomdir [37].

2.2.2. Malign Tümörler

2.2.2.1. Metastaz

Omurga, sistemik kanser olgularında karaciğer ve akciğerden sonra en yaygın üçüncü metastaz bölgesidir [38, 39]. Omurga metastazları omurganın en yaygın malign tümörleridir ve omurga görüntülemesinde karşılaşılan malign kitlelerin yaklaşık %90'ını oluşturur. Kemik metastazları yaklaşık %20 vakada spinal korda uzanır ve sinir invazyonuna bağlı klinik oluşturabilir. Metastazlar en sık torakal bölgede izlenmektedir, bunu sırasıyla lomber ve servikal bölge takip etmektedir [40]. Omurgaya tümör yayılımı hematojen, direkt ya da lenfatik sistem aracılığıyla gerçekleşebilir [41]. Omurgada en sık metastaz oluşturan tümörler sırasıyla; meme (%21), akciğer (%19), prostat (%8), böbrek (%5), gastrointestinal sistem (%4.5) ve tiroid (%2.5) maligniteleridir [42, 43].

Tanıda kullanılan temel modaliteler direkt radyografi, BT ve MRG'dir. Direkt radyografi, travma ve dejeneratif değişikliklerin değerlendirilmesinde öncelikli olarak tercih edilen görüntüleme tekniğidir. Ancak metastaz ya da diğer kitlesel lezyonların tespitinde duyarlılığı oldukça düşüktür. Lezyonların %40 kadarı grafilerde tanınmaz, patolojik kırık geliştiğinde kırığın kabaca tespitinde yararlı olabilir [44].

BT kemik dokunun ve kortikal harabiyetin değerlendirmesinde mükemmel rezolüsyon göstermektedir. Ancak kortikal yıkım oluşturmamış metastatik lezyonlar gözden kaçabilmektedir. Ayrıca radyasyon maruziyeti riski, komşu kemik ve yumuşak dokuların gölgelenmesine neden olabilen ışın sertleşmesi artefaktı, kemik yapıda oluşan dejeneratif değişiklikler ve mineralizasyon bozukluklarında lezyonların zor ayırt edilebilmesi başlıca dezavantajlarıdır [45].

MRG omurga metastazlarının tespitinde altın standart görüntüleme yöntemidir. Diğer görüntüleme yöntemlerinden farklı olarak, kemik iliğinde oluşan değişiklikleri erken evrelerden itibaren tespit edebilmektedir. Lezyonların karakterizasyonunu sağlayabilir ve spinal kord ya da diğer dokuların invazyon özelliklerini ortaya koyabilmektedir [46].

Normal kemik iliği kırmızı ve sarı ilikte farklı kompozisyonda olmakla birlikte yağ ve su içerir. İnfiltratif durumlarda yağ diffüz, dissemine ya da bölgesel olarak yok olabilir. Bu nedenle yağ ve su sinyalleri arasındaki farklılıkları gösteren MRG sekansları tanıda oldukça faydalıdır [47].

T1 ağırlıklı MR sekanslarında yağlı kemik iliği yüksek sinyalli izlenmektedir. Eşit düzeyde yağ ve su ihtiva eden hematopoetik (kırmızı) kemik iliği ise yağlı iliğe göre hipointens, kas dokuya göre hiperintens izlenmektedir. Omurga görüntülemesinde, kas doku ve disk yapılarına göre düşük sinyalli kemik iliği, çok yüksek ihtimalle anormaldir [48]. İnfiltratif lezyonlar, T1 ağırlıklı MR sekanslarında düşük sinyale sahiptir. T2 ağırlıklı MR sekanslarında metastatik lezyonlar yüksek su içerikleri dolayısıyla kemik iliğine kıyasla hiperintens görülmektedir. Metastatik lezyonların etrafında her zaman olmamak kaydıyla yüksek sinyalli bir 'halo'

bulunabilir. Yüksek sinyal ve lezyon çevresindeki halo işaretinin varlığı metastatik hastalığın güçlü destekleyici özellikleridir [47].

Kontrast madde, standart tümör görüntülemesinde mutlaka yer almaktadır. Lezyon uzanımları, spinal kord invazyonu ve tedavi değişiklikleri kontrastlı tetkiklerde daha iyi değerlendirilmektedir. Kontrastlı incelemede, kontrast tutan lezyonlar normal yağlı kemik iliğiyle benzer sinyalde izlenebilir, buna bağlı lezyon belirsizleşebilir. Normal yağlı kemik iliğini baskılayan sekanslar kontrastlanan metastatik odakların net bir şekilde tanımlanmasına olanak tanır [49]. Vertebra korpus metastazına ait MRG özellikleri Şekil 5'te verilmiştir.

Omurga görüntülemesinde temel olarak fat-saturation (FAT-SAT) ve Short Tau Inversion Recovery (STIR) yağ baskılama sekansları kullanılmaktadır. Yağ baskılı sekanslarda lezyonlar, konvansiyonel (T1 ve T2 ağırlıklı) görüntülere göre daha belirgin şekilde izlenmektedir. Kontrastlı incelemeler yağ baskılı T1 görüntülerden elde edilmektedir. Yağ baskılı T2 ağırlıklı incelemelerde metastatik lezyonlar miks ya da yüksek sinyalli izlenirken malign olmayan lezyonlar düşük sinyallidir [50].

Benign çökme kırıkları ve malign lezyonlar arasında benzerlik izlenebilir. Akut fazdaki benign çökme kırıklarında, ödemin normal kemik iliği yapısını değiştirmesi nedeniyle T1 ağırlıklı görüntülerde düşük sinyal, T2 ağırlıklı görüntülerde ise yüksek sinyal gözlenir. Kırık gelişen vertebra gövdesinde kontrast tutulumu izlenebilir. Kemik iliği değişiminin morfolojisi, bir kırığın benign veya patolojik nedenini tahmin etmede yardımcı olmaktadır [51].

Patolojik kırığı düşündüren konvansiyonel MRG özellikleri; vertebra gövdesinin konveks arka sınırı, pedikül veya posterior elemanların anormal sinyali, çevreleyen epidural kitle, fokal paraspinal kitle ve diğer spinal metastazlardır [27]. Paravertebral yumuşak doku kitleleri ve posterior elemanların infiltrasyonu, malign bir kırığın en güvenilir işaretleridir [51, 52].


Akut osteoporotik çökme kırıklarını destekleyen MR görüntüleme bulguları arasında, T1 ve T2 ağırlıklı görüntülerde hipointens kırık hattı, vertebra gövdesinin korunan normal kemik iliği sinyali, posterior kemik fragmanının geriye doğru itilmesi ve birden fazla kompresyon kırığı bulunur [27]. Akut çökme kırığına ait MRG özellikleri şekil 6'da sunulmuştur.

Vertebra gövde metastazlarının diğer ayırıcı tanıları arasında; VH, diskojenik uç plaka (endplate) değişiklikleri ve diskit- osteomyelit yer alır. VH'ler T1- ağırlıklı görüntülerde hiperintens izlenirler. Bu lezyonlar, yağ ve vasküler bileşenlerin oranına bağlı olarak STIR sekansında hipo veya hiperintens olabilir. Kalın dikey trabeküller, radyografilerde kadife veya petek görünümünü andırır. İç trabeküller MRG'de belirsiz olabilir ve "atipik" VH vakalarında BT ile daha iyi ayırt edilebilir. Bu lezyonların vasküler bileşeni nedeniyle kontrast tutulumu yaygındır [53].

Diskit- osteomyelitte, endplate erozyonları, intradiskal sıvı ve yamalı kontrast tutulumu görülür. Komşu endplateler anormal sıvı kemik iliği sinyali ve kontrast tutulumu göstermektedir. Kemik metastazları genellikle bir vertebra gövdesinden diğerine yayılırken disk aralığını geçmezler. Avasküler disk, tümör invazyonuna dirençlidir [47].

a)


b)



Şekil 5: Vertebra korpus metastazı MRG özellikleri; sagittal yağ baskısız T1A ve b) sagittal yağ baskısız T2A MR görüntüsü

a)

b)



Şekil 6: Akut çökme kırığı MRG özellikleri; sagittal yağ baskısız T1A ve b) sagittal yağ baskısız T2A MR görüntüsü

Diğer sık görülen malign tümörler; multiple miyelom, lenfoma, kordoma, kondrosarkom, osteosarkom ve Ewing sarkomudur [37].

2.2.3. Enfeksiyonlar

2.2.3.1. Spondilodiskit (Diskit- Osteomyelit)

Spinal enfeksiyonlar, doğrudan primer bir hastalık olarak ortaya çıkabileceği gibi, sistemik sinir sistemi enfeksiyonlarının bir sonucu olarak da ikincil şekilde gelişebilir. Enfeksiyon, doğrudan inokülasyon, lenfatik sistem, hematojen yol veya beyin omurilik sıvısı (BOS) aracılığıyla yayılabilir [54].


Spinal enfeksiyonlar, tutulum yerine göre spondilit (kemik), diskit (disk) ve paraspinal enfeksiyonlar olarak sınıflandırılabilir. Etiyolojik olarak spondilodiskitler, piyojenik ve piyojenik olmayan olarak ayrılabilir. Ayrıca, etkene göre bakteriyel, granülomatöz (tüberküloz, brusella ve mantar) ve parazitik olarak tasnif edilebilir [55].

Bakteriyel (piyojenik) spondilodiskitte *Staphylococcus aureus* (%60) ve enterobakter (%30) en sık etkenlerdir, sırasıyla lomber (%58), torasik (%30), servikal (%11) bölge en sık tutulan lokalizasyondur [56]. Kemik dansitesinde azalma, lizis, anterosuperior end-plate düzensizlik erken radyografi bulgularıdır [57]. Görüntüleme MRG altın standarttır. Erişkinde en erken anormallik T2A'da artmış, T1A'da azalmış sinyal intensitesi, postkontrast serilerde kontrastlanma gösteren subkondral kemik iliği ödemi bulgularıdır. Ödem end platolarda düzensizliğe ve erozyona ilerleyebilir. Disk tutulumunda erken evrede disk yüksekliği artar, diskte T2A sinyalinde artış, diffüz kontrastlanma gözlenir. Geç evrede ise disk yüksekliği ve T2A sinyalinde kayıp izlenmektedir. Kemik iliğinde patolojik sinyal olmadan, izole T2A parlak sinyalli diskit durumları normal yorumlanabileceğinden dolayı kontrast madde verilmesi son derece önemlidir. Diskte periferik kontrastlanma olabileceği gibi, santralde diffüz, yamasal ya da ince lineer kontrastlanma görülebilir [58].

Diğer sık görülen piyojenik olmayan enfeksiyon etkenleri tüberküloz ve brusellozdur [59, 60]. Spondilodiskite ait MRG özellikleri şekil 7'de verilmiştir.

a)

b)




Şekil 7: Spondilodiskit MRG özellikleri; sagittal yağ baskısız T1A ve b) sagittal yağ baskısız T2A MR görüntüsü

2.3. YAPAY ZEKA

Yapay zeka, insanın düşünme yapısını taklit ederek veya onun gerektirdiği görevleri yerine getirmek için sistemler geliştirmeye odaklanan bir bilim dalı olarak tanımlanabilir. Günümüzde, yapay zeka birçok endüstriyel alanda yaygın olarak kullanılmakta olup, tıp dahil olmak üzere çeşitli disiplinlerde önemli ilerlemelere katkı sağlamaktadır.

Radyoloji bilimi, sahip olduğu teknolojik altyapısı sayesinde yapay zeka araştırmalarının merkezinde yer almaktadır. Görüntüleme cihazlarının ana unsurlarından, oluşturulan görüntülerin kalitesini artırmaya kadar pek çok aşamada yapay zeka desteği kullanılmaya başlanmıştır. Ayrıca, tanı sürecinde görüntü sınıflandırma yöntemleri kullanılarak radyologların karar verme süreçlerine destek olan birçok çalışma alanı geliştirilmiştir [61].

Yapay zeka, temelde birbiriyle ilişkili iki ana alt kümeye ayrılır: makine öğrenmesi ve derin öğrenme (Şekil 8).



Şekil 8: Yapay zeka hiyerarşisinin diyagramı [62].

2.3.1. Makine Öğrenmesi

Makine öğrenmesi, bilgisayar sistemlerinin, önceden açıkça programlanmaya gerek kalmaksızın, veri ve deneyimlerden elde edilen örüntüleri öğrenerek belirli görevleri yerine getirmesine olanak sağlayan bir yapay zeka disiplini. Bu alan, matematiksel modeller ve istatistiksel yöntemler kullanarak, sistemlerin veri içerisindeki anlamlı ilişkileri veya desenleri tanımlamasını ve bu öğrenim sürecinden elde edilen bilgiyi gelecekteki tahminler ya da kararlar için uygulamasını hedefler. Temel olarak üç alt kısma ayrılır.

2.3.1.1. Denetimli Makine Öğrenmesi

Bu yöntemde, algoritmalar etiketli veri setleri ile eğitilir. Model, girdiler ile bu girdilere ait doğru çıktılar arasındaki bağıntıları öğrenir. Eğitim sonuçlandığında, model yeni, etiketlenmemiş veriler üzerinde tahminler yapabilir. Yaygın uygulamalar arasında sınıflandırma ve regresyon bulunur. Günümüzde en sık kullanılan makine öğrenme metodudur [63, 64].

2.3.1.2. Denetimsiz Makine Öğrenmesi

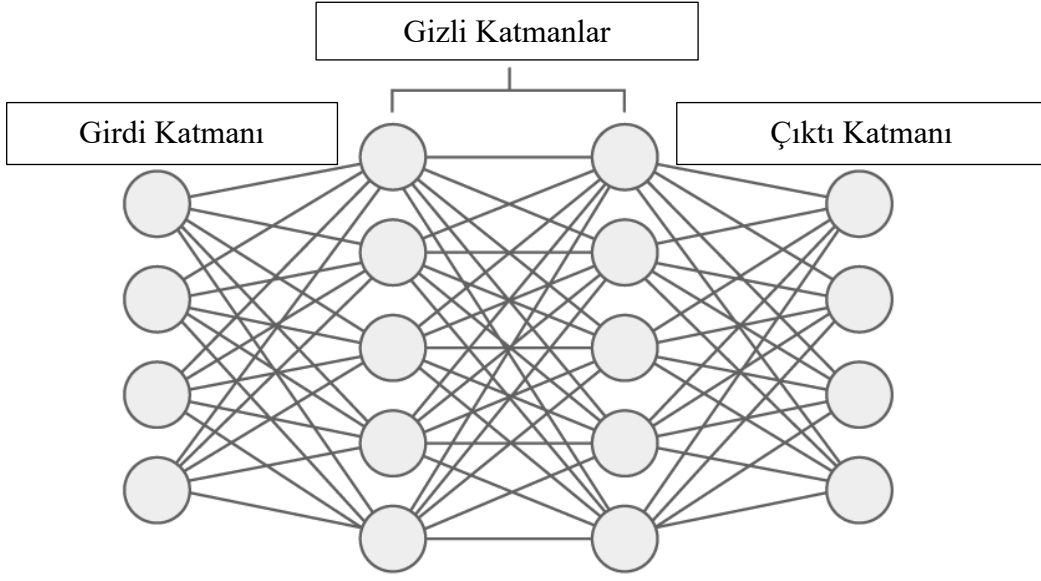
Bu yaklaşımda, algoritmalar etiketlenmemiş veri setleri üzerinde çalışarak, verilerdeki gizli desenleri ve yapıları ortaya çıkarmayı hedefler. Kümeleme ve boyut indirgeme yaygın denetimsiz öğrenme yöntemleridir [65].

2.3.1.3. Yarı Denetimli Makine Öğrenmesi

Yarı denetimli makine öğrenmesi (semi-supervised learning), az miktarda etiketlenmiş veri ile geniş bir etiketlenmemiş veri kümesinin bir arada kullanıldığı bir öğrenme yaklaşımıdır. Bu yaklaşım, tamamen denetimli (supervised) ve denetimsiz (unsupervised) öğrenme yöntemlerinin arasında yer alır ve her iki yöntemden de yararlanır [66].

2.3.2. Derin Öğrenme

Derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla büyük veri setlerinden karmaşık kalıpları öğrenen güçlü bir makine öğrenimi dalıdır. Derin öğrenme, çok katmanlı sinir ağları (deep neural networks) ile çalışır ve genellikle insan benzeri kararlar alabilen modeller oluşturur [67]. Günümüzde birçok alanda başarılı uygulamalara sahip olup, gelecekte de önemli ilerlemeler kaydetmesi beklenmektedir. Derin öğrenmedeki "derin" kavramı, modelin çok katmanlı bir mimariye sahip olduğunu ifade eder. Bu katmanlar, girdilerden (input) bilgi toplayarak, her adımda yeni özellikler öğrenir ve bu bilgiyi işleyerek son aşamada bir çıktı (output) üretir. Yapay sinir ağları, birbiriyle bağlantılı birimlerden oluşan bir yapıdır. Her bağlantı, bir birimden diğerine aktivasyonu iletir ve bu bağlantıların etkisi, bağlantının ağırlığıyla ifade edilen bir sayısal değerle belirlenir. Bu ağırlıklar, modelin öğrenme sürecinde verilerden elde ettiği bilgiyi yansıtır. [64, 68]. Yapay sinir ağına ait görsel şekil 9'da verilmiştir.



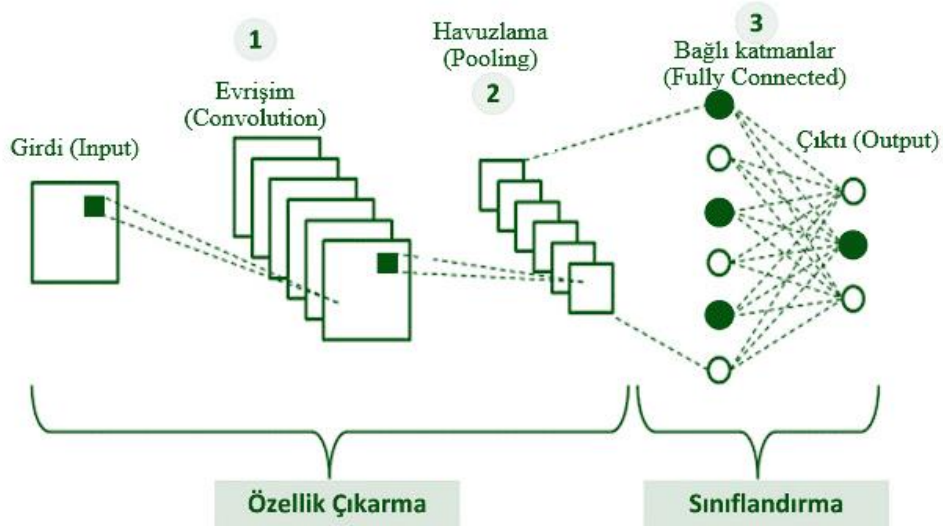
Şekil 9: Yapay sinir ağı [69].

Son yıllarda teknoloji alanındaki ilerlemeler, özellikle grafik işleme birimlerine (GPU) dayalı yüksek performanslı donanımların geliştirilmesiyle, derin öğrenmeyi yapay zekâ çalışmalarında ön plana çıkarmıştır. GPU'lar, büyük veri setlerini işleme ve karmaşık hesaplamaları paralel olarak gerçekleştirme yetenekleriyle bu alandaki çalışmaları hızlandırmıştır. Büyük veri kümelerinin daha kolay depolanması ve erişilebilirliği, derin öğrenme modellerinin daha verimli ve hassas bir şekilde eğitilmesine olanak sağlamıştır. Bu durum, derin öğrenmeyi sağlık, görüntü analizi, dil işleme ve otomasyon gibi pek çok alanda kullanılabilen önemli bir araç haline getirmiştir [68, 70].

Derin öğrenme, büyük tıbbi veri setlerini işleme kapasitesiyle tıp alanında oldukça etkili bir araçtır ve özellikle tıbbi görüntülerin analizinde yüksek başarı göstermektedir. Tıbbi görüntüleme derin öğrenmenin temel görevleri ve uygulama alanları şunlardır: görüntü ön işleme ve kalite artırımı; görüntülerin netleştirilmesi ve gürültünün azaltılması, sınıflandırma; belirli hastalıkların veya durumların tanımlanması, lezyon tespiti; anormal bölgelerin belirlenmesi, segmentasyon (bölütleme); belirli doku ya da organların sınırlarının ayrılması ve lezyon izleme;

hastalığın zaman içindeki ilerlemesinin veya tedaviye yanıtının değerlendirilmesidir [71, 72].


Derin öğrenmenin görüntüleme analizi oluşturmak için temelini evrişimli sinir ağları (CNN) oluşturmaktadır [71, 73]. CNN, klasik olarak üç tabakadan oluşur. Bunlar; evrişim (convolution) katmanları , havuzlama (pooling) katmanları ve tamamen bağlı katmanlardan (fully connected layers) oluşmaktadır (Şekil 9) [74]. Evrişim katmanı, görüntüde konvolüsyon işlemi uygulayarak temel özellikleri öğrenir ve bu özellikleri sonraki katmanlara iletir. Bu işlemde, görüntüye filtreler uygulanır ve bunlar , görüntünün önemli özelliklerini yakalar. Konvolüsyon aşamasının çıktısına ReLU (Rectified Linear Unit) aktivasyon fonksiyonu uygulanarak modelin öğrenme ve genelleştirme kapasitesi artırılır. Havuzlama katmanı, modelin öğrenilen özelliklerinin boyutunu küçülterek hesaplama maliyetinin azaltmasını ve aşırı öğrenmenin (overfitting) engellemesini sağlar. Son olarak, tamamen bağlı katmanlar, önceki katmanlarda öğrenilen özellikleri kullanarak nihai sınıflandırma işlemi gerçekleştirir. Bu katmandaki her bir nöron, önceki katmanların tüm nöronlarıyla bağlantılıdır ve böylece tüm bilgiyi işleyerek sonuç üretir [74, 75].



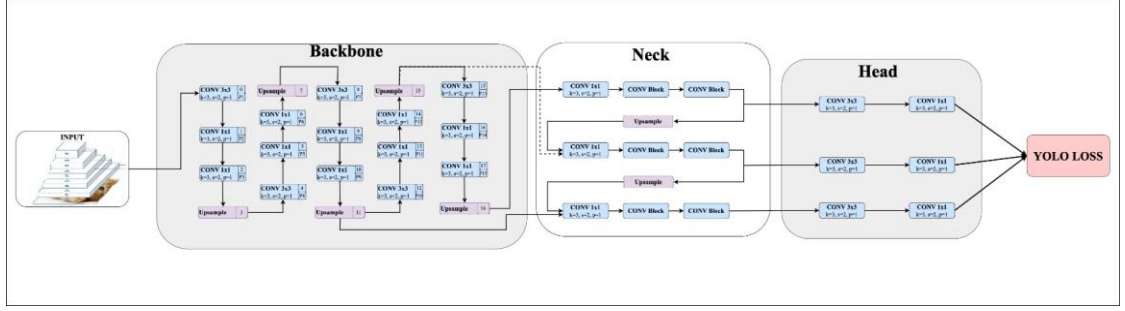
Şekil 10: Evrişimli sinir ağı (CNN) [75].

2.3.2.1. YOLO (You Only Look Once):

YOLO, bir görüntü üzerindeki nesnelere gerçek zamanlı olarak algılayarak tanıma işlemi gerçekleştiren bir derin öğrenme modelidir [76]. Bu algoritma, nesne tanımayı bir regresyon problemi olarak ele alıp, tespit edilen nesnelerin sınıf olasılıklarını da belirler. Algoritma, nesnelere algılamak için evrişimli sinir ağlarını (CNN) kullanmaktadır, her bir nesne tespiti için yalnızca tek bir ileri yayılım işlemi gerektirmektedir. Bu da tüm görüntünün tek bir işlemle tahmin edilmesini sağlar [77]. Tıbbi görüntüleme analizlerinde özellikle anormalliklerin (kırık, tümör vb.) tespit ve sınıflandırılmasında kullanılmaktadır [78]. Bunun dışında otonom araçlarda (örn. MOBESE ile yaya, araç, plaka vs. tespiti), tarım teknolojilerinde (örn. bitki hastalıklarının tespiti), güvenlik ve gözetim sistemlerinde (örn. yüz tanıma, tehdit tespiti), insansız hava araçlarında (örn. arazi analizi, arama-kurtarma) ve endüstriyel uygulamalarda (örn. üründeki hataların tespiti) yaygın olarak kullanılmaktadır [79, 80, 81, 82, 83]. Güncel olarak YOLOv1.....v11 ve PP-YOLO, tiny-YOLO gibi gibi versiyonları mevcuttur [84, 85]. Çalışmada kullandığımız YOLOv8 modeli, mevcut diğer modellere (YOLOv7, YOLOv6 ve YOLOv5) kıyasla COCO (Common Objects in Context) veri kümesi üzerinde yapılan test sonuçlarıyla iki ana metrik üzerinden daha iyi performans sergilemektedir [86]. Şekil 10'da diğer modeller ile karşılaştırma grafikleri gösterilmiştir. YOLOv8'in mimarisi şekil 11'de sunulmuştur.



Şekil 11: YOLO ve diğer modellerin karşılaştırma grafikleri [86].



Şekil 12: YOLOv8 mimarisi

Bu çalışmada kullanılan derin öğrenme hiperparametreleri ve ilgili kavramlar aşağıda detaylı olarak tanımlanmıştır.

Batch normalizasyon: Her katmandaki çıktıları belirli bir ölçüğe çekerek, ağı daha stabil ve hızlı öğrenmesini sağlar. Her katmanın aktivasyonlarını ortalama 0 ve varyans 1 olacak şekilde normalize eder. Bu sayede; eğitim hızını artırır, daha derin ağ yapılarının eğitimini kolaylaştırır ve aşırı öğrenmeyi (overfitting) azaltır [87].

Maksimum tur sayısı (Epoch): Bu parametre, bir yapay sinir ağının eğitim sürecinde veri seti üzerinde tamamlayacağı toplam tekrar sayısını ifade eder [88].

Imgsz: Eğitimde kullanılan görüntülerin hedef boyutunu belirtir ve model doğruluğu ile karmaşıklığını etkiler [89].

Optimizatör: SGD, Adam, AdamW, NAdam, RAdam ve RMSProp gibi seçenekler arasından seçilmiştir; bu seçim, yakınsama hızını ve kararlılığını etkiler [89].

Momentum: Adam optimizier için momentum faktörünü ifade eder ve geçmiş gradyanların güncellemeye dahil edilme sürecini etkiler [89].

Box ve cls: Kayıp fonksiyonundaki kutu ve sınıflandırma kaybının ağırlık değerleridir ve modelin nesne konumları ile sınıf tahminlerinin hassasiyetini optimize eder [90].

Öğrenme Hızı (Learning rate): Öğrenme hızı, bir modelin eğitimi sırasında ağırlıkların güncellenme hızını belirleyen ve model performansını doğrudan etkileyen en önemli hiperparametrelerden biridir [91].

Augmentasyon (Artırma / Genişletme): Augmentasyon, derin öğrenme modellerinin eğitiminde kullanılan bir tekniktir. Bu yöntem, mevcut eğitim verilerine döndürme, kaydırma, yansıtma gibi işlemler uygulayarak veri setini genişletmeyi ve modelin daha iyi genelleme yapabilmesini sağlamayı amaçlar [92].

3. GEREÇ VE YÖNTEM

3.1. HASTALARIN BELİRLENMESİ

Bu çalışma tek merkezli ve retrospektif olarak tasarlanmıştır. Hastanemizde, Ocak 2019- Mart 2024 tarihleri arasında torakal ve lomber spinal MRG çekimi yapılmış 18 yaş üstü hastalar çalışmamıza dahil edilmiştir. Hastanemizde kullandığımız PACS sistemindeki 1.5 Tesla (T) MRG' de çekilen tüm görüntüler taranarak çalışmaya dahil edilecek hastalar belirlenmiştir. Dışlama kriterlerimiz; görüntü kalitesi yetersiz hastalar, vertebra korpusunda patolojik bulgusu olmayan hastalar, lezyon boyutu 1 cm'nin altındaki hastalar, cerrahi enstrümantasyon uygulanmış hastalar, metastaz hasta grubunda radyoterapi uygulananlar, metastaz grubunda PET-BT'si bulunmayan hastalar, metastaz hasta grubu dışındaki diğer gruplarda en erken 6 aylık süreçte takip görüntülemesi bulunmayan hastalar ve atipik hemanjiom grubunda BT görüntülemesi bulunmayan hastalardır. Dışlama kriterlerini kullandıktan sonra MR görüntülemesi yapılmış 3756 hastadan 235 tanesi çalışmaya dahil edilmiştir. Hastaların görüntüleme özelliklerine göre radyolojik tanı dağılımları Tablo 1'de verilmiştir. Bütün hastaların yaş, cinsiyet ve radyolojik tanıları kaydedilmiştir. Ayrıca metastaz hasta grubunda pedikül tutulumu, patolojik kırık varlığı, spinal kord invazyonu, çoklu vertebra tutulumu ve sağkalım özellikleri kaydedilmiştir.

Tablo 1: Çalışmaya dahil edilen hasta/lezyon sayısı

Radyolojik Tanı **Hasta/Lezyon Sayısı**

Akut Çökme Kırığı	63/66
Metastaz	69/190
Hemanjiom	40/44
Atipik Hemanjiom	32/32
Spondilodiskit	30/60*
Toplam	235/392

*Spondilodiskit tespit edilen düzeyde intervertebral diske komşu her iki vertebra değerlendirilmediği dahil edilmiştir.

3.2. MRG ÇEKİM PROTOKOLÜ

MRG incelemeleri, 1.5 T MRG (Siemens Magnetom Area, Erlangen, Almanya) cihazı ile torakal ve lomber bölge için 11 kanallı spinal koil kullanılarak yapıldı. Torakal spinal MRG’de sagittal T1 turbo spin eko (TSE) görüntüleri [TR 524 milisaniye(msn), TE 9,6 msn FOV 24 cm, kalınlık 5,2 mm, NEX 2, voksel boyutu (mm, mm, mm): 1,1x0,7x0,4] ve sagittal T2 TSE [TR 3440 msn, TE 105 msn, FOV 24 cm , kalınlık 5,2 mm, NEX 2, voksel boyutu (mm, mm, mm): 1,1x0,7x0,4] görüntüleri elde edildi. Lomber spinal MRG’de sagittal T1 TSE görüntüleri [TR 450 msn, TE 9,6 msn, FOV 24 cm , kalınlık 5,2 mm, NEX 2, voksel boyutu (mm, mm, mm): 1,1x0,7x0,4] ve T2 TSE [TR 3200 msn, TE 104 msn, FOV 24 cm , kalınlık 5,2 mm, NEX 2, voksel boyutu (mm, mm, mm): 1,1x0,7x0,4] görüntüleri elde edildi. Tüm hastaların T1 ve T2 ağırlıklı görüntüleri kullanıldı. Tüm görüntüler sagittal plandaki kesitlerden elde edildi.

3.3. GÖRÜNTÜ ÖN İŞLEME

Çalışmaya dahil edilen tüm hastaların görüntüleri deneyimli bir radyolog tarafından değerlendirilerek beş farklı tanı grubu oluşturuldu. Daha sonra torakal ve lomber MRG’de sagittal kesitten elde edilen görüntülerin tamamı hastaya ait kimlik bilgilerinden ve görüntüleme parametrelerinden arındırıldı. DICOM formatında oluşturulmuş MR görüntüleri, hastanemizdeki resim arşivleme ve iletişim sistemlerinden (PACS) JPEG formatında dışa aktarıldı. Lezyonların en belirgin olduğu kesitlerden çoklu görüntüler elde edildi. Bu görüntülerde, spinal kord, pedikül ve kesit içinde yer alan diğer alanlar kapsam dışı bırakıldı. Radyolog tarafından sagittal MRG üzerinde, yalnızca lezyon ve vertebra korpusunu tamamen kapsayacak şekilde ilgi alanı (ROI - Region of Interest) bölgeleri manuel olarak belirlendi ve bu bölgeler uygun etiketlerle işaretlendi. Çalışmanın görüntü işleme sürecinde, 1403 × 937 piksel boyutlarındaki ham görüntüler, belirli odak dilimleri kullanılarak analiz sırasında tutarlılık oranını yükseltmek ve işlem süresini iyileştirmek için 640 × 640 piksel boyutunda standartlaştırılmış görüntülere dönüştürüldü. Bu işlemler sonucunda, nesne algılama eğitimi için kullanılacak nihai görüntüler oluşturuldu.

3.4. ÇALIŞMA TASARIMI

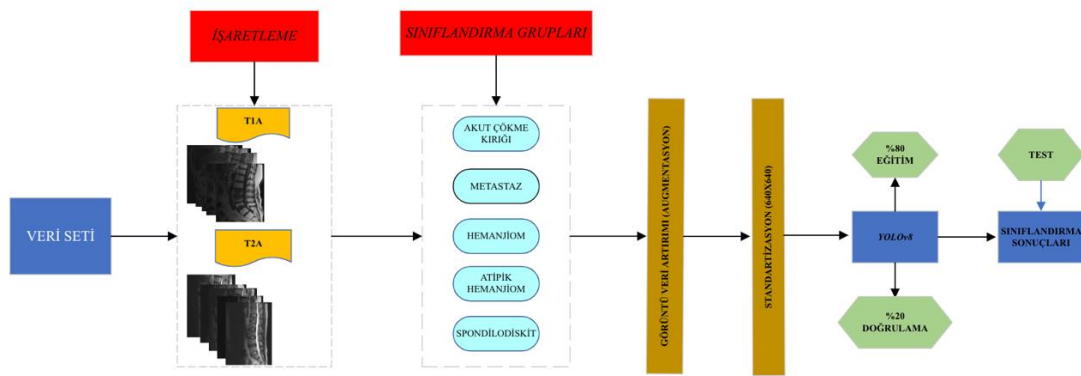
Farklı gruplar arasında sınıflandırma yapmak amacıyla tüm görüntüler kullanılarak beş ayrı tanı grubu oluşturuldu. Grup 1: Akut çökme kırığı, Grup 2: Metastaz Grup 3: Hemanjiom Grup 4: Atipik hemanjiom Grup 5: Spondilodiskit. Her bir grup için T1 ve T2 ağırlıklı sekanslardan elde edilen görüntüler için ayrı ayrı sınıflandırma işlemi gerçekleştirildi. Görüntü sayısının sınırlı olması nedeniyle veri artırma (augmentation) teknikleri kullanıldı. Bu yöntemle, başlangıçta modelin eğitim ve doğrulama seti amacıyla belirlenen 181 hastadan elde edilen 1745 görüntü, veri artırma teknikleriyle üç kat artırılarak 4179 görüntüye çıkarıldı.

3.5. DERİN ÖĞRENME

Bu tez çalışmasında, manyetik rezonans görüntülemenin (MRG) T1A ve T2A sekansları üzerinde analizler gerçekleştirilmiştir. Bu sekanslar, lezyonların tespiti ve sınıflandırılmasında kullanılan temel görüntüleme verilerini oluşturmaktadır. Bu doğrultuda, çalışma planı şekil 13'te sunulmaktadır. Çalışmamızda, modelin eğitimi için "Akut Çökme Kırığı", "Metastaz", "Hemanjiyom", "Atipik Hemanjiyom" ve "Spondilodiskit" olmak üzere beş farklı patolojiye ait görüntüler kullanılmıştır. Görseller, Roboflow ortamına yüklenerek, tespit edilmek istenen bölgeler sınırlayıcı kutulara (bounding box) ayrılmış ve sınıflandırma için uygun etiketleme yapılmıştır. Çalışmada, toplam 181 hastaya ait görüntülerden oluşan veri setinin %80'i eğitim ve %20'si doğrulama için ayrılmıştır. Buna ek, modelin performansını değerlendirmek için, test seti olarak, görüntü verisi artırımı uygulanmamış 54 hastanın görüntüleri kullanılmıştır. Bu çalışmada derin öğrenme modeli olarak bir nesne algılama algoritması olan YOLOv8 mimarisi kullanılmıştır.

YOLOv8 modelinin hızlı eğitimi için NVIDIA RTX 4090 grafi işlemci ünitesi (GPU) kullanılmış ve CUDA işlevselliği etkinleştirilmiştir. Kullanılan CUDA sürümü 11.2.x olup, tüm işlemler GPU üzerinde gerçekleştirilerek eğitim süresi önemli ölçüde kısaltılmıştır. Eğitim işleminde ultralytics 8.x, pytorch 2.0 ve opencv kütüphaneleri kullanılmıştır. Modelin eğitim parametreleri Tablo 2'de sunulmaktadır.

Eđitim parametrelerinde, 70 epoch ile ařırı ğrenmeyi nleyerek yeterli eđitim sresi sađlarken, batch boyutunun 8 olması modelin ğrenme srecini hızlandırmaktadır. İmgz boyutu 640, modelin kk nesneleri algılayabilmesi iin idealdir. Adam optimizier, dinamik ađırlık gncellemeleri ile eđitim srecini hızlandırırken, momentum 0.937 ğrenme hızını optimize eder. Box 7.5 ve cls 0.5 deđerleri, konumlandırma ve sınıflandırma performansını dengelemek amacıyla seilmiřtir.




Şekil 13: alıřma planı

Tablo 2: YOLOv8 eđitim parametreleri

Parametreler	cls	optimizatr	box	momentum	Imgsz	Batch	Epoch
Deđerleri	0,5	Adam	7,5	0,937	640	8	70

Optimizasyon işlemi tamamlandıktan sonra YOLOv8 modelinin sınırlayıcı kutular ile tespit etme ve sınıflandırma başarısı örneği görüntü üzerinden şekil 14'te sunulmuştur



Şekil 14: YOLOv8'in sınırlandırıcı kutular ile tespit ve sınıflandırma örneği

3.6. İSTATİSTİK

Verilerin analizinde SPSS 29.0 istatistik paket programı kullanılmıştır. Değerlendirme sonuçlarının tanımlayıcı istatistikleri; kategorik değişkenler için frekans ve yüzde, sayısal değişkenler için ise ortalama, standart sapma, minimum ve maksimum değerler olarak raporlanmıştır. Grupların normal dağılıma uygunluğu Kolmogorov-Smirnov testi ile değerlendirilmiştir. Bağımsız iki grup arasındaki sayısal değişkenlerin karşılaştırılmasında, normal dağılım koşulu sağlanmadığı için Mann-Whitney U testi uygulanmıştır. Üç veya daha fazla bağımsız grup arasındaki sayısal değişkenlerin karşılaştırılması ise, normal dağılım koşulunun sağlanmadığı durumlarda Kruskal-Wallis testi ile yapılmıştır. Bağımsız gruplardaki kategorik değişkenlerin karşılaştırılması için Ki-kare testi kullanılmıştır. İstatistiksel anlamlılık düzeyi $p < 0,05$ olarak belirlenmiştir.

Elde edilen performans metriklerine ait formülasyon ve açıklamaları aşağıda verilmiştir [93].

$$\text{Doğruluk: } (TP + TN) / (TP + TN + FN + FP)$$

$$\text{Kesinlik (Precision): } TP / (TP + FP)$$

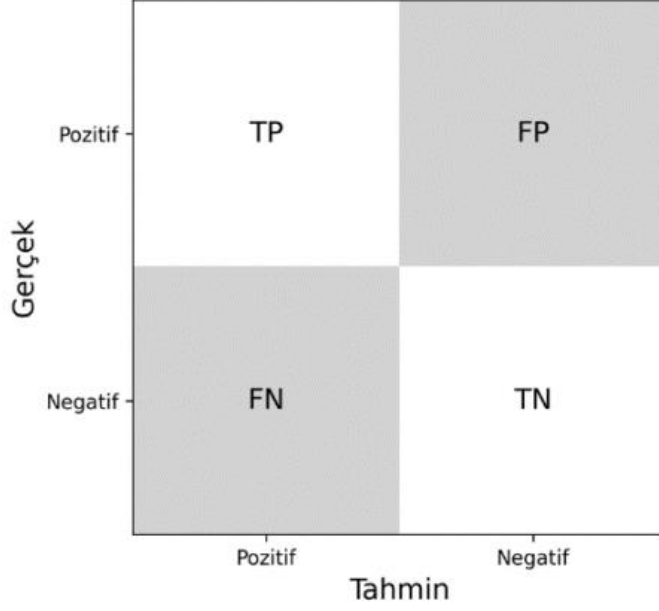
$$\text{Geri çağırma (Recall): } TP / (TP + FN)$$

F1 skoru: Kesinlik ve geri çağırma metriklerinin harmonik ortalamasıdır. Bu metrik, modelin hem kesinlik hem de duyarlılığını dengeler ve genellikle veri setlerinde dengesizliklerin bulunduğu durumlarda daha kapsamlı bir değerlendirme sağlar [94]. Formülasyonu; $2 \times \text{kesinlik} \times \text{geri çağırma} / \text{kesinlik} + \text{geri çağırma}$

Mean Average Precision (mAP): Bu metrik, sınırlayıcı kutu (bounding box) ve segmentasyon tespiti bağlamında, Intersection over Union (IoU) eşik değerinin %50 olduğu durumda hesaplanan Ortalama Kesinlik (Average Precision, AP) değerinin ortalamasını ifade eder. Modelin tahmin ettiği sınırlayıcı kutuların gerçek kutularla %50 veya daha fazla örtüşme oranına sahip olduğu durumlarda ortalama kesinliği ölçer [95].

(TP: Gerçek pozitif, FP: Yalancı pozitif, TN: gerçek negatif, FN: yalancı negatif)

Elde edilen sonuçlara ait karışıklık matrislerinin formülasyonu şekil 15'te verilmiştir.



Şekil 15: Karışıklık matrisinin şematik gösterimi

4. BULGULAR

Çalışmamıza dahil edilen 235 hastanın 137'si (%58,3) kadın, 98'i (%41,7) erkekti. Hastaların yaş ortalaması $66,1 \pm 13,4$ 'tür. Hastaların cinsiyet, yaş ve radyolojik tanı dağılımları tablo 3'te verilmiştir.

Tablo 3: Hastaların yaş ortalaması, cinsiyet ve radyolojik tanı dağılımları

Yaş (ort±SS) (Min-Maks)	66,1±13,4 (18-93)	
	n	%
Cinsiyet		
Erkek	98	41,7
Kadın	137	58,3
Radyolojik Tanı		
Akut Çökme Kırığı	63	26,8
Metastaz	69	29,4
Hemanjiyom	41	17,4
Atipik Hemanjiom	32	13,6
Spondilodiskit	30	12,8

Akut çökme kırığı grubundaki 63 hastanın 45 (%71,4)'i kadın, 18 (%28,6)'i erkekti. Metastaz grubundaki 69 hastanın 24 (%34,8)'ü kadın, 45 (%65,2)'i erkekti. Hemanjiom grubundaki 41 hastanın 29 (%70,7)'ü kadın, 12 (%29,3)'si erkekti. Atipik hemanjiom grubunda 32 hastanın 22 (%68,7)'si kadın, 10 (%31,3) tanesi erkek hastadan oluşmaktaydı. Spondilodiskit grubundaki 30 hastanın 17 (%56,6)'si kadın, 13 (%43,4)'ü erkekti (Tablo 4).

Tablo 4: Lezyon gruplarına göre cinsiyet dağılımı

Tanı	Kadın	Erkek
	n(%)	n(%)
Akut Çökme Kırığı	45 (%71,4)	18 (%28,6)
Metastaz	24 (%34,8)	45 (%65,2)
Hemanjiom	29 (%70,7)	12 (%29,3)
Atipik Hemanjiom	22 (%68,7)	10 (%31,3)
Spondilodiskit	17 (%56,6)	13 (%43,4)

Akut çökme kırığı, metastaz, hemanjiom, atipik hemanjiom ve spondilodiskit hasta grupları için yaş ortalamaları sırasıyla $71,7\pm12,9$, $69,6\pm11,3$, $60,3\pm13,1$, $55,3\pm14$ ve $65,4\pm9,2$ ' dir (Tablo 5).

Tablo 5: Tüm tanı gruplarının yaş ortalamaları

	Akut Çökme Kırığı	Metastaz	Hemanjiom	Atipik Hemanjiom	Spondilodiskit	p*
Yaş						
Ort±SS	71,7±12,9	69,6±11,3	60,3±11,3	55,3±14	65,4±9,2	<0,001
Medyan (Min-Maks)	74 (34-93)	69 (39-93)	61 (31-89)	57,5 (18-77)	66 (43-88)	

(*Kruskal Wallis Testi)

Metastaz grubunda yer alan 69 hastanın primer malignite türleri şu şekilde dağılım göstermiştir: 23 hasta (%33,3) akciğer kanseri, 14 hasta (%20,2) meme kanseri, 14 hasta (%20,2) prostat kanseri, 3 hasta (%4,3) plazmositom, 2 hasta (%2,8) kolon kanseri, 2 hasta (%2,8) renal hücreli karsinom, 8 hasta (%11,2) diğer maligniteler ve 3 hasta (%4,3) primeri bilinmeyen malignite ile tanımlanmıştır. Metastatik lezyonların kökeni ile ilgili detaylı bilgiler Tablo 6'da sunulmuştur.

Tablo 6: Metastaz tanı grubunun primer hastalık bölgeleri

Metastaz Orijini	n/%
Akciğer	23/33,3
Meme	14/20,2
Prostat	14/20,2
Plazmositom	3/4,3
Kolon	2/2,8
Renal hücreli karsinom	2/2,8
Diğer*	8/11,5
Primeri bilinmeyen	3/4,3

*Mesane(2), mide(2), over, hepatosellüler karsinom, dil skuamöz hücreli karsinom ve lenfoma

Metastaz grubunun diğer özellikleri tablo 7’de verilmiştir.

Tablo 7: Metastaz tanı grubunun diğer epidemiyolojik, klinik ve radyolojik özellikleri

	n	%
Lezyon Tutulumu		
Çoklu(multiple)	45	65,2
Tek	24	34,8
Patolojik Kırık		
Var	28	40,5
Yok	41	59,5
Sağkalım		
Sağ	27	39,1
Ölü	42	60,9
Pedikül Tutulumu		
Var	48	69,6
Yok	21	31,4
Spinal Kord İnvazyonu		
Var	5	7,2
Yok	64	92,8

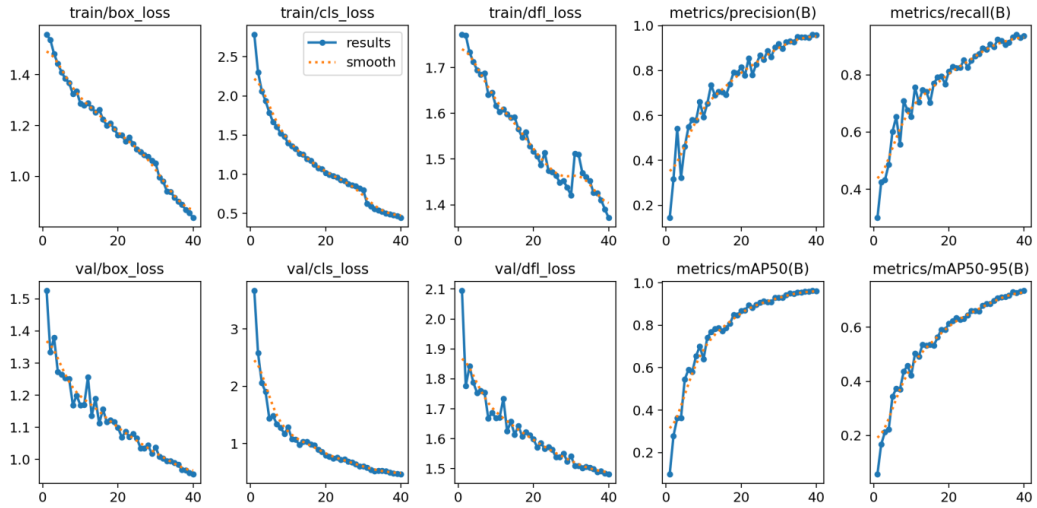
Akciğer, meme ve prostat kanserlerinin vertebra korpus metastazlarında patolojik kırık gelişimi ile kanser alt tipi arasında istatistiksel açıdan anlamlı fark saptanmamıştır ($p>0,05$), (Tablo 8).

Tablo 8: Metastaz alt grubunda malignite alt grubu ile patolojik kırık varlığı ilişkisi

Metastaz Orijini	Patolojik Kırık		p*
	Var	Yok	
Akciğer	10	13	0,51
Meme	5	9	
Prostat	5	9	

Çalışmaya ait tüm veri setlerindeki görüntü veri artırımı gerçekleştirilerek oluşturulan toplam 4189 görüntünün %80'i eğitim ve %20'si doğrulama için ayrılmıştır. Test seti için 54 hastaya ait görüntü veri artırımı uygulanmayan 218 ham görüntü kullanılmıştır. Bu görüntülerin 111'i T1A, 107'si ise T2A sekanslarından elde edilmiştir.

YOLOv8'e ait eğitim-doğrulama işlemlerine ait metriklerin detaylı analizi ve kayıp değerleri şekil 16'da verilmiştir.



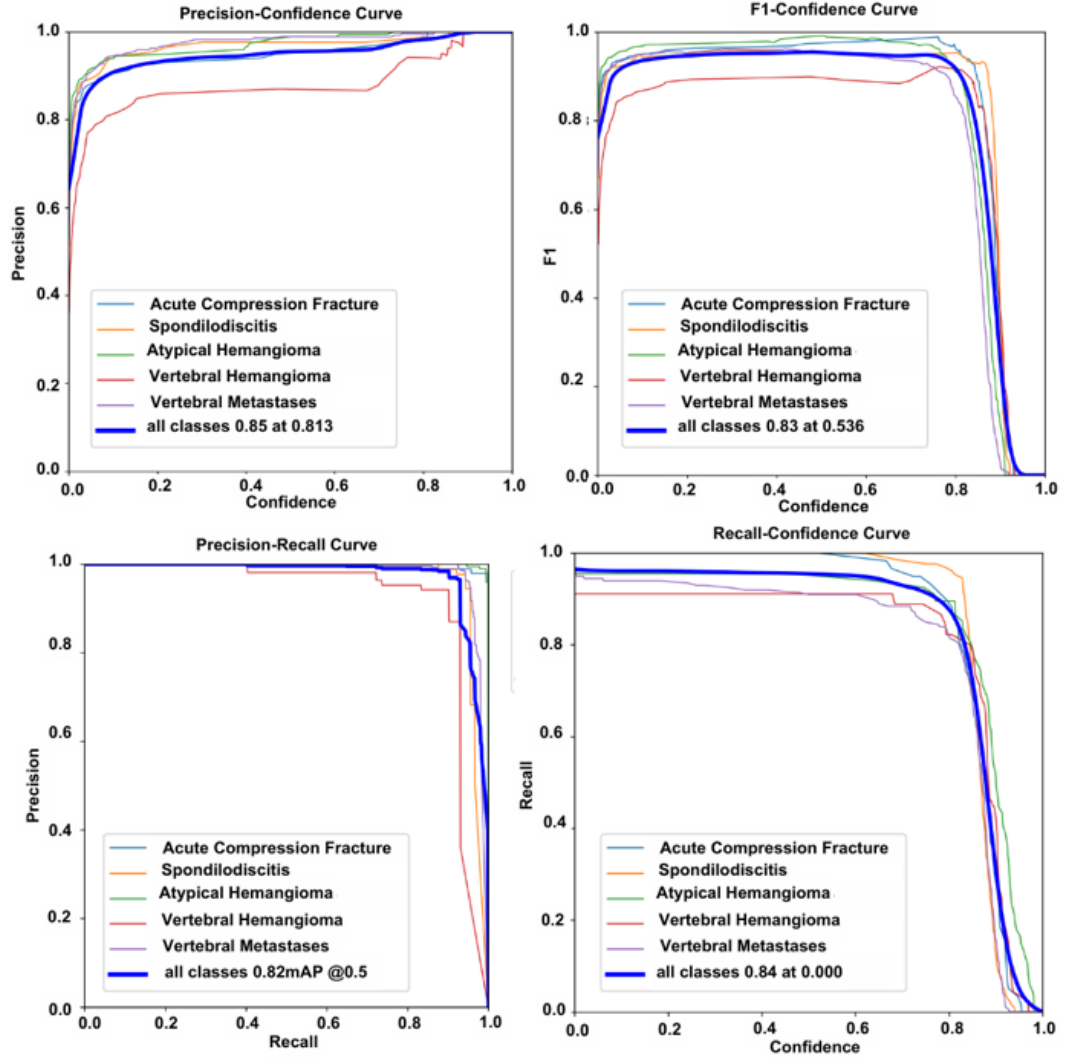
Şekil 16: YOLOv8 modelinin eğitim-doğrulama metrikleri ve kayıp değerleri analizi

Test setinden elde edilen sonuçlara göre, tanımlanan lezyon gruplarının performans ölçütleri şu şekildedir: mAP 50 (Box) değeri: T1 sekansları için 0,82, T2 sekansları için 0,86'dir. mAP 50 (Mask) değeri: T1 sekansları için 0,83, T2 sekansları için 0,85'tir. Kesinlik (Precision, Box) değeri: T1 sekanslarında 0,85, T2 sekanslarında 0,86; Kesinlik (Precision, Mask) değeri: T1 sekanslarında 0,81, T2 sekanslarında 0,82'dir. Geri çağırma (Recall, Box) değeri: T1 sekanslarında 0,82, T2 sekanslarında 0,84; Geri çağırma (Recall, Mask) değeri: T1 sekanslarında 0,84, T2 sekanslarında 0,82'dir. F1 Skoru: T1 sekansları için 0,83, T2 sekansları için 0,82'dir.

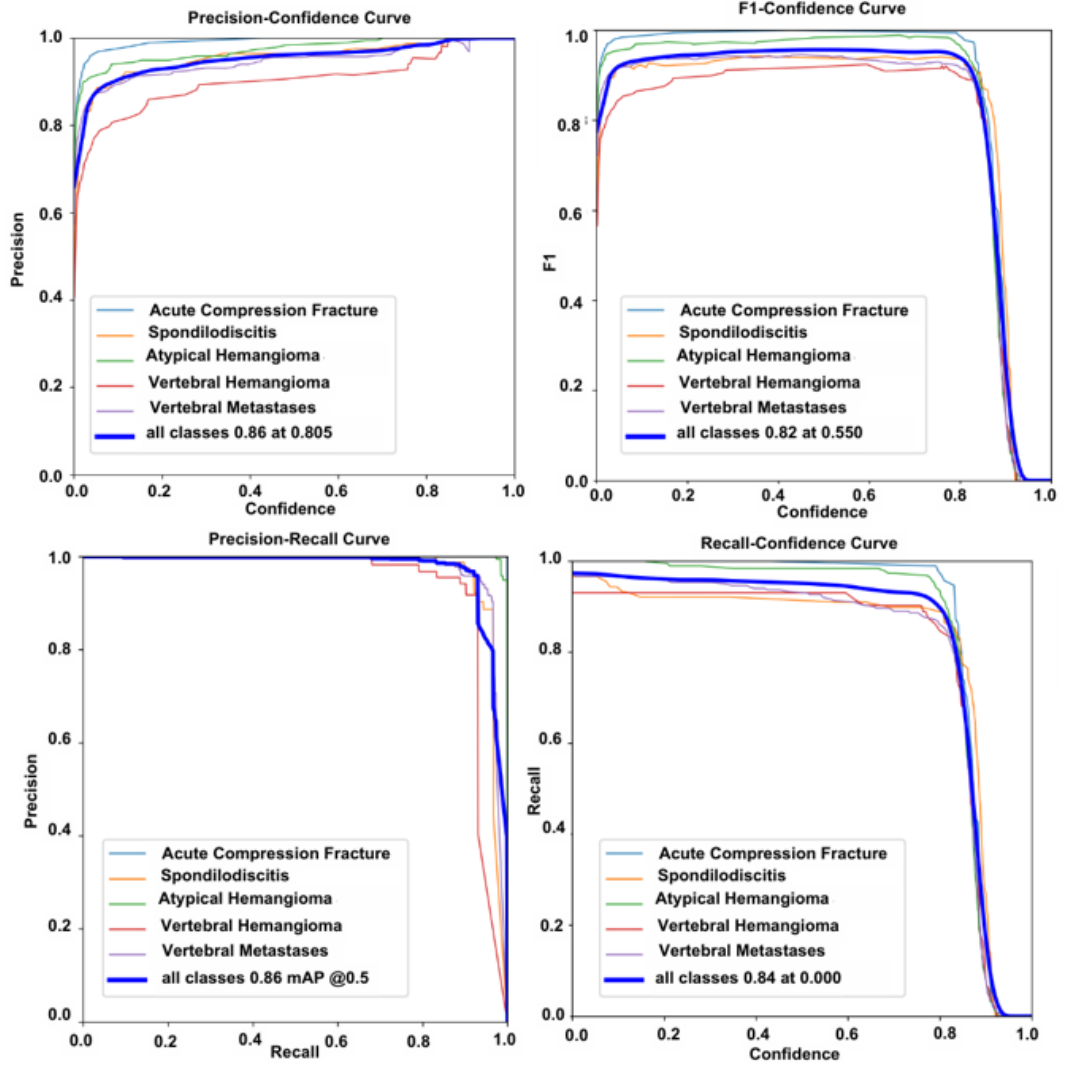
Tablo 9: YOLOv8 modelinin T1 ve T2 veri setinde test performansı

Veri Seti	mAP(B)	mAP(M)	Kesinlik(B)	Kesinlik(M)	Geri Çağırma(B)	Geri Çağırma(M)	F1 Skoru
T1	0,82	0,83	0,85	0,81	0,82	0,84	0,83
T2	0,86	0,85	0,86	0,82	0,84	0,82	0,82

Model veri setlerinde oluşturulan sınırlayıcı kutulara ve gerçekleştirilen sınıflandırmaya ait Kesinlik-Güven eğrisi, F1 skoru-Güven eğrisi, Kesinlik-Duyarlılık eğrisi ve Duyarlılık-Güven eğrisi grafikleri T1 veri seti için şekil 17'de, T2 veri seti için şekil 18'de verilmiştir.

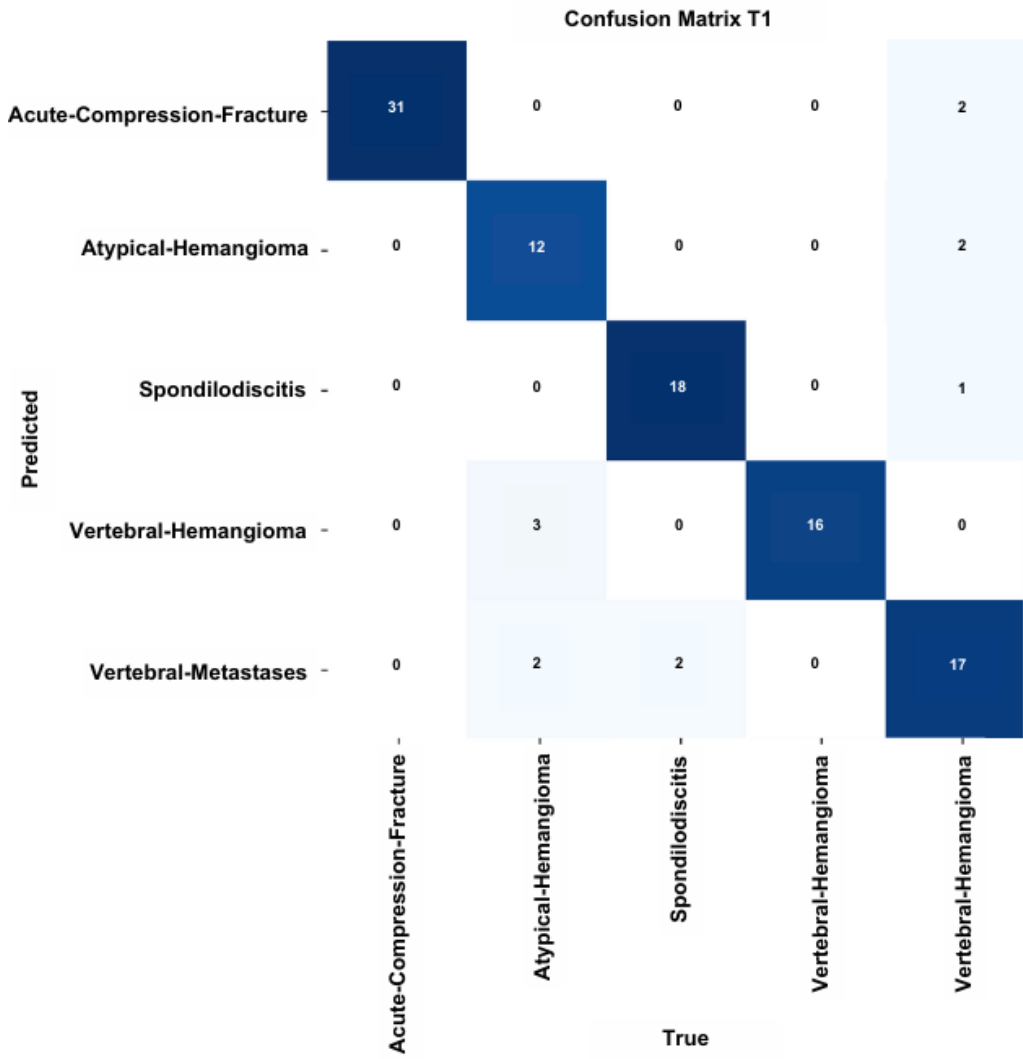


Şekil 17: T1 veri setine göre sınırlayıcı kutu (bounding box) ve yapılan sınıflandırma grafikleri

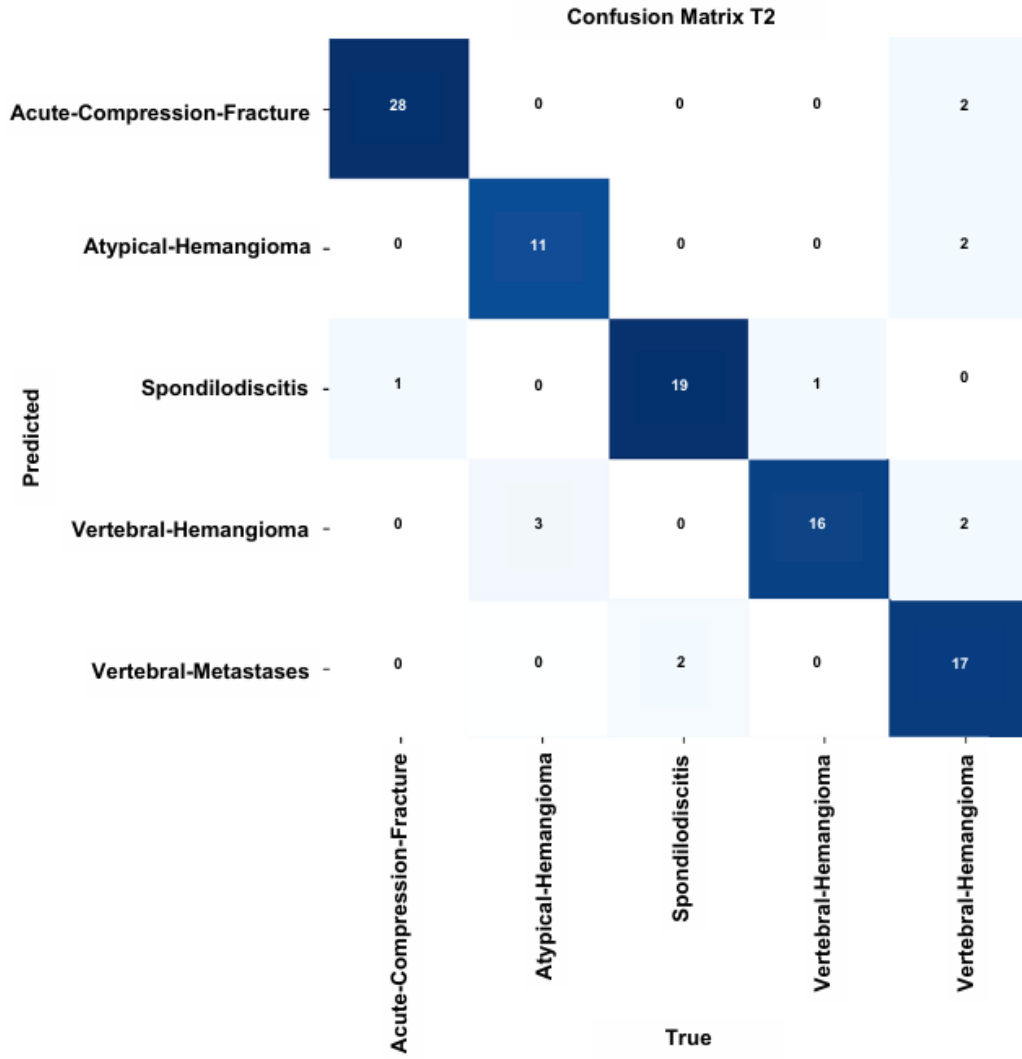


Şekil 18: T2 veri setine göre sınırlayıcı kutu (bounding box) ve yapılan sınıflandırma grafikleri

Sınıflandırmanın yapıldığı veri setlerine ait görüntülerin karışıklık matrisleri (Confusion matrix) T1 veri seti için şekil 19’da, T2 veri seti için şekil 20’de verilmiştir.



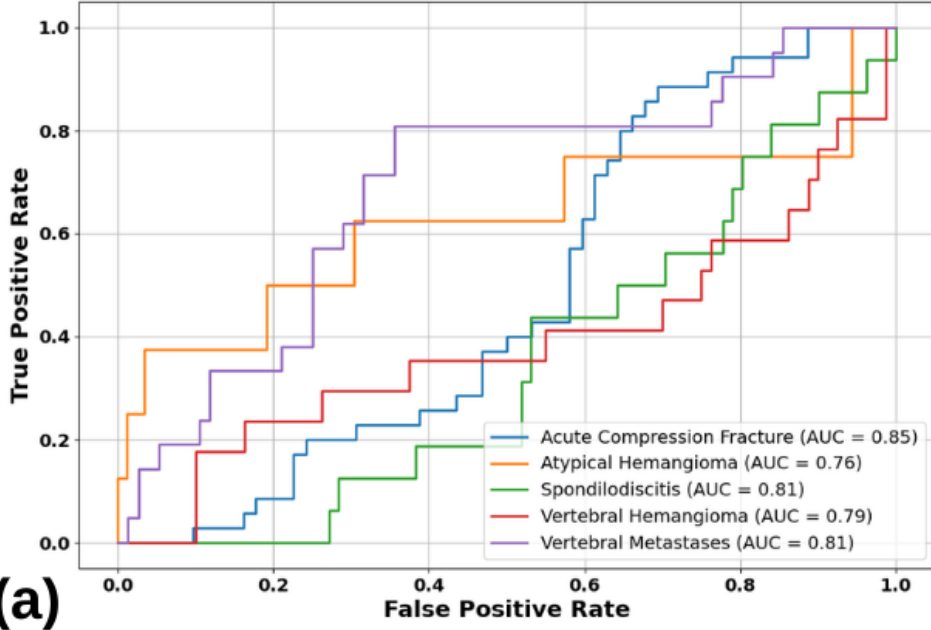
Şekil 19: YOLOv8 modelinin T1 veri seti için karışıklık matrisi



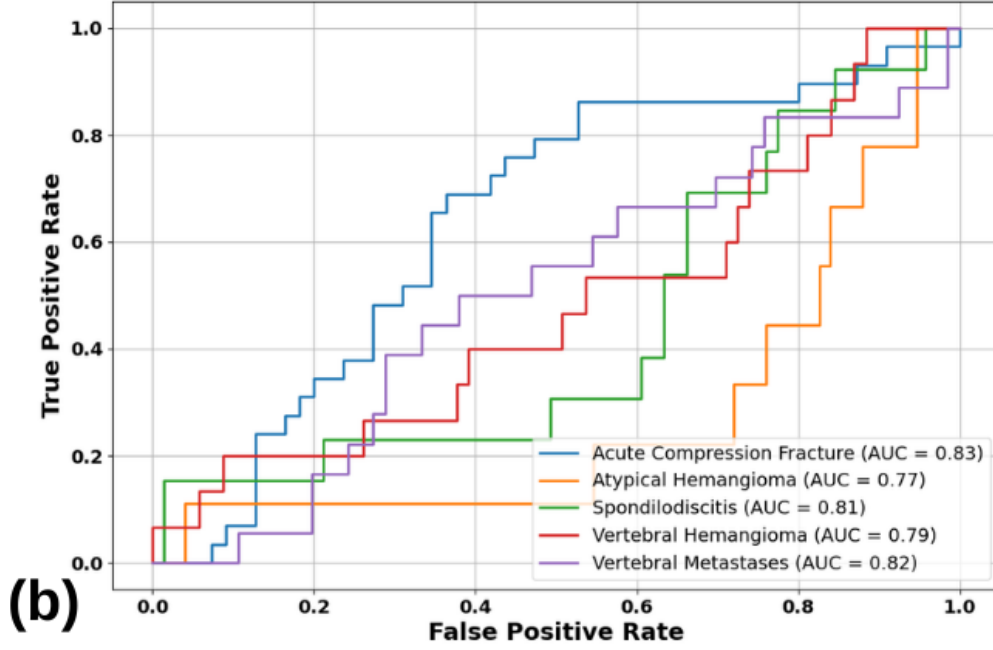
Şekil 20: YOLOv8 modelinin T2 veri seti için karışıklık matrisi

T1 veri setinde akut kompresyon fraktürü, metastaz, spondilodiskit, hemanjiom ve atipik hemanjiom için Area Under Curve (AUC) değerleri sırasıyla 0,85, 0,81, 0,81, 0,79 ve 0,76'dır. T2 veri seti için AUC değerleri sırasıyla 0,83, 0,82, 0,81, 0,79 ve 0,77'dir. T1 ve T2 veri setine ait Receiver Operating Characteristic (ROC) eğrisi analizleri şekil 21'de verilmiştir.

T1 ROC Curve



T2 ROC Curve



Şekil 21: (a) T1 test setinin, (b) T2 test setinin ROC eğri analizi

5. TARTIŞMA

Vertebra, vücudun aksiyel iskeletini oluşturmakta, postürün stabilizasyonunda, omurilik ve sinir köklerinin korunmasında görev almaktadır. Vertebra korpusunda ilerleyen yaş ve yaşam ömrünün uzamasıyla birlikte malignite ve diğer grup hastalıklar oldukça sık görülmektedir [96]. Dejeneratif hastalıklar en sık görülenlerdir ve 65 yaş üstünde %75-85 oranında tespit edilmektedir [97]. Metastazlar, vertebrada en sık görülen malign lezyonlardır [98]. Vertebra metastazları, en sık görülen kemik metastazı bölgesi olup ilerlemiş evredeki kanser hastalarında yapılan çeşitli çalışmalarda %30-70 oranında vertebralarda metastaz geliştiği bildirilmektedir [98], [99, 100]. Vertebral hemanjiomlar, omurgada en sık izlenen benign tümör grubu olup popülasyonun yaklaşık %10-12'sinde görülmektedir [101]. Spondilodiskit, intervertebral diskler ve komşu vertebra yapılarının enfeksiyonu olarak tanımlanır. Yaygınlığı genel popülasyonda düşük olmakla birlikte, yaşlılık ve kronik hastalıklar (örneğin diyabet, böbrek yetmezliği) gibi risk faktörleri olanlarda artış göstermektedir [54]. Ayrıca girişimsel işlemlerin yaygınlığı görülme sıklığını artırmaktadır. Ortalama insidansı çeşitli çalışmalarda 100.000'de 2-12 olarak gösterilmektedir [102, 103]. Çökme kırıkları, 50 yaş üstünde osteoporozlu popülasyonun %30-50'sini etkilemekte ve yaştan ilerlemesiyle birlikte ortaya çıkma sıklığı katlanarak artmaktadır [104]. Postmenopozal kadınların yaklaşık %16'sında osteoporoza bağlı çökme kırığı gelişmektedir [41]. Çökme kırığı insidansı kadınlarda 1000'de 10,7 ve erkeklerde 1000'de 5,7 olarak belirtilmektedir [105].

Vertebra korpus lezyonlarının ayırıcı tanısında özellikle metastaz, hemanjiom, spondilodiskit ve çökme kırıkları gibi hastalıkların doğru tanısı, hastalıkların görülme sıklığı, tedavi yaklaşımlarındaki farklılıklar ve bu hastalıkların oluşturduğu komorbiditeler nedeniyle büyük önem taşımaktadır [106, 107].

Hastalıkların tanısında direkt grafi, BT ve MRG temel görüntüleme modaliteleridir. Direkt grafinin lezyonları ayırt etmede yeterliliği sınırlıdır. Kırık varlığında ya da lezyonların belirgin olduğu durumlarda tanıya katkısı olabilmektedir [44, 47].

BT görüntüleme, kemik korteksinin değerlendirilmesi ve hasarının belirlenmesinde oldukça etkili ve yüksek çözünürlüklü bir yöntemdir. Ancak, yumuşak doku özelliklerinin değerlendirilmesinde sınırlı bilgi sağlaması ve her lezyonun korteks yıkımına yol açmaması, BT'nin kullanımını kısıtlamaktadır. Ayrıca iyonize radyasyon maruziyeti riski içermesi BT kullanımını sınırlayan faktörlerdendir [47, 108]. Farklı çalışmalarda tanısal başarı için duyarlılığı %73-79, özgüllüğü %92-95 olarak bildirilmektedir [109, 110].

MRG yüksek yumuşak doku rezolüsyonu ve hastalıkların kemik iliğinde oluşturduğu değişiklikleri erken dönemden itibaren ortaya koyabilmesiyle omurga lezyonlarının tanısında en duyarlı görüntüleme yöntemidir [111]. Lezyonların kemik dışı yayılımlarını ve çevre dokulara uzanımlarını hassas olarak saptayabilmektedir. MRG'nin tanısal başarısı için yapılmış çeşitli çalışmalarda, duyarlılığı %91-95, özgüllüğü %90-95 olarak bildirilmektedir [110, 112].

MR görüntüleme, yüksek duyarlılık ve özgüllüğe sahip olmasına rağmen, metastatik lezyonlar ve diğer patolojilerin benzer bulgular göstermesi nedeniyle ayırıcı tanıda zorluklar yaşanabilmektedir. Kesin tanı koymak amacıyla biyopsi gerekebilir ancak biyopsi işleminin malign hastalıklar için yaklaşık olarak duyarlılığı %85-90, benign hastalıklar için %75-80 düzeyinde bildirilmektedir [9, 113].

Çalışmamızda, vertebra korpusunda sık karşılaşılan ve tanı ile tedavi yaklaşımları açısından belirgin farklılıklar bulunan metastaz, hemanjiom, spondilodiskit ve akut çökme kırıklarının otomatik tespiti ve sınıflandırılması amacıyla derin öğrenme tabanlı bir nesne algılama algoritması olan YOLOv8 mimarisi kullanılmıştır. Tıbbi görüntüleme, YOLO ve diğer nesne algılama modelleriyle yapılan yapay zeka çalışmaları ağırlıklı olarak lezyonların ya da hastalıklı bölgelerin tespitine odaklanmıştır [114]. Vertebralarla ilgili çalışmalarda ise çoğunlukla vertebra bölgelerinin belirlenmesi, kırık tespiti, benign ve patolojik kırıkların ayrımı, tümör tespiti, dejeneratif vertebra segmentlerinin analizine yönelik uygulamalar ön plana çıkmış ve oldukça başarılı sonuçlar ortaya konmuştur [114, 115, 116, 117]. Bildiğimiz kadarıyla bu çalışma, literatürde YOLO mimarisi kullanılarak vertebra korpus yerleşimli metastaz ve farklı gruplardaki benign lezyonların hem tespit hem de

sınıflandırılmasını amaçlayan öncü çalışmalardan birisi olma özelliğini taşımaktadır. Bu yönüyle literatüre önemli bir yenilik ve katkı sağlamakla birlikte bu durum ilgili literatürle doğrudan karşılaştırma yapma imkanını kısıtlamaktadır.

Literatürde, vertebra lezyonlarının ayırıcı tanısında MRG dışında BT ve radyografi görüntüleri kullanılarak yapılan derin öğrenme çalışmaları da mevcuttur. Bu çalışmalara örnek olarak Koike ve ark. [118] BT görüntüleri üzerinden vertebra segmentlerini tespit etmek ve litik kemik metastazlarını sınıflandırmak üzere yaptıkları derin öğrenme çalışmasına 79 hastaya ait toplamda 2125 görüntü dahil edilmiştir. Bu çalışmada vertebra tespiti YOLOv5 algoritması ile, sınıflandırma Inception V3 modeliyle gerçekleştirilmiş olup test sonuçları için 0,68 IoU eşik değerinde doğruluk 0,87, kesinlik 0,94, geri çağırma 0,74, F1 puanı 0,83 olarak bildirilmiştir. Bu çalışmada IoU değeri yüksek kabul edildiğinden dolayı geri çağırma performansı diğer ölçütlere göre daha zayıf bulunmuştur. Ayrıca, bu çalışmada YOLO modeli yalnızca tespit amacıyla kullanılmış olup sınıflandırma işlemleri için tıbbi veri setlerinde daha yaygın kullanılan Inception V3 algoritması tercih edilmiştir.

Başka bir çalışmada Foreman ve ark. [119], BT görüntüleri kullanarak benign ve malign vertebra kırıklarını sınıflandırma amacıyla U-Net algoritmasını uygulamış ve 381 hasta üzerinde değerlendirme yapmıştır. Bu çalışmada, AUC değeri, dahili test setinde 0,85, harici test setinde ise 0,75 olarak elde edilmiştir. Ayrıca, modelin performansı radyoloji asistanlarıyla karşılaştırılmış ve daha başarılı sonuçlar ortaya koyduğu görülmüştür.

Edelmers ve ark. [39] 115 metastatik hasta üzerinde yine BT görüntüleri kullanılarak yaptıkları bir çalışmada, metastaz bölgelerinin segmentasyonu ve litik ile sklerotik metastazların tespit edilmesi amacıyla U-Net modeli kullanılmıştır. Çalışma sonuçlarına göre, metastatik alanların segmentasyonunda yüksek bir başarı elde edilmiştir. Bununla birlikte, litik metastazların tespitinde, sklerotik metastazlara göre daha iyi sonuçlar elde edilmiştir. Ancak, genel olarak tespit başarısı, segmentasyon başarısına kıyasla daha düşük bulunmuştur. Bu durum, segmentasyon ve tespit süreçlerinin zorluk derecesini ve farklı türdeki metastazların sınıflandırılmasındaki model performansını vurgulamaktadır.

Liu ve ark. [120] erken spinal tüberküloz ile akut çökme kırıklarının ayırıcı tanısını yapmak amacıyla, BT görüntüleme kullanarak gerçekleştirdikleri çalışmalarında toplam 373 hastayı değerlendirmiştir. Çalışmada, MVITV2, ResNet101, ResNet50 ve EfficientNet-B3 modelleri kullanılmış ve bu modellerin performansları birbiriyle karşılaştırılmıştır. Harici bir test seti olarak 71 hastadan elde edilen görüntüler üzerinde yapılan değerlendirmede, en yüksek doğruluk ve AUC değerleri MVITV2 modeli ile elde edilmiştir. Ayrıca, bu modelin, deneyimsiz omurga cerrahlarının teşhis performansına kıyasla daha üstün sonuçlar sunduğu rapor edilmiştir.

Derin öğrenme dışında, vertebra lezyonlarıyla ilgili radyomiks ve makine öğrenmesi çalışmaları da bulunmaktadır. Chianca ve ark. [121] 146 hastayı dahil ettikleri bir çalışmada, MRG görüntülerini kullanarak radyomiks tabanlı bir makine öğrenmesi yöntemiyle metastaz, primer malign lezyonlar ve benign lezyonların üç etiketli sınıflandırmasını gerçekleştirmiştir. Çalışmada, 10 katlı çapraz doğrulama 10 kez tekrarlanarak analizler yapılmıştır. Radyomiks tarafından ortaya çıkarılan özellikler ve bunlarla ilişkili sonuçlara göre dahili doğrulama setine göre 0,80, harici test setine göre 0,76 doğruluk oranları elde edilmiştir.

MRG kullanılarak vertebral lezyonların ayırıcı tanısı için yapılmış literatürde nispeten sınırlı sayıda derin öğrenme çalışması mevcuttur. Bunlardan Liawrungrueang ve ark. [122] 515 hastadan elde edilmiş 1000 görüntü üzerinden disk dejenerasyonu derecelendirmesi için yaptıkları tespit ve sınıflandırma çalışmasında sagittal T2A görüntüleri kullanmışlardır. Veri seti %80 eğitim ve %20 test olarak ayrılmıştır. YOLOv5 modelini kullanarak yaptıkları derin transfer öğrenme çalışmasında eğitim seti için doğruluk değeri 0,95 ve F1 skoru 0,48 güven değerinde 0,98 olarak bildirilmiş olup disk dejenerasyonu derecelendirmesi için model yüksek eğitim başarısı göstermiştir. Çalışmada test sonuçları ayrıca bildirilmemiştir.

Liu ve ark. [123] 585 hasta üzerinde gerçekleştirdikleri derin öğrenme çalışmasında çoklu model ağırlıklı füzyon çerçevesi (WFF) modeli kullanarak MRG görüntüleri üzerinden benign ve malign tümörlerin tespitini ve sınıflandırmasını gerçekleştirmişlerdir. Bu füzyon modelinde tespit amacıyla Faster R-CNN ve

sınıflandırma için ResNetxt101 kullanılmıştır. Çalışma modeline görüntü verisi dışında klinik olarak yaş verisi de eklenmiştir. Ayrıca, sınıflandırma sonuçlarını uzman omurga cerrahlarının değerlendirmeleriyle karşılaştırmışlardır. Sonuç verisi olarak 0,82 doğruluk değeri elde edilmiş olup cerrahların değerlendirmelerinden daha üstün başarı elde edilmiştir. Ayrıca yaş bilgisinin eklenmesi model doğruluğunu artırmıştır. Bizim çalışmamızda T1 veri seti için 0,84 , T2 veri seti için 0,85 doğruluk ve sırasıyla 0,82 ve 0,86 mAP değeri elde edilmiştir. Modelimiz bu çalışmaya göre daha güçlü performans sergilemektedir.

Duan ve ark. [124], spinal tüberküloz ve metastaz ayırımını gerçekleştirmek amacıyla MRG görüntülerini kullandıkları çalışmalarında, 121 hasta görüntüsü üzerinde dört farklı derin öğrenme modelinin etkinliğini karşılaştırmıştır. Bu modeller arasında MVITV2, EfficientNet-B3, ResNet101 ve ResNet34 bulunmaktadır. Çalışma sonuçlarına göre, MVITV2 modeli doğruluk oranı 0,92, F1 skoru 0,91 ve AUC değeri 0,95 ile en yüksek performansı göstermiştir ve diğer modellere kıyasla üstün bir başarı sergilemiştir. Bizim çalışmamız ise MVITV2 modeline göre daha düşük performans göstermektedir. ResNet34 modeline kıyasla ise daha yüksek sonuçlar elde edilmiştir. ResNet101 ve EfficientNet-B3 modelleriyle benzer başarı sağlamaktadır. Çalışmamızda T1 ve T2 veri setleri için sırasıyla F1 skorları 0,83 ve 0,82 doğruluk oranları 0,84 ve 0,85 olarak hesaplanmıştır. Çalışmamızda ROC eğrisi ve AUC değeri, literatürdeki çalışmalarla karşılaştırma amacıyla dahil edilmiş olup AUC değerleri açısından, spondilodiskit için T1 ve T2 veri setlerinde 0,81 ve 0,81, metastaz için ise sırasıyla 0,81 ve 0,82 değerleri elde edilmiştir. YOLO ve diğer nesne tespit modellerinde mAP, kesinlik, geri çağırma ve F1 skoru metrikleri model verimliliği açısından daha doğru bir değerlendirme sunmaktadır [125].

Liu ve ark. [126] benign ve malign vertebra fraktürlerini ayırt etmek amacıyla yaptıkları çalışmada TSCNN modelini kullanmışlardır. Çalışmaya 123 hastaya ait benign ve 86 hastaya ait malign vertebra kırığının T1A ve yağ baskılı T2A görüntülerini dahil etmişlerdir. T1A ve yağ baskılı T2A sekansları için doğruluk değerleri sırasıyla 0,95 ve 0,90 olarak bulunmuştur. Model radyologlarla kıyaslandığında daha yüksek tanı başarısı elde etmiştir. Bizim çalışmamızda doğruluk oranları T1A sekansları için 0,84 ve T2A sekansları için 0,85, mAP değerleri sırasıyla

0,82 ve 0,86 elde edilmiş olup bu çalışma ile rekabetçi sonuçlar elde edilmiştir. Bu çalışmada kullanılan TSCNN modelinin optik akış hesaplamaları ve karmaşık veri hazırlama süreci nedeniyle uygulamada zaman alıcı olduğu belirtilmektedir [127]. Bu durum, gerçek zamanlı uygulamalar için TSCNN'nin kullanımını sınırlayabilir. Buna karşın, çalışmamızda kullanılan YOLO modeli, hem hızlı hem de gerçek zamanlı işlem gerçekleştirebilme kapasitesine sahip olmasıyla öne çıkmakta ve yüksek sınıflandırma başarısı sunmaktadır [128]. YOLO'nun bu özellikleri, klinik kullanımda daha pratik ve etkili bir çözüm sağlamasına olanak tanımaktadır.

MRG ile yapılan başka bir derin öğrenme çalışmasında Yeh ve ark. [129] benign ve malign vertebra kırıklarını ayırt etmek amacıyla, 190 hastanın görüntülerini analiz edilerek ResNet50 modeli kullanmışlardır. Çalışmada, modelin sınıflama sonuçları kas-iskelet sistemi uzmanı, dördüncü yıl ve birinci yıl radyoloji asistanlarının değerlendirmeleriyle karşılaştırılmıştır. Bulgular, modelin birinci yıl radyoloji asistanlarından daha yüksek performans gösterdiğini ortaya koymuştur. Ayrıca, modelin kullanımıyla birlikte asistanların sınıflandırma başarılarının da arttığı gözlemlenmiştir. Bu durum, derin öğrenme modellerinin klinik karar destek aracı olarak etkinliğini vurgulamaktadır.

Çalışmamız, hem tespit hem de sınıflandırma işlemlerini kapsayacak şekilde gerçekleştirilmiştir. Bu sayede modelimizin, patolojik alanların yerini belirleme ve ilgili patolojileri doğru şekilde sınıflandırma yetenekleri bir arada değerlendirilmiştir. T1A sekanslardan elde edilen veri setinde, F1 skoru, T2A veri setine kıyasla daha yüksek bulunmuştur. mAP, kesinlik ve geri çağırma ölçütlerinde T2A sekansı daha başarılı performans sergilemiştir. Karışıklık matrisi üzerinden elde edilen doğruluk değerleri, T1A için 0,84 ve T2 için 0,85 olarak tespit edilmiştir. Genel olarak çalışmamızda, performans ölçütlerine göre, tespit ve sınıflandırma başarısı için hem T1A hem de T2A sekansların birbirlerine belirgin üstünlüğünün bulunmadığı sonucuna ulaşılmıştır.

Modelimiz güçlü bir tespit başarısı sağlamasının yanında sınıflandırma başarısında, sınıflandırma için özelleşmiş modellere kıyasla, yarışmacı nitelik sergilemektedir. Bu sonuçlar, nesne tespiti için özelleşmiş YOLO modelinin, yüksek

sınıflandırma başarısını da etkili bir şekilde ortaya koyabileceğini göstermektedir ve potansiyel uygulama alanları açısından umut verici bulunmuştur. Bu bağlamda, elde edilen sonuç verileri modelimizin vertebra korpus patolojilerinin ayırıcı tanısında iyi bir alternatif olabileceğini desteklemektedir. Önümüzdeki çalışmalarda, daha geniş hasta grupları ile radyolog ve klinisyen değerlendirmeleriyle karşılaştırmalar yapılarak modelin klinik uygulamalardaki etkinliğini daha kapsamlı bir şekilde ortaya koyabilmeyi amaçlamaktayız.

Çalışmamızda bazı kısıtlılıklar bulunmaktadır. Bir; çalışmamız retrospektif bir yöntemle gerçekleştirilmiştir. İki; hasta sayısı görece sınırlı olduğundan, bu kısıtlılığı aşmak için görüntü verisi artırımı yöntemi kullanılmıştır. Üç; hastalıkların tanısı yalnızca görüntüleme bulguları, klinik ve görüntüleme takibi özelliklerine dayanılarak konmuş olup, histopatolojik veri bulunmamaktadır. Dört: Çalışmamızdaki kullanılan görüntü verileri, tek bir merkezde aynı MR cihazı ile elde edilmiş olup, çalışmada harici test verisi bulunmamaktadır.

6. SONUÇ

Vertebra korpusunda sık olarak görülen metastaz ve metastaz dışı lezyonların ayırıcı tanısında MRG en etkin yöntem olmasına rağmen lezyonların morfolojik benzerlikleri tanı koymada güçlük oluşturabilmektedir. Arada kalınan durumlarda biyopsi işlemi gerçekleştiriliyor olmasına rağmen her zaman doğru tanıya ulaşılamamaktadır. Görüntüleme yöntemleri ve biyopsi sonuçları, yüksek tanı duyarlılığı sağlamalarına rağmen, bu süreçlerin uygulanması önemli ölçüde iş gücü, zaman ve deneyim gerektirmektedir. Ayrıca görüntüleme değerlendirmelerinde hekim kaynaklı yorum farklılıkları veya hata riski bulunabilir. Biyopsi ise invaziv bir yöntem olup, hastane yatışı, gözlem ve işlem sonrası komplikasyon riskleri gibi ek yükler getirebilmektedir. Çalışmamızda, bu zorlukları ele alarak yapay zeka ve derin öğrenme modellerinin tanısal süreçlerde kullanım potansiyeli incelenmiştir. Özellikle, vertebra korpus lezyonlarının ayırıcı tanısında çok sekanslı MR görüntüleriyle derin öğrenme modellerinin kullanımı, tanı doğruluğunu artırma ve süreçleri hızlandırma açısından önemli bir alternatif sunmaktadır. Elde edilen sonuçlar, derin öğrenme mimarilerinin, görüntüleme analizleri gerçekleştirerek tanısal prosedürlerde değerli bir araç olarak kullanılabileceğini göstermektedir. Sonuç olarak, derin öğrenme yaklaşımları, vertebra korpus lezyonlarının tespiti ve ayırıcı tanısı gibi aşamalarda klinik uygulamalara güçlü bir destek sağlayarak hastalık yönetiminin iyileştirilmesine katkıda bulunabilecek bir potansiyele sahiptir.

7. KAYNAKLAR

- [1] O. Haim *et al.*, “Differentiating spinal pathologies by deep learning approach,” *The Spine Journal*, vol. 24, no. 2, pp. 297–303, Feb. 2024, doi: 10.1016/j.spinee.2023.09.019.
- [2] B. W. Burkhardt, A. Simgen, G. Wagenpfeil, P. Hendrix, W. Reith, and J. M. Oertel, “Adjacent segment disease following anterior cervical fusion and the presence of surgery for lumbar disc herniation and surgery at the musculoskeletal joints: are they related?,” *The Spine Journal*, vol. 20, no. 12, pp. 1925–1933, Dec. 2020, doi: 10.1016/j.spinee.2020.07.008.
- [3] J. Xuan, B. Ke, W. Ma, Y. Liang, and W. Hu, “Spinal disease diagnosis assistant based on MRI images using deep transfer learning methods,” *Front Public Health*, vol. 11, Feb. 2023, doi: 10.3389/fpubh.2023.1044525.
- [4] “Boden, Scott D., et al. ‘Abnormal magnetic-resonance scans of the lumbar spine in asymptomatic subjects. A prospective investigation.’ *JBJS* 72.3 (1990): 403-408.”.
- [5] J. G. Jarvik and R. A. Deyo, “Diagnostic evaluation of low back pain with emphasis on imaging,” *Ann Intern Med*, vol. 137, no. 7, pp. 586–597, Oct. 2002, doi: 10.7326/0003-4819-137-7-200210010-00010.
- [6] T. T. Nguyen, J. C. Thelen, and A. A. Bhatt, “Bone up on spinal osseous lesions: a case review series,” *Insights Imaging*, vol. 11, no. 1, pp. 1–20, Dec. 2020, doi: 10.1186/S13244-020-00883-6/TABLES/1.
- [7] C.-Y. Wu, W.-C. Yeh, S.-M. Chang, C.-W. Hsu, and Z.-J. Lin, “The Application of Deep Learning to Accurately Identify the Dimensions of Spinal Canal and Intervertebral Foramen as Evaluated by the IoU Index,” *Bioengineering*, vol. 11, no. 10, p. 981, Sep. 2024, doi: 10.3390/bioengineering11100981.
- [8] F. R. Eweje *et al.*, “Deep Learning for Classification of Bone Lesions on Routine MRI,” *EBioMedicine*, vol. 68, p. 103402, Jun. 2021, doi: 10.1016/j.ebiom.2021.103402.
- [9] N. Ali, “Percutaneous Spine Biopsy: A Literature Review,” *International Journal of Radiology and Radiation Oncology*, vol. 1, no. 1, pp. 023–028, Dec. 2015, doi: 10.17352/ijrro.000007.

- [10] K. B. Gala, N. S. Shetty, A. K. Janu, N. Shetty, and S. S. Kulkarni, "Percutaneous CT Guided Vertebral Biopsy: Anatomy and Technical Considerations," *Journal of Clinical Interventional Radiology ISVIR*, vol. 05, no. 03, pp. 150–157, Dec. 2021, doi: 10.1055/s-0041-1729778.
- [11] E. Montagnon *et al.*, "Deep learning workflow in radiology: a primer," *Insights Imaging*, vol. 11, no. 1, p. 22, Dec. 2020, doi: 10.1186/s13244-019-0832-5.
- [12] Q. Li, W. Cai, X. Wang, Y. Zhou, D. D. Feng, and M. Chen, "Medical image classification with convolutional neural network," in *2014 13th International Conference on Control Automation Robotics & Vision (ICARCV)*, IEEE, Dec. 2014, pp. 844–848. doi: 10.1109/ICARCV.2014.7064414.
- [13] D. R. Sarvamangala and R. V. Kulkarni, "Convolutional neural networks in medical image understanding: a survey," *Evol Intell*, vol. 15, no. 1, pp. 1–22, Mar. 2022, doi: 10.1007/s12065-020-00540-3.
- [14] S. Saluja, S. Patil, and N. Vasudeva, "Morphometric Analysis of Sub-axial Cervical Vertebrae and Its Surgical Implications," *J Clin Diagn Res*, vol. 9, no. 11, p. AC01, Nov. 2015, doi: 10.7860/JCDR/2015/15053.6808.
- [15] S. H. Parson, "Clinically Oriented Anatomy, 6th edn.," *J Anat*, vol. 215, no. 4, p. 474, Oct. 2009, doi: 10.1111/J.1469-7580.2009.01136.X.
- [16] B. A. Frost, S. Camarero-Espinosa, and E. Johan Foster, "Materials for the Spine: Anatomy, Problems, and Solutions," *Materials*, vol. 12, no. 2, p. 253, Jan. 2019, doi: 10.3390/MA12020253.
- [17] "Khan, Muhammad Sameer. 'Diagnosis of lumbar spinal stenosis using deep learning of MRIs.' (2024).".
- [18] A. Rawls and R. E. Fisher, "Developmental and Functional Anatomy of the Spine," in *The Genetics and Development of Scoliosis*, Cham: Springer International Publishing, 2018, pp. 1–29. doi: 10.1007/978-3-319-90149-7_1.
- [19] *Middleditch, A., & Oliver, J. (2005). Functional anatomy of the spine. Elsevier Health Sciences.*
- [20] J. A. Waxenbaum, V. Reddy, A. C. Black, and B. Futterman, "Anatomy, Back, Cervical Vertebrae," *StatPearls*, Nov. 2023, Accessed: Jul. 11, 2024. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK459200/>

- [21] N. Bogduk, "Functional anatomy of the spine," 2016, pp. 675–688. doi: 10.1016/B978-0-444-53486-6.00032-6.
- [22] T. D. , M. T. B. and P. A. F. White, *Human osteology*, Third. Amsterdam: Elsevier/Academic Press, 2012.
- [23] A. M. , G. R. , M. and J. C. W. Gilroy, *Atlas of Anatomy*. Thieme, 2020.
- [24] J. K. Smith, K. Lury, and M. Castillo, "Imaging of Spinal and Spinal Cord Tumors," *Semin Roentgenol*, vol. 41, no. 4, pp. 274–293, Oct. 2006, doi: 10.1053/j.ro.2006.07.002.
- [25] V. Baudrez, C. Galant, and B. C. Vande Berg, "Benign vertebral hemangioma: MR-histological correlation," *Skeletal Radiol*, vol. 30, no. 8, pp. 442–446, Aug. 2001, doi: 10.1007/s002560100390.
- [26] N. Sans, M. Faruch, F. Lapègue, A. Ponsot, H. Chiavassa, and J.-J. Railhac, "Infections of the spinal column – Spondylodiscitis," *Diagn Interv Imaging*, vol. 93, no. 6, pp. 520–529, Jun. 2012, doi: 10.1016/j.diii.2012.04.003.
- [27] H.-S. Jung, W.-H. Jee, T. R. McCauley, K.-Y. Ha, and K.-H. Choi, "Discrimination of Metastatic from Acute Osteoporotic Compression Spinal Fractures with MR Imaging¹ ," *RadioGraphics*, vol. 23, no. 1, pp. 179–187, Jan. 2003, doi: 10.1148/rg.231025043.
- [28] R. Aich, A. Deb, A. Banerjee, R. Karim, and P. Gupta, "Symptomatic vertebral hemangioma: Treatment with radiotherapy," *J Cancer Res Ther*, vol. 6, no. 2, p. 199, 2010, doi: 10.4103/0973-1482.65248.
- [29] S. Gaudino *et al.*, "A systematic approach to vertebral hemangioma," *Skeletal Radiol*, vol. 44, no. 1, pp. 25–36, Jan. 2015, doi: 10.1007/S00256-014-2035-Y.
- [30] J. S. Ross, T. J. Masaryk, M. T. Modic, J. R. Carter, T. Mapstone, and F. H. Dengel, "Vertebral hemangiomas: MR imaging.," *Radiology*, vol. 165, no. 1, pp. 165–169, Oct. 1987, doi: 10.1148/radiology.165.1.3628764.
- [31] M. D. Murphey, J. J. Choi, M. J. Kransdorf, D. J. Flemming, and F. H. Gannon, "Imaging of Osteochondroma: Variants and Complications with Radiologic-Pathologic Correlation," *RadioGraphics*, vol. 20, no. 5, pp. 1407–1434, Sep. 2000, doi: 10.1148/radiographics.20.5.g00se171407.

- [32] L. Dang *et al.*, “Aggressive vertebral hemangioma of the thoracic spine without typical radiological appearance,” *European Spine Journal*, vol. 21, no. 10, p. 1994, Oct. 2012, doi: 10.1007/S00586-012-2349-1.
- [33] J. P. Nguyen *et al.*, “Vertebral hemangiomas presenting with neurologic symptoms,” *Surg Neurol*, vol. 27, no. 4, pp. 391–397, Apr. 1987, doi: 10.1016/0090-3019(87)90020-6.
- [34] J. S. Ross, T. J. Masaryk, M. T. Modic, J. R. Carter, T. Mapstone, and F. H. Dengel, “Vertebral hemangiomas: MR imaging,” *Radiology*, vol. 165, no. 1, pp. 165–169, Oct. 1987, doi: 10.1148/radiology.165.1.3628764.
- [35] K. A. Morales, J. Arevalo-Perez, K. K. Peck, A. I. Holodny, E. Lis, and S. Karimi, “Differentiating Atypical Hemangiomas and Metastatic Vertebral Lesions: The Role of T1-Weighted Dynamic Contrast-Enhanced MRI,” *American Journal of Neuroradiology*, vol. 39, no. 5, pp. 968–973, May 2018, doi: 10.3174/ajnr.A5630.
- [36] A. Rouhi, S. R. Turner, S. Johnson, and R. MacEwan, “Atypical Vertebral Hemangioma in a Patient With Newly Diagnosed Pulmonary Nodule,” *Annals of Thoracic Surgery Short Reports*, vol. 1, no. 1, pp. 115–117, Mar. 2023, doi: 10.1016/j.atssr.2022.06.002.
- [37] S. Orguc and R. Arkun, “Primary Tumors of the Spine,” *Semin Musculoskelet Radiol*, vol. 18, no. 03, pp. 280–299, Jun. 2014, doi: 10.1055/s-0034-1375570.
- [38] T. F. Witham, Y. A. Khavkin, G. L. Gallia, J.-P. Wolinsky, and Z. L. Gokaslan, “Surgery Insight: current management of epidural spinal cord compression from metastatic spine disease,” *Nat Clin Pract Neurol*, vol. 2, no. 2, pp. 87–94, Feb. 2006, doi: 10.1038/ncpneuro0116.
- [39] E. Edelmers *et al.*, “AI-Assisted Detection and Localization of Spinal Metastatic Lesions,” *Diagnostics*, vol. 14, no. 21, p. 2458, Nov. 2024, doi: 10.3390/diagnostics14212458.
- [40] G. R. Mundy, “Metastasis to bone: causes, consequences and therapeutic opportunities,” *Nat Rev Cancer*, vol. 2, no. 8, pp. 584–593, Aug. 2002, doi: 10.1038/NRC867.
- [41] M. C. Chamberlain, A. Sloan, and F. Vrionis, “Systematic review of the diagnosis and management of malignant extradural spine cord compression:

- The Cancer Care Ontario Practice Guidelines Initiative's Neuro-Oncology Disease Site Group," *J Clin Oncol*, vol. 23, no. 30, pp. 7750–7751, 2005, doi: 10.1200/JCO.2005.02.7029.
- [42] E. Ziu, V. K. Viswanathan, and F. B. Mesfin, "Spinal Metastasis," *StatPearls*, Aug. 2023, Accessed: Jul. 17, 2024. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK441950/>
- [43] J. Li, W. Wei, F. Xu, Y. Wang, Y. Liu, and C. Fu, "Clinical Therapy of Metastatic Spinal Tumors," *Front Surg*, vol. 8, Apr. 2021, doi: 10.3389/fsurg.2021.626873.
- [44] N. Salvo *et al.*, "The Role of Plain Radiographs in Management of Bone Metastases," *J Palliat Med*, vol. 12, no. 2, pp. 195–198, Feb. 2009, doi: 10.1089/jpm.2008.0055.
- [45] R. Kamholtz and G. Sze, "Current imaging in spinal metastatic disease.," *Semin Oncol*, vol. 18, no. 2, pp. 158–69, Apr. 1991.
- [46] V. Sethi, R. Garg, C. Gui, K. J. Redmond, and M. Khan, "Neuroimaging for Spine Metastasis," in *Image Guided Interventions of the Spine*, Cham: Springer International Publishing, 2021, pp. 169–182. doi: 10.1007/978-3-030-80079-6_10.
- [47] L. M. Shah and K. L. Salzman, "Imaging of Spinal Metastatic Disease," *Int J Surg Oncol*, vol. 2011, pp. 1–12, 2011, doi: 10.1155/2011/769753.
- [48] K. W. Carroll, J. F. Feller, and P. F. J. Tirman, "Useful internal standards for distinguishing infiltrative marrow pathology from hematopoietic marrow at MRI," *Journal of Magnetic Resonance Imaging*, vol. 7, no. 2, pp. 394–398, Mar. 1997, doi: 10.1002/jmri.1880070224.
- [49] G. P. Schmidt, S. O. Schoenberg, M. F. Reiser, and A. Baur-Melnyk, "Whole-body MR imaging of bone marrow," *Eur J Radiol*, vol. 55, no. 1, pp. 33–40, Jul. 2005, doi: 10.1016/j.ejrad.2005.01.019.
- [50] N. Uchida, K. Sugimura, A. Kajitani, T. Yoshizako, and T. Ishida, "MR imaging of vertebral metastases: evaluation of fat saturation imaging," *Eur J Radiol*, vol. 17, no. 2, pp. 91–94, Sep. 1993, doi: 10.1016/0720-048X(93)90041-K.
- [51] J. T. Mauch, C. M. Carr, H. Cloft, and F. E. Diehn, "Review of the Imaging Features of Benign Osteoporotic and Malignant Vertebral Compression

- Fractures,” *American Journal of Neuroradiology*, vol. 39, no. 9, pp. 1584–1592, Sep. 2018, doi: 10.3174/ajnr.A5528.
- [52] T. Yoda *et al.*, “Automated Differentiation between Osteoporotic Vertebral Fracture and Malignant Vertebral Fracture on MRI Using a Deep Convolutional Neural Network,” *Spine (Phila Pa 1976)*, vol. 47, no. 8, pp. E347–E352, Apr. 2022, doi: 10.1097/BRS.0000000000004307.
- [53] M. H. Rodallec *et al.*, “Diagnostic Imaging of Solitary Tumors of the Spine: What to Do and Say,” *RadioGraphics*, vol. 28, no. 4, pp. 1019–1041, Jul. 2008, doi: 10.1148/rg.284075156.
- [54] G. S. Skaf *et al.*, “Pyogenic spondylodiscitis: An overview,” *J Infect Public Health*, vol. 3, no. 1, pp. 5–16, 2010, doi: 10.1016/j.jiph.2010.01.001.
- [55] S. H. Hong, J.-Y. Choi, J. W. Lee, N. R. Kim, J.-A. Choi, and H. S. Kang, “MR Imaging Assessment of the Spine: Infection or an Imitation?,” *RadioGraphics*, vol. 29, no. 2, pp. 599–612, Mar. 2009, doi: 10.1148/rg.292085137.
- [56] E. T. Tali, “Spinal infections,” *Eur J Radiol*, vol. 50, no. 2, pp. 120–133, May 2004, doi: 10.1016/J.EJRAD.2003.10.022.
- [57] A. R. Gillams, B. Chaddha, and A. P. Carter, “MR appearances of the temporal evolution and resolution of infectious spondylitis,” *American Journal of Roentgenology*, vol. 166, no. 4, pp. 903–907, Apr. 1996, doi: 10.2214/ajr.166.4.8610571.
- [58] H. P. Ledermann, M. E. Schweitzer, W. B. Morrison, and J. A. Carrino, “MR Imaging Findings in Spinal Infections: Rules or Myths?,” *Radiology*, vol. 228, no. 2, pp. 506–514, Aug. 2003, doi: 10.1148/radiol.2282020752.
- [59] S. Moorthy and N. K. Prabhu, “Spectrum of MR imaging findings in spinal tuberculosis,” *American Journal of Roentgenology*, vol. 179, no. 4, pp. 979–983, Nov. 2002, doi: 10.2214/AJR.179.4.1790979/ASSET/IMAGES/10_AC0125_12B.JPEG.
- [60] E. T. Tali, A. M. Koc, and A. Y. Oner, “Spinal Brucellosis,” *Neuroimaging Clin N Am*, vol. 25, no. 2, pp. 233–245, May 2015, doi: 10.1016/j.nic.2015.01.004.
- [61] O. Oren, B. J. Gersh, and D. L. Bhatt, “Artificial intelligence in medical imaging: switching from radiographic pathological data to clinically

- meaningful endpoints,” *Lancet Digit Health*, vol. 2, no. 9, pp. e486–e488, Sep. 2020, doi: 10.1016/S2589-7500(20)30160-6.
- [62] W. Ong *et al.*, “Application of Artificial Intelligence Methods for Imaging of Spinal Metastasis,” *Cancers (Basel)*, vol. 14, no. 16, p. 4025, Aug. 2022, doi: 10.3390/cancers14164025.
- [63] M.B. Bishop, *Pattern Recognition and Machine Learning*, Last. New York: Springer, 2006.
- [64] G. Litjens *et al.*, “A survey on deep learning in medical image analysis,” *Med Image Anal*, vol. 42, pp. 60–88, Dec. 2017, doi: 10.1016/j.media.2017.07.005.
- [65] T. Hastie, R. Tibshirani, and J. Friedman, “The Elements of Statistical Learning,” 2009, doi: 10.1007/978-0-387-84858-7.
- [66] X. Zhu and A. B. Goldberg, “Introduction to Semi-Supervised Learning,” *Introduction to Semi-Supervised Learning*, 2009, doi: 10.1007/978-3-031-01548-9.
- [67] L. Deng and D. Yu, “Deep Learning: Methods and Applications,” *Foundations and Trends® in Signal Processing*, vol. 7, no. 3–4, pp. 197–387, 2014, doi: 10.1561/20000000039.
- [68] J.-G. Lee *et al.*, “Deep Learning in Medical Imaging: General Overview,” *Korean J Radiol*, vol. 18, no. 4, p. 570, 2017, doi: 10.3348/kjr.2017.18.4.570.
- [69] S. Soffer, A. Ben-Cohen, O. Shimon, M. M. Amitai, H. Greenspan, and E. Klang, “Convolutional Neural Networks for Radiologic Images: A Radiologist’s Guide,” *Radiology*, vol. 290, no. 3, pp. 590–606, Mar. 2019, doi: 10.1148/radiol.2018180547.
- [70] “What the radiologist should know about artificial intelligence – an ESR white paper,” *Insights Imaging*, vol. 10, no. 1, p. 44, Dec. 2019, doi: 10.1186/s13244-019-0738-2.
- [71] P. M. Cheng *et al.*, “Deep Learning: An Update for Radiologists,” *RadioGraphics*, vol. 41, no. 5, pp. 1427–1445, Sep. 2021, doi: 10.1148/rg.2021200210.
- [72] E. Montagnon *et al.*, “Deep learning workflow in radiology: a primer,” *Insights Imaging*, vol. 11, no. 1, p. 22, Dec. 2020, doi: 10.1186/s13244-019-0832-5.

- [73] S. M. Anwar, M. Majid, A. Qayyum, M. Awais, M. Alnowami, and M. K. Khan, "Medical Image Analysis using Convolutional Neural Networks: A Review," *J Med Syst*, vol. 42, no. 11, pp. 1–13, Nov. 2018, doi: 10.1007/S10916-018-1088-1/TABLES/4.
- [74] S. Soffer, A. Ben-Cohen, O. Shimon, M. M. Amitai, H. Greenspan, and E. Klang, "Convolutional Neural Networks for Radiologic Images: A Radiologist's Guide," *Radiology*, vol. 290, no. 3, pp. 590–606, Mar. 2019, doi: 10.1148/radiol.2018180547.
- [75] V. H. Phung and E. J. Rhee, "A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets," *Applied Sciences*, vol. 9, no. 21, p. 4500, Oct. 2019, doi: 10.3390/app9214500.
- [76] W. Liawrungrueang, S. T. Cho, V. Kotheeranurak, K. Jitpakdee, P. Kim, and P. Sarasombath, "Osteoporotic vertebral compression fracture (OVCF) detection using artificial neural networks model based on the AO spine-DGOU osteoporotic fracture classification system," *North American Spine Society Journal (NASSJ)*, vol. 19, p. 100515, Sep. 2024, doi: 10.1016/j.xnsj.2024.100515.
- [77] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun. 2016, pp. 779–788. doi: 10.1109/CVPR.2016.91.
- [78] M. G. Ragab *et al.*, "A Comprehensive Systematic Review of YOLO for Medical Object Detection (2018 to 2023)," *IEEE Access*, vol. 12, pp. 57815–57836, 2024, doi: 10.1109/ACCESS.2024.3386826.
- [79] "Redmon, J. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition."
- [80] "Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90."
- [81] H. H. Nguyen, T. N. Ta, N. C. Nguyen, V. T. Bui, H. M. Pham, and D. M. Nguyen, "YOLO Based Real-Time Human Detection for Smart Video

- Surveillance at the Edge,” in *2020 IEEE Eighth International Conference on Communications and Electronics (ICCE)*, IEEE, Jan. 2021, pp. 439–444. doi: 10.1109/ICCE48956.2021.9352144.
- [82] N. Pawar *et al.*, “Miniscule Object Detection in Aerial Images Using YOLOR: A Review,” 2023, pp. 697–708. doi: 10.1007/978-981-19-3951-8_52.
- [83] M. Hussain, “YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection,” *Machines*, vol. 11, no. 7, p. 677, Jun. 2023, doi: 10.3390/machines11070677.
- [84] J. Terven, D.-M. Córdova-Esparza, and J.-A. Romero-González, “A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS,” *Mach Learn Knowl Extr*, vol. 5, no. 4, pp. 1680–1716, Nov. 2023, doi: 10.3390/make5040083.
- [85] “Augmented Startups. (t.y.). YOLOv10 ve YOLOv9: Hız ve doğruluk karşılaştırması. Erişim adresi: <https://www.augmentedstartups.com/blog/yolov10-vs--yolov9>”.
- [86] M. Nicancı Sinanoğlu and Ş. Kaya, “Local Climate Zone Classification Using YOLOV8 Modeling in Instance Segmentation Method,” *International Journal of Environment and Geoinformatics*, vol. 11, no. 2, pp. 1–9, Jun. 2024, doi: 10.30897/ijegeo.1456352.
- [87] S. Ioffe and C. Szegedy, ““Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift,” *CoRR*, vol. abs/1502.03167.
- [88] A. Esteva *et al.*, “Erratum: Corrigendum: Dermatologist-level classification of skin cancer with deep neural networks,” *Nature*, vol. 546, no. 7660, pp. 686–686, Jun. 2017, doi: 10.1038/nature22985.
- [89] N. Rane, S. Choudhary, and J. Rane, “YOLO and Faster R-CNN Object Detection in Architecture, Engineering and Construction (AEC): Applications, Challenges, and Future Prospects,” *SSRN Electronic Journal*, 2023, doi: 10.2139/ssrn.4624204.
- [90] A. Bochkovski, C.-Y. Wang, and H.-Y. M. Liao, “YOLOv4: Optimal Speed and Accuracy of Object Detection,” Apr. 2020.

- [91] X. W. L. L. and R. M. S. K. Yan, “ ‘DeepLesion: Automated Deep Mining, Categorization and Detection of Significant Radiology Image Findings using Large-Scale Clinical Lesion Annotations,’ ,” [Online].
- [92] G. B. CANGÖZ and S. GÜNEY, “The Effects of the Traditional Data Augmentation Techniques on Long Bone Fracture Detection,” *Bilge International Journal of Science and Technology Research*, vol. 7, no. 1, pp. 63–69, Mar. 2023, doi: 10.30516/bilgesci.1128622.
- [93] X. Shen *et al.*, “Deep learning-assisted diagnosis of parotid gland tumors by using contrast-enhanced CT imaging,” *Oral Dis*, vol. 29, no. 8, pp. 3325–3336, Nov. 2023, doi: 10.1111/odi.14474.
- [94] R. , N. S. L. , & da S. Padilla, “A Survey on Performance Metrics for Object-Detection Algorithms” In *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*. 2020.
- [95] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, “YOLOv4: Optimal Speed and Accuracy of Object Detection,” Apr. 2020.
- [96] “Liang G. Clinical Study on Treatment of Degenerative Spondylitis of the Lumbar Spine with Self-Weight Suspension Traction. Guangzhou: Guangzhou University of Chinese Medicine (2015).”.
- [97] L. Chen *et al.*, “Surgical interventions for degenerative lumbar spinal stenosis: a systematic review with network meta-analysis,” *BMC Med*, vol. 22, no. 1, p. 430, Oct. 2024, doi: 10.1186/s12916-024-03653-z.
- [98] T. Morimoto *et al.*, “A new era in the management of spinal metastasis,” *Front Oncol*, vol. 14, Apr. 2024, doi: 10.3389/fonc.2024.1374915.
- [99] J. T. Wewel and J. E. O’Toole, “Epidemiology of spinal cord and column tumors,” *Neurooncol Pract*, vol. 7, no. Supplement_1, pp. i5–i9, Nov. 2020, doi: 10.1093/nop/npaa046.
- [100] B. A. Georgy, “Metastatic Spinal Lesions: State-of-the-Art Treatment Options and Future Trends,” *American Journal of Neuroradiology*, vol. 29, no. 9, pp. 1605–1611, Oct. 2008, doi: 10.3174/ajnr.A1137.
- [101] K. Kato, N. Teferi, M. Challa, K. Eschbacher, and S. Yamaguchi, “Vertebral hemangiomas: a review on diagnosis and management,” *J Orthop Surg Res*, vol. 19, no. 1, p. 310, May 2024, doi: 10.1186/s13018-024-04799-5.

- [102] G. Waheed, M. A. R. Soliman, A. M. Ali, and M. H. Aly, “Spontaneous spondylodiscitis: review, incidence, management, and clinical outcome in 44 patients,” *Neurosurg Focus*, vol. 46, no. 1, p. E10, Jan. 2019, doi: 10.3171/2018.10.FOCUS18463.
- [103] J. S. Butler, M. J. Shelly, M. Timlin, W. G. Powderly, and J. M. O’Byrne, “Nontuberculous Pyogenic Spinal Infection in Adults,” *Spine (Phila Pa 1976)*, vol. 31, no. 23, pp. 2695–2700, Nov. 2006, doi: 10.1097/01.brs.0000244662.78725.37.
- [104] K. Al Taha *et al.*, “Multidisciplinary and Coordinated Management of Osteoporotic Vertebral Compression Fractures: Current State of the Art,” *J Clin Med*, vol. 13, no. 4, p. 930, Feb. 2024, doi: 10.3390/jcm13040930.
- [105] “Incidence of Vertebral Fracture in Europe: Results From the European Prospective Osteoporosis Study (EPOS),” *Journal of Bone and Mineral Research*, vol. 17, no. 4, pp. 716–724, Apr. 2002, doi: 10.1359/jbmr.2002.17.4.716.
- [106] G. A. Toomayan and N. M. Major, “Utility of CT-Guided Biopsy of Suspicious Skeletal Lesions in Patients With Known Primary Malignancies,” *American Journal of Roentgenology*, vol. 196, no. 2, pp. 416–423, Feb. 2011, doi: 10.2214/AJR.10.4934.
- [107] M. H. Rodallec *et al.*, “Diagnostic Imaging of Solitary Tumors of the Spine: What to Do and Say,” *RadioGraphics*, vol. 28, no. 4, pp. 1019–1041, Jul. 2008, doi: 10.1148/rg.284075156.
- [108] S. Buhmann (Kirchhoff), C. Becker, H. R. Duerr, M. Reiser, and A. Baur-Melnyk, “Detection of osseous metastases of the spine: Comparison of high resolution multi-detector-CT with MRI,” *Eur J Radiol*, vol. 69, no. 3, pp. 567–573, Mar. 2009, doi: 10.1016/j.ejrad.2007.11.039.
- [109] T. Liu *et al.*, “Detection of vertebral metastases: a meta-analysis comparing MRI, CT, PET, BS and BS with SPECT,” *J Cancer Res Clin Oncol*, vol. 143, no. 3, pp. 457–465, Mar. 2017, doi: 10.1007/s00432-016-2288-z.
- [110] T. Liu, T. Cheng, W. Xu, W.-L. Yan, J. Liu, and H.-L. Yang, “A meta-analysis of 18FDG-PET, MRI and bone scintigraphy for diagnosis of bone metastases in

- patients with breast cancer,” *Skeletal Radiol*, vol. 40, no. 5, pp. 523–531, May 2011, doi: 10.1007/s00256-010-0963-8.
- [111] T. Takigawa, M. Tanaka, Y. Sugimoto, T. Tetsunaga, K. Nishida, and T. Ozaki, “Discrimination between Malignant and Benign Vertebral Fractures Using Magnetic Resonance Imaging,” *Asian Spine J*, vol. 11, no. 3, pp. 478–483, Jun. 2017, doi: 10.4184/asj.2017.11.3.478.
- [112] S. Buhmann (Kirchhoff), C. Becker, H. R. Duerr, M. Reiser, and A. Baur-Melnyk, “Detection of osseous metastases of the spine: Comparison of high resolution multi-detector-CT with MRI,” *Eur J Radiol*, vol. 69, no. 3, pp. 567–573, Mar. 2009, doi: 10.1016/j.ejrad.2007.11.039.
- [113] Y. J. Yang and T. A. Damron, “Comparison of Needle Core Biopsy and Fine-Needle Aspiration for Diagnostic Accuracy in Musculoskeletal Lesions,” *Arch Pathol Lab Med*, vol. 128, no. 7, pp. 759–764, Jul. 2004, doi: 10.5858/2004-128-759-CONCBA.
- [114] G. Sha, J. Wu, and B. Yu, “Detection of Spinal Fracture Lesions Based on Improved Yolo-tiny,” in *2020 IEEE International Conference on Advances in Electrical Engineering and Computer Applications(AEECA)*, IEEE, Aug. 2020, pp. 298–301. doi: 10.1109/AEECA49918.2020.9213684.
- [115] J. Li *et al.*, “Primary bone tumor detection and classification in full-field bone radiographs via YOLO deep learning model,” *Eur Radiol*, vol. 33, no. 6, pp. 4237–4248, Nov. 2022, doi: 10.1007/s00330-022-09289-y.
- [116] J. Park, J. Yang, S. Park, and J. Kim, “Deep Learning-Based Approaches for Classifying Foraminal Stenosis Using Cervical Spine Radiographs,” *Electronics (Basel)*, vol. 12, no. 1, p. 195, Dec. 2022, doi: 10.3390/electronics12010195.
- [117] M.-H. Hsieh, C.-Y. Chang, and S.-M. Hsu, “Accurate detection of fresh and old vertebral compression fractures on CT images using ensemble YOLOR,” *Multimed Tools Appl*, vol. 83, no. 41, pp. 89375–89391, Nov. 2024, doi: 10.1007/s11042-024-20355-z.
- [118] Y. Koike *et al.*, “Artificial intelligence-aided lytic spinal bone metastasis classification on CT scans,” *Int J Comput Assist Radiol Surg*, vol. 18, no. 10, pp. 1867–1874, Mar. 2023, doi: 10.1007/s11548-023-02880-8.

- [119] S. C. Foreman *et al.*, “Deep Learning to Differentiate Benign and Malignant Vertebral Fractures at Multidetector CT,” *Radiology*, vol. 310, no. 3, Mar. 2024, doi: 10.1148/radiol.231429.
- [120] W. Liu *et al.*, “Deep Learning for Discrimination of Early Spinal Tuberculosis from Acute Osteoporotic Vertebral Fracture on CT,” *Infect Drug Resist*, vol. Volume 18, pp. 31–42, Jan. 2025, doi: 10.2147/IDR.S482584.
- [121] V. Chianca *et al.*, “Radiomic Machine Learning Classifiers in Spine Bone Tumors: A Multi-Software, Multi-Scanner Study,” *Eur J Radiol*, vol. 137, p. 109586, Apr. 2021, doi: 10.1016/j.ejrad.2021.109586.
- [122] W. Liawrungrueang, P. Kim, V. Kotheeranurak, K. Jitpakdee, and P. Sarasombath, “Automatic Detection, Classification, and Grading of Lumbar Intervertebral Disc Degeneration Using an Artificial Neural Network Model,” *Diagnostics*, vol. 13, no. 4, p. 663, Feb. 2023, doi: 10.3390/diagnostics13040663.
- [123] H. Liu *et al.*, “Benign and malignant diagnosis of spinal tumors based on deep learning and weighted fusion framework on MRI,” *Insights Imaging*, vol. 13, no. 1, p. 87, Dec. 2022, doi: 10.1186/s13244-022-01227-2.
- [124] S. Duan *et al.*, “Accurate Differentiation of Spinal Tuberculosis and Spinal Metastases Using MR-Based Deep Learning Algorithms,” *Infect Drug Resist*, vol. 16, pp. 4325–4334, 2023, doi: 10.2147/IDR.S417663.
- [125] R. Padilla, S. L. Netto, and E. A. B. da Silva, “A Survey on Performance Metrics for Object-Detection Algorithms,” in *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, IEEE, Jul. 2020, pp. 237–242. doi: 10.1109/IWSSIP48289.2020.9145130.
- [126] B. Liu, Y. Jin, S. Feng, H. Yu, Y. Zhang, and Y. Li, “Benign vs malignant vertebral compression fractures with MRI: a comparison between automatic deep learning network and radiologist’s assessment,” *Eur Radiol*, vol. 33, no. 7, pp. 5060–5068, May 2023, doi: 10.1007/s00330-023-09713-x.
- [127] K. Simonyan and A. Zisserman, “Two-Stream Convolutional Networks for Action Recognition in Videos,” Jun. 2014.
- [128] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” Jun. 2015.

- [129] L. R. Yeh *et al.*, “A deep learning-based method for the diagnosis of vertebral fractures on spine MRI: retrospective training and validation of ResNet,” *European Spine Journal*, vol. 31, no. 8, pp. 2022–2030, Aug. 2022, doi: 10.1007/S00586-022-07121-1.



T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığı



Sayı : E-40465587-050.01.04-1140
Konu : Etik Kurul

18.07.2024

Sayın Doç. Dr. Mehmet BEYAZAL

Üniversitemiz Girişimsel Olmayan Klinik Araştırmalar Etik Kuruluna yapmış olduğunuz “**Manyetik Rezonans Görüntülemeye Saptanan Vertebra Korpus Lezyonlarının Ayırıcı Tanısında Derin Öğrenme Tabanlı Yapay Zekanın Etkinliğinin Değerlendirilmesi**” isimli başvurunuz etik kurulumuz yönergesine göre 11.07.2024 tarihinde yapmış olduğu toplantıda incelenmiş olup, 2024/176 karar numarası ile bilimsel ve etik yönden uygun bulunmuştur. Bilgilerinizi ve gereğini saygılarımla rica ederim.

Doç. Dr. Tahsin Gökhan TELATAR
Başkan

Bu belge güvenli elektronik imza ile imzalanmıştır.
Belge Doğrulama Kodu : 0584055e32cc **Belge Takip Adresi: <http://ebys.erdogan.edu.tr/EBYS/eimzadogrulama>**

Zihni Derin Yerleşkesi 53100 Fener-Rize
Telefon No :+90 (464) 223 61 26 Faks No :+90 (464) 223 53 76
e-Posta : İnternet Adresi:<http://www.erdogan.edu.tr/>
Kep Adresi:

Bilgi için : BURAK HANKAYA
Bilgisayar İşletmen

