



Kas-iskelet sistemi görüntülemesinde yapay zekâ uygulamaları: Makine öğrenmesi ve derin öğrenme teknikleri

Artificial intelligence in musculoskeletal system imaging: Machine learning and deep learning techniques

Murat Yüce, Gül Gizem Pamuk

İstanbul Bağcılar Eğitim ve Araştırma Hastanesi, Radyoloji Kliniği, İstanbul

Yapay zekâ teknikleri, makine öğrenmesi ve derin öğrenme yoluyla geliştirilmiş olup, sağlık hizmetlerinde, özellikle tıbbi görüntü analizinde en umut verici yenilik alanlarından biri olarak ortaya çıkmıştır. Bu derlemede, kas-iskelet sistemi görüntülemeye yönelik geliştirilen makine öğrenmesi ve derin öğrenme algoritmalarını değerlendirerek radyoloji hekimi ile ortopedi ve travmatoloji hekimi okurlara güncel bir bakış açısı sunmayı amaçladık. Son yıllarda kas-iskelet sistemi görüntüleme alanında yapılan yapay zekâ çalışmalarının sayısı gün geçtikçe artmakta ve bu çalışmalar klinik uygulamalarda önemli avantajlar yaratmaktadır. Bu alandaki çalışmalar, görüntüleme protokollerini optimize etme, iş akışı verimliliğini artırma, otomatik lezyon tespiti ve sınıflandırma, otomatik ölçüm ve klinik sonuçların veya prognoz tahmini gibi amaçlara hizmet etmektedir. Bu teknolojilerin kullanımıyla, tıbbi görüntüleme alanında önemli gelişmelere yol açma, hastaların tedavi süreçlerini ve sonuçlarını tahmin etmede fayda sağlama amaçlanmaktadır. Yine de klinik pratikte rutin kullanım için uygun modeller henüz yaygınlaşmamıştır. Gelecekte bu tarz modellerin geliştirilmesiyle ortopedi ve travmatoloji hekimi ile radyologların iş akışında pozitif yönde değişiklikler beklenilmektedir.

Anahtar sözcükler: kas-iskelet sistemi görüntüleme; yapay zekâ; derin öğrenme; makine öğrenmesi

Artificial intelligence techniques, developed through machine learning and deep learning, have emerged as one of the most promising areas of innovation in healthcare, particularly in medical image analysis. In this review, we aimed to provide radiologists and orthopedists with a current perspective by evaluating machine learning and deep learning algorithms developed for musculoskeletal imaging. The number of artificial intelligence studies in the musculoskeletal imaging field has been increasing day by day in recent years, and these studies create significant advantages in clinical applications. Research in this area serves purposes such as optimizing imaging protocols, increasing workflow efficiency, automatic lesion detection and classification, automatic measurement, and predicting clinical outcomes or prognosis. The use of these technologies aims to lead to significant advancements in the field of medical imaging and to benefit patients in predicting their treatment processes and outcomes. However, suitable models for routine use in clinical practice have not yet become widespread. In the future, the development of such models is expected to bring positive changes to the workflow of orthopedists and radiologists.

Key words: musculoskeletal imaging; artificial intelligence; deep learning; machine learning

Makine öğrenmesi ve derin öğrenme yoluyla geliştirilen yapay zekâ (YZ) teknikleri, sağlık hizmetlerinde, özellikle tıbbi görüntü analizinde en umut verici yenilik alanlarından biri olarak ortaya çıkmıştır. Bilgi işlem gücü ve büyük veri kümelerinin kullanılabilirliğindeki gelişmeler, tıbbi görüntüleme yapay zekâ ve makine öğrenimi uygulamalarında devrim yaratmıştır. Bu bağlamda, YZ ilişkili görüntüleme çalışmalarında güncel olarak en fazla çalışma nörorad-

yoloji alanında yayınlanmıştır ancak kas-iskelet sistemi (KİS) görüntülemeye yönelik araştırma sayısı ikinci sırada gelmektedir.^[1] Kas-iskelet sistemi görüntüleme alanında yapılan YZ çalışmalarının sayısı gün geçtikçe artmakta ve bu çalışmalar klinik uygulamalarda önemli avantajlar yaratmaktadır.

Bu derlemede, literatürde KİS görüntülemeye yönelik geliştirilen makine öğrenmesi ve derin öğrenme

İletişim / Contact: Uzm. Dr. Murat Yüce • **E-posta / E-mail:** muratyuce.dr@gmail.com

ORCID iD: Murat Yüce, 0000-0003-0619-5868 • Gül Gizem Pamuk, 0000-0002-8326-7506

Geliş / Received: 29 Ağustos 2023 • **Revizyon / Revised:** 7 Kasım 2023, 23 Kasım 2023 • **Kabul / Accepted:** 26 Kasım 2023

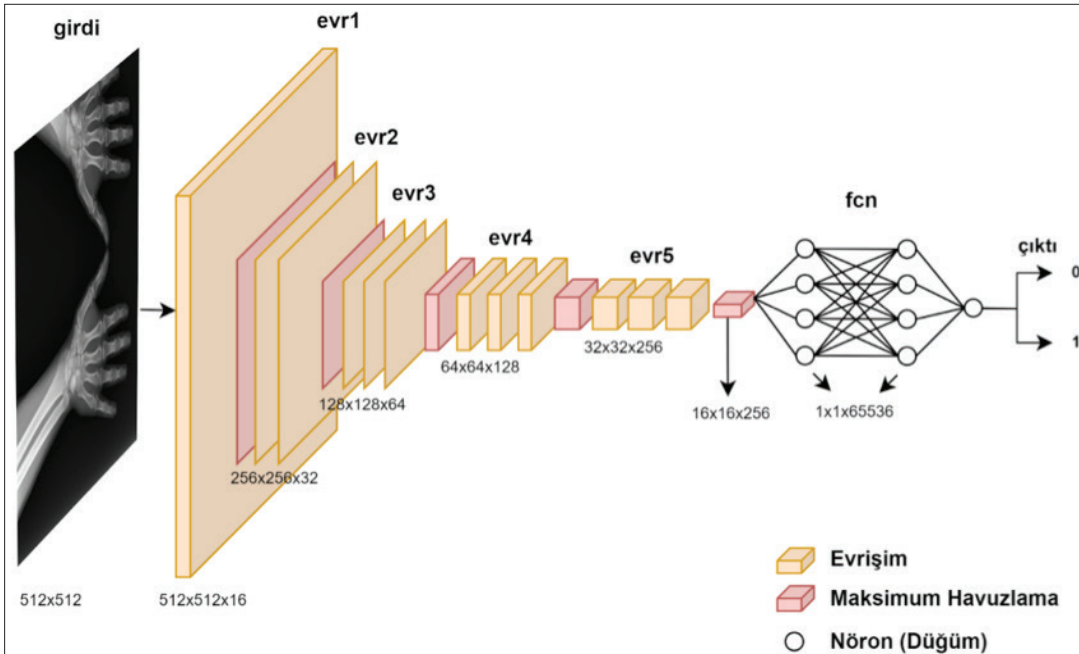
algoritmalarını değerlendirerek radyoloji hekimi ile ortopedi ve travmatoloji hekimi okurlara güncel bir bakış açısı sunmayı amaçladık. Görüntüleme kullanılarak geliştirilen YZ algoritmalarının temel amaçları arasında görüntüleme öncesi planlama ve görüntü kalitesini artırma, otomatik lezyon tespit etme, sınıflandırma, otomatik ölçüm ve klinik sonlanıma (veya prognoz) ilişkin ön tahmin yer almaktadır. Büyük çoğunluğu son beş yıl içerisinde yayınlanmış olan araştırmaları bu amaçlara uygun olarak beş ayrı alt başlıkta değerlendirdik.

TERMİNOLOJİ

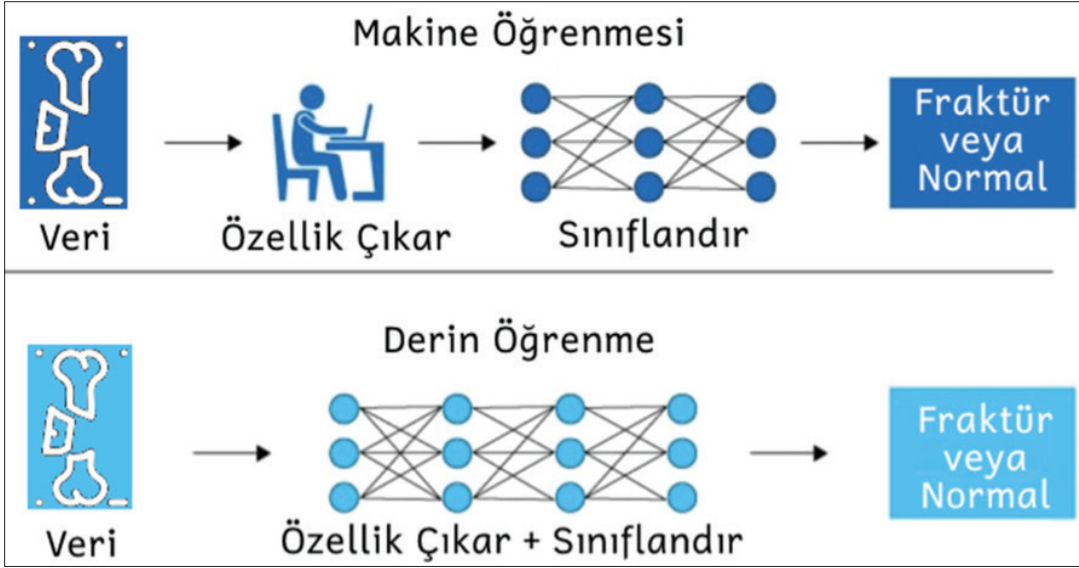
Yapay zekâ, insan zekâsının genelleştirilebilir matematiksel ve istatistiksel hesaplamalar yoluyla taklit edilmesini ifade etmektedir. İki ana bileşenden oluşur; makine öğrenimi (MÖ) ve derin öğrenme (DÖ). Yapay zekâ, MÖ ve DÖ terimleri sıklıkla birbirinin yerine kullanılır, ancak farklı anlamlara sahiptir. Yapay zekâ, bilgisayarların insan zekâsını taklit etmeyi sağlayan herhangi bir tekniği ifade eder. Makine öğrenimi, istatistiksel, matematiksel araçları ve bilgisayar bilimi araçlarını kullanarak deneyim yoluyla görev performansını geliştirmeye odaklanan YZ'nin özelleştirilmiş bir alt alanıdır. Derin öğrenme ise büyük veri kümelerine maruz kalan derin sinir ağlarının kullanımını inceleyen, MÖ çatısında daha da özelleştirilmiş bir alt alandır. Derin öğrenmede öğrenme sürecini hızlandırmak için yapay evrişimli sinir ağları (ESA) kullanılmaktadır (Şekil 1). Yapay evrişimli sinir ağları, girdiler

ve çıktılar arasındaki karmaşık ilişkileri, dönüşümlerin çok katmanlı yapıları aracılığıyla simüle edebilen doğrusal olmayan yapılarıdır. Yapay evrişimli sinir ağları sayesinde farklı görüntülerdeki ortak özellikler belirlenerek görüntüler özelliklerine göre sınıflandırılarak DÖ modelleri eğitilebilir. Bu sistemler, örneğin bir direkt grafide kemik kırıklarına (fraktürlerine) ait özellikleri bularak kırıklı ve kırıksız görüntüler arasında ayırım yapmayı öğrenebilir. Böylelikle, otomatik olarak oldukça duyarlı ve objektif teşhisler yaparak yorumlayıcıların verimliliği ve üretkenliği artırılabilir. Derin öğrenme görüntü sınıflandırması, semantik etiketleme, obje tanıma ve doğal dil işleme gibi alanlarda önemli gelişmelere yol açmıştır.

Sinir ağları, YZ'nin yapı taşlarıdır ve girdilere matematiksel işlemler gerçekleştirip çıktılarını yine matematiksel fonksiyonlardan oluşan bağlı düğümlere ileten düğümlerden oluşur. Bu ağlar ayrıca doğrusal olmayan işlemleri de içerir ve düğümlerden gelen bilgiyi katmanlara aktarırlar; her katman önceki katmanlardan girdi alır. Bu katmanlı yapı, insan beynindeki duyuşal uyarıların işlenmesine benzer. Makine öğrenmesinde veriyi en iyi şekilde temsil edecek özellikler/değişkenlerin tasarlanması insan eliyle yapılmaktadır, DÖ içerdiği kompleks yapı sayesinde ham veya birtakım temel ön işleme süreçlerinden geçmiş verilerde insan müdahalesine gerek kalmadan özellik çıkarımı yapılabilmektedir (Şekil 2). Derin öğrenme modelleri, eğitim sırasında işlenmemiş verilerin önemli özelliklerini öğrenirken, sonraki katmanlar sınıflandır-



Şekil 1. Evrişimsel sinir ağı örnek mimarisi. Sabit bir matris boyutundaki (örneğin; 512 x 512) girdiye her evrişim işlemi sonrası yeni katmanlar eklenmekte, kompleksiteyi azaltmak için maksimum havuzlama ile matris boyutu küçültülmekte ve sonunda tamamen birbirine bağlı nöron yapılarına (fcn) matris elemanları beslenmektedir. Sonuç değişkenine göre ilgili yapı özelleştirilerek farklı mimariler oluşturulabilmektedir.



Şekil 2. Makine öğrenmesi ve derin öğrenmede özellik çıkarımı aşamasındaki fark.

ma gerçekleştirir. Sinir ağlarının eğitimi bu sistemlerin yinelemeli olarak eğitim verisindeki tahminlerinin gerçek sonuçlarla kıyaslanması ve buradan elde edilen geri besleme mekanizmasıyla fonksiyon ağırlıklarının değiştirilmesiyle gerçekleştirilir. Veriye dayalı olarak başarıyı değiştiren bu sistemlerde büyük veri kümelerinin ve bilgisayar hesaplama gücünün kullanılabilirliği kritiktir.

Modern internetin ortaya çıkması, erişilebilir verilerin artışıyla birlikte hesaplama hızı ve kapasitesindeki gelişmeler, DÖ'nün önemli destekçileri olmuştur. Derin sinir ağı eğitimi süreci hesaplama açısından yoğundur, ancak ağı eğitildikten sonra yeni verilerin işlenmesi son derece hızlı ve verimli olabilmektedir.

GÖRÜNTÜLEME ÖNCESİ PLANLAMA ve GÖRÜNTÜ KALİTESİ

Hastaların tanı, takip, tedavi planlama ve operasyon öncesi hazırlığında uygun görüntüleme yönteminin ve protokolün belirlenmesi kompleks bir süreçtir. Bu aşamada maliyet etkin bir yöntemle en uygun görüntüleme yöntemi ve protokolün tercih edilmesi gerekmektedir. Uygun planlanmamış bir görüntüleme iyonize radyasyon içeren bilgisayarlı tomografi (BT) gibi görüntüleme çalışmalarını neticesinde hastanın fazla radyasyon almasına, kontrastlı incelemelerde gereksiz kontrast madde kullanımına neden olabilmektedir. Ek olarak gerekli olmayan istemler sonucunda iş yükü planlamasında sorunlar ortaya çıkmaktadır.^[2]

Literatürde görüntüleme yöntem ve protokollerinin optimizasyonuna yönelik otomatize sistemler önerilmiştir. Trivedi ve ark. KİS'e yönelik manyetik rezonans (MR)

görüntüleme protokollerinde intravenöz (IV) kontrast kullanım ihtiyacını otomatik olarak belirleyen bir makine öğrenmesi temelli doğal dil sınıflandırma algoritması kullanmışlardır.^[3] Toplam 1.480 adet MR protokolüyle eğitilen ve doğrulaması yapılan model, kıyasla IV kontrast kullanım ihtiyacında orijinal protokole %83,2, ikinci bir değerlendiriciyle kıyaslandığında ise %88,6 doğruluk oranına ulaşmıştır. Eğitim için 5.258, test için 1.018 hastaya ait MR istem verisi (istem yapan birim, hasta yaşı, cinsiyeti, inceleme bölgesi ve kontrast madde kullanımı) kullanılan başka bir tek merkezli çalışmada ESA modeli eğitilerek MR görüntüleme öncesi rutin protokol ve tümör protokolü ihtiyacı %95,76 özgüllük, %92,10 duyarlılık ile tahmin edilmiştir.^[4] Bu çalışmalar, görüntüleme protokollerini optimize etme ve iş akışı verimliliğini arttırmada makine öğrenimi ve derin öğrenme tekniklerini kullanmanın fizibilitesini göstermektedir.

Protokol optimizasyonuna ek olarak, uygunsuz kas-iskelet sistemi radyografisi taleplerini belirlemek için makine öğrenimi ve doğal dil işleme teknikleri uygulanabilir. Hugh ve ark. %24,5'i uygunsuz istemlerden oluşan 50.000 adet direkt grafiyle düşük kaliteli radyoloji istemlerini otomatik olarak belirlemek için Naïve Bayes sınıflandırıcısı kullanmış ve %98'lik bir doğruluk elde etmişlerdir.^[5] Görüntüleme yöntemlerinin hasta bazında gerekliliğinin objektif ve doğru biçimde tespit edilmesi sağlık sisteminin ortaya çıkardığı yüksek maliyetin azaltılması ve hasta güvenliğinin artırılması için oldukça etkin bir yaklaşımdır. Bu çalışmalar gelecekte bu amaca hizmet edebilecek otomatize sistemlerin uygulanabilirliğini ortaya koymaktadır.

Kas-iskelet sistemi görüntüleme kalitesinin yazılımsal olarak artırılmasına yönelik güncel çalışmalar mevcuttur. Chaudhari ve ark. geliştirdikleri *DeepResolve* isimli nöral ağ ile kalın kesit diz MR görüntülerini tanısallık kaliteyi bozmadan ince kesit görüntülere dönüştürmüşlerdir.^[6] Geliştirilen algoritma çıktıları iki ayrı yorumlayıcı tarafından değerlendirilmiş, geleneksel (konvansiyonel) trikübik ve *fourier* interpolasyon yöntemlerine kıyasla daha başarılı sonuçlar elde edilmiştir ($p < 0,01$, yorumlayıcılar arası uyum $\kappa = 0,73$). Zhang ve Yu, BT görüntülerindeki metal artefaktlarını azaltmak için bir ESA geliştirmiştir.^[7] Önerilen yöntem, artefaktların baskılanması ve metal implantların yakınındaki anatomik yapıların korunmasında diğer tekniklerden daha iyi performans göstermektedir. Çalışma, bu yaklaşımın hem simüle edilmiş hem de gerçek veriler üzerindeki etkinliğini ortaya koymakta ve BT görüntüsünde metal artefaktların azaltılması için umut verici bir çözüm sunmaktadır.

OTOMATİK LEZYON TESPİTİ


Nesne tanıma, dijital görüntülerde ve videolarda belirli bir sınıftaki (insanlar, binalar veya arabalar gibi) nesnelere algılamakla ilgilenen bir bilgisayar teknolojisidir.^[8] Bir nesne tanıma algoritması, görüntüde bulunan her nesne için bir sınırlayıcı kutu ve her bir sınırlayıcı kutuyla ilişkili olarak, içerdiği nesnenin türünü verir (Şekil 3).^[9]

Son yıllarda KİS'te nesne tanıma yöntemleri ile MR, direkt radyografi, BT, ultrasonografi (US) görüntülerini kullanarak kırık (fraktür) varlığı, kırık (kartilaj) defekt-

leri-menisküs yırtıkları, kemik metastazları, rotator manşet patolojileri gibi birçok KİS bulgusu tespit edilebilmektedir.^[10-13]

Yapay zekâ algoritmalarını kullanarak menisküs ve ön çapraz bağ (*anterior cruciate ligament, ACL*) yırtığını otomatik olarak tespit eden birçok araştırma bulunmaktadır. Yine bazı çalışmalar menisküs yırtıklarının derecelendirilmesi ve tiplendirmesi konusuna değinmiştir. Bien ve ark. 1.370 adet diz MR görüntüsü kullandıkları model ile ACL ve menisküs yırtıklarını sırasıyla %95 ve %84 doğrulukla tespit edebilmişlerdir.^[11] Artroskopi incelemelerinin referans olarak kullanıldığı Liu ve ark.'nın çalışmasında 175 adet diffüz kalın ve 175 adet normal ACL MR görüntüsü kullanılmıştır.^[14] Modelin ACL yırtığını tespit etme duyarlılık ve özgüllüğünü %96 olarak belirtmişlerdir.

Kemik kırıkları acil servislerde çok yaygın görülen ortopedi ve travmatoloji alanındaki acil başvuru sebeplerinden biridir. Literatürde çok sayıda, farklı anatomik bölgelerde, farklı YZ modelleriyle otomatik kırık tespiti çalışması bulunmaktadır. Oka ve ark.'nın el bilek grafisiyle yaptıkları ve distal radius kırıklarını nesne tanıma modeliyle tespit ettikleri çalışmada, modelin anteroposterior (AP) grafilerde duyarlılık ve özgüllüğü sırasıyla $95 \pm 3,1$ ve $97 \pm 2,6$ olarak bulunmuştur.^[10] Xue ve ark.'nın 3.067 adet el grafisindeki kırıkları tespit etmek amacıyla *Faster R-CNN* derin öğrenme tabanlı nesne tanıma algoritmasını kullandıkları çalışmada ortalama kesinlik (mAP) değeri %70,7 ve F-1 skoru %86,6 olarak bulunmuştur.^[15]



Şekil 3. Direkt grafide nesne tanıma algoritma tahmini. Sağ el oblik grafide birinci distal falankta bifid falanks ve dördüncü falanks bazisinde ayrışmamış (*non-deplase*) kırık (fraktür) hattı gözleniyor (a). Sağdaki model tahmininde sadece kırık olan yere kutucuk yerleştirip doğru tahmin gerçekleştiriyor (b).

Cheng ve ark. prostat ve meme kanseri hastalarında, kemik sintigrafilerinde toraks bölgesinde kemik metastazların tespit etme ve sınıflandırma için YOLOv4 derin öğrenme modeli geliştirmiştir.^[12] Geliştirilen modelle lezyon lokasyon tespiti %72 duyarlılık ve %90 kesinlik göstermiş, aynı zamanda hasta bazlı yapılan analizde modeller metastaz tipini sınıflandırmada %94 duyarlılık ve %92 özgüllüğe ulaşmıştır.

SINIFLANDIRMA ALGORİTMALARI

Yapay zekâ sınıflandırma algoritmalarıyla radyolojik görüntülerde var olan patolojilerin sınıflandırması yapılabilir. Kemik tümörlerinin sınıflandırılması, osteoartrit derecelendirmesi, menisküs yırtıklarının sınıflandırılması, kemik kırıklarının ve kalça protez tiplerinin sınıflandırılması gibi birçok alanda YZ sınıflandırma yöntemleri kullanılabilir.^[16-23]

Hastanın yaşı gibi demografik bilgilerin yanı sıra, tümörün radyografik görünümü, boyutu, yeri, sınırları, periost reaksiyonunun varlığı ve kortikal defekt oluşması gibi faktörler *benign* ve *malign* kemik tümörlerini ayırt etmede yardımcı olan en önemli ipuçlarıdır. Kemik tümörlerinde ana sorun *malign-benign* ayrımı yapabilmektir. Von Schacky ve ark. histopatolojik sonuçları referans alarak inceledikleri 934 adet radyografi görüntüsündeki kemik tümörlerini *benign* ve *malign* olarak sınıflandırmışlardır.^[16] Modelin kemik tümörlerini iyi huylu ve kötü huylu olarak sınıflandırmadaki doğruluğu %80,2, duyarlılığı %62,9, özgüllüğü %88,2 olarak hesaplanmıştır. Modelin doğruluk oranının iki farklı radyoloji asistanından daha iyi ve KİS radyolojisinde deneyimli radyologlara yakın olarak belirtmişlerdir. Yao ve ark. pozitron emisyon tomografisi/bilgisayarlı tomografi (PET/CT) incelemesinde vertebra metastazlarının tespiti ve karakterizasyonunu araştırdıkları çalışmalarında litik, sklerotik ve mikst tipteki lezyonları ayırıp segmente edip daha sonra sınıflandırmışlardır.^[17] Modelin test setindeki sklerotik, litik ve mikst lezyon tespit etme duyarlılığı sırasıyla %81, %81 ve %76 olarak ölçülmüştür. Kemik tümörlerini MR görüntülerini kullanarak *benign* ve *malign* olarak sınıflandıran başka bir çalışmada histopatolojik olarak doğrulanmış 1.060 adet farklı kemik lezyonunun ameliyat öncesi T1 ve T2 ağırlıklı görüntüleri kullanılmıştır.^[18] Bu çalışmada bulgular radyolog verileriyle karşılaştırılmış ve radyologlarla benzer doğruluk, özgüllük ve duyarlılık değerleri elde edilmiştir.

Osteoartrit progresyonunun ön görülmesi oldukça zor ve zaman alıcı bir süreçtir. Ancak hastanın tanı ve tedavi protokolünün belirlenmesinde bu süreç önemli bir rol oynar. Doğru tedavi ile birçok total eklem protezi ameliyatının önüne geçilebilir ve maliyet etkin yaklaşım-

lar sergilenebilir. Tiulpin ve ark. 3.918 diz radyografisinin osteoartrit derecelendirmesini evrimsel sinir ağları (ESA) modeliyle sınıflandırıp umut verici sonuçlar elde etmiştir.^[19] Liu ve ark. diz eklemindeki kıkırdak dejenerasyonunu ve akut kıkırdak hasarında geliştirdikleri sınıflandırma modelinin KİS radyolojisinde farklı deneyimlere sahip radyologlar ile benzer tanısal performansla sahip olduğunu ifade etmişlerdir.^[20]


Pedoia ve ark. yaptıkları çalışmada geliştirdikleri U-net tabanlı derin öğrenme modeliyle menisküs yırtıklarının derecelendirilmesini ve patellofemoral kıkırdak (kartilaj) lezyon tespitini değerlendirmişlerdir.^[24] Çalışmayla menisküs lezyonları tespitinde %89,81 duyarlılık ve %81,98 özgüllük, kıkırdak lezyonu tespitinde ise %80,0 duyarlılık ve %80,27 özgüllüğe ulaşmıştır.

Olczak ve ark. ResNet mimarisinden oluşan derin sinir ağıyla ayak bileği radyografilerini AO Foundation/Orthopedic Trauma Association (AO/OTA) 2018 sınıflandırmasına göre sınıflamayı amaçlamıştır.^[22] Araştırmacılar geliştirdikleri modelin en yaygın büyük kırıklar olan mal-leolar tip B kırıklarını sınıflandırmada %93 eğri altında kalan alan (*area under the curve*, AUC) değerine ulaştığını göstermiştir.

Murphy ve ark. 10 farklı ESA modeli kullanarak radyografi görüntüleriyle revizyon gerektiren başarısız kalça protezlerindeki implantları, sıklıkla kullanılan sekiz farklı model/markaya göre sınıflandırmışlar ve nihai modelle telefon uygulaması geliştirmişlerdir.^[23] Bu çalışma revizyon cerrahisi için implant tanımlamasında cerrahlara zaman kazandırma potansiyelini ortaya koymuştur.

SEGMENTASYON ve OTOMATİK ÖLÇÜM

Kas-iskelet sisteminde el-el bilek grafilerinde kemik yaşı tayini, ayak grafilerinde pes planus tespiti için kalkaneal inklinasyon açısı, skolyoz tanısı ve takibinde kullanılan Cobb açısı gibi çeşitli ölçümlere yönelik YZ uygulamaları güncel literatürde karşımıza çıkmaktadır.^[25-27] İki boyutlu görüntüler üzerinden yapılan ölçümlere ek olarak BT veya MR görüntülemeye olduğu gibi üç boyutlu görüntülemelerde belirli bir anatomik yapıya ait tüm vokseller işaretlenerek volumetrik ölçümler de elde edilebilmektedir.^[28] Segmentasyon terimi bir görüntüdeki objelerin piksel veya vokselle bazlı sınıflandırılmasını ifade eder (Şekil 4). Güncel makine öğrenmesi ve derin öğrenme algoritmalarıyla çeşitli anatomik yapıların ve lezyonların iki veya üç boyutlu segmentasyonu otomatik olarak gerçekleştirilebilmekte, bu yolla objektif ve hassas ölçümler yapılabilmektedir. Örnek olarak kemik yaşı tayininde araştırmacılar %97,6'ya ulaşan bir doğrulukla sol el bilek grafilerinde bir derin öğrenme modeli geliştirmişlerdir.^[25] Araştırmacılar geliştirdikleri modelle insan faktörlerinden



Şekil 4. Sagittal planda diz MR kesitlerinde efüzyon (mavi), medial menisküs (sarı) ve lateral menisküs (kırmızı) segmentasyon örneği.

etkilenen ve oldukça vakit alan bu değerlendirmeyi otomatize etmişlerdir.

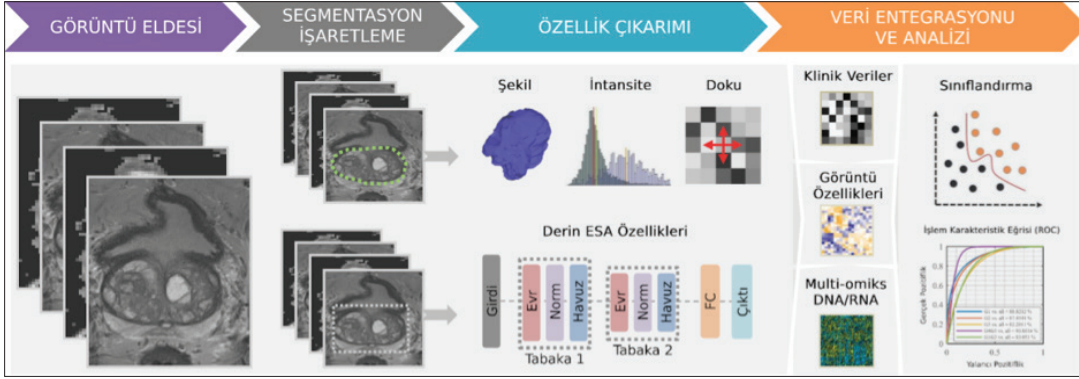
Gül ve ark. 14-47 yaş aralığındaki 439 hastanın pes planusa yönelik lateral direkt grafilerinden oluşan veri setiyle geliştirdikleri otomatize pes planus teşhisi yapan bir algoritma öne sürmüşlerdir.^[26] Bu çalışmada ön eğitimi yapılmış *MobileNetV2* isimli bir derin öğrenme model mimarisine elde edilen grafilerden özellik çıkarımı yapılmış ve çıkarılan özelliklerle “*Support Vector Machine (SVM)*” eğitilerek %95,14 doğruluk ile pes planus sınıflandırması yapılmıştır.

İskelet kası segmentasyonu ortopedi ve travmatoloji alanındaki girişimlerde girişim öncesi kasların pozisyon ve hacimlerinin, kas atrofilerinin değerlendirilmesinde yardımcı bir yöntemdir.^[28,29] Özellikle üç boyutlu görüntüleme yöntemlerinde bir anatomik yapının volümetrik analiz için manuel olarak işaretlenmesi saatler sürebilen ve uzmanlık gerektiren bir iştir. Bu sürecin otomatize, kullanıcı bağımsız, objektif ve doğru bir şekilde gerçekleştirilebilmesi için Hiasa ve ark. *The Cancer Imaging Archive (TCIA)* veri tabanından elde ettikleri BT görüntüleri ile 19 ayrı kas grubunda U-net derin öğrenme mimarisini kullanarak %84,5’e ulaşan ortalama örtüşme *dice* skoru elde etmişlerdir.^[29] Omuz manşetindeki kasların segmentasyonu için sagittal MR görüntülerinde ESA

kullanılarak yapılan başka bir çalışmada ise örtüşme skorlarının %90 üzerine çıktığı gösterilmektedir.^[30]

Anatomik yapıların segmentasyonu bu yapılar arasındaki uzaklık, açı gibi ilişkilerin de temel matematiksel hesaplamalarla otomatik olarak tespitine imkân sağlamaktadır. Pei ve ark. genu varum ve valguma yönelik çekilen alt ekstremitte direkt grafilerinde femur başı, femoral kondiller ile tibia proksimali ve ayak bileğinde otomatik segmentasyon algoritması geliştirilerek segmente edilen yapıların merkez noktasını formüle etmiş, kalça-diz-ayak bileği açısını otomatik olarak hesaplamışlardır.^[31] Üç yüz doksan sekiz çift (sağ ve sol) direkt grafi kullandıkları çalışmalarında U-net mimarisini ile belirtilen anatomik yapıları %83 ve üzeri örtüşme oranlarıyla tahmin etmiş ve manuel ölçümlere kıyasla yalnızca 0,49°’lik bir farkla açı ölçümü yapabilmişlerdir.

Sonuç olarak segmentasyon ve otomatik ölçüm amacıyla KİS görüntülemeye yönelik araştırmalar oldukça çeşitli alanlarda ve farklı klinik ihtiyaçlara yönelik gerçekleştirilmekte olup bu araştırmalarda umut verici sonuçlar elde edilmektedir. Yakın gelecekte sınıflandırma, segmentasyon ve regresyona dayalı yöntemlerin birlikte kullanılarak bir uzmanlık alanındaki genel uygulamalara tek bir platformda entegre edilmesi ve görüntü, klinik veri, laboratuvar verisi gibi multimodal verilerle daha doğru



Şekil 5. Radyomiks çalışmalarda tercih edilen araştırma basamakları. Chaddad ve ark.'nın yayınladığı "Magnetic Resonance Imaging Based Radiomic Models of Prostate Cancer: A Narrative Review" makalesinden Türkçeleştirilerek alınmıştır.^[32]

sonuçlar veren geliştirilebilir modellerin geliştirilmesi için daha ileri araştırmalara da ihtiyaç vardır.

RADYOMİKS ANALİZ ve PROGNOSTİK TAHMİN

Radyomiks, kantitatif görüntülemenin bir alt alanıdır ve hastalığa özgü paternleri ortaya çıkarabilmek için medikal görüntülerden çok boyutlu verilerin çıkarılmasını içerir (Şekil 5).^[32] Bu yaklaşımın, özellikle YZ algoritmalarıyla birlikte kullanıldığında, KİS görüntü analizinde doğruluk ve etkinliği artıracağı beklenilmektedir. Hasta sonlanımı ve prognostik tahminde özellikle radyomiks analiz ve YZ yöntemlerinin potansiyeli farklı çalışmalarla gösterilmiştir.

Lee ve ark. *benign* ve *malign* yumuşak doku tümörlerinin ayrımında T1, T2, kontrastlı T1, diffüzyon ve ADC sekanslara dayalı MR görüntüleri üzerinde radyomiks özellik çıkarımı yapmış ve geliştirdikleri ortak *ensemble* modeller ile %77,4 düzeyinde AUC (eğri altında kalan alan) değeri elde etmişlerdir.^[33] Araştırmacılar öne sürdükleri yöntemde özellik çıkarımını farklı sekanslardan yaparak geliştirilebilir ve daha hassas özellikler elde edebilmiş, ortak modellemenin önemini de vurgulamışlardır. Osteoartritte D vitamini etkileri (VIDEO) çalışmasından elde edilen 216 hasta verisiyle gerçekleştirilen başka bir çalışmada, hastaların demografik ve klinik verileri ile diz MR'larından çıkarılan radyomiks özellikler kullanılmış, lojistik regresyon modelleme ile iki yıl içerisinde diz ağrısındaki iyileşme %80 AUC ile tahmin edilmiştir.^[34]

Hasta prognozunun tedavi öncesi tahmin edilebilmesi, uygun tedavi seçimi, tedavi başarımının artırılması ve hastaya özel yaklaşımların geliştirilebilmesi için potansiyel oluşturmaktadır. Zhao ve ark.'nın 112 hasta (9-67 yaş) üzerinde yaptığı bir çalışma, difüzyon ağırlıklı manyetik rezonans görüntüleme (DWI-MRI) ile elde edilen radyomiks özellikler ile lokalize osteosarkomda genel sağkalım (GS) tahmini yapmayı amaçlamıştır.^[35] Çalışmada, tümör boyutu, tedavi öncesi alkalin fosfat (ALP) seviyesi ve kemoterapi süresinin osteosarkomun GS süresiyle

ilişkili klinik prognostik faktörler olduğu bulunmuştur. Radyomiks özelliklerin, klinik risk faktörlerinden bağımsız olarak GS ile anlamlı şekilde ilişkili olduğu gösterilmiştir (HR= 5,11, %95 CI= 2,85, 9,18, p< 0,001). Çalışmada, radyomiks özellikler ile geleneksel klinik risk faktörlerinin kombinasyonunun osteosarkomlu hastalarda bireysel GS tahmininde daha iyi performans gösterdiği sonucuna ulaşılmıştır (C-indeksi: 0,813; %95 CI= 0,75, 0,89).

Kas-iskelet sistemi görüntülemeye YZ algoritmalarının umut verici sonuçlarına rağmen ele alınması gereken birkaç zorluk ve sınırlama bulunmaktadır. Bunların başında, özellikle nadir kas-iskelet sistemi kötü huylu tümörleri için eğitim ve doğrulama amacıyla kullanılacak büyük, yüksek kaliteli veri setlerinin kısıtlılığı gelmektedir. Ayrıca, YZ'nin klinik uygulamaya entegrasyonu, veri gizliliği, etik hususlar ve düzenleyici onayla ilgili endişeleri ele almayı gerektirmektedir. Gelecekteki araştırmalar, KİS görüntülemeye MÖ ve DÖ algoritmalarının klinik faydasını doğrulamaya, yukarıda belirtilen sınırlamaları ele almaya ve bu alandaki radyomiks ve kantitatif analiz potansiyelini keşfetmeye odaklanmalıdır.

SONUÇ

Sonuç olarak, yapay zekâ teknikleri, özellikle makine öğrenimi ve derin öğrenme, kas-iskelet sistemi görüntülemesi alanında umut verici ilerlemeler göstermiştir. Bu teknikler, tıbbi görüntülemenin çeşitli yönlerine uygulanmıştır, bunlar arasında; görüntüleme öncesi planlama ve görüntü kalitesi iyileştirme, otomatik lezyon tespiti, sınıflandırma ve otomatik ölçüm, klinik sonuçlar ve prognoz tahmini bulunmaktadır. Yapay zekâ uygulamalarındaki bu ilerlemeler, kas-iskelet sistemi görüntülemesi için tanı doğruluğunu ve duyarlılığını artırma, iş akışı verimliliğini geliştirme ve nihayetinde daha iyi hasta yönetimi sağlama potansiyeline sahiptir. Bununla birlikte, bu tekniklerin güvenilirliğini, geliştirilebilirliğini ve klinik uygulanabilirliğini sağlamak için potansiyel olarak farklı veri

kaynaklarını kullanabilen, genelleştirilebilir, multi-modal algoritmalara ve bunlara rutin pratikte erişim kolaylığı sağlayabilecek yazılımlara ihtiyaç vardır.

KAYNAKLAR

- Martin-Carreras TT, Li H, Chen PH. Interpretative applications of artificial intelligence in musculoskeletal imaging: Concepts, current practice, and future directions. *J Med Artif Intell* 2020;3. [Crossref](#)
- Gorelik N, Gyftopoulos S. Applications of artificial intelligence in musculoskeletal imaging: From the request to the report. *Can Assoc Radiol J* 2021;72(1):45-59. [Crossref](#)
- Trivedi H, Mesterhazy J, Laguna B, Vu T, Sohn JH. Automatic determination of the need for intravenous contrast in musculoskeletal MRI examinations using IBM Watson's natural language processing algorithm. *J Digit Imaging* 2018;31:245-51. [Crossref](#)
- Lee YH. Efficiency improvement in a busy radiology practice: Determination of musculoskeletal magnetic resonance imaging protocol using deep-learning convolutional neural networks. *J Digit Imaging* 2018;31:604-10. [Crossref](#)
- Hugh Z, Alabousi A, Mironov O. Classification of musculoskeletal radiograph requisition appropriateness using machine learning. *Can Assoc Radiol J* 2023;74(1):93-9. [Crossref](#)
- Chaudhari AS, Fang Z, Kogan F, Wood J, Stevens KJ, Gibbons EK, et al. Super-resolution musculoskeletal MRI using deep learning. *Magn Reson Med* 2018;80(5):2139-54. [Crossref](#)
- Zhang Y, Yu H. Convolutional neural network based metal artifact reduction in x-ray computed tomography. *IEEE Trans Med Imaging* 2018;37(6):1370-81. [Crossref](#)
- Dasiopoulou S, Mezaris V, Kompatsiaris I, Papastathis VK, Strintzis MG. Knowledge-assisted semantic video object detection. *IEEE IEEE Trans Circuits Syst Video Technol* 2005;15(10):1210-24. [Crossref](#)
- Chen YW, Jain LC. Deep learning in healthcare. Paradigms and applications. Springer, Heidelberg. 2020. [Crossref](#)
- Oka K, Shiode R, Yoshii Y, Tanaka H, Iwahashi T, Murase T. Artificial intelligence to diagnosis distal radius fracture using biplane plain X-rays. *J Orthop Surg Res* 2021;16(1):1-7. [Crossref](#)
- Bien N, Rajpurkar P, Ball RL, Irvin J, Park A, Jones E, et al. Deep-learning-assisted diagnosis for knee magnetic resonance imaging: development and retrospective validation of MRNet. *PLoS Med* 2018;27:15. [Crossref](#)
- Cheng DC, Hsieh TC, Yen KY, Kao CH. Lesion-based bone metastasis detection in chest bone scintigraphy images of prostate cancer patients using pre-train, negative mining, and deep learning. *Diagnostics* 2021;11(3):518. [Crossref](#)
- Esfandiari MA, Tafti MF, Dabanloo NJ, Yousefirizi F. Detection of the rotator cuff tears using a novel convolutional neural network from magnetic resonance image (MRI). *Heliyon* 2023;9(5). [Crossref](#)
- Liu F, Guan B, Zhou Z, Samsonov A, Rosas H, Lian K, et al. Fully automated diagnosis of anterior cruciate ligament tears on knee MR images by using deep learning. *Radiol Artif Intell* 2019;1(3):180091. [Crossref](#)
- Xue L, Yan W, Luo P, Zhang X, Chaikovska T, Liu K, et al. Detection and localization of hand fractures based on GA_Faster R-CNN. *Alex Eng J* 2021;60(5):4555-62. [Crossref](#)
- von Schacky CE, Wilhelm NJ, Schäfer VS, Leonhardt Y, Gassert FG, Foreman SC, et al. Multitask deep learning for segmentation and classification of primary bone tumors on radiographs. *Radiol* 2021;301(2). [Crossref](#)
- Yao J, Burns JE, Sanoria V, Summers RM. Mixed spine metastasis detection through positron emission tomography/computed tomography synthesis and multiclassifier. *J Med Imag* 2017;4(2):024504. [Crossref](#)
- Eweje FR, Bao B, Wu J, Dalal D, Liao WH, He Y, et al. Deep learning for classification of bone lesions on routine MRI. *EBioMedicine* 2021;68. [Crossref](#)
- Tiulpin A, Klein S, Bierma-Zeinstra SM, Thevenot J, Rahtu E, Meurs JV, et al. Multimodal machine learning-based knee osteoarthritis progression prediction from plain radiographs and clinical data. *Sci Rep* 2019;9(1):20038. [Crossref](#)
- Liu F, Zhou Z, Samsonov A, Blankenbaker D, Larison W, Kanarek A, et al. Deep learning approach for evaluating knee MR images: Achieving high diagnostic performance for cartilage lesion detection. *Radiol* 2018;289(1):160-9. [Crossref](#)
- Rizk B, Brat H, Zille P, Guillin R, Pouchy C, Adam C, et al. Meniscal lesion detection and characterization in adult knee MRI: A deep learning model approach with external validation. *Physica Medica* 2021;83:64-71. [Crossref](#)
- Olczak J, Emilson F, Razavian A, Antonsson T, Stark A, Gordon M. Ankle fracture classification using deep learning: Automating detailed AO Foundation/Orthopedic Trauma Association (AO/OTA) 2018 malleolar fracture identification reaches a high degree of correct classification. *Acta Orthop* 2020;92(1):102-8. [Crossref](#)
- Murphy M, Killen C, Burnham R, Sarvari F, Wu K, Brown N. Artificial intelligence accurately identifies total hip arthroplasty implants: A tool for revision surgery. *Hip Int* 2022;32(6):766-70. [Crossref](#)
- Pedraza V, Norman B, Mehany SN, Bucknor MD, Link TM, Majumdar S. 3D convolutional neural networks for detection and severity staging of meniscus and PFJ cartilage morphological degenerative changes in osteoarthritis and anterior cruciate ligament subjects. *J Magn Reson Imaging* 2019;49(2):400-10. [Crossref](#)
- Han Y, Wang G. Skeletal bone age prediction based on a deep residual network with spatial transformer. *Comput Methods Programs Biomed* 2020;197:105754. [Crossref](#)
- Gül Y, Yaman S, Avcı D, Çilengir AH, Balaban M, Güler H. A novel deep transfer learning-based approach for automated pes planus diagnosis using x-ray image. *Diagnostics* 2023;13(9):1662. [Crossref](#)
- Tu Y, Wang N, Tong F, Chen H. Automatic measurement algorithm of scoliosis Cobb angle based on deep learning. *InJournal of Physics: Conference Series* 2019;1187(4):042100. [Crossref](#)
- Kamiya N. Muscle Segmentation for Orthopedic Interventions. *Adv Exp Med Biol* 2018;1093:81-91. [Crossref](#)
- Hiasa Y, Otake Y, Takao M, Ogawa T, Sugano N, Sato Y. Automated muscle segmentation from clinical CT using

- Bayesian U-Net for personalized musculoskeletal modeling. *IEEE Trans Med Imaging* 2019;39(4):1030-40. [Crossref](#)
30. Medina G, Buckless CG, Thomasson E, Oh LS, Torriani M. Deep learning method for segmentation of rotator cuff muscles on MR images. *Skeletal Radiol* 2021;50(4):683-92. [Crossref](#)
 31. Pei Y, Yang W, Wei S, Cai R, Li J, Guo S, et al. Automated measurement of hip-knee-ankle angle on the unilateral lower limb X-rays using deep learning. *Phys Eng Sci Med* 2021;44(1):53-62. [Crossref](#)
 32. Chaddad A, Kucharczyk MJ, Cheddad A, Clarke SE, Hassan L, Ding S, et al. Magnetic resonance imaging based radiomic models of prostate cancer: A narrative review. *Cancers* 2021;13(3):552. [Crossref](#)
 33. Lee S, Lee SY, Jung JY, Nam Y, Jeon HJ, Jung CK, et al. Ensemble learning-based radiomics with multi-sequence magnetic resonance imaging for benign and malignant soft tissue tumor differentiation. *Plos One* 2023;18(5):e0286417. [Crossref](#)
 34. Lin T, Peng S, Lu S, Fu S, Zeng D, Li J, et al. Prediction of knee pain improvement over two years for knee osteoarthritis using a dynamic nomogram based on MRI-derived radiomics: A proof-of-concept study. *Osteoarthritis Cartilage* 2023;31(2):267-78. [Crossref](#)
 35. Zhao S, Su Y, Duan J, Qiu Q, Ge X, Wang A, et al. Radiomics signature extracted from diffusion-weighted magnetic resonance imaging predicts outcomes in osteosarcoma. *J Bone Oncol* 2019;19:100263. [Crossref](#)