

Medikal Görüntüleme ve Yapay Zekâ

Süreyya Nur¹

Özet

Tıbbi görüntülemede yapay zekânın ortaya çıkmasının ardındaki temel itici güç, klinik açısından verimliliği arttırmaktır. Radyolojik görüntüleme verileri sürekli artarken, bu verileri değerlendirecek uzman sayısının sınırlı kalması, yorumlama ve raporlama süreçlerini giderek zorlaştırmaktadır. Bu tür değerlendirmeler genellikle eğitim ve deneyime dayanır ve zaman zaman öznel olabilir. Bu tür nitel değerlendirmeler, yapay zekâ görüntüleme verileri ile karmaşık kalıpları tanımada üstündür ve otomatik bir şekilde nicel bir değerlendirme sağlayabilir. Yapay zekâ, radyolojik tetkikleri uygulayan ve bu tetkikleri yorumlayan uzmanlara yardımcı olmak için bir araç olarak klinik iş akışına entegre edildiğinde daha doğru ve tekrarlanabilir radyoloji değerlendirmeleri yapabilir. Birçok tıbbi durumla ilgili araştırmalar, daha hızlı ve tekrarlanabilir nicel görüntüleme belirteçlerinin geliştirilmesine olanak sağlayarak bu yaklaşımlardan büyük ölçüde faydalanmıştır. Bu belirteçler, hastalık teşhisine, prognozun belirlenmesine, tedavi için hasta seçimine ve tedaviye verilen yanıtların takibine yardımcı olmak için kullanılmıştır. Bu tür yapay zekâ programları ile, bilgisayarlı tomografi ve manyetik rezonans görüntülemede, vücut genelindeki organ ve dokuların otomatik segmentasyonu arttırılmıştır.

Bu bölümün amacı, yapay zekâ uygulamalarının; radyografi, oral radyoloji, mamografi, ultrasonografi, bilgisayarlı tomografi ve manyetik rezonans görüntüleme gibi farklı modalitelerde görüntü kalitesinin artırılması, artefaktların azaltılması, lezyon tespiti ve sınıflandırmasının otomatikleştirilmesi ile tanısal doğruluğun yükseltilmesine önemli katkılar sağlamaktır. Derin öğrenme temelli algoritmalar, klinik iş akışını ve radyolojik tetkiklerin uygulanmasını optimize ederken, radyologların karar destek süreçlerini güçlendirmekte ve hasta yönetiminde daha hızlı, güvenilir ve standardize yaklaşımların geliştirilmesine olanak tanımaktadır.

1 Dr. Öğr. Üyesi, Hatay Mustafa Kemal Üniversitesi, Hatay Sağlık Hizmetleri MYO, Orcid:0000-0002-8504-5309, sureyyanur@mku.edu.tr

1. GİRİŞ

1890'lardaki X-ışını görüntülemenin ilk günlerinden BT ve MR taramalarındaki son gelişmelere kadar, tıbbi görüntüleme tıbbi tedavinin temel taşlarından biri olmaya devam etmektedir. Görüntüleme donanımlarındaki mevcut gelişmeler (kalite, hassasiyet ve çözünürlük açısından) doku yoğunluklarındaki küçük farklılıkların ayırt edilmesini mümkün kılmaktadır. Bu tür farklılıkların, bazı durumlarda eğitimli bir göz ve hatta klinikte kullanılan bazı geleneksel yapay zekâ yöntemleri tarafından fark edilmesi zordur. Önceden tanımlanmış özelliklere dayalı geleneksel yöntemlerin aksine, derin öğrenme algoritmalarının verilerle ölçeklendirilmesi; yani her gün veri üretildikçe ve devam eden araştırma çalışmalarıyla performansta göreceli iyileştirmeler görülmesi beklenmektedir [Hosny vd, 2018].

Radyoloji, kuruluşundan bu yana devrim niteliğinde bir yolculuk geçirmiş ve modern tıbbi derin etkisiyle etkilemiştir. X-ışınlarının keşfinden yapay zekâ (YZ) ve makine öğreniminin (ML) entegrasyonuna kadar, bu çok yönlü disiplin sürekli olarak gelişmekte, kendini ve temelini oluşturduğu sağlık ekosistemini dönüştürmektedir [Najjar, 2023].

Yapay zekâ (YZ), son zamanlarda algı (duyusal bilgilerin yorumlanması) alanında önemli ilerlemeler kaydederek makinelerin karmaşık verileri daha iyi temsil etmesini ve yorumlamasını sağlamıştır. YZ algoritmaları, özellikle derin öğrenme, görüntü tanıma görevlerinde kayda değer ilerlemeler göstermiştir [Pàmies, 2017; Hosny vd, 2018]. Derin öğrenme, insan beyninden esinlenen bir sinir ağı yapısına benzeyen makine öğrenmesinin bir alt kümesidir. Bu tür yapılar, verilerden ayırt edici özellikleri otomatik olarak öğrenerek, çok karmaşık doğrusal olmayan ilişkileri tahmin etme yeteneği kazanır. İlk çıkan YZ yöntemlerinin çoğu insan altı performansa sahip uygulamalara yol açmış olsa da, yeni derin öğrenme algoritmaları, göreve özgü uygulamalarda insanlarla eşleşebilmekte ve hatta onları geçebilmektedir [Hosny vd, 2018; Mnih vd, 2015; Moravčík vd, 2017; Xiong vd, 2017; Pendleton vd, 2017]. Bunun nedeni, mevcut olan yüksek miktardaki dijital veriyi, modern ve güçlü hesaplama donanımlarını, YZ araştırmalarındaki algoritmaların eğitiminde kullanılmasıdır.

Sonuç olarak, bilgisayar destekli sınıflandırma veya tanı, sağlık hizmetlerindeki kaçınılmaz hataları ve içsel tanı değişkenliklerini azaltmalı, rehberlik sağlamalı ve özellikle ameliyathanede karar alma süreçlerini hızlandırmalıdır. Makine öğreniminin sağlık hizmetlerine getireceği görünüşte engin ve umut verici fırsatlar, aynı zamanda bireysel hasta düzeyinde hassas tıp ve hastalık yönetimini de ilerletmelidir.

Bu bölümde, medikal görüntüleme alanında yapay zekânın temel kavramları, gelişim süreci ve klinik uygulamaları ele alınmaktadır. Makine öğrenmesi ve derin öğrenme yaklaşımlarının radyolojik görüntülerin elde edilmesi, işlenmesi ve yorumlanmasındaki rolü açıklanmakta; tanısal doğruluğun artırılması, iş yükünün azaltılması ve karar destek sistemlerinin gelişimi vurgulanmaktadır.

2. Radyografi Görüntülemede Yapay Zekâ

Radyoloji, disiplinler arası tıbbi ekiplerin karmaşık mekanizmasında hayati bir dişli görevi görür. Radyologlar, hassas ve zamanında görüntüleme raporları sunarak çeşitli uzmanlar arasındaki iletişimi geliştirir ve kritik kararları şekillendirir; bu da bütünsel, hasta odaklı bir sağlık hizmeti yaklaşımına katkıda bulunur [Hosny vd, 2018].

Tıbbi Görüntüleme, invaziv prosedürler olmadan iç yapıların görselleştirilmesini sağlayarak çeşitli hastalıkların teşhisine yardımcı olur. Tıbbi Görüntü İşleme teknolojisinin çoğu, hastalık tahminini, tespitini, analizini ve değerlendirmesini daha da geliştirmiştir. Tıbbi görüntülerin insan yorumlaması hataya yatkın olduğundan, bu veriler, tıbbi yardım ve öğrenmeyi geliştiren akıllı sistemler geliştirmek için Makine Öğrenimi (ML) ve Derin Öğrenme (DL) modellerinde kullanılır. Bununla birlikte, yüksek kaliteli sağlık hizmeti sunumu için doğruluk çok önemlidir. Abhisheka ve arkadaşlarının, beş Manyetik Algoritma yöntemine ilişkin yapmış olduğu kısa bir incelemeye göre x-ışını görüntülemeye, kemik analizi alanında ideal bir uygulama olduğunu belirtmiştir [Abhisheka vd, 2024].

Tıbbi görüntülemenin sağladığı anatomik, fizyolojik ve moleküler hastalık süreçleri ile ilgili karmaşık veriler, hasta bakımı üzerinde önemli bir etkiye sahip olup, tedavilerin kişiye özel olarak düzenlenmesini kolaylaştırıp, tedavi sonuçlarını iyileştirerek yan etkileri en aza indirdiği belirtilmiştir [Brady vd, 2021; Giardino vd, 2017; Jameson&Longo, 2015].

Röntgen görüntülemeye yapay zekâ (YZ), görüntü kalitesini artırma, radyolog iş yükünü azaltma ve tanısal doğruluğu yükseltme potansiyeli nedeniyle son yıllarda önemli bir araştırma ve uygulama alanı hâline gelmiştir. Derin öğrenme yöntemleri özellikle akciğer, kemik ve ortopedik patolojilerin tespitinde büyük başarı göstermiştir. Frontal göğüs röntgeni görüntülerinden zatürreyi tespit eden bir algoritma geliştiren Rajpurkar ve arkadaşları, algoritmalarının birden fazla hastalığı tespit etmek için kullandıkları veriler sayesinde, daha önce geliştirilen teknolojiyi geride bıraktığını ifade etmiştir. Uzman seviyesinde otomasyonla, bu teknolojinin sağlık hizmeti sunumunu iyileştirebileceğini ve yetenekli radyologlara erişimin sınırlı olduğu dünya

bölgelerinde tıbbi görüntüleme uzmanlığına erişimi artırabileceğini ifade etmişlerdir [Rajpurkar vd, 2017].

Gale ve arkadaşlarının kullandıkları yapay zekâ tabanlı model ile bilek ve el kırığı tespitinde yüksek doğruluk ve klinik öneme sahip olduğunu göstererek, kırık tiplerinin güvenilir bir şekilde lokalizasyonunu ve ayırt edilmesini sağladıklarını belirtmişler. Ayrıca, kas-iskelet sistemi radyolojisinde tanı hızını ve güvenilirliği artırdığı ifade edilmiştir [Gale vd., 2017]. Guan ve arkadaşlarının çalışmasında ise, x-ışınları ile görüntülemeye uyuk kemliği kırıklarını tespit etmek için tasarlanan yenir bir derin öğrenme programının daha önce yapılmış diğer çalışmalara göre daha iyi bir performans gösterdiği ifade edilmiştir [Guan vd, 2022]. Zhang ve arkadaşları tarafından geliştirilen CV19-Net modeli, deneyimli radyologlarının performansını aşan bir performansla, koronavirüs hastalığı 2019 ile ilişkili zatürreyi diğer zatürre türlerinden ayırt edebildiğini vurgulamışlardır [Zhang vd, 2021]. Jia ve arkadaşları tarafından yapılan çalışmada, akciğer radyografileri için geliştirilen yapay zekâ modelinin, COVID-19 ve diğer zatürre türlerini teşhis etmede başarılı olabileceğini ancak, klinik karar verme aracı olarak henüz uygulanamadığı belirtilmiştir [Jia vd, 2022].

Tek bir bulguyu tespit etmek için birçok dar kapsamlı makine öğrenimi modeli geliştirilmiştir. Bunların gerekçesi, özellikle önemli bulgulara yönelik klinik ihtiyaca dayanmaktadır. Örneğin, akciğer kanseri dünya çapında en yaygın kanser türü ve kanserden ölümün en yaygın nedenidir ve genel olarak kötü bir prognoza sahiptir [Polanski vd, 2016]. Bilgisayarlı tomografi, tarama programlarında akciğer kanseri tespiti için daha yüksek hassasiyete sahip olsa da, tıpta yaygın olarak kullanılan akciğer röntgeni (CXR), genellikle erken teşhis için ilk fırsatı sağlar. Bununla birlikte, tanısı konulmayan akciğer kanserlerinin yüzde doksani akciğer röntgeni tanı hatalarından kaynaklanmaktadır [Del Ciello vd, 2017]. Son kanıtlar, akciğer röntgeninde akciğer kanserini tanımlamak için tasarlanmış makine öğrenimi modellerinin oldukça hassas olduğunu göstermektedir. Diğer çalışmalar, pnömoni, pnömotoraks, pnömokonyoz, kardiyomegali, pulmoner hipertansiyon ve tüberküloz tespiti için tasarlanmış dar kapsamlı modellerin güçlü performansını göstermiştir [Jang vd, 2020; Hurt vd, 2020; Hwang vd, 2020; Wang vd, 2020; Zhou vd, 2019; Zou vd, 2020, Pasa vd, 2019]. Bununla birlikte, dar modeller, tespit edilmek istenen bulgunun varlığına veya yokluğuna göre eğitilirse, yorumlayan klinisyenin diğer önemli klinik bulgulara dikkatini veremeyeceği ifade edilmiştir [Jones vd, 2021; Mayats-Alpay, 2022].

Günümüzde yapılan son çalışmalar, radyolojide tanı amaçlı yapay zekânın kullanılmasının potansiyel bir değer taşıdığını ve yapay zekâyâ olan ilginin

devam ettiğini göstermektedir. Ancak, güvenli ve etkili tedarik, uygulama, doğrulama ve değerlendirmeye yardımcı olmak için, kanıt tabanındaki mevcut boşlukları gidermek üzere araştırma planlanma yaptırılması ve kullanılması gerektiği belirtilmiştir. Bu, radyoloji pratiğinin karmaşıklığında yapay zekânın tamamlayıcı bir araç olarak en iyi şekilde nasıl kullanılacağına dair yardımcı olacağı sonucuna varılmıştır [Lawrence vd., 2025].

3. Oral Radyolojide Yapay Zekâ

Yapay zekâ, radyolog veya diş hekimine yorumlama ve teşhis sürecinde yardımcı olmayı hedeflemeli, ancak nihai tanı veya tedavi planlama kararlarını vermemelidir. Bu tür kararlar makineler tarafından değil, insanlar tarafından verilmelidir. Amaç, klinisyenin değerlendirmesi ve yorumlaması için endişe alanlarını belirtmek ve bir tür yönetim kararına yol açmaktır. Özünde, yapay zekâ “artırılmış zekâ” anlamına gelmelidir. Mayo ve Leung, yapay zekâ için 4 hedef öne sürmüşler; radyolog performansını iyileştirmek, zamandan tasarruf sağlamak, iş akışına sorunsuz bir şekilde entegre olmak ve daha düşük maliyetlere sahip olmak [Mayo & Leung, 2018]. Ağız ve çene radyolojisinde amaç, karar verici olarak radyolog veya diş hekiminin yerini almak değildir [Tyndall, 2024].

Nagi ve ark. yapay zekânın, 2D ve 3D görüntülerin değerlendirilmesinde referans noktalarının yorumlanması ve doğru lokalizasyonu ile kemik mimarisinin karakterizasyonu için umut vaat ettiği sonucuna varmışlardır. Ayrıca radyologların yapay zekâ sistemlerinin kullanımında eğitilmeleri ve bunları çalışmalarına uygulamaları gerektiği sonucuna da varmışlardır. Ayrıca, yapay zekânın teori ve pratikteki bilgisinin büyük olasılıkla OMR (Oral and Maxillofacial Radiology) programları için akreditasyon gereksinimlerine eklenebileceğini belirtmektedir [Nagi vd, 2023].

Yapay zekânın OMR ve diş hekimliğindeki uygulamaları çok çeşitli ve geniştir. Yapılan çalışmalar arasında dişlerin haritalandırılması ve çürük, periodontal hastalık ve endodontik periapikal lezyon belirtilerinin belirlenmesi gibi dentoalveolar uygulamalar, ardından ortodonti, oral patoloji ve temporomandibular eklem (Temporomandibular Joint-TMJ) hastalıklarına yönelik uygulamalar yer almaktadır. Kalite güvencesiyle ilgili potansiyel uygulamalar da ele alınmıştır [Brown vd, 2017; Kim vd, 2019; Endres vd, 2020].

Diş tespiti ve etiketlemesine yönelik çeşitli yapay zekâ ve bilgisayar destekli tanı araçları son zamanlarda ortaya çıkmıştır. Bu araçların geliştirilmesinin ardındaki ilham, zaman tasarrufu sağlama, iş akışı ve doğruluğu iyileştirme beklentileriyle ilgilidir. Dişlerin haritalandırılmasındaki yanlışlık, diş hekimliğinde hala endişe

verici bir sorundur [Brown vd, 2017]. Bu nedenle, diş haritalamasında klinik uzmanların doğruluğunu artırmada Dİnin bir yardımcı araç olarak kullanımıyla ilgili daha fazla çalışmaya ihtiyaç olduğu belirtilmiştir [Tyndall, 2024]. Kim ve ark., panoramik radyograflarda periodontal kemik kaybının tespitinde derin öğrenmeyi uyguladıktan sonra, derin öğrenmenin tanı koymada yararlı bir yardımcı olabileceği sonucuna varmıştır [Kim vd, 2019]. Endres ve ark., periapikal granülomlar, periapikal kistler ve tümörler de dahil olmak üzere lezyonların ayırıcı tanısını yapmak için klinik olarak doğrulanmış bir referans standardı kullanarak panoramik radyograflarda periapikal radyolüsenslerin saptanması için Dİyi kullandılar [Endres vd, 2020]. Derin öğrenme kullanan bir çalışmada, Jung ve Kim, sefalometrik radyograflara dayanarak ortodontik amaçlarla diş çekimi ihtiyacını değerlendirmede oral radyoloji uzmanları ile yapay zekâ sisteminin tahminleri arasında küçük farklılıklar olduğu sonucuna varmışlardır [Jung & Kim, 2016].

Lee ve ark., panoramik radyograflar ve CBCT kullanarak 3 tip kistik lezyonun (odontojenik keratokist, dentigeröz kist ve periapikal kist) incelenmesinde, CBCT görüntülerini referans standart olarak kullanan önceden eğitilmiş modelin iyi bir tanı performansı verdiğini ifade etmişlerdir [Lee vd, 2020]. CBCT sistemlerinin daha fazla satın alınması ve kullanımı hızla arttığı için, CBCT taramalarında çene lezyonlarını belirlemek için yapay zekâ teknolojisinin kullanımının önemi artsa da, CBCT hacmini yorumlayacak yeterli oral radyologu bulunmamaktadır. Bu nedenle, olası çene lezyonlarını belirlemede dental radyologlarına yardımcı olacak yapay zekâ ile ilgili çalışmalar artmıştır [Heo vd, 2021].

4. Mamografide Yapay Zekâ

Meme kanseri, dünya genelinde kadınlarda en sık görülen kanser türüdür ve 2012 yılında yaklaşık 1,7 milyon yeni vaka teşhis edilmiştir (genel olarak ikinci en sık görülen kanser); bu, tüm yeni kanser vakalarının yaklaşık %12'sini ve kadınlardaki tüm kanserlerin %25'ini temsil etmektedir [Lukong, 2017]. 2022 yılında dünya genelinde yaklaşık 2,3 milyon kadına meme kanseri teşhisi konulmuş ve 670.000 kadın hayatını kaybetmiştir. Dünyanın herhangi bir yerinde her 14 saniyede bir kadına meme kanseri teşhisi konulmaktadır [Bcrf, 2025]. Türkiye'de de benzer şekilde meme kanseri, kadınlarda en sık görülen kanser türü olup her **4 kadın kanseri tanısından 1'i** meme kanseridir. Güncel tahminlere göre Türkiye'de her yıl yaklaşık **27 bin** kadına meme kanseri teşhisi konulmaktadır [Hasuder, 2025].

Meme kanserinin mamografi ile tespit edilebilen bilinen asemptomatik bir evresi vardır ve bu nedenle mamografi, tarama için birincil görüntüleme

yöntemidir. Çift okuma (iki radyologun aynı mamogramları bağımsız olarak okuması), gözden kaçan kanser oranını azaltmak için önerilmiştir ve şu anda çoğu tarama programına dahil edilmiştir [Lukong, 2017]. Bununla birlikte, çift okuma ek iş yükü ve maliyetlere yol açmaktadır. Alternatif olarak, bilgisayar destekli tanı (CAD) sistemleri, mamogramları okurken tek bir radyoloğa yardımcı olarak kararlarını destekleyebilir. Bu sistemler, radyologlar tarafından ikinci görüş kriterleri olarak kullanılabilir ve meme kanserinin erken teşhisinde önemli bir rol oynayarak, meme kanserli kadınlarda ölüm oranını maliyet etkin bir şekilde azaltmaya yardımcı olabilir [Dandil vd, 2015].

Mamografinin yaygın olarak benimsenmesine rağmen, bu görüntülerin yorumlanması zorlu olmaya devam etmektedir. Kanser tespitinde uzmanlar tarafından elde edilen doğruluk büyük ölçüde değişmektedir [McKinney vd, 2020] Retrospektif çalışmalarda, popülasyon tabanlı bir tarama popülasyonundan gelen mamografileri radyolog değerlendirmesi gerektirmeyen ve gelişmiş değerlendirmeye tabi tutulan olarak sınıflandırmak için ticari bir yapay zekâ kanser tespit cihazı kullanmanın, radyologların iş yükünü yarıdan fazla azaltabileceğini ve aksi takdirde daha sonra teşhis edilecek kanserlerin önemli bir bölümünü önceden tespit edebileceğini göstermektedir. Bulguları doğrulamak için diğer ortamlarda geriye dönük çalışmalar ve ileriye dönük bir çalışmanın yapılması gerektiği vurgulanmıştır [Dembrower vd, 2020].

Rodriguez-Ruiz ve ark. larının yapmış olduğu derin öğrenme algoritmalarına dayalı test edilen yapay zekâ sisteminde, mamografide meme kanserini tespit etmede ortalama bir radyologla benzer performans sergilediği ifade edilmiştir. Bu sonuçlar, geniş, heterojen, çok merkezli, çok üreticili ve kanser açısından zengin bir mamografi kohortunda tutarlı bir şekilde gözlemlenmiştir. Umut verici olmasına rağmen, bu tür bir yapay zekâ sisteminin tarama ortamındaki performansı ve uygulama şekli daha fazla araştırılmayı gerektirdiği belirtilmiştir [Rodriguez-Ruiz vd, 2019].

Derin öğrenme sistemleri, yapay sinir ağlarındaki çoklu katmanlar sayesinde geniş bir uygulama yelpazesi sunmaktadır; bu, girdi verileri ile istenen çıktılar arasında esnek eşleme işlevleri sağlayan önemli bir bileşendir. Karmaşık eğitim aşaması bu eşlemeyi yaklaşık olarak sağlar, ancak karmaşıklık genellikle sonuçların doğrudan yorumlanmasını engeller. Yapay zekâ çözümleri trilyonlarca parametre aracılığıyla daha karmaşık hale geldikçe, insan anlayışı geride kalmakta ve bu sistemlerin denetlenmesi için çabalar gerektirmektedir. Yapay zekâda açıklanabilirlik, bu boşluğu gidermek için önem kazanmış olup, yalnızca işlevsel faydalar sağlamayı değil, aynı zamanda klinik güveni artırmayı ve yasal ve etik standartlara uyumu sağlamayı da hedeflemektedir. Açıklanabilirliğe olan ilginin yeniden canlanması, özellikle insan uzmanlarının

yapay zekâ sistemlerini anlamaya ve kontrol etmeye çalıştığı kritik karar verme senaryolarında yüksek performans arayışından sonra gelmektedir [Borys vd, 2023].

Meme görüntülemesinde yapay zekânın entegrasyonu, tanı ve tarama süreçlerinde devrim yaratma konusunda büyük bir potansiyel taşımaktadır. Gelişmelere ve sayısız uygulamaya rağmen, veri sorunlarından yapay zekâ sistemlerinde şeffaflık ve güven ihtiyacına kadar çeşitli zorluklar devam etmektedir. Bu zorlukların ele alınması, meme görüntülemesinde yapay zekânın sorumlu ve etkili bir şekilde uygulanması için çok önemlidir. Yasal ve etik hususlar, kapsamlı düzenlemelerin, etik çerçevelerin ve şeffaf yapay zekâ modellerinin geliştirilmesini gerektiren önemli bir rol oynamaktadır. Karmaşık ortamda yol almak ve uyumluluğu sağlamak için yapay zekâ ekipleri içindeki hukuk uzmanlarının iş birliği şarttır. Ayrıca, şeffaflık, hesap verebilirlik ve kapsayıcılık da dahil olmak üzere etik ilkelere bağlılık, yapay zekâ teknolojilerinin başarılı ve bilinçli bir şekilde entegrasyonu için çok önemlidir. Yapay zekâ gelişmeye devam ettikçe, yasal, etik ve sosyal boyutlara dikkat etmek, meme görüntülemesinin dinamik ortamında potansiyel riskleri en aza indirirken faydalarını en üst düzeye çıkarmada çok önemli olacaktır [Durur-Subasi & Özçelik, 2023].

5. Ultrasonda Yapay Zekâ

Ultrason, invaziv olmayan, kullanışlı ve maliyet etkin bir tanı ve tedavi yöntemi olarak, insan dokularının ve organlarının morfolojisini ve işlevini etkili bir şekilde yansıtarak klinik uygulamalarda önemli bir rol oynamaktadır. Bununla birlikte, gerçek ultrason tanı pratiğinde, sonuçlar hekimin deneyimi ve öznel faktörlerden etkilenen sapmalar gösterebilir [Xu vd, 2023]. Ayrıca, ultrason muayeneleriyle ilişkili yüksek iş yükü ve bazı uygulayıcıların nispeten düşük verimliliği, ultrason tanı ve tedavisiyle ilgili hasta memnuniyetinde önemli ölçüde iyileştirme alanı olduğunu göstermektedir.

Yapay zekânın ultrason tıbbındaki uygulaması, temelde makine öğrenimi (ML) ve görüntü tanıma algoritmalarındaki uygulaması gibi gelişmiş teknolojilere dayanmaktadır. Geniş ultrason görüntü veri kümeleri üzerinde eğitilen bu algoritmalar, patolojik özellikleri otomatik olarak tanımlayarak hekimlerin daha doğru teşhisler koymasına yardımcı olur. Yapay zekâ destekli ultrason teşhisinin iş akışı tipik olarak birkaç adımdan oluşur: Öncelikle, elde edilen ultrason görüntüleri, görüntü kalitesini iyileştirmek için gürültü giderme ve iyileştirme dahil olmak üzere hesaplama teknikleri yoluyla ön işleme tabi tutulur; daha sonra, ön işlenmiş görüntülerin özellik çıkarımı ve sınıflandırılması için yapay zekâ algoritmaları kullanılır; ve son olarak, yapay

zekâ sistemi, tanıma sonuçlarına dayanarak tanısal öneriler sunarak hekimlerin karar verme süreçlerine yardımcı olur [Yan vd, 2025]

Evrışimsel sinir ağları (CNN) gibi gelişmiş algoritmaları kullanarak, YZ görüntü elde etmeyi, kalite değerlendirmesini ve objektif hastalık tanısını önemli ölçüde geliştirmiştir. YZ odaklı çözümler artık otomatik görüntü analizini, akıllı tanı desteğini ve tıp eğitimini kolaylaştırarak, çeşitli organlarda hassas lezyon tespiti sağlarken hekim iş yükünü azaltmaktadır [Yan vd, 2025]

Tiroid kanserinin artan sıklığı ve hekimlerin iş yükü, tiroid ultrason görüntülerini verimli bir şekilde işlemek için yapay zekânın kullanılması ihtiyacını doğurmuştur [Cao vd, 2023]. Tiroid nodülü değerlendirmesi bağlamında, yapay zekâ tanı, değerlendirme ve yönetimi iyileştirmeyi amaçlayan hayati bir araç olarak ortaya çıkmıştır [Barinov vd, 2023; Etehadtavakol vd, 2024; Tessler & Thomas, 2023]. Etkili yapay zekâ modelleri geliştirmenin kritik bir bileşeni, ultrason görüntülerinden ilgili özelliklerin çıkarılmasıdır. Bu, nodüllerin dokusal, şekil ve kenar özelliklerinin analizinin yanı sıra boyut, şekil ve ekogenite gibi sayısal verilerin entegrasyonunu içerir. Bu özelliklerden yararlanmak, tiroid nodüllerinin tanınmasını ve sınıflandırılmasını iyileştirmenin yanı sıra tanı doğruluğunu da artırır.

Meme kanserinde, etkili tedavi ve iyileştirilmiş hayatta kalma oranları için erken teşhis çok önemlidir [Dar vd, 2022; Li vd, 2021; Dong vd, 2021]. Ultrason muayenesi tarama ve ayırıcı tanı için hayati önem taşımaktadır, ancak etkinliği operatöre bağlıdır ve kaynak dağılımı bakım eşitsizliklerine yol açabilir. Hekim deneyimindeki farklılıklar tanı ve prognozu daha da etkileyebilir. Yapay zekâ, meme nodüllerinin tespitini ve tanısını geliştirebilir ve insan yorumuna değerli bir tamamlayıcı olarak hizmet edebilir. Son yıllarda, derin öğrenme yöntemleri, klinik verimliliği ve doğruluğu artırmak için umut vadeden bir yol olarak ortaya çıkmıştır [Jia vd, 2023]

Yapay zekâdaki gelişmeler, kardiyovasküler tıpta uygulanmasını araştıran çalışmaların patlamasına yol açmıştır [Barinov vd, 2023; Nedadur vd, 2022] De Siqueira ve ark. tarafından belirtildiği gibi, çeşitli ekokardiyogram tiplerinin (örneğin transtorasik ekokardiyogramlar (TTE), transözofageal ekokardiyogramlar ve Doppler ekokardiyografi) otomatik analizi için yapay zekânın, özellikle DL ve ML algoritmalarının kullanımını araştıran çeşitli çalışmalar yapılmıştır [De Siqueira vd, 2022; De Siqueira vd, 2020]. Ekokardiyografik tanıda, yapay zekâ teknolojileri, duvar hareket anormallikleri gibi kalpteki yapısal anormallikleri otomatik olarak tanımlayabilir ve böylece miyokardiyal iskemi de dahil olmak üzere kardiyak durumların erken teşhisi için güçlü bir destek sağlayabilir [Yan vd, 2025].

Son yirmi yılda, hepatolojide tanı, prognoz ve tedavi seçeneklerinde kayda değer ilerlemeler kaydederek oldukça karmaşık bir tıp uzmanlık alanına dönüştü [Schattenberg vd, 2023]. Yapay zekânın karaciğerin incelenmesi için mükemmel bir araç olduğu gösterilmiştir [Balsano vd, 2023]. Şu anda, yapay zekâ algoritmaları karaciğer görüntülemesinde, histopatoloji yorumlamasında, invaziv olmayan testlerde ve tahmin modellemesinde kullanılmaktadır.

Meme ve tiroid görüntüleme gibi diğer alanların aksine, yapay zekânın etkileri kadın doğum/jinekoloji alanında o kadar güçlü hissedilmemiştir [Shrestha vd, 2022]. 2020 yılının ortalarına kadar, kadın doğum/jinekolojide yapay zekâ üzerine yapılan araştırmaların çoğu ön nitelikteydi ve genellikle uzmanlaşmamış dergilerde yayınlanıyordu. Bulgular, kadın doğum/jinekoloji dergilerinde yayınlandığında, genellikle birden fazla veri kümesi üzerinde doğrulama ve yapay zekâ süreçlerinin güvenilirliğini sağlamak için çok önemli olan temel klinik doğrulama eksikliği vardı [Dhombres vd, 2022; Akazawa & Hashimoto, 2021].

Sonuç olarak, ultrasonografide yapay zekâ teknolojisinin uygulanması ve klinik pratikte kapsamlı kullanımı konusunda hala önemli ilerlemeler kaydedilmesi gerekiyor. Bununla birlikte, teknolojinin sürekli gelişmesi ve iyileştirilmesiyle yapay zekâ ve ultrasonografi tıbbının entegrasyonunun giderek daha derin ve yaygın hale geleceğine ve nihayetinde küresel sağlığa önemli katkılar sağlayacağına inanılmaktadır [Yan vd, 2025].

6. DEXA'da Yapay Zekâ

Osteoporoz, özellikle menopoz sonrası kadınlar arasında yaygın bir durumdur, ancak genellikle kırık oluşana kadar fark edilmez. Osteoporozun zamanında tespiti, osteoporotik kırıkların önlenmesi için çok önemlidir. Amerika Birleşik Devletleri'nde, osteoporoza bağlı kırıkların görülme sıklığı, inme, kalp krizi ve meme kanserinin toplamından dört kat daha fazladır [Hosseini vd, 2010]. Osteoporozun teşhisinde en güvenilir yöntem, Çift Enerjili X-ışını Absorpsiyometrisi (DXA) kullanılarak kalça ve lomber omurgada kemik mineral yoğunluğunun (BMD) ölçülmesidir [Yamamoto vd, 2020]. Dünya Sağlık Örgütü (WHO) tarafından belirlenen kılavuzlara göre, genç yetişkin ortalamasının 2,5 standart sapmasının altında veya ona eşit bir BMD ölçümü ($T \text{ skoru} \leq -2,5$) osteoporozu gösterirken, herhangi bir bölgede $-1,0$ ile $-2,5$ arasında değişen bir T skoru düşük kemik kütleli veya osteopeniyi gösterir. Ayrıca, ABD Önleyici Hizmetler Görev Gücü, osteoporotik kırıklara karşı önleyici bir önlem olarak 65 yaş ve üstü kadınlar için BMD testini önermektedir [Curry vd, 2018].

Tsai ve ark. Tarafından yapılan çalışmada, BMD T skorlarını tahmin edebilen ve yüksek riskli osteoporoz hastalarını sınıflandırabilen, Yapay zekâ destekli CXR (chest X-ray) tabanlı bir Dijital Lenfoid Model (DLM) yapay zekâ modeli geliştirilmiştir. Ayrıca, potansiyel yüksek riskli osteoporoz hastaları belirlenerek gelecekteki yüksek ölüm riskleri konusunda hastaları uyarmak suretiyle uygulama genişletilmiştir. Kemik yoğunluğu için DXA muayenesi geçirmemiş hastalar için, mevcut CXR ve yapay zekâ modeli aracılığıyla osteoporoz riski erken dönemde tespit edilebilmiştir. Yapay zekâ destekli BMD T skoru tahmini, insan gücüne gerek kalmadan, potansiyel bir osteoporoz risk değerlendirmesi olarak sağlık bilgi sistemlerine entegre edilebildiği ve sağlık hizmeti sağlayıcılarının risk farkındalığını artırabildiği ifade edilmiştir [Tsai vd, 2024].

İskelet kas kütlesi ve gücünde ilerleyici kayıp ile karakterize edilen sarkopeni, yaşlı yetişkinlerde fiziksel fonksiyonu ve yaşam kalitesini önemli ölçüde etkiler. Son zamanlarda, Park ve ark., uzun-bacak röntgenlerinden kas kütlesini tahmin etmek için yapay zekâ destekli otomatik segmentasyon modelini başarıyla geliştirmiş ve doğrulamıştır. Model, DEXA'ya erişilebilir bir alternatif sunmakta olup, toplum ve birinci basamak sağlık hizmeti ortamlarında sarkopeni tanısını ve yönetimini iyileştirme potansiyeline sahip olduğu belirtilmiştir [Park vd, 2025].

7. BT'de Yapay Zekâ

Karakterizasyon, bir hastalığın segmentasyonunu, teşhisini ve evrelemesini ifade eden genel bir terimdir. Bu görevler, bir anormallığın boyutu, yaygınlığı ve iç dokusu gibi radyolojik özelliklerinin niceliksel olarak belirlenmesiyle gerçekleştirilir. Tıbbi görüntüleri incelemek gibi rutin görevleri yerine getirirken, radyologlar, birçok nitel özellikten fazlasını hesaba katma yeteneğine sahiptir. Bu durum, bazı okuyucuların diğerlerinden daha iyi performans göstermesiyle, radyologlar arasındaki kaçınılmaz değişkenlikle daha da kötüleşir. Yapay zekâ aracılığıyla otomasyon, prensip olarak, eldeki görevi her seferinde tekrarlanabilir bir şekilde gerçekleştirirken çok sayıda nicel özelliği, bunların alaka dereceleriyle birlikte değerlendirebilir. Örneğin, BT taramalarındaki iyi huylu ve kötü huylu nodüller arasındaki benzerlik nedeniyle, akciğerdeki kötü huylu tümör durumunu doğru bir şekilde tahmin etmesi zordur. Yapay zekâ, bu özellikleri ve diğer birçok özelliği görüntüleme biyobelirteçleri olarak ele alırken otomatik olarak belirleyebilir. Bu nedenle, bu tür biyobelirteçler, risk değerlendirmesi, ayırıcı tanı, prognoz ve tedaviye yanıt gibi diğer klinik son noktaların yanı sıra kötü huylu tümör olasılığını tahmin etmek için kullanılabilir [Hosny vd, 2018].

Algoritmalarındaki iş akışının başlangıcından itibaren, iyileştirilecek görevlerden ilki yeniden yapılandırma. Görüntü edinme donanımındaki ve görüntü yeniden oluşturma yazılımındaki gelişmeler arasında, giderek artan bir boşluk olduğunu belirten çalışmalar vardır, bu boşluk, artefaktların önüne geçme ve genel kaliteyi iyileştirme açısından yeni derin öğrenme yöntemleriyle potansiyel olarak giderilebilmektedir. Ancak, BT’de yeniden yapılandırma algoritmalarının, son 25 yılda neredeyse hiç değişmediği ifade edilmiştir [Pan vd, 2009]. Ek olarak, birçok filtrelenmiş geri projeksiyonlu yeniden yapılandırma algoritması hem maliyetli hem de görüntüde bozulmalara yol açmaktadır [Moura vd, 2005]. Diğer çalışmalar, görüntüleri düzeltmek ve BT’deki sınırlı aç problemi gibi belirli görüntüleme modalitesine özgü sorunları ele almak için yeni yapay zekâ yöntemleri kullanır; bu, tarayıcının nesneler etrafında tam 180° dönüş yapamaması nedeniyle taranan alanın yalnızca bir kısmının yeniden oluşturulabildiği bir eksik veri problemi bulunmaktadır [Hammerink vd, 2017]. Çalışmalar ayrıca, metal artefaktları gidermek için, orijinal ve düzeltilmiş görüntülerden gelen bilgileri birleştirmek üzere CNN’ler ve sentetik olarak oluşturulmuş görüntülerden yararlanmıştır [Gjesteby vd, 2017].

Kaburga kırıklarının teşhisi, travma şiddetinin belirlenmesinde önemli bir rol oynar. Ancak, giderek artan hasta sayısı ile birlikte çok sayıda BT görüntüsünde kaburga kırıklarının hızlı ve doğru bir şekilde belirlenmesi zorlu bir iştir ve bu aynı zamanda radyologların yeterliliğine de bağlıdır. BT taramalarından kaburga kırıklarının tespiti ve segmentasyonu için klinik olarak uygulanabilir otomatik bir sistem geliştiren Jin ve arkadaşları, klinik pratikte derin öğrenme destekli tanının, büyük bir potansiyele sahip olduğunu ifade etmiştir [Jin vd, 2020].

Akciğer kanseri, dünya çapında kansere bağlı ölümlerin önde gelen nedenlerinden biridir. Erken teşhis, ölüm oranını etkili bir şekilde azaltabilir ve doktorlara yardımcı olmanın önemli bir yolu olarak CAD hızla gelişmiştir. Özellikle, BT görüntülerinde otomatik pulmoner nodül tespiti CAD için hayati önem taşır [Xie vd., 2019].

8. MR’da Yapay Zekâ

Manyetik rezonans görüntüleme (MRG), nöroanatomiye incelemek için kullanılan baskın bir görüntüleme yöntemidir. MRG’de, beyindeki yumuşak dokular, farklı puls sekansları kullanılarak farklı doku kontrastlarıyla görüntülenebilir. Manyetize edilmiş gradyan eko (MPRAGE) ve bozulmuş gradyan geri çağrılmış (SPGR) gibi puls sekansları, gri madde (GM) ve beyaz madde (WM) dokuları arasında iyi görüntü kontrastı sağlayan T1 ağırlıklı

(T1w) doku kontrastı üretir. Son çalışmalar, derin öğrenmenin çeşitli MRI görüntüleme stratejileri için yeniden yapılandırma dönüşümlerini öğrenmedeki esnekliğini ortaya koymaktadır. Bu esneklik, yeniden yapılandırma sürecinin, tarayıcı sensörleri ile elde edilen görüntüler arasında bir eşlemenin türetildiği denetimli bir öğrenme görevi olarak ele alınmasıyla sağlanmaktadır [Zhu vd, 2018].

$T1w$, $T2w$ ve P_{Dw} görüntülerinden bir FLAIR görüntüsü sentezlemek için yapılan çalışmada, REPLICA adlı bir uygulama kullanılmıştır. Bu işlem, FLAIR görüntüleri elde edilmemişse, elde edilen FLAIR görüntüleri bozuka veya daha yüksek çözünürlüklü FLAIR görüntülerine ihtiyaç duyuluyorsa yararlı olabilir. REPLICA hesaplama açısından hızlı olduğu belirtilmiştir. FLAIR puls sekansı, multipl skleroz (MS) ve diğer hastalıkları olan hastaların görüntülenmesinde rutin olarak kullanılmaktadır. Özellikle MS hastalarında gözlemlenen beyaz madde lezyonlarının (WML) görselleştirilmesi için faydalıdır. Beyaz madde lezyonları FLAIR görüntülerinde hiperintens görünür ve otomatik segmentasyon algoritmaları kullanılarak kolayca sınırlandırılabilir. FLAIR dizisi uzun bir T1 değerine ihtiyaç duyar ve bu nedenle, daha hızlı tarama süresi için genellikle daha düşük çözünürlükte elde edilir. FLAIR görüntüleri ayrıca sıklıkla, lezyonlarla karıştırılabilecek hiperintensitelere neden olan artefaktlara da maruz kalmaktadır [Stuckey vd., 2007]. Eksik FLAIR görüntüleri, lezyon segmentasyonunda da engeller oluşturabilir, çünkü önde gelen lezyon segmentasyon algoritmalarının çoğu FLAIR'i girdi yöntemi olarak kullanmaktadır. Eksik FLAIR görüntülerinin sentezlenmesi, bu sorunların önlenmesine ve segmentasyon ile daha ileri görüntü analizinin yapılmasına yardımcı olabileceği belirtilmiştir [Jog vd, 2017].

Makine öğrenimi ve derin öğrenme tekniklerindeki gelişmeler, görüntü elde etme ve yeniden yapılandırmayı hızlandıran algoritmaların geliştirilmesine yol açarak tanı kalitesinden ödün vermeden tarama sürelerini azaltmaktadır. MR taramalarını hızlandırma çabaları, fizik tabanlı hızlı görüntüleme dizilerini, donanım tabanlı paralel görüntülemeyi ve azaltılmış örneklerden sinyal işleme tabanlı MR görüntü yeniden yapılandırmasını içermekte olup, CNN'ler gibi derin öğrenme teknikleri, yetersiz örneklenmiş k-uzay verilerinden MR görüntülerini yeniden yapılandırmada umut vaat ederek görüntülemeye verimliliği ve etkinliği potansiyel olarak artırmaktadır [Wang vd, 2016]. Bu hızlandırılmış protokollerin, sinoviyum, kıkırdak ve kemik gibi romatizmal hastalıklardan etkilenen kas-iskelet yapılarının daha hassas görselleştirilmesini sağlayarak görüntü kalitesini koruduğu veya hatta iyileştirdiği gösterilmiştir [Herrmann vd, 2023].

MR, romatizmal hastalıklarla birlikte görülen yapısal ve patolojik değişikliklere dair eşsiz bilgiler sunan, paha biçilmez, invaziv olmayan bir görüntüleme tekniği olarak ortaya çıkmıştır [Oostveen vd, 2000; Østergaard vd, 1996]. Romatoid artrit (RA), ankilozan spondilit (AS) dahil spondiloartrit (SpA), osteoartrit (OA) ve diğerlerinin tanı ve yönetiminde önemli bir rol oynar ve özellikle yaşlılarda sık karşılaşılan romatizmal rahatsızlıklarda hastalarda eklem ve yumuşak doku anormalliklerini, iltihabı ve yapısal hasarı değerlendirmek için invaziv olmayan bir yol sunar. Bununla birlikte, MR yorumlaması zahmetli, zaman alıcı ve gözlemciler arası ve gözlemci içi değişkenliğe tabidir. Ayrıca, MR cihazlarının yüksek maliyeti ve sınırlı bulunabilirliği, romatolojide yaygın olarak uygulanmasını kısıtlamaktadır [Stoel, 2020; Dadak vd, 2022; Küçük&Küçük, 2025; Potočník vd, 2017].

Uzun MRI tarama süreleri, tanısal görüntü kalitesini ve sinyal-gürültü oranı ile artefakt azaltımında algılanan faydaları korurken tarama süresini hızlandırmak için yapay zekâ tabanlı DL görüntü yeniden yapılandırma yöntemlerinin geliştirilmesine ilham vermiştir [Bash vd, 2022; Gassenmaier vd, 2021]

Çeşitli görüntüleme koşullarındaki verilerle eğitilen ve eğitilmiş bu modelleri birbirine entegre eden DLS (Deep Learning System), kontrast madde kullanılmadığı durumlarda bile klinik ortamlarda karaciğer tümörleri için doğru ve zaman kazandıran bir yardımcı tanı stratejisi olarak kullanılabilir. Bu nedenle DLS, kontrast maddeye bağlı yan etkilerden kaçınma ve karaciğer tümörü hastaları için mevcut standart MRI inceleme uygulamalarıyla ilişkili ekonomik maliyetleri azaltma potansiyeline sahiptir [Zhen vd, 2020].

Yapay zekâ destekli MR görüntülemenin meme kanseri tedavi yanıtının değerlendirilmesi ve tahmininde uygulanması, görüntülemenin hasta bakımını yönlendirmesi ve hatta yeniden şekillendirmesi için benzersiz bir fırsat sunmaktadır. Bu vizyonu gerçekleştirme yolculuğu hala uzun olsa da, veriler çabanın karşılığını fazlasıyla verdiğini göstermektedir [Gullo vd, 2020].

Yapay zekâ çözümleri, raporlamanın ötesinde tarama kalitesini artırır, eksik sekansları belirler ve idari veri girişini yöneterek tüm tanı sürecindeki aksaklıkları azaltır [Hosny vd, 2018].

7. SONUÇ

Bu çalışma kapsamında, radyografi, oral radyoloji, mamografi, ultrasonografi, bilgisayarlı tomografi ve manyetik rezonans görüntüleme gibi temel tıbbi görüntüleme modalitelerinde yapay zekâ uygulamalarının klinik tanı süreçlerine olan katkıları bütüncül bir yaklaşımla değerlendirilmiştir. Yapay zekâ tabanlı yöntemlerin, farklı modalitelerde ortak olarak tanısal doğruluğu

artırma, yorumlama süresini kısaltma ve klinik iş akışını standardize etme potansiyeline sahip olduğu görülmüştür. Bu bulgular, literatürde rapor edilen ve yapay zekânın radyolog performansını destekleyici bir karar destek aracı olarak etkinliğini ortaya koyan çalışmalarla uyumluluk göstermektedir.

Benzer çalışmalarda, özellikle mamografi ve BT uygulamalarında yapay zekâ destekli sistemlerin duyarlılık ve özgüllüğü artırdığı, MR ve ultrason görüntülemeye ise görüntü kalitesi ve operatör bağımlılığını azalttığı bildirilmektedir. Oral radyoloji ve konvansiyonel radyografide yapılan güncel çalışmalar da, yapay zekânın erken lezyon saptama ve sınıflandırma süreçlerinde klinik karar verme mekanizmalarını güçlendirdiğini göstermektedir. Bu çalışmanın ulaştığı genel sonuçlar, söz konusu literatür bulgularını destekler niteliktedir ve yapay zekânın tek başına değil, uzman değerlendirmesini tamamlayıcı bir araç olarak kullanılmasının önemini vurgulamaktadır.

Bununla birlikte, yapay zekâ modellerinin performansının büyük ölçüde veri setlerinin kalitesi, çeşitliliği ve temsil gücüne bağlı olması, çalışmanın temel kısıtları arasında yer almaktadır. Ayrıca, farklı cihazlar, yazılım altyapıları ve klinik protokoller arasındaki değişkenlik, sonuçların genelleştirilmesini sınırlamaktadır. Gelecekte yapılacak çalışmalarda, çok merkezli ve standartlaştırılmış veri setlerinin kullanılması, algoritmaların şeffaflığının ve açıklanabilirliğinin artırılması ve klinik entegrasyon süreçlerinin uzun dönemli sonuçlarla değerlendirilmesi önerilmektedir. Bu yaklaşımlar, yapay zekâ uygulamalarının tıbbi görüntülemeye güvenli, etkili ve sürdürülebilir biçimde kullanımına önemli katkılar sağlayacaktır.

Kaynaklar

- Abhisheka, B., Biswas, S.K., Purkayastha, B. *et al.* (2024). Recent trend in medical imaging modalities and their applications in disease diagnosis: a review. *Multimed Tools Appl* 83, 43035–43070. <https://doi.org/10.1007/s11042-023-17326-1>
- Akazawa, M., & Hashimoto, K. (2021). Artificial intelligence in gynecologic cancers: Current status and future challenges—A systematic review. *Artificial Intelligence in Medicine*, 120, 102164.
- Balsano, C., Burra, P., Duvoux, C., Alisi, A., Piscaglia, F., Gerussi, A., ... & Donatelli, P. (2023). Artificial Intelligence and liver: Opportunities and barriers. *Digestive and Liver Disease*, 55(11), 1455-1461.
- Barinov, L., Jairaj, A., Middleton, W. D., Beland, Kirsch, J., Filice, R. W., ... & Grant, E. G. (2023). Improving the efficacy of ACR TI-RADS through deep learning-based descriptor augmentation. *Journal of Digital Imaging*, 36(6), 2392-2401.
- Bash, S., Johnson, B., Gibbs, W., Zhang, T., Shankaranarayanan, A., & Tanenbaum, L. N. (2022). Deep learning image processing enables 40% faster spinal MR scans which match or exceed quality of standard of care: a prospective multicenter multireader study. *Clinical Neuroradiology*, 32(1), 197-203.
- Borys, K., Schmitt, Y. A., Nauta, M., Seifert, C., Krämer, N., Friedrich, C. M., & Nensa, F. (2023). Explainable AI in medical imaging: An overview for clinical practitioners—Saliency-based XAI approaches. *European journal of radiology*, 162, 110787.
- Brady, A. P., Bello, J. A., Derchi, L. E., Fuchsjäger, M., Goergen, S., Krestin, G. P., ... & Brink, J. A. (2021). Radiology in the era of value-based health-care: a multi-society expert statement from the ACR, CAR, ESR, IS3R, RANZCR, and RSNA.
- Brown, N. L., Jephcote, V. E., Morrison, J. N., & Sutton, J. E. (2017). Inaccurate dental charting in an audit of 1128 general dental practice records. *Dental update*, 44(3), 254-260.
- Cao, C. L., Li, Q. L., Tong, J., Shi, L. N., Li, W. X., Xu, Y., ... & Cui, X. W. (2023). Artificial intelligence in thyroid ultrasound. *Frontiers in Oncology*, 13, 1060702.
- Curry, S.J., et al. (2018). *Screening for osteoporosis to prevent fractures: US Preventive Services Task Force recommendation statement*. *Jama*. 319(24): p. 2521-2531.
- Dadak, A., Küçük, N., & Küçük, İ. (2022). Yaşlılık ve Polifarmasi. Editörler: Prof.Dr. Engin Şahna, Prof.Dr. Hasan Akgül, Prof.Dr. Zeliha Selamoğlu, *Sağlık Bilimlerinde Araştırma ve Değerlendirmeler-I*, Gece Kitaplığı, 15-25.

- Dandıl, E., Ekşi, Z., & Çakıroğlu, M. (2015). Mamogram Görüntülerinden Bilgisayar Destekli Kitle Teşhisi Sistemi.
- Dar, R. A., Rasool, M., & Assad, A. (2022). Breast cancer detection using deep learning: Datasets, methods, and challenges ahead. *Computers in biology and medicine*, 149, 106073.
- De Siqueira, V. S., Borges, M. M., Furtado, R. G., Dourado, C. N., & da Costa, R. M. (2021). Artificial intelligence applied to support medical decisions for the automatic analysis of echocardiogram images: A systematic review. *Artificial intelligence in medicine*, 120, 102165.
- De Siqueira, V. S., de Castro Rodrigues, D., Dourado, C. N., Borges, M. M., Furtado, R. G., Delfino, H. P., ... & da Costa, R. M. (2020, July). Machine learning applied to support medical decision in transthoracic echocardiogram exams: a systematic review. In *2020 IEEE 44th annual computers, software, and applications conference (COMPSAC)* (pp. 400-407). IEEE.
- Del Ciello, A., Franchi, P., Contegiacomo, A., Cicchetti, G., Bonomo, L., & Larici, A. R. (2017). Missed lung cancer: when, where, and why?. *Diagnostic and interventional radiology*, 23(2), 118.
- Dembrower, K., Wählin, E., Liu, Y., Salim, M., Smith, K., Lindholm, P., ... & Strand, F. (2020). Effect of artificial intelligence-based triaging of breast cancer screening mammograms on cancer detection and radiologist workload: a retrospective simulation study. *The Lancet Digital Health*, 2(9), e468-e474.
- Dhombres, F., Bonnard, J., Bailly, K., Maurice, P., Papageorgiou, A. T., & Jouannic, J. M. (2022). Contributions of artificial intelligence reported in obstetrics and gynecology journals: systematic review. *Journal of medical Internet research*, 24(4), e35465.
- Dong, F., She, R., Cui, C., Shi, S., Hu, X., Zeng, J., ... & Zhang, Y. (2021). One step further into the blackbox: a pilot study of how to build more confidence around an AI-based decision system of breast nodule assessment in 2D ultrasound. *European radiology*, 31(7), 4991-5000.
- Durur-Subasi, I., & Özçelik, Ş. B. (2023). Artificial Intelligence in breast imaging: opportunities, challenges, and legal–ethical considerations. *The Eurasian Journal of Medicine*, 55(Suppl 1), S114.
- Endres, M. G., Hillen, F., Salloumis, M., Sedaghat, A. R., Niehues, S. M., Quatela, O., ... & Gaudin, R. A. (2020). Development of a deep learning algorithm for periapical disease detection in dental radiographs. *Diagnostics*, 10(6), 430.
- Etehadtavakol, M., Etehadtavakol, M., & Ng, E. Y. (2024). Enhanced thyroid nodule segmentation through U-Net and VGG16 fusion with feature engineering: A comprehensive study. *Computer Methods and Programs in Biomedicine*, 251, 108209.

- Gale, W., Oakden-Rayner, L., Carneiro, G., Bradley, A. P., & Palmer, L. J. (2017). Detecting hip fractures with radiologist-level performance using deep neural networks. *arXiv preprint arXiv:1711.06504*.
- Gassenmaier, S., Küstner, T., Nickel, D., Herrmann, J., Hoffmann, R., Almansour, H., ... & Othman, A. E. (2021). Deep learning applications in magnetic resonance imaging: has the future become present?. *Diagnostics*, 11(12), 2181.
- Giardino, A., Gupta, S., Olson, E., Sepulveda, K., Lenchik, L., Ivanidze, J., ... & Ganeshan, D. (2017). Role of imaging in the era of precision medicine. *Academic radiology*, 24(5), 639-649.
- Gjesteby, L., Cong, W., & Wang, G. (2017, September). Numerical study on simultaneous emission and transmission tomography in the MRI framework. In *Developments in X-Ray Tomography XI* (Vol. 10391, pp. 54-62). SPIE.
- Guan, B., Yao, J., Wang, S., Zhang, G., Zhang, Y., Wang, X., & Wang, M. (2022). Automatic detection and localization of thighbone fractures in X-ray based on improved deep learning method. *Computer Vision and Image Understanding*, 216, 103345.
- Gullo, R. L., Marcus, E., Huayanay, J., Eskreis-Winkler, S., Thakur, S., Teuwen, J., & Pinker, K. (2024). Artificial intelligence-enhanced breast MRI: applications in breast cancer primary treatment response assessment and prediction. *Investigative Radiology*, 59(3), 230-242.
- Hammernik, K., Würfl, T., Pock, T., & Maier, A. (2017, March). A deep learning architecture for limited-angle computed tomography reconstruction. In *Bildverarbeitung für die Medizin 2017: Algorithmen-Systeme-Anwendungen. Proceedings des Workshops vom 12. bis 14. März 2017 in Heidelberg* (pp. 92-97). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Heo, M. S., Kim, J. E., Hwang, J. J., Han, S. S., Kim, J. S., Yi, W. J., & Park, I. W. (2021). Artificial intelligence in oral and maxillofacial radiology: what is currently possible?. *Dentomaxillofacial Radiology*, 50(3), 20200375.
- Herrmann, J., Gassenmaier, S., Keller, G., Koerzdoerfer, G., Almansour, H., Nickel, D., ... & Werner, S. (2023). Deep learning MRI reconstruction for accelerating turbo spin echo hand and wrist imaging: a comparison of image quality, visualization of anatomy, and detection of common pathologies with standard imaging. *Academic Radiology*, 30(11), 2606-2615.
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. (2018). Artificial intelligence in radiology. *Nature Reviews Cancer*, 18(8), 500-510.
- Hossein Gharib, M. D., Enrico Papini, M. D., Ralf Paschke, M. D., Daniel, S. D. M., Roberto Valcavi, M. D., Laszlo Hegedüs, M. D., & Paolo Vitti, M. D. (2010). American association of clinical endocrinologists, associ-

- azione medici endocrinologi, and european thyroid association medical guidelines for clinical practice for the diagnosis and management of thyroid nodules. *Endocrine Practice*, 16, 1.
- <https://www.bcrf.org/breast-cancer-statistics-and-resources/> (Erişim Tarihi:19.12.2025)
- <https://www.hasuder.org.tr/manset-hasuder/detay/1-31-ekim-meme-kanse-ri-farkindalik-ayi-202510031043> (Erişim Tarihi:19.12.2025)
- Hurt, B., Yen, A., Kligerman, S., & Hsiao, A. (2020). Augmenting interpretation of chest radiographs with deep learning probability maps. *Journal of thoracic imaging*, 35(5), 285-293.
- Hwang, E. J., Hong, J. H., Lee, K. H., Kim, J. I., Nam, J. G., Kim, D. S., ... & Park, C. M. (2020). Deep learning algorithm for surveillance of pneumothorax after lung biopsy: a multicenter diagnostic cohort study. *European radiology*, 30(7), 3660-3671.
- Jameson, J. L., & Longo, D. L. (2015). Precision medicine—personalized, problematic, and promising. *Obstetrical & gynecological survey*, 70(10), 612-614.
- Jang, S., Song, H., Shin, Y. J., Kim, J., Kim, J., Lee, K. W., ... & Lee, K. H. (2020). Deep learning–based automatic detection algorithm for reducing overlooked lung cancers on chest radiographs. *Radiology*, 296(3), 652-661.
- Jia, L. L., Zhao, J. X., Pan, N. N., Shi, L. Y., Zhao, L. P., Tian, J. H., & Huang, G. (2022). Artificial intelligence model on chest imaging to diagnose COVID-19 and other pneumonias: A systematic review and meta-analysis. *European journal of radiology open*, 9, 100438.
- Jia, Y., Wu, R., Lu, X., Duan, Y., Zhu, Y., Ma, Y., & Nie, F. (2023). Deep learning with transformer or convolutional neural network in the assessment of tumor-infiltrating lymphocytes (TILs) in breast cancer based on US images: a dual-center retrospective study. *Cancers*, 15(3), 838.
- Jin, L., Yang, J., Kuang, K., Ni, B., Gao, Y., Sun, Y., ... & Li, M. (2020). Deep-learning-assisted detection and segmentation of rib fractures from CT scans: Development and validation of FracNet. *EBioMedicine*, 62.
- Jog, A., Carass, A., Roy, S., Pham, D. L., & Prince, J. L. (2017). Random forest regression for magnetic resonance image synthesis. *Medical image analysis*, 35, 475-488.
- Jones, C. M., Buchlak, Q. D., Oakden-Rayner, L., Milne, M., Seah, J., Esmaili, N., & Hachey, B. (2021). Chest radiographs and machine learning—Past, present and future. *Journal of Medical Imaging and Radiation Oncology*, 65(5), 538-544.

- Jung, S. K., & Kim, T. W. (2016). New approach for the diagnosis of extractions with neural network machine learning. *American Journal of Orthodontics and Dentofacial Orthopedics*, 149(1), 127-133.
- Kim, J., Lee, H. S., Song, I. S., & Jung, K. H. (2019). *DeNTNet: Deep Neural Transfer Network for the detection of periodontal bone loss using panoramic dental radiographs*. *Sci Rep*, 9 (1), 17615.
- Küçük, N., & Küçük, İ., (2025). Yaşlılık Fizyolojisi – Fizyolojiden Patofizyolojiye Yaşlılık. Editörler; Prof.Dr. Onur Koyuncu, Öğr.Gör.Abdullah Dadak. Geriatrik Hastalarda Multidisipliner Yaklaşım (pp.9-26), Ankara: UBAK.
- Lawrence, R., Dodsworth, E., Massou, E., Sherlaw-Johnson, C., Ramsay, A. I., Walton, H., ... & Fulop, N. J. (2025). Artificial intelligence for diagnostics in radiology practice: a rapid systematic scoping review. *EClinicalMedicine*, 83.
- Lee, J. H., Kim, D. H., & Jeong, S. N. (2020). Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. *Oral diseases*, 26(1), 152-158.
- Li, J., Bu, Y., Lu, S., Pang, H., Luo, C., Liu, Y., & Qian, L. (2021). Development of a deep learning-based model for diagnosing breast nodules with ultrasound. *Journal of ultrasound in medicine*, 40(3), 513-520.
- Lukong, K. E. (2017). Understanding breast cancer–The long and winding road. *BBA clinical*, 7, 64-77.
- Mayats-Alpay, L. (2022). Artificial intelligence for automatic detection and classification disease on the X-ray images. *arXiv preprint arXiv:2211.08244*.
- Mayo, R. C., & Leung, J. (2018). Artificial intelligence and deep learning–Radiology’s next frontier?. *Clinical imaging*, 49, 87-88.
- McKinney, S. M., Sieniek, M., Godbole, V., Godwin, J., Antropova, N., Ashrafian, H., ... & Shetty, S. (2020). International evaluation of an AI system for breast cancer screening. *Nature*, 577(7788), 89-94.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *nature*, 518(7540), 529-533.
- Moravčík, M., Schmid, M., Burch, N., Lisý, V., Morrill, D., Bard, N., ... & Bowling, M. (2017). Deepstack: Expert-level artificial intelligence in heads-up no-limit poker. *Science*, 356(6337), 508-513.
- Moura, J. M., Jin, Y., Stancil, D., Zhu, J. G., Cepni, A., Jiang, Y., & Henty, B. (2005, March). Single antenna time reversal adaptive interference cancellation. In *Proceedings. (ICASSP’05). IEEE International Conference on Acoustics, Speech, and Signal Processing, 2005*. (Vol. 4, pp. iv-1121). IEEE.
- Nagi, F., Salih, R., Alzubaidi, M., Shah, H., Alam, T., Shah, Z., & Househ, M. (2023). Applications of artificial intelligence (AI) in medical education:

- a scoping review. *Healthcare Transformation with Informatics and Artificial Intelligence*, 648-651.
- Najjar, R. (2023). Redefining radiology: a review of artificial intelligence integration in medical imaging. *Diagnostics*, 13(17), 2760.
- Nedadur, R., Wang, B., & Tsang, W. (2022). Artificial intelligence for the echocardiographic assessment of valvular heart disease. *Heart*, 108(20), 1592-1599.
- Oostveen, J. C., & van de Laar, M. A. (2000, August). Magnetic resonance imaging in rheumatic disorders of the spine and sacroiliac joints. In *Seminars in arthritis and rheumatism* (Vol. 30, No. 1, pp. 52-69). WB Saunders.
- Østergaard, M., Hansen, M., Stoltenberg, M., & Lorenzen, I. (1996). Quantitative assessment of the synovial membrane in the rheumatoid wrist: an easily obtained MRI score reflects the synovial volume. *Rheumatology*, 35(10), 965-971.
- Pámies, P. (2017). Auspicious machine learning. *Nat. Biomed. Eng*, 1, 0036.
- Pan, X., Sidky, E. Y., & Vannier, M. (2009). Why do commercial CT scanners still employ traditional, filtered back-projection for image reconstruction?. *Inverse problems*, 25(12), 123009.
- Park, H., Kim, H., & Yoo, J. (2025). *AI-Enhanced Lower Extremity X-Ray Segmentation: A Promising Tool for Sarcopenia Diagnosis*. *Healthcare* 2025, 13, 2488.
- Pasa, F., Golkov, V., Pfeiffer, F., Cremers, D., & Pfeiffer, D. (2019). Efficient deep network architectures for fast chest X-ray tuberculosis screening and visualization. *Scientific reports*, 9(1), 6268.
- Pendleton, S. D., Andersen, H., Du, X., Shen, X., Meghjani, M., Eng, Y. H., ... & Ang, M. H. (2017). Perception, planning, control, and coordination for autonomous vehicles. *Machines*, 5(1), 6.
- Polanski, J., Jankowska-Polanska, B., Rosinczuk, J., Chabowski, M., & Szymanska-Chabowska, A. (2016). Quality of life of patients with lung cancer. *OncoTargets and therapy*, 1023-1028.
- Potočník, J., Foley, S., & Thomas, E. (2023). Current and potential applications of artificial intelligence in medical imaging practice: A narrative review. *Journal of medical imaging and radiation sciences*, 54(2), 376-385.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv:1711.05225*.
- Rodriguez-Ruiz, A., Lång, K., Gubern-Merida, A., Broeders, M., Gennaro, G., Clauser, P., ... & Sechopoulos, I. (2019). Stand-alone artificial intelligence for breast cancer detection in mammography: comparison with 101 radiologists. *JNCI: Journal of the National Cancer Institute*, 111(9), 916-922.

- Schattenberg, J. M., Chalasani, N., & Alkhouri, N. (2023). Artificial intelligence applications in hepatology. *Clinical Gastroenterology and Hepatology*, 21(8), 2015-2025.
- Shrestha, P., Poudyal, B., Yadollahi, S., Wright, D. E., Gregory, A. V., Warner, J. D., ... & Kline, T. L. (2022). A systematic review on the use of artificial intelligence in gynecologic imaging—background, state of the art, and future directions. *Gynecologic oncology*, 166(3), 596-605.
- Stoel, B. (2020). Use of artificial intelligence in imaging in rheumatology—current status and future perspectives. *RMD open*, 6(1).
- Stuckey, S. L., Goh, T. D., Heffernan, T., & Rowan, D. (2007). Hyperintensity in the subarachnoid space on FLAIR MRI. *American journal of roentgenology*, 189(4), 913-921.
- Tessler, F. N., & Thomas, J. (2023). Artificial intelligence for evaluation of thyroid nodules: a primer. *Thyroid*, 33(2), 150-158.
- Tsai, D. J., Lin, C., Lin, C. S., Lee, C. C., Wang, C. H., & Fang, W. H. (2024). Artificial intelligence-enabled chest X-ray classifies osteoporosis and identifies mortality risk. *Journal of medical systems*, 48(1), 12.
- Tyndall, D. A. (2024). A primer and overview of the role of artificial intelligence in oral and maxillofacial radiology. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 138(1), 112-117.
- Wang, S., Su, Z., Ying, L., Peng, X., Zhu, S., Liang, F., ... & Liang, D. (2016, April). Accelerating magnetic resonance imaging via deep learning. In *2016 IEEE 13th international symposium on biomedical imaging (ISBI)* (pp. 514-517). IEEE.
- Wang, X., Yu, J., Zhu, Q., Li, S., Zhao, Z., Yang, B., & Pu, J. (2020). Potential of deep learning in assessing pneumoconiosis depicted on digital chest radiography. *Occupational and environmental medicine*, 77(9), 597-602.
- Xie, H., Yang, D., Sun, N., Chen, Z., & Zhang, Y. (2019). Automated pulmonary nodule detection in CT images using deep convolutional neural networks. *Pattern recognition*, 85, 109-119.
- Xiong, W., Droppo, J., Huang, X., Seide, F., Seltzer, M. L., Stolcke, A., ... & Zweig, G. (2017). Toward human parity in conversational speech recognition. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 25(12), 2410-2423.
- Xu, W., Jia, X., Mei, Z., Gu, X., Lu, Y., Fu, C. C., ... & Chinese Artificial Intelligence Alliance for Thyroid and Breast Ultrasound. (2023). Generalizability and diagnostic performance of AI models for thyroid US. *RadioLOGY*, 307(5), e221157.
- Yamamoto, N., Sukegawa, S., Kitamura, A., Goto, R., Noda, T., Nakano, K., ... & Ozaki, T. (2020). Deep learning for osteoporosis classification using hip radiographs and patient clinical covariates. *Biomolecules*, 10(11), 1534.

- Yan, L., Li, Q., Fu, K., Zhou, X., & Zhang, K. (2025). Progress in the application of artificial intelligence in ultrasound-assisted medical diagnosis. *Bi-engineering*, 12(3), 288.
- Zhang, R., Tie, X., Qi, Z., Bevins, N. B., Zhang, C., Griner, D., ... & Chen, G. H. (2021). Diagnosis of coronavirus disease 2019 pneumonia by using chest radiography: Value of artificial intelligence. *Radiology*, 298(2), E88-E97.
- Zhen, S. H., Cheng, M., Tao, Y. B., Wang, Y. F., Juengpanich, S., Jiang, Z. Y., ... & Cai, X. J. (2020). Deep learning for accurate diagnosis of liver tumor based on magnetic resonance imaging and clinical data. *Frontiers in oncology*, 10, 680.
- Zhou, S., Zhang, X., & Zhang, R. (2019). Identifying cardiomegaly in ChestX-ray8 using transfer learning. In *MEDINFO 2019: Health and Wellbeing e-Networks for All* (pp. 482-486). IOS Press.
- Zhu, B., Liu, J. Z., Cauley, S. F., Rosen, B. R., & Rosen, M. S. (2018). Image reconstruction by domain-transform manifold learning. *Nature*, 555(7697), 487-492.
- Zou, X. L., Ren, Y., Feng, D. Y., He, X. Q., Guo, Y. F., Yang, H. L., ... & Zhang, T. T. (2020). A promising approach for screening pulmonary hypertension based on frontal chest radiographs using deep learning: a retrospective study. *PloS one*, 15(7), e0236378.