

Tıbbi Radyasyon Cihazları: Klinik Uygulamalar ve Yapay Zekâ Tabanlı Yaklaşımlar

Editörler: Dr. Öğr. Üyesi Süreyya NUR
Doç. Dr. Turan ŞAHMARAN

Tıbbi Radyasyon Cihazları: Klinik Uygulamalar ve Yapay Zekâ Tabanlı Yaklaşımlar

Editörler:

Dr. Öğr. Üyesi Süreyya NUR

Doç. Dr. Turan ŞAHMARAN



Published by

Özgür Yayın-Dağıtım Co. Ltd.

Certificate Number: 45503

📍 15 Temmuz Mah. 148136. Sk. No: 9 Şhitkamil/Gaziantep

☎ +90.850 260 09 97

📞 +90.532 289 82 15

🌐 www.ozgurayinlari.com

✉ info@ozgurayinlari.com

Tıbbi Radyasyon Cihazları Klinik Uygulamalar ve Yapay Zekâ Tabanlı Yaklaşımlar

Editörler: Dr. Öğr. Üyesi Süreyya NUR • Doç. Dr. Turan ŞAHMARAN

Language: Turkish

Publication Date: 2025

Cover design by Mehmet Çakır

Cover design and image licensed under CC BY-NC 4.0

Print and digital versions typeset by Çizgi Medya Co. Ltd.

ISBN (PDF): 978-625-8562-47-7

DOI: <https://doi.org/10.58830/ozgur.pub1104>



This work is licensed under the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0). To view a copy of this license, visit <https://creativecommons.org/licenses/by-nc/4.0/>
This license allows for copying any part of the work for personal use, not commercial use, providing author attribution is clearly stated.

Suggested citation:

Nur, S. (ed), Şahmaran, T. (ed) (2025). *Tıbbi Radyasyon Cihazları Klinik Uygulamalar ve Yapay Zekâ Tabanlı Yaklaşımlar*. Özgür Publications. DOI: <https://doi.org/10.58830/ozgur.pub1104>. License: CC-BY-NC 4.0

The full text of this book has been peer-reviewed to ensure high academic standards. For full review policies, see <https://www.ozgurayinlari.com/>



Ön Söz

Yapay Zekâ (YZ), tıbbın çeşitli alanlarında hızla kullanılmaya başlanmış, özellikle klinik uygulamalarda hasta bakımının iyileştirilmesi, hastalıkların erken teşhisi ve tedavi süreçlerinin optimizasyonunda önemli bir potansiyele sahip olmuştur. Yapay zekâ, görüntüleme analizi, klinik karar destek sistemleri, hasta izleme ve kişiselleştirilmiş tedavi yaklaşımlarında etkili bir araç olarak ön plana çıkmaktadır. Ancak, klinik ortamda başarılı bir şekilde uygulanabilmesi için bazı etik, teknik ve güvenlik sorunları ele alınmalıdır.

YZ, klinikte pratik olarak kullanıma girmeye başladıktan sonra, hastaların tedavi süreçlerini önemli ölçüde değiştirebilir. YZ, klinik karar destek sistemlerinin geliştirilmesine yardımcı olmakta ve kişiselleştirilmiş tedavi planları oluşturulmasında etkin bir şekilde kullanılmaktadır. YZ, hasta verilerini analiz ederek, risk değerlendirmeleri yapabilir ve tedavi stratejileri oluşturabilir. Özellikle kanser tedavisinde, YZ'nin görüntüleme ve genetik verileri analiz ederek doğru tedavi planlarını oluşturabilmesi, tedavi süreçlerini büyük ölçüde iyileştirmektedir. YZ ayrıca, takip edilen hastaların izlenmesinde de etkili bir araçtır. Örneğin, kanser hastalarının tedaviye yanıtlarını değerlendirmek ve hastalığın seyrini izlemek, YZ algoritmaları sayesinde daha hassas bir şekilde yapılabilir.

Bu kitap, medikal görüntüleme, nükleer tıp ve radyoterapi alanlarında yaşanan teknolojik dönüşümü, yapay zekâ uygulamaları odağında bütüncül bir bakış açısıyla ele almaktadır. Sağlık fiziki ve tıbbi görüntüleme disiplinlerinde yapay zekâ tabanlı yaklaşımların tanı, tedavi planlama, dozimetri ve kalite kontrol süreçlerine entegrasyonu, güncel literatür ve klinik uygulamalar çerçevesinde değerlendirilmektedir. YZ destekli ölçüm, dozimetri ve kalite kontrol uygulamalarının hasta güvenliği, doğruluk ve standardizasyon üzerindeki etkileri vurgulanmaktadır. Ayrıca, radyoterapi alanında tedavi planlama süreçlerinin kritik aşamalarından biri olan konturlama işlemlerinde yapay zekânın sağladığı zaman tasarrufu, kullanıcı bağımlılığının azaltılması ve planlama kalitesinin artırılmasına yönelik katkılar ele alınmaktadır. Brakiterapi uygulamalarında ve otomatik tedavi planlama sistemlerinde yapay zekâ tabanlı yöntemlerin doz dağılımı optimizasyonu ve klinik iş akışına entegrasyonu kapsamlı biçimde değerlendirilmektedir.

Sonuç olarak bu kitap, yapay zekânın medikal görüntüleme ve tedavi süreçlerinde sunduğu olanakları disiplinler arası bir perspektifle ele alarak

hem akademik hem de klinik uygulamalara yönelik güncel ve kapsamlı bir başvuru kaynağı sunmayı amaçlamaktadır.

Kitapta; tıpta kullanılan radyasyon üreten cihazlar, medikal görüntülemede yapay zekâ uygulamaları, nükleer tıpta hibrit görüntülemede görüntü kalitesini etkileyen faktörler ve görüntü optimizasyonu, hibrit ve dijital sistemlerle teknolojik dönüşüm, yapay zekâ destekli ölçüm–dozimetri–kalite kontrol, radyoterapi tedavi planlama konturlamasında yapay zekâ ile brakiterapide yapay zekâ ve otomatik tedavi planlama sistemleri (OTPS) gibi konular ele alınmıştır.

İçindekiler

Ön Söz	iii
--------	-----

Bölüm 1

Medikal Görüntüleme ve Yapay Zekâ	1
<i>Süreyya Nur</i>	

Bölüm 2

Nükleer Tıp Hibrit Görüntülemeye Görüntü Kalitesine Etki Eden Faktörler ve Görüntü Optimizasyonu	25
<i>Feryal Çakır</i>	

Bölüm 3

Nükleer Tıpta Teknolojik Dönüşüm: Hibrit Ve Dijital Sistemler	57
<i>Turan Şahmaran</i>	

Bölüm 4

Yapay Zekâ Destekli Ölçüm, Dozimetri ve Kalite Kontrol	87
<i>Esil Kara</i>	

Bölüm 5

Radyoterapi Tedavi Planlama Konturlamasında Yapay Zeka	115
<i>Hikmettin Demir</i>	

Bölüm 6

Brakiterapide Yapay Zeka	131
<i>Telat Aksu</i>	

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 tanılabilirliğin 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, pnömöni, 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 [Hossein 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 kütlesini 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 bozuxsa 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.

Nükleer Tıp Hibrit Görüntülemede Görüntü Kalitesine Etki Eden Faktörler ve Görüntü Optimizasyonu

Feryal Çakır¹

Özet

Bu bölüm, nükleer tıpta kullanılan hibrit görüntüleme sistemlerinde görüntü kalitesi ile kantitatif performansı belirleyen teknik bileşenleri özetler. Görüntü kalitesi; lezyon saptanabilirliği, kontrast, gürültü ve uzaysal çözünürlük gibi ölçülebilir metrikler üzerinden değerlendirilir ve klinik amaca göre hedef metrik tanımlama yaklaşımı benimsenir. Donanımsal bileşenler kapsamında dedektör teknolojisi ve geometrisi, kolimatör özellikleri, görüş alanı ve sayım-hızı sınırlılıkları ele alınır. Bilgi edinme aşamasında enjekte edilen aktivite ile bilgi edinim süresi bileşimi, yatak başına bilgi edinim süresi, matris ile piksel /voksel boyutu, örnekleme açısı, enerji penceresi seçimi, solunum ve hasta hareketi yönetimi ile hasta özelliklerinin gürültü / kontrast dengesine etkisi açıklanır. Bilgisayarlı tomografi bileşeninde tüp gerilimi ve tüp akımı seçimi, metal artefaktları ve bilgisayarlı tomografi tabanlı foton azalım haritasının doğruluğu; manyetik rezonans görüntülemede ise manyetik rezonans tabanlı foton azalım düzeltmesinde segmentasyon hataları, bobin/implant zayıflatması ve zaman uyumsuzluğu tartışılır. Görüntü yeniden yapılandırılması ve düzeltme zincirinde foton azalım ve saçılma düzeltmeleri, ölü zaman düzeltmesi, nokta yayılım fonksiyonu ve uçuş zamanı modellemesi, iterasyon–altküme seçimi, sonradan filtreleme ve kısmi hacim etkisinin hem görüntü görünümü hem de standartlaştırılmış tutulum değeri ve aktivite ölçümlerine etkisi özetlenir. Son olarak, merkezler arası karşılaştırılabilirlik için çapraz kalibrasyon, fantom temelli doğrulama, standart parametre raporlama ve sürekli kalite kontrol/kalite güvencesi zinciri vurgulanır; optimizasyonun tek bir evrensel protokol yerine tanımlı klinik soruya uygun, ölçülebilir hedeflerle yürütülmesi önerilir.

1 Dr., Ankara Etlik Şehir Hastanesi, Nükleer Tıp Kliniği, Orcid: 0009-0004-8260-367X, feryal_060881@hotmail.com

1.GİRİŞ

Hibrit görüntüleme; nükleer tıbbın uzun yıllardır sürdürdüğü fonksiyonel görüntüleme yaklaşımını aynı incelemede anatomik bilgiyle bütünleştiren ‘fonksiyonel görüntüleme–anatomik korelasyon’ düzeyine taşımıştır. Bu bütünleşme; görüntü yorumunu yalnızca görsel değerlendirmeye sınırlamayıp, tekrarlanabilir ve karşılaştırılabilir kantitatif metriklere dayalı bir değerlendirme yaklaşımını giderek daha merkezi hâle getirmiştir. Güncel klinik pratikte hibrit sistemler; yalnızca lezyon saptama, evreleme ve tedavi yanıtı değerlendirmesi için değil; aynı zamanda standardize edilebilir nicel ölçümler üzerinden klinik karar süreçlerini güçlendiren platformlar olarak konumlanmaktadır. Bu nicel çerçeve; standartlaştırılmış tutulum değeri (Standardized Uptake Value, SUV ve türevleri), aktivite konsantrasyonu (kBq/mL), kinetik parametreler ve görüntü-temelli dozimetri için kullanılan girdileri kapsar (Boellaard et al., 2015; Kinahan et al., 2020). Bu dönüşüm güzel görüntünün tek başına yeterli olmadığını; özellikle nicel uygulamalarda toplam ölçüm belirsizliğinin kontrol edilmesi gerektiğini göstermektedir. Bu nedenle, nicel çıktılar için hata bileşenlerinin sistematik olarak yönetilmesi ve sonuçların tekrarlanabilirlik ile yeniden üretilebilirlik düzeylerinde güvence altına alınması zorunludur (Boellaard et al., 2015; Kinahan et al., 2020).

Nicel doğruluğun güvenilir biçimde elde edilebilmesi için hibrit görüntüleme performansı; görsel kontrast ve keskinliğin ötesinde, kalite kontrol zinciri ve fiziksel düzeltmelerin doğruluğu (foton azalım saçılım, ölü-zaman vb.), gürültü davranışı ve zaman içindeki kararlılık gibi bileşenlerin bileşkesi olarak ele alınmalıdır (Dickson et al., 2023; Koole et al., 2023). Bu nedenle performans yönetimi, tek seferlik kabul testlerinden ibaret olmayıp; kalite kontrol (Quality Control, QC) ve kalite güvencesi (Quality Assurance, QA) çerçevesinde tanımlı sıklıklarla yürütülen, tolerans dışındaki sapmaların erken yakalanmasını hedefleyen rutin bir süreç olarak kurgulanmalıdır (Koole et al., 2023; American Association of Physicists in Medicine [AAPM], 2019a). Benzer biçimde, cihaz performansının ortak bir ölçme ve raporlama dili ile izlenmesi; hem merkez içi süreklilik hem de merkezler arası karşılaştırılabilirlik ve harmonizasyon açısından kritik önem taşır (Dickson et al., 2023; Koole et al., 2023).

Görüntü optimizasyonu, tek bir evrensel parametre seti tanımlamaktan ziyade; belirli bir klinik görev için performans hedeflerini ve klinik kısıtları birlikte optimize eden çok değişkenli bir problemdir. Optimum ayarlar, hedeflenen çıktıya göre (örn. lezyon saptama performansı, SUV kararlılığı, aktivite konsantrasyonu doğruluğu, kinetik parametre güvenilirliği veya görüntü-temelli dozimetri belirsizliğinin azaltılması) değişebilmektedir.

Hibrit sistemlerde görüntü kalitesi ve kantitatif performans; sistem donanımının belirlediği fiziksel sınırlar, veri toplama (bilgi edinme) ve görüntü işleme/rekonstrüksiyon olmak üzere üç unsurun birlikte etkisiyle belirlenir. Sisteme ait donanımsal faktörler; Pozitron Emisyon Tomografisi (Positron Emission Tomography, PET) için dedektör teknolojisi ve geometrisi, zaman çözünürlüğü ve uçuş zamanı (TOF) kapasitesi, enerji çözünürlüğü ve eksenel görüş alanı, Tek Foton Emisyonlu Bilgisayarlı Tomografi (Single Photon Emission Computed Tomography, SPECT) için kolimatör tasarımı (delik çapı/uzunluğu, septa kalınlığı) ve dedektör–kolimatör yanıtı, Bilgisayarlı Tomografi (Computed Tomography, BT/CT) bileşeni için ise tüp–dedektör mimarisi ve spektral/foton akısı özellikleri gibi bileşenleri içerir. Manyetik Rezonans Görüntüleme (MRG) bileşeninde ise B0 homojenliği ve kararlılığı, gradyan sistem performansı (lineerlik, slew-rate) ve RF iletim/alım zinciri ile koil mimarisi üzerinden görüntü kalitesini ve kantitatif ölçümlerin tekrarlanabilirliğini belirgin biçimde etkiler. Bu değişkenler, standardize performans testleri ile nicel olarak karakterize edilir. PET ve SPECT performans ölçümleri NEMA test çerçevelerinde raporlanırken (National Electrical Manufacturers Association [NEMA], 2018a, 2018b), CT performans değerlendirmesi görev-tabanlı metrikleri de içeren AAPM raporlarıyla sistematikleştirilmiştir (American Association of Physicists in Medicine [AAPM], 2019b). MRG için gürültü, homojenite ve geometrik distorsiyon gibi metriklerin ölçümü ise MRG'ye özgü NEMA prosedürleri ve QA raporlarıyla tarif edilir (NEMA, 2021a, 2021b, 2021c).

Veri toplama (bilgi edinme) parametreleri; hasta hazırlığı ve biyolojik değişkenliği azaltmaya yönelik ön koşullar (örn. enjeksiyon–çekim zamanlaması), bilgi edinme süresi (PET'te yatak başı süresi; SPECT'te projeksiyon süresi ve projeksiyon sayısı), matris ve zoom seçimi, enerji penceresi tanımları ile BT/MRG protokol parametreleri gibi unsurları kapsar (Heathcote et al., 2010; Koole et al., 2023). Görüntü işleme (rekonstrüksiyon) parametreleri ise; foton azalımı ve saçılma gibi fiziksel etkilerin düzeltilmesi, ölü-zaman düzeltilmesi, iteratif yeniden yapılandırma ayarları ile nicel çıktının doğrulanmasına yönelik analiz adımlarını kapsar (Boellaard et al., 2015; Dickson et al., 2023).

Nicel hibrit görüntülemede temel hedef, yalnızca iyi görünen görüntü değil; farklı cihaz ve merkezlerde karşılaştırılabilir ölçüm üretmektir. Rekonstrüksiyon ve düzeltme zincirindeki seçimler lezyon kontrastını artırma bile nicel metriklerde merkezler arası uyumu etkileyebilmektedir. Bu nedenle merkezler arası harmonizasyon yaklaşımı; standardize bilgi edinme–yeniden yapılandırma hedefleri ve fantom temelli uygunluk değerlendirmeleri ile ölçümlerin cihaz/merkez bağımlılığını azaltmayı ve nicel performansı tanımlı kabul aralıkları içinde tutmayı amaçlar (Kaalep et al., 2018).

Bu bölümün amacı, hibrit görüntüleme görüntü kalitesini belirleyen etkenleri donanımın fiziksel sınırları, bilgi edinme parametreleri, düzeltme zinciri –yeniden yapılandırma parametreleri, harmonizasyon başlıkları altında tek bir çerçevede birleştirerek, okuyucuya klinik soruya uygun protokol optimizasyonu için uygulanabilir bir yaklaşım sunmaktır.


1. HİBRİT GÖRÜNTÜLEMEDE GÖRÜNTÜ KALİTESİNE ETKİ EDEN FAKTÖRLER

1.1. Hibrit Görüntüleme Görüntü Kalitesini Etkileyen Donanımsal Faktörler

Hibrit sistemlerde görüntü kalitesi ve nicel doğruluk, yalnızca daha iyi rekonstrüksiyon veya daha fazla sayım ile belirlenmez. Dedektör tasarımı ve geometrisi, elektronik-zamanlama altyapısı, sayım hızı–ölü zaman davranışı ve hibrit eşleşmenin (PET/CT, SPECT/CT, PET/MR) mekanik–geometrik kararlılığı gibi donanımsal bileşenlerin birlikte belirlediği fiziksel sınırlar tarafından şekillenir. Bu nedenle donanımsal performans, düzenli QC/QA ve artefakt farkındalığı ile rutin klinik kullanıma güvenli şekilde taşınmalıdır (International Atomic Energy Agency-IAEA, 2014).


1.1.1 PET: Dedektör Blokları, Sinyal İşleme Elektroniği ve Ham Veri Üzerinden Donanım Kaynaklı Artefaktlar

PET, binlerce sintilasyon kristali–fotodetektör elemanının blok mimarisi içinde organize edildiği bir yapıdır. Bu elemanların enerji çözünürlüğü, zamanlama performansı ve blok içi/arası kazanç–uniformite özellikleri, aktivite dağılımının doğru belirlenmesi için kritik önemdedir. Donanım kaynaklı arızalar (Şekil 1) yeniden yapılandırma sonrası görüntüde çoğu zaman genel kalite düşüşü veya sıra dışı bulgularla ortaya çıkabilir.



Şekil 1. Bellek kartı arızası (10. ve 20. görüntüler) ile olay sıralama/ayıklama problemlerini (7-9. ve 17-19. görüntüler) gösteren aksiyel 2-B PET görüntüleri (PET/CT atlas on quality control and image artefacts (Human Health Series No. 27; STI/PUB/1642, p. 32), by International Atomic Energy Agency [IAEA], 2014, Vienna: IAEA dan alıntılanmıştır)


Buna karşın ham veride (örn. sinogram) blok hatası, modül devre dışı kalması veya normalizasyon sapması gibi paternler daha erken ve daha seçici biçimde yakalanabilir (Şekil 2). Bu nedenle ham veri temelli kontrol, klinik nicel doğruluğu korumada pratik bir erken uyarı basamağıdır (IAEA, 2014).



Şekil 2. İki çalışmayan dedektör bloğu bulunan PET ile elde edilmiş NEMA/IEC fantomuna ait emisyon sinogramı ve rekonstrükte görüntü (PET/CT atlas on quality control and image artefacts (Human Health Series No. 27; STI/PUB/1642, p. 29), by International Atomic Energy Agency [IAEA], 2014, Vienna: IAEA dan alıntılanmıştır)

1.1.2 SPECT: Donanım Kaynaklı Tipik Artefaktlar


SPECT’te donanım kaynaklı artefaktların görünmemesi, hem tomografik görüntü yorumunun güvenilirliği hem de kantitatif ölçümlerin doğruluğu açısından kritiktir. Klinik pratikte en sık ve en ayırt edici paternlerden biri halka (ring) artefaktıdır. Bu patern çoğunlukla dedektör yanıtındaki non-uniformite (Şekil 3), COR (center-of-rotation) ofseti veya hatalı/uygunsuz uniformite (flood) düzeltme devresi ile ilişkilidir (IAEA, 2019).



Şekil 3. Dedektör non-uniformitesini yansıtan Jaszczak fantomuna ait SPECT kesit görüntüleri (SPECT/CT atlas of quality control and image artefacts (Human Health Series No. 36; STI/PUB/1860, p. 36), by International Atomic Energy Agency [IAEA], 2019, Vienna: IAEA dan alıntılanmıştır)

Bunun yanında enerji piki kayması (Şekil 4), gantri–dedektör başlığı mekanik hizalanma hataları, çift dedektörlü (çift başlı) sistemlerde dedektör başlıkları arası geometrik uyumsuzluk ve dedektörler arası hassasiyet uyumsuzluğu gibi mekanik/elektronik sapmalar, projeksiyon verisine yansiyarak rekonstrüksiyon

kesitlerinde homojenliği bozabilir ve kontrast-gürültü dengesini olumsuz etkileyebilir (IAEA, 2019).



Şekil 4. Miyokard perfüzyon SPECT çalışmasına ait projeksiyon görüntüleri (a) 125 keV ve 140 keV için düşük enerji penceresi kullanımı (b) 115 keV ve 140 keV için yüksek enerji penceresi kullanımı. (SPECT/CT atlas of quality control and image artefacts (Human Health Series No. 36; STI/PUB/1860, p. 43), by International Atomic Energy Agency [IAEA], 2019, Vienna: IAEA dan alıntılanmıştır)

1.1.3 PET/SPECT/BT: Hibrit Mimarinin Getirdiği Entegrasyon Sorunları

BT verisi, PET/BT ve SPECT/BT de hem anatomik referans hem de BT temelli foton azalım düzeltmesi (BT-AC) için kullanıldığından, BT'deki hatalar PET, SPECT kantifikasyonuna doğrudan yansiyabilir. Yüksek yoğunluklu materyallerin BT sayılarında oluşturduğu sapmalar, BT-PET-SPECT görüş alanı (Field of View, FOV) örtüşmesinin bozulması ve ardışık görüntülemeye bağlı hareket, BT-AC haritasında lokal hatalara ve buna bağlı nicel sapmalara neden olur (IAEA, 2014).


Örneğin BT transvers FOV'u, PET-SPECT FOV'unu periferde kapsamadığında, ilgili bölge azalım haritası dışında kalır ve aktivite konsantrasyon dağılımı olduğundan farklı görülebilir. (Şekil 5). Sentetik FOV genişletme çözümleri bulunsa da bu durum entegrasyon kaynaklı tipik bir sınırlılıktır (IAEA, 2014).



Şekil 5. ¹¹¹In işaretli monoklonal antikor ile yapılan bir SPECT/BT incelemesine ait koronal görüntüde, hastanın her iki kolu boyunca BT trunkasyonu görülmektedir. BT'deki bu trunkasyon, trunkasyona uğrayan anatomiye komşu bölgelerde büyük BT sayılarına (kırmızı oklar) yol açmakta ve bunun sonucu olarak bu bölgelerde radyoaktivite tutulumu yapay biçimde artmış görünmektedir (beyaz oklar). (Human Health Series No. 36; STI/PUB/1860, p. 104), by International Atomic Energy Agency [IAEA], 2019, Vienna: IAEA dan alıntılanmıştır)

1.1.4. PET/MR: Hibrit Mimarinin Getirdiği Entegrasyon Sorunları

PET/MR sistemlerinde artefaktlar ve sistematik nicel sapmaların önemli bir bölümü, BT yerine MR'dan türetilen foton azalım düzeltme haritasının (MRAC) doğruluğuna bağlıdır. MR sinyali 511 keV zayıflatma katsayılarını doğrudan temsil etmediğinden, kemik ve akciğer gibi dokuların hatalı sınıflanması, sınırlı MR görüş alanına bağlı trunkasyon ve RF koillerinin attenuasyonunun haritaya eksik/yanlış yansıtılması PET kantifikasyonunda bölgesel yanlışlıklara yol açabilir (Keereman et al, 2013; Mehranian et al., 2016). Bu hatalar her zaman belirgin bir artefakt üretmeyebilir ancak SUV, aktivite konsantrasyonu gibi metriklerde sistematik hata oluşturarak klinik yorumlamayı etkileyebilir. Dolayısıyla PET/MR'da artefakt yönetimi, yalnızca görüntü eşleşmesi değil; MRAC üretim stratejisi ve donanım bileşenlerinin (özellikle koiller) azalım modeline dahil edilmesi bağlamında, düzeltme zinciri perspektifiyle ele alınmalıdır (Mehranian et al., 2016).



Şekil 6. A, B: Atenuiasyon (foton azalım) düzeltmesi (AC) ile ilişkili artefaktlar. (A) Bu hastada MR sinyali, ventriküler beyin şantının yakın çevresinde belirgin şekilde bozulmuştur [T1 gadolinyumlu (Gad) görüntüde ok]. Bunun sonucunda sistem, AC için Dixon VIBE sekansından doğru bir μ -haritası (μ -map) türetemez (μ -map) ve bu bölge başın bir parçası olarak değil, hava olarak yanlış sınıflandırılır. Dolayısıyla etkilenen voksellerde düzeltilmiş PET bilgisi mevcut değildir [PET(AC)'de yıldız işareti] ve bunun yerine düzeltilmemiş PET verilerinin değerlendirilmesi gerekir [PET(NAC)]. (B) Sistem, yağ ve suya ait atenuiasyon değerlerini hatalı biçimde atanmıştır (hatalı μ -map); doğru atama ise altta gösterilmektedir (doğru μ -map). Foton atenuiasyon değerlerinin yanlış atanması, rekonstrüksiyon sonrası PET sinyalinin genel olarak olduğundan yüksek tahmin edilmesine yol açar [hatalı PET(AC)]. (https://www.researchgate.net/figure/A-B-Attenuation-correction-AC-related-artefacts-A-In-this-patient-the-MR-signal-is_fig5_290441613)

1.2. Hibrit Görüntülemelerde Görüntü Kalitesini Etkileyen Bilgi Edinme Parametreleri

Hibrit görüntülemelerde (PET/BT, SPECT/BT, PET/MR) bilgi edinme parametreleri; sistemin ürettiği ham sinyalin hangi sayım istatistiği düzeyinde (aktivite-süre bileşimi), hangi uzaysal örnekleme şemasında (matris, vokseller/piksel boyutu, kesit kalınlığı), hangi hareket yönetimi yaklaşımıyla (nefes paterni, gating/yeniden hizalama stratejileri) ve hangi anatomik referansla (BT veya MR) toplanacağını tanımlar. Anatomik bileşen, yalnızca lokalizasyon amacıyla değil; aynı zamanda foton azalım düzeltmesi başta olmak üzere düzeltme zincirinin kritik bir girdisi olarak emisyon verisinin kantitatif doğruluğunu belirler. Bu nedenle bilgi edinimindeki seçimler; lezyon saptanabilirliği, görüntü yapısı, uzaysal çözünürlük ve kantitatif sapma (örn. SUV veya aktivite

konsantrasyonu) üzerinde doğrudan belirleyicidir (Boellaard, 2009b; Boellaard et al., 2015).

1.2.1. PET Bilgi Edinme Parametreleri

Klinik PET’te görüntü kalitesini pratikte en güçlü biçimde belirleyen unsur, hastadan toplanan toplam sayım istatistiği (dolayısıyla gürültü–kontrast dengesi) olup bu istatistik esasen enjekte edilen aktivite ile yatak başına (bed position) bilgi edinim süresi çarpımının ve sistem duyarlılığının bir fonksiyonudur (Boellaard, 2009a). Sayım istatistiği azaldığında görüntü gürültüsü artar, bu durum özellikle küçük/düşük kontrastlı lezyonların saptanabilirliğini düşürür ve kantitatif ölçümlerin (SUV vb.) tekrarlanabilirliğini olumsuz etkiler (Boellaard et al., 2015).

Bununla birlikte, aktivitenin artırılması doğrusal bir iyileşme sağlamaz çünkü aktivite yükseldikçe saçılma ve random olaylar ile ölü zaman kısıtları belirginleşir ve gürültü gibi etkin istatistik göstergeleri plato yapabilir. Ayrıca hasta ağırlığı/ vücut kitle indeksi arttıkça foton azalımı ve saçılma artışı nedeniyle etkin sayımlar azalır. (Queiroz et al., 2014). Bu nedenle günlük rutinde sabit süre yaklaşımı yerine; hasta profili ve sistem tipine göre tanımlanmış aktivite–süre protokol optimizasyonu kullanmak daha rasyoneldir. Çok merkezli nicel uyum hedefleniyorsa, bu seçimin formülle standardize edilmesi ve merkezler arası karşılaştırılabilirliğin Avrupa Nükleer Tıp Derneği (European Association of Nuclear Medicine, EANM) bünyesindeki Avrupa Akreditasyon Programı (European Accreditation Programme, EARL) kapsamında korunması önerilir (Boellaard et al., 2015; EANM Forschungs GmbH [EARL], 2023).

PET’te karşılaştırılabilir SUV ölçümü için en kritik klinik adımlardan biri enjeksiyon–çekim arasındaki tutulum (uptake) süresinin standardizasyonudur. Uptake zamanı, radyofarmasötüğün biyodağılımını ve lezyon/arka plan kontrastını etkilediği için aynı hastada farklı günlerde veya farklı merkezlerde uptake süresinin değişmesi, tedavi yanıtı gibi SUV temelli yorumlarda belirsizliği artırır. EANM kılavuzu, FDG enjeksiyonu ile görüntüleme başlangıcı arasında 60 dk’lık bir aralığı önerir ve kabul edilebilir pencereyi 55–75 dk olarak tanımlar. Ayrıca gerçek enjeksiyon–çekim aralığının mutlaka kaydedilmesini ve bunun genellikle “aktivitenin kalibrasyon zamanı” ile aynı olmadığını bilinmesini vurgular (Boellaard et al., 2015; ACR–ACNM–SNMMI–SPR, 2021).

Tarama kapsamı (örn. kafa tabanı–uyluk, tüm vücut) ile yatak sayısı ve yataklar arası örtüşme, vücut boyunca gürültünün homojenliğini ve dolayısıyla SUV kararlılığını etkileyen temel bilgi edinim parametreleridir. EANM, çoğu onkolojik endikasyonda kafa tabanı–uyluk kapsamının yeterli olduğunu;


klirik gereksinime göre daha uzun (tüm vücut/ekstremitte veya beyin dahil) kapsamın protokolle tanımlanabileceğini belirtir (Boellaard et al., 2015). Buna ek olarak, UPICT (Uniform Protocols for Imaging in Clinical Trials) protokolünde yataklar arası örtüşme miktarının toplam tarama süresini değiştirdiği; tarama süresindeki bu değişimin de pratikte gereken enjekte dozla birlikte düşünülmesi gerektiği açıkça vurgulanır. Örtüşmenin yetersiz olduğu bölgelerde yatak sınırlarında gürültü artışı ve duyarlılık dalgalanması görülebilir. Bu etki, PET sistemlerinin aksiyel duyarlılık profilindeki kenar/merkez farklılıklarıyla da ilişkilidir. NEMA NU 2-2018 kapsamında aksiyel duyarlılık profilinin tanımlanması ve değerlendirmede aksiyel FOV'un merkezi bir bölümünün esas alınması, kenar bölgelerde duyarlılık düşüşünün nicel ölçümleri etkileyebileceğine işaret eden teknik bir çerçeve sağlar (Boellaard, 2009a; National Electrical Manufacturers Association [NEMA], 2018). Bu nedenle klinikte tarama kapsamı-yatak sayısı- yataklar arası örtüşme seçimi, cihazın aksiyel görüş alanına uygun biçimde protokolle sabitlenmelidir.

1.2.2. SPECT Bilgi Edinme Parametreleri

SPECT'te bilgi edinme, yeniden yapılandırmanın girdi verisini tanımladığı için görüntü kalitesini doğrudan şekillendirir. Bu aşamada yapılan seçimler; projeksiyon verisinin sayım istatistiğini, açısız ve uzaysal örneklemesini, saçılma ve septal penetrasyon bileşenlerini ve hastaya bağlı hareket etkilerini belirler. Bu nedenle edinim parametreleri; yeniden yapılandırma algoritması ne kadar gelişmiş olursa olsun, elde edilebilecek nihai görüntü kalitesinin ve kantifikasyon performansının üst sınırını belirleyen temel kontrol noktasıdır. Kantitatif SPECT/BT uygulamalarında bu önem daha da artar çünkü hedef yalnızca görsel olarak kabul edilebilir görüntü değil, tekrarlanabilir ve doğrulanabilir aktivite kantifikasyonudur (Dickson et al., 2023).

Bilgi edinim tasarımı, yeniden yapılandırmanın matematiksel stabilitesi ve uzaysal doğruluğu için yeterli açısız örnekleme sağlarken, aynı zamanda klinik amacın gerektirdiği sayım istatistiğini karşılamalıdır. Bu iki eksen çoğu zaman birbirini sınırlar. Örneğin projeksiyon sayısını artırmak açısız örnekleme iyileştirirken, toplam bilgi edinim süresi sabitse her projeksiyona düşen süre azalır; piksel başına sayım düşer, gürültü artar ve düşük kontrastlı lezyonların saptanabilirliği zorlaşabilir (Dickson et al., 2023). Bu nedenle optimizasyon, tek bir parametreyi artırma yaklaşımıyla değil; klinik soruya göre (lezyon saptanabilirliği, sınır keskinliği veya kantitatif doğruluk/tekrarlanabilirlik) bilgi edinim parametrelerinin birlikte ele alınmasıyla gerçekleştirilmelidir. (Dickson et al., 2023).

Kolimatör seçimi SPECT sisteminde duyarlılık ve uzaysal çözünürlüğü birlikte belirleyen en baskın bileşenlerden biridir. Bu seçim yalnızca çözünürlük-duyarlılık dengesi değil aynı zamanda izotop enerjisine bağlı septal penetrasyon ve saçılma yükü üzerinden artefakt riskinin yönetimidir. Klinik pratikte izotop enerjisi ile uyumsuz kolimatör kullanımı görüntüde artefaktlar üretebilir (Şekil 7). (International Atomic Energy Agency [IAEA], 2019).



Şekil 7. ^{99m}Tc ile görüntülenen striatal fantomda kolimatör tipinin görüntü keskinliği ve gürültüye etkisi: (a) LEUHR, (b) LEHR, (c) MEGP. Bilgi edinme; 3,3 mm piksel boyutu, 120 projeksiyon ve 15 cm dönüş yarıçapı ile toplam 10 dakikada gerçekleştirilmiş; görüntüler Butterworth filtreli FBP ile (cut-off: 0,45 Nyquist; mertebesi: 10) yeniden yapılandırma ile elde edilmiştir. Kolimatör geometrisine bağlı olarak uzaysal çözünürlük-duyarlılık dengesi değişmekte; özellikle daha kalın septalı MEGP kolimatörde çözünürlükte yumuşama görülebilmektedir (Human Health Series No. 36; STI/PUB/1860, p. 60), by International Atomic Energy Agency [IAEA], 2019, Vienna: IAEA dan alıntılanmıştır)

Enerji penceresi seçimi ve saçılma yönetimi, bilgi edinim aşamasında kontrast ve kantitatif doğruluğu belirleyen bir diğer kritik kontrol noktasıdır. Enerji penceresinin amacı primer fotonları mümkün olduğunca korurken saçılma katkısını sınırlamaktır. Saçılma, kontrastı düşürmekle kalmaz, kantifikasyonda sayımın yanlış enerji bilgisi içermesine yol açarak sistematik sapmaları büyütebilir. Bu nedenle enerji penceresi yalnızca sayımı artıran bir parametre değil, görüntü kalitesi ve kantitatif doğruluk açısından kontrollü bir filtre gibi düşünülmelidir (IAEA, 2019). Kantitatif SPECT/BT'de enerji penceresi tanımı, kullanılacak saçılma düzeltme yaklaşımıyla birlikte protokolleştirilerek tekrarlanabilirlik ve merkezler arası karşılaştırılabilirlik hedefleriyle uyumlu hale getirilmelidir (Dickson et al., 2023).

Bilgi edinim geometrisi (orbit tipi, dönüş yarıçapı, hasta konturu takibi) kolimatör kaynaklı geometrik bulanıklık üzerinde doğrudan etkilidir. Dedektörün hastaya yaklaştırılması ve özellikle non-dairesel orbit / auto-

contour yaklaşımları, periferik yapıların çözünürlüğünü iyileştirebilir; ancak çarpma riski, immobilizasyon ekipmanları, hasta konforu ve SPECT/BT hizalaması gibi pratik sınırlılıkları vardır. (IAEA, 2019).

Açısal örnekleme (projeksiyon sayısı), yeniden yapılandırmanın stabilitesi için kritiktir. Örnekleme yetersiz kaldığında çizgisel/şeritlenme benzeri yapı bozulmaları, artefaktlar ve kantitatif sapmalar görülebilir. Bu nedenle projeksiyon sayısı seçimi; ne kadar çok o kadar iyi şeklinde değil, matriks/piksel boyutu, hedef lezyon boyutu ve planlanan filtreleme stratejisiyle uyumlu bir şekilde yapılmalıdır (Dickson et al., 2023). Benzer biçimde projeksiyon süresi ve toplam bilgi edinim süresi, SPECT görüntüsündeki gürültünün ana belirleyicisi olan sayım istatistiğini yönetir. Poisson istatistiği nedeniyle sayım arttıkça görelî belirsizlik azalır, ancak süreyi uzatmak hareket artefaktına duyarlılığı artırır ve klinik iş akışını zorlayabilir (Dickson et al., 2023). Bu nedenle bilgi edinim süresi; klinik amaçla uyumlu bir sayım hedefi üzerinden planlanmalı, gerektiğinde aktivite süre kombinasyonu hasta özellikleri ve sistem performansına göre optimize edilmelidir (Dickson et al., 2023).

Uzaysal örnekleme kararları (matriks, piksel boyutu, zoom) da görüntü gürültüsünü doğrudan etkiler. Daha küçük piksel boyutu anatomik ve lezyon sınırlarının daha iyi temsil edilmesine katkı sağlasa da, aynı toplam sayımda piksel başına düşen sayımı azaltarak gürültüyü artırabilir. Bu nedenle matriks/zoom seçimi tek başına bir çözünürlük ayarı değil, sayım istatistiği ile birlikte ele alınması gereken bir örnekleme kararıdır (IAEA, 2019). Klinikte suboptimal bilgi edinim seçimlerinin görüntüde artefaktlara ve yorum hatalarına dönüşebileceğini gösteren vaka temelli yaklaşım, bu denge ihtiyacını pratik düzeyde destekler (IAEA, 2019).

SPECT/BT'ye özgü en kritik limitlerden biri, SPECT- BT görüntülerinin tam eşleşmemesidir. (misregistration) Bu durum hem görsel kaliteyi hem de kantitatif doğruluğu bozabilir. Hasta hareketi, pozisyon değişimi ve solunuma bağlı etkiler özellikle küçük lezyonlarda kontrast kaybı ve hatalı lokalizasyonla sonuçlanabilir (IAEA, 2019).

1.2.3. BT Bilgi Edinme Parametreleri

Hibrit görüntüleme sistemlerinde BT bileşeni; foton azalım düzeltmesi (BT-AC) için doğrusal zayıflatma haritası üretmek, anatomik lokalizasyon sağlamak ve uygun endikasyonda tanısal BT bilgisi sunmak üzere farklı klinik görevler için konumlandırılmıştır. Bu nedenle BT protokolü tek tip değildir. BT-AC odaklı ultra-düşük doz, lokalizasyon amaçlı düşük doz ya da tanısal BT seçenekleri, klinik soruya göre belirlenir. (International Atomic Energy Agency [IAEA], 2014).


BT'de görüntü kalitesi ve hasta dozu; tüp gerilimi (kVp), tüp akımı–zaman (mA, mAs / efektif mAs), rotasyon zamanı, pitch ve kolimasyon/dedektör konfigürasyonu, tarama uzunluğu (scan length) ve yeniden yapılandırma (kesit kalınlığı, kernel/algoritma) tarafından birlikte belirlenir (Heathcote et al, 2010).

KVp; foton spektrumunu ve doku kontrastını belirler, aynı zamanda zayıflatma katsayılarının Hounsfield Unit (HU)'den μ 'ya dönüşümünü etkileyerek BT-AC zincirine yansır. Pratik bir yaklaşım olarak kVp arttıkça penetrasyon artar; ancak kontrast ve doz dengesi yeniden değerlendirilmelidir (Heathcote et al., 2010). BT-AC odaklı protokoller genellikle kabul edilebilir HU doğruluğu, düşük gürültü eşiği sağlayacak en düşük kVp ile hedeflenir. Hasta kalınlığı arttıkça kVp yükseltme ihtiyacı doğabilir. Tanısal BT hedefinde ise klinik endikasyon (örn. abdomen/toraks), kontrast kullanımı ve hasta boyutuna göre kVp seçimi ayrıca optimize edilir.

BT'de foton istatistiğini doğrudan belirleyen temel değişken mAs'tır (mA $\times$ rotasyon zamanı). mAs artarsa gürültü azalır fakat doz yükselir (Heathcote et al., 2010). Hibrit uygulamalarda iki kritik nokta bulunmaktadır. BT-AC için temel gereksinim; doğru zayıflatma haritası üretmek ve belirgin BT artefaktlarını önlemektir. Bu, tanısal BT'ye kıyasla daha düşük mAs ile sağlanabilir (Heathcote et al., 2010). Çok agresif doz düşürmede HU gürültüsü/artefaktları artırarak AC haritasını bozabilir; bu nedenle BT-AC için en düşük doz yaklaşımı, artefakt kontrolü ile birlikte yürütülmelidir (IAEA, 2014).

Helikal BT'de pitch, masa ilerlemesi ile gantry rotasyonu arasındaki ilişkiyi tanımlar. Pitch yükseltmek aynı anatomik alanı daha kısa sürede taramayı sağlar ancak aynı mA/mAs değerlerinde efektif örnekleme ve gürültü/doz dengesi değişir. Bu yüzden uygulamada efektif mAs kavramı önem kazanır (Heathcote et al, 2010).

BT'de tarama uzunluğu, doz–uzunluk çarpımı (Dose–Length Product, DLP)'ni doğrudan büyüten temel belirleyicilerdendir. Hibrit uygulamalarda BT kapsamı PET/SPECT kapsamıyla uyumlu planlanmalı, gereksiz anatomik alan taramasından kaçınılmalıdır (Heathcote et al., 2010). Pozisyonlama tarafında; kol pozisyonu, metal aksesuarlar (Şekil 8) ve solunum paterni BT-AC'yi etkileyebilecek artefaktlara zemin hazırlayabilir. Bu nedenle BT-AC hedefleniyorsa hasta hazırlığı ve immobilizasyon, artefakt minimizasyonu odaklı standardize edilmelidir (IAEA, 2014).



Şekil 8. Yedi metal nesnenin fantoma tutturulduğu önizleme taraması; nesnelerin tamamı kolaylıkla saptanabilmektedir. Parmak yüzükleri (f) ve (g), suyla doldurulmuş şırınga parmaklarına monte edilmiştir. Kalan nesneler ise doğrudan fantomun yüzeyine bantlanmıştır. (Human Health Series No. 36; STI/PUB/1860, p. 88), by International Atomic Energy Agency [IAEA], 2019, Vienna: IAEA dan alınmıştır)

1.2.4. MR Bilgi Edinme Parametreleri

PET/MR hibrit sistemlerinde MR yalnızca PET bulgularına anatomik eşlik sağlayan ek bir modül olarak değerlendirilemez çünkü PET kantifikasyon zincirinin kritik bir adımı olan foton azalım düzeltmesi, PET/MR'de çoğunlukla MR görüntülerinden türetilen azalım haritasına (MR-based attenuation correction, MRAC) dayanır. Bu nedenle MR bilgi edinimindeki kalite, stabilite ve artefakt profili; yalnız MR görüntüsünün okunabilirliğini değil, PET SUV doğruluğunu ve nicel ölçümlerin tekrarlanabilirliğini de belirler. PET'in kantitatif üretimi için BT- veya MR-tabanlı bir azalım haritasının gerekli olduğu ve PET/MR bileşeninde MR bilgi ediniminin kalite kontrol kapsamına alınmasının zorunlu olduğu vurgulanmaktadır (Koole et al., 2023).

PET/MR'da MRAC'ye hizmet eden bilgi edinim parametreleri, PET nicel doğruluğu açısından en kritik girdilerden biridir. Dolayısıyla MR bilgi edinim parametreleri yalnızca MR görüntü kalitesi hedefiyle değil, aynı zamanda MRAC haritasının güvenilir üretimi ve PET ile doğru hizalanması (registration) gözetilerek optimize edilmelidir (Koole et al., 2023).

MR'de ölçülebilir görüntü kalitesi, temelde örnekleme ve gürültü dengesini belirleyen bilgi edinim parametrelerinin birlikte etkisiyle oluşur. PET/MR bağlamında bu parametreler MRAC ve PET kantifikasyon hatasına taşınabilir olduğu için daha kritik hale gelir. Örneğin PET FOV'u ile uyumlu anatomik kapsama sağlanmadığında MRAC haritasında trunkasyon riski artar ve bu durum özellikle gövde periferinde azalım haritasının yanlış modellenmesine yol açabilir (Koole et al., 2023). Benzer şekilde matris/piksel boyutu (in-plane çözünürlük), kesit kalınlığı ve dilimler arası aralık; anatomik sınırların temsili ile gürültü arasında bir köprü oluşturur. Çok küçük piksel ve/veya çok ince kesit, anatomik keskinliği artırsa bile gürültü maliyeti doğurarak artefakt duyarlılığını yükseltebilir, buna karşılık kalın kesit ve dilimler arası boşluk, özellikle küçük anatomik yapıların ve sınırların temsilde kısmi hacim etkisini artırarak segmentasyon/sınıflama hatasına zemin hazırlayabilir ve MRAC doğruluğunu olumsuz etkileyebilir (Koole et al., 2023). 2B-3B edinim tercihi de benzer biçimde değerlendirilmelidir. 3B sekanslar izotropik voksel ve çok düzlemlili yeniden yapılandırma avantajı sağlarken hareket duyarlılığını artırabilir, bu nedenle PET yatak süresi, beklenen hareket profili ve hedef klinik görev birlikte gözetilmelidir (Koole et al., 2023).

Zamanlama parametreleri (TR/TE), flip angle, bant genişliği, echo train özellikleri ve hızlandırma yaklaşımları MR'de gürültü-kontrast-distorsiyon dengesini belirler. PET/MR'de bu denge; inceleme süresi uzadıkça hasta hareketinin artma ihtimali, MRAC üretimine giden MR verisindeki artefakt oluşumu gibi sebeplerden PET düzeltmelerine yansiyabilir ve SUV ölçümlerinde sistematik sapma oluşturabilir (Koole et al., 2023). Bu nedenle protokol tasarımında en yüksek MR çözünürlüğü hedefi tek başına optimizasyon kriteri değildir. Klinik görev- PET kantifikasyon güvenilirliği- süre/hareket riski birlikte optimize edilmelidir (Koole et al., 2023).

PET/MR'da koil konfigürasyonu, koil yerleşimi, hasta üstü aksesuarların standardizasyonu ve tarama odası disiplininin korunması hem güvenlik hem de ölçüm tekrarlanabilirliği açısından protokolün parçası olarak tanımlanmalıdır (Koole et al., 2023). Özellikle MRAC sekansları planlanırken distorsiyon ve sınıflama hatasına yatkın bölgelerde (örn. diyafram/akciğer tabanları, sinüsler, metal implant çevresi) kötü senaryo dikkate alınmalı; hareket azaltma stratejileri ve hizalama kontrol adımları rutin iş akışına entegre edilmelidir (Koole et al., 2023).

Çok merkezli uyum ve akreditasyon hedeflenen senaryolarda PET/MR'de azalım düzeltmesi süreçlerinin üretici tarafından önerilen prosedürlere uygun yürütülmesi ve sistemin sunduğu kalite kontrol araçlarının protokol

yaklaşımıyla birlikte işletilmesi önerilmektedir (EANM Forschungs GmbH [EARL], 2023).

1.3. Hibrit Görüntülemelerde Görüntü Kalitesini Etkileyen Yeniden Yapılandırma Parametreleri

Hibrit görüntülemelerde (PET/BT, SPECT/BT ve PET/MR) yeniden yapılandırma; projeksiyon verilerinin düzeltmeler (zayıflama, saçılma vb.) ile birlikte modele dâhil edilerek kesitsel görüntüye dönüştürüldüğü ve uzaysal çözünürlük–gürültü–kontrast–kantitatif sapma dengesinin nihai olarak belirlendiği kritik aşamadır. Bu nedenle yeniden yapılandırma seçimleri yalnız görsel kaliteyi değil; SUV, aktivite konsantrasyonu ve voksel tabanlı kantifikasyon gibi ölçümlerin doğruluğunu, tekrarlanabilirliğini ve merkezler arası karşılaştırılabilirliğini de doğrudan etkiler (Boellaard et al., 2015; Boellaard et al., 2025).

İteratif yeniden yapılandırma yaklaşımlarında (PET ve SPECT’te yaygın olarak OSEM (Ordered Subsets Expectation Maximization) algoritması ve türevleri) görüntü kalitesi temelde üç eksenin birlikte etkileşimiyle şekillenir. Modelleme; sistem geometrisi ve fiziksel süreçlerin (foton azalımı, saçılımı, çözünürlük modeli; SPECT’te kolimatör–dedektör yanıtı gibi) yeniden yapılandırma modelinde ne kadar doğru temsil edildiğini ifade eder. Model zenginleştirildikçe çözünürlük ve kontrast toparlanımı artabilir ancak yanlış veya eksik temsil artefaktlara ya da doku sınıflama hatalarına yol açarak kantitatif sapma üretebilir (Dickson et al., 2023; International Atomic Energy Agency [IAEA], 2019). Yakınsama ise güncelleme sayısı (iterasyon $\times$ subset) arttıkça aktivite dağılımının modele daha iyi uyumlanmasıyla ilişkilidir. Buna karşın gürültünün artma eğilimi nedeniyle tam yakınsama çoğu zaman klinik olarak hedeflenmez ve pratikte yeterli yakınsama ile kabul edilebilir gürültü arasında bir denge kurulması gerekir (Dickson et al., 2023). Bu dengeyi sürdürülebilir kılmak için düzenleme ve filtreleme stratejileri devreye girer. Erken durdurma, post-filtreleme ya da öncül bilgi temelli yaklaşımlar gürültüyü kontrol ederken, çoğu durumda uzaysal çözünürlükte yumuşama ve küçük lezyon kontrastında azalma gibi bir bedel yaratabilir (Tsutsui et al., 2017).

Klinik PET’te OSEM temelli yeniden yapılandırmada iterasyon ve subset seçimi, toplam güncelleme sayısı üzerinden gürültü ve kantitatif yakınsamayı birlikte belirler. Güncelleme sayısı düşük seçildiğinde yetersiz yakınsama özellikle küçük odaklarda toparlanım eksikliği ve SUV sapmalarına yol açabilir. Çok yüksek güncelleme ise gürültüyü ve gürültü korelasyonunu artırarak düşük kontrastlı lezyon saptanabilirliğini zorlaştırabilir (Boellaard et al., 2015; Tsutsui et al., 2017). Bu nedenle hedef klinik amaç (örn. tedavi yanıtı takibi, küçük

lezyon saptanabilirliği, çok merkezli harmonizasyon), güncelleme sayısı ve gürültü kontrol stratejileriyle birlikte ele alınmalıdır (Boellaard et al., 2015).

PSF (çözünürlük modelleme) ve TOF gibi sistem modelini zenginleştiren bileşenler kontrast toparlanımını artırabilir. Ancak PSF tabanlı yeniden yapılandırmalarda keskin aktivite geçişlerinde kenar aşımı artefaktları gelişebilir ve SUV_{max} 'ın artmasına neden olabilir. Bu etkinin şiddeti; iterasyon sayısı, piksel boyutu ve post-filtrelemenin yarı maksimumdaki tam genişlik (Full Width at Half Maximum, FWHM) değeri gibi parametrelerle anlamlı biçimde değişebilmektedir (Tsutsui et al., 2017). Bu nedenle PSF/TOF kullanımı, raporlanacak metrik (SUV_{max} yerine SUV_{peak}/SUV_{mean}), lezyon boyutu dağılımı ve harmonizasyon gereksinimleri ile birlikte değerlendirilmelidir (Tsutsui et al., 2017; EARL, 2023). Gürültü kontrolü için uygulanan Gaussian post-filtreleme gürültüyü azaltırken uzaysal çözünürlüğü düşürerek küçük lezyon kontrastını etkileyebilir; özellikle PSF'li yeniden yapılandırmalarda filtrenin artefakt şiddetini arttırdığı unutulmamalıdır (Tsutsui et al., 2017).

PET/BT'de yeniden yapılandırma performansı, BT tabanlı zayıflama düzeltmesi (BT-AC) ve saçılma düzeltmesi ile yakından ilişkilidir. BT'deki metal artefaktı gibi sorunlar azalım haritasını bozarak PET kantifikasyonuna yansiyabilir (Boellaard et al., 2015; IAEA, 2019). Bu bağlamda BT metal artefakt azaltım algoritmalarının PET foton azalım düzeltmesini etkileyerek hem yorum güvenini hem de kantitatif ölçümleri iyileştirebildiği gösterilmiştir (Van der Vos et al., 2017).

SPECT/BT'de OSEM güncelleme sayısı yakınsamayı belirler ancak SPECT'te farklı bölgeler ve farklı aktivite düzeyleri farklı hızlarda yakınsayabildiğinden, güncelleme sayısına bağlı bölgesel kantitatif sapma görülebilir. Kantitatif SPECT/BT'ye yönelik EANM kılavuzu, bu nedenle protokolün bilgi edinim – düzeltmeler – yeniden yapılandırma ile birlikte tasarlanmasını ve klinik kullanım amacına göre doğrulanmasını özellikle vurgular (Dickson et al., 2023). Ayrıca BT'den türetilen zayıflama haritasının yeniden yapılandırmaya gömülü kullanımı nedeniyle, BT turankasyon ve metal artefaktları SPECT kantifikasyonunu da bozabilir. Turankasyon düzeltmesi ve metal artefakt yönetimi bu açıdan kritik bileşenlerdir (IAEA, 2019).

SPECT'te uzaysal çözünürlük kolimatör geometrisine bağlı olarak derinlikle bozulur. Bu etkiyi telafi etmek için kolimatör–dedektör yanıt modellemesi (resolution recovery) kullanılabilir ve bu yaklaşım kontrast toparlanımını ve kantitatif doğruluğu iyileştirebilir. Bununla birlikte çözünürlük toparlanımı gürültüyü artırabileceğinden, klinikte post-filtreleme (Gaussian/Butterworth vb.) veya düzenleme ile gürültü–çözünürlük dengesi yeniden kurulmalıdır (Dickson et al., 2023; IAEA, 2019).

Hibrit sistemlerde BT, bir yandan anatomik korelasyon sağlarken diğer yandan emisyon verisi için azalım düzeltmesi altyapısını üretir. Bu nedenle CT’de kernel seçimi, kesit kalınlığı ve artefakt azaltım seçenekleri yalnız BT görüntüsünü değil, azalım haritası üzerinden PET/SPECT kantifikasyonunu da etkileyebilir (IAEA, 2019; Van der Vos et al., 2017).


1.4. Hibrit Görüntülemelerde Görüntü Kalitesini Etkileyen Hasta Kaynaklı Parametreler

Hibrit görüntülemelerde hasta kaynaklı parametreler, görüntüleme protokolü doğru seçilmiş olsa bile görüntü kalitesini ve kantifikasyonu bozabilen; çoğu zaman ise standartlaştırma ile kontrol altına alınabilen değişkenlerdir. Bu parametreler; hastaya ait fizyolojik/metabolik durum, radyofarmasötik uygulama kalitesi, radyofarmasötüğün uptake fazı, görüntüleme sırasında hasta hareketi / pozisyonlaması/solunumu gibi biyomekanik faktörlerdir. EANM prosedür yaklaşımında bu faktörler özellikle FDG PET/BT’de SUV harmonizasyonu için hazırlık ve zamanlama ilkeleriyle açık biçimde standardize edilir (Boellaard et al., 2015; Boellaard et al., 2025)

Hasta hazırlığında ilk kritik nokta, radyofarmasötik biyodağılımını belirleyen glukoz/insülin fizyolojisi ve kas/kahverengi yağ aktivasyonudur. Çekimden önce fiziksel egzersiz, soğuk maruziyet ve kas aktivitesi; kas ve kahverengi yağ dokusunda özellikle FDG tutulumunu artırarak lezyon saptanabilirliğini ve arka plan kontrastını olumsuz etkileyebilir. Bu nedenle çekim öncesinde hastanın sıcak tutulması, egzersizden kaçınması ve uygun açlık koşullarının sağlanması önerilir (Surasi et al., 2014).


İkinci kritik nokta, uptake süresi ve zamanlama standardizasyonudur. FDG PET/BT’de enjeksiyon–görüntüleme aralığının merkezler arası değişmesi SUV’u değiştirdiğinden, prosedürler genellikle 60 dakikalık uptake süresi etrafında dar toleranslarla standardizasyonu hedefler (örn. ± 5 dk gibi) (Hogg & Testanera, 2010). Zamanlamanın standardize edilmesi yalnızca biyolojik kinetik açısından değil, aynı hastanın ardışık çalışmalarında tedavi yanıt takibi gibi senaryolarda ölçüm tekrarlanabilirliği için de zorunludur (Boellaard et al., 2015).

Bir diğer nokta radyofarmasötik enjeksiyonunun teknik kalitesidir. Enjeksiyon infiltrasyonu/ ekstrasvazasyonu (Şekil 9), hedef dokuya ulaşan gerçek dozun azalmasına ve görüntü kantifikasyonunda hata oluşmasına yol açabilir. Bu nedenle enjeksiyon sahası kontrolü ve şüpheli durumda kayıt altına alma, prosedürel kalite güvence kapsamındadır (Boellaard et al., 2025). Bu tip durumlar, görüntü güzel görüne bile SUV’un biyolojik anlamını zedelediği için özellikle nicel çalışmalarda kritik bir sapma kaynağıdır.



Şekil 9. Radyofarmösitiğin uygulamasından sonra sol kolda subkutan infiltrasyon gösteren tüm vücut FDG-PET görüntüsü (PET/CT atlas on quality control and image artefacts (Human Health Series No. 27; STI/PUB/1642, p. 71), by International Atomic Energy Agency [IAEA], 2014, Vienna: IAEA dan alınmıştır)

Görüntü kalitesini bozan bir diğer unsur, hareket ve solunum kaynaklı misregistration etkileridir. Görüntüleme sırasında hastanın solunum döngüsünün periyodu dikkate alındığında PET-SPECT emisyon veri seti, BT'nin anlık fazıyla uyuşmadığında diyafram çevresinde fotopenik alanlar ve artefaktlar oluşabilir (Şekil 10). Bu etkiler, PET/BT'de sık solunumun tutarlı sürdürülmesi veya BT'nin normal ekspirasyonda alınmasıyla azaltılabilir (Middlebrooks, 2021). Ayrıca solunuma bağlı hareket, özellikle akciğer tabanı ve karaciğer kubbe gibi yüksek deplasman bölgelerinde küçük lezyonların bulanıklaşmasına ve aktivite konsantrasyonunun olduğundan düşük hesaplanmasına neden olabilir. Solunum gating, kantifikasyon doğruluğunu artırabilir ancak sabit tarama süresinde sayım istatistiğini bölerek gürültüyü artıracak için klinik hedefe göre dengelenmelidir (Middlebrooks, 2021).



Şekil 10. (a) BT, (b) noAC-PET, (c) AC-PET ve (d) birleştirilmiş AC-PET/BT koronal görüntü düzlemleri, diyafram bölgesinde lokal PET-BT uyumsuzluğunu göstermektedir; bu da diyaframın üzerinde, o bölgedeki zayıflamanın yetersiz düzeltilmesine karşılık gelen fotopenik alanlara neden olmaktadır. AC: azalım düzeltilmiş; noAC: azalım düzeltilmemiş (PET/CT atlas on quality control and image artefacts (Human Health Series No. 27; STI/PUB/1642, p. 58), by International Atomic Energy Agency [IAEA], 2014, Vienna: IAEA dan alıntılanmıştır)

Hasta kaynaklı parametrelerin hibrit sistemlere özgü bir diğer faktörü, pozisyonlama ve “FOV–trunkasyon” sorunlarıdır. Özellikle kolların pozisyonu, omuz kuşağı ve vücut postürü; hem BT’nin kapsama alanını hem de PET-SPECT te foton azalım düzeltme doğruluğunu etkileyebilir. Bu nedenle standart çekim pozisyonunun (ör. kollar yukarı/aşağı seçimi) klinik endikasyonla uyumlu, tekrarlanabilir ve artefakt riskini azaltacak şekilde belirlenmesi; çok merkezli uyum hedeflerinde prosedürün ayrılmaz parçasıdır (Boellaard et al., 2015). SPECT’te uzun süreli bilgi edinim sırasında küçük hareketler dahi projeksiyonlarda bozulma yaratabildiğinden, hareket şüphesinde projeksiyonların gözlenmesi, yeniden çekim kararı ve sabitleme ekipmanlarının kullanımı önerilir.

2. HİBRİT GÖRÜNTÜLEMEDE GÖRÜNTÜ KALİTESİNİ ÖLÇÜLEBİLİR KILAN METRİKLER

Hibrit görüntülemede iyi görüntü, yalnızca görsel beğeniyle değil; tanımlı klinik görevi (lezyon saptama, evreleme, tedavi yanıtı izleme, kantifikasyon, dozimetri vb.) ne ölçüde desteklediğinin sayısal göstergeleri ile tanımlanmalıdır. Bu nedenle görüntü kalitesi; kontrast–gürültü dengesi, uzaysal çözünürlük, kantitatif doğruluk, tekrarlanabilirlik ve koregistrasyon doğruluğu gibi çoklu

metrik eksenleri üzerinden ölçülebilir kılınır (Boellaard et al., 2015; Daube-Witherspoon et al., 2002).

2.1. Metrik Sınıfları: Cihaz-Tabanlı, Görüntü-Tabanlı ve Kantifikasyon-Tabanlı Ölçümler

Hibrit sistemlerde metrikler pratikte üç tamamlayıcı sınıfta ele alınır.

Cihaz-tabanlı performans metrikleri: Sistem fiziğini temsil eder. Uzaysal çözünürlük (FWHM), duyarlılık, sayım-hızı performansı gibi parametreler bu sınıftadır. Bu metrikler, sistemler arası karşılaştırma ve kabul testleri için temel çerçeveyi oluşturur (Daube-Witherspoon et al., 2002; American Association of Physicists in Medicine [AAPM], 2019a).

Görüntü-tabanlı kalite metrikleri: Klinik saptanabilirlik ile doğrudan ilişkili ölçümlerdir. Kontrast toparlanımı/geri kazanımı (contrast recovery; CR/RC), arka plan gürültüsü (background variability; BV veya COV_{BG}), akciğer rezidüsü (lung residual error) gibi fantom temelli metrikler, yeniden yapılandırma ve düzeltme zincirinin birlikte oluşturduğu sonucu sayısallaştırır (Daube-Witherspoon et al., 2002; EANM Forschungs GmbH [EARL], 2023).

Kantifikasyon-tabanlı metrikler: Klinik biyobelirteç niteliği taşıyan ölçümlerdir. PET’te SUV/SUL ve türevleri (SUV_{max}, SUV_{mean}, SUV_{peak}/SUL_{peak}), hacimsel ölçümler (ör. TLG) ve SPECT/BT’de aktivite konsantrasyonu/RC gibi ölçümler, kaliteyi ölçüm güvenilirliği üzerinden tanımlar (Boellaard et al., 2025; Dickson et al., 2023).

2.2. Uzaysal çözünürlük ve Keskinlik

Uzaysal çözünürlük, küçük yapıların ayrılabilirliğini belirleyen temel değişkendir ve pratikte FWHM ile raporlanır. PET’te uzaysal çözünürlük; dedektör fiziği ve yeniden yapılandırma modellemesinin (TOF/PSF gibi) ortak çıktısıdır. Çözünürlükteki değişim, doğrudan kısmi hacim etkisini ve dolayısıyla küçük lezyonlarda aktivite konsantrasyonunun olduğundan düşük ölçülmesi riskini belirler (Daube-Witherspoon et al., 2002). SPECT/BT tarafında da benzer biçimde çözünürlük; kolimatör-dedektör yanıtı ve yeniden yapılandırmanın birlikte belirlediği bir çıktıdır. Bu nedenle çözünürlük metrikleri kantifikasyon hatasıyla birlikte düşünülmelidir (Dickson et al., 2023; International Atomic Energy Agency [IAEA], 2019).

2.3. Kontrast Geri Kazanımı, Kısmi Hacim ve RC/CR Eğrileri

Görüntü kalitesini klinik olarak anlamlı kılan metriklerin merkezinde, lezyon-benzeri hedeflerin kontrastının ne ölçüde geri kazanıldığı yer alır. IEC/NEMA tip fantom analizlerinde kontrast geri kazanımı (veya recovery coefficient)

hedef boyutuna göre değişir. Bu, kısmi hacim etkisinin ölçümsel karşılığıdır. Bu nedenle RC/CR eğrileri hem sistemin çözünürlük kapasitesini hem de yeniden yapılandırmanın kontrastı ne pahasına yükselttiğini sayısallaştırır (Daube-Witherspoon et al., 2002; EARL, 2023).

SPECT/BT’de kantitatif performansın standardizasyonu açısından RC yaklaşımı daha da kritiktir çünkü kolimatör kaynaklı çözünürlük kaybı ve saçılma/azalım etkileri, aktivite konsantrasyonu ölçümlerinde hedef boyuta bağlı belirgin sapmalar doğurabilir. Bu nedenle RC temelli fantom değerlendirmesi, protokol optimizasyonunun ölçülebilir parametresidir (Dickson et al., 2023; IAEA, 2019).

2.4. Gürültü Metrikleri: BV , CoV_{BG} ve Gürültünün Kantifikasyona Etkisi

Gürültü, kantifikasyonun güvenilirliğini ve özellikle küçük lezyon saptanabilirliğini doğrudan etkiler. NEMA çerçevesinde arka plan gürültüsü, tipik olarak arka plan ilgi bölgelerindeki (Region of Interest, ROI) arka plan değişkenliği (background variability) veya bunun değişim katsayısı olarak ifade edilen CoV_{BG} ile temsil edilir (Daube-Witherspoon et al., 2002). Bu metrik, kontrast toparlanımı (contrast recovery, CR) veya toparlanım katsayısı (recovery coefficient, RC) ile birlikte raporlandığında, yeniden yapılandırmanın sağladığı kontrast artışının gürültü maliyeti daha görünür hâle gelir (Daube-Witherspoon et al., 2002). Bu nedenle kalite değerlendirmesinde tek başına yüksek kontrast hedeflemek yerine, klinik göreve uygun kabul edilebilir CoV_{BG} bandı içinde kalacak şekilde optimizasyon yapılması önerilir (Boellaard et al., 2015; EARL, 2023).

2.5. Kantifikasyon Metrikleri: SUV/SUL ve Türevleri

PET’te klinik kantifikasyonun omurgası SUV/SUL metrikleridir. Bu metriklerin tanımı ve raporlama standardizasyonu, merkezler arası karşılaştırılabilirlik açısından kritik olduğundan prosedür kılavuzlarında açık biçimde tarif edilir (Boellaard et al., 2015; Boellaard et al., 2025). Özellikle gürültüye duyarlılık açısından SUV_{max} (tek vokselle maksimumu) ile SUV_{peak}/SUL_{peak} (sabit hacimde ortalama) arasında ölçümsel stabilite farkı bulunduğundan, yanıt değerlendirme ve çok merkezli uyum hedeflerinde daha kararlı metriklerin seçilmesi gerekir (Boellaard et al., 2025; EARL, 2023).

SPECT/BT’de ise kantifikasyon metrikleri, mutlak aktivite konsantrasyonu ve/veya RC düzeltmeleri üzerinden tanımlanır. Bu nedenle SPECT kantifikasyon performansı SUV benzeri tek bir sayıdan ziyade, fantom temelli doğrulama

ve düzeltme zincirinin tutarlılığı ile tanımlanmalıdır (Dickson et al., 2023; IAEA, 2019).

2.6. Tekrarlanabilirlik, Karşılaştırılabilirlik Ve Harmonizasyon Metrikleri (EARL perspektifi)

Klinik izlem ve çok merkezli veri birleştirme senaryolarında hedef, tek bir taramada iyi görüntüden öte; zaman içinde kararlı ve merkezler arasında değiştirilebilir ölçümler üretebilmektir. EARL akreditasyon yaklaşımı bu amacı; IEC/NEMA fantomu üzerinden ölçülen RC/CR ve gürültü profillerini hedef bantlarla tanımlayarak, belirli edinim-yeniden yapılandırma kombinasyonlarının uyumlu kalmasını sağlayacak şekilde yapılandırır (EANM Forschungs GmbH [EARL], 2023). Bu nedenle hibrit kalite metrikleri, rutin klinik üretimde de periyodik fantom ölçümleriyle izlenmeli; metriklerin hedef aralıklardan sapması, protokol veya sistem performansında değişime işaret eden erken uyarı olarak değerlendirilmelidir (EARL, 2023; Koole et al., 2023).

2.7. Hibrit Koregistrasyon Doğruluğu: Kalite Metriklerinin “Geometrik” Bileşeni

Hibrit görüntülemeye koregistrasyon doğruluğu, yalnız anatomik lokalizasyonu değil BT/MR tabanlı azalım düzeltmesi üzerinden PET/SPECT kantifikasyonunu da etkileyen geometrik bir kalite bileşenidir. Özellikle solunum hareketi, hasta pozisyon farkı ve BT/MR'nin anlık yakaladığı faz ile emisyon verisinin zaman ortalaması arasındaki uyumsuzluk hem artefakt hem de bölgesel SUV sapması üretebilir (IAEA, 2014; AAPM, 2019). Bu nedenle koregistrasyon hatasına duyarlı bölgelerde kalite değerlendirmesi, kantitatif metrik yorumuyla birlikte ele alınmalıdır.

3. Görüntü Optimizasyonu

Hibrit görüntülemeye optimizasyon, tek bir evrensel en iyi protokol tanımlamaktan ziyade; belirli bir klinik görev (lezyon saptama, evreleme, tedavi yanıtı izlemi, kantitatif takip, dozimetri vb.) için ölçülebilir performans uç noktalarını hedefleyerek, hasta dozu ve toplam inceleme süresini makul ölçüde elde edilebilecek en düşük düzeyde tutan (As Low As Reasonably Achievable, ALARA) çok parametrelili bir karar sürecidir (Boellaard et al., 2015; American Association of Physicists in Medicine [AAPM], 2019). Bu çerçevede iyi görüntü yalnız görsel beğeni ile değil standardize kalite kontrol göstergeleri ve kantitatif çıktının güvenilirliği ile tanımlanır (AAPM, 2019; National Electrical Manufacturers Association [NEMA], 2018).

Optimizasyonun omurgası, klinik hedeflerle teknik kısıtların açık biçimde eşleştirilmesidir. İlk adım, klinik görevin hangi ölçülebilir metriklerle temsil edileceğinin belirlenmesidir. Küçük lezyon saptanabilirliğinde kontrast–gürültü dengesi ve uzaysal çözünürlük öne çıkarken, tedavi yanıtı izlemi ve çok merkezli karşılaştırmalarda kantitatif doğruluk/tekrarlanabilirlik ve zaman periyodu boyunca kararlılık daha kritik hale gelir. Hasta dozimetrisi gibi uygulamalarda ise mutlak aktivite kantifikasyonunun izlenebilirliği ve doğrulanabilirliği temel performans kriteri haline gelir (Boellaard et al., 2015; Dewaraja et al., 2013; Ljungberg et al., 2016). İkinci adım, kısıtların netleştirilmesidir. PET enjekte aktivitesi ve BT dozu, toplam çekim süresi (yatak başı süre, MR sekans süresi), hasta konforu ve hareket riski, cihazın sayım-hızı/ölü-zaman sınırları, ayrıca merkezler arası uyum gereksinimi optimizasyonun sınır koşullarını belirler (AAPM, 2019; NEMA, 2018). Bu nedenle optimizasyon çoğu zaman bir uyum problemidir. Daha yüksek sayım istatistiği gürültüyü azaltabilir ancak belirli bir noktadan sonra sayım-hızı kısıtları, ölü-zaman, saçılma kesri ve hareket artefaktı gibi doğrusal olmayan etkiler nedeniyle beklenen fayda sınırlanabilir.

Bu karar süreci pratikte dört teknik bileşenin birlikte yönetilmesiyle yürütülür.

- 1) Bilgi edinme (PET/SPECT’te sayım istatistiği, BT/MR’de sinyal istatistiği ve örnekleme)
- 2) Düzeltme zinciri (zayıflama, saçılma, ölü-zaman, normalizasyon ve sistem yanıtı)
- 3) Yeniden yapılandırma (iterasyon–subset, filtreleme v.b)
- 4) Hasta kaynaklı değişkenler (hareket/solunum, metal/kontrast etkileri, glukoz ve uptake zamanı gibi) (Boellaard et al., 2015; Dickson et al., 2023).

PET bileşeninde optimizasyonun başlangıç noktası, klinik pratikte görüntü kalitesinin birincil belirleyicisi olan toplam sayım istatistiğinin yönetilmesidir. Bu hedef, enjekte edilen aktivite miktarı ile yatak başına edinim süresinin birlikte seçimiyle sağlanır (Boellaard et al., 2015). Sabit süreli bilgi toplama, farklı vücut kalınlıklarında gürültü düzeyini heterojenleştirebildiğinden; kilo/vücut kitle indeksi veya hedef gürültü temelli protokoller daha rasyonel bir standardizasyon yaklaşımı sunar (Boellaard et al., 2015). Sistem teknolojisi bu dengeyi doğrudan etkiler. TOF bilgisinin yeniden yapılandırmaya dahil edilmesi, özellikle kilolu hastalarda gürültüyü azaltarak aynı görüntü kalitesi için daha kısa edinim süresi veya daha düşük enjekte aktivite olanağı sağlayabilir. Bu nedenle TOF kapasitesi ve sistem duyarlılığı, protokol tasarımıyla serbestlik derecesi olarak değerlendirilerek aktivite–süre seçimi hedef metrikler korunacak şekilde yeniden ölçeklenmelidir (Kaalep et al., 2018; NEMA, 2018). Bununla

birlikte enjekte edilen aktiviteyi artırmak her zaman doğrusal kazanç üretmez. Saçılma kesri ve ölü-zaman etkileri nedeniyle belirli bir noktadan sonra etkin sayım penceresinin dışına çıkılabilir. Dolayısıyla PET optimizasyonu daha çok aktivite değil, cihazın sayım-hızı karakteristiği içinde kalarak etkin sayımı maksimize etmeyi hedefleyen bir seçimdir (AAPM, 2019; NEMA, 2018). Yeniden yapılandırma tarafında ise düzenleme gücü (örn. penalize edilebilirlik yaklaşımlarında/BSREM'de β benzeri parametreler (Teoh et al., 2015)) görüntü dokusunu ve küçük lezyon kontrastını doğrudan değiştirdiğinden klinik amaçla tutarlı seçilmeli; seri takip veya çok merkezli kullanımda görsel tercih yerine standardize kantitatif performans penceresinin korunması esas alınmalıdır (Boellaard et al., 2015; EANM Forschungs GmbH [EARL], 2023).

BT bileşeninde optimizasyon, BT'nin hibrit sistemde üstlendiği göreve göre değişir. Yalnız azalım düzeltilmesi amaçlı BT, lokalizasyon/füzyon amaçlı düşük-orta doz BT ve tanısal BT birbirinden farklı hedefler taşır ve aynı parametre setiyle yönetilmemelidir (AAPM, 2019; Vali et al., 2021). BTAC için ana hedef, PET/SPECT kantifikasyonunu bozmayacak yeterli azalım haritasını en düşük makul BT dozu ile üretmektir ancak aşırı agresif doz düşürme HU gürültüsünü ve artefaktları artırarak azalım haritasını bozabilir. Bu nedenle BTAC'de en düşük doz yaklaşımı, artefakt kontrolü ile birlikte değerlendirilmelidir (AAPM, 2019; Vali et al., 2021). BT doz-kalite dengesinde kVp, mAs, pitch, rotasyon süresi, kolimasyon ve yeniden yapılandırma parametre seçimi birlikte rol oynar. Pediatrik hastalarda protokol, erişkin protokolünün küçültülmüş hali değil, vücut boyutu-temelli hedefler ve pediatrik kılavuzlarla uyumlu yaklaşımlar ile yapılandırılmalıdır (Vali et al., 2021). Metal implantlar veya yoğun kontrast maddeler BT'de artefakt üreterek BT-AC haritasını bozabilir ve PET/SPECT'te bölgesel sapmalara yol açabilir. Bu nedenle riskli klinik senaryolarda BT-AC için ayrı bir bilgi edinim parametre seti düşünmek veya artefakt azaltım stratejilerini protokolün parçası yapmak gerekebilir (AAPM, 2019; Vali et al., 2021).

SPECT/BT optimizasyonu, PET'e kıyasla daha belirgin şekilde kolimatör-enerji penceresi-düzeltilme zinciri etkileşimine bağlıdır ve kantitatif uygulamalarda doğruluk bileşeni daha hassastır. Bu nedenle hedef yalnız daha az gürültü değil, aynı zamanda mutlak aktivite kantifikasyonunun izlenebilirliğini güvenceye almak olmalıdır (Dickson et al., 2023; Dewaraja et al., 2013). Kantitatif SPECT'te sistem duyarlılığı/kalibrasyon faktörü (çapraz kalibrasyon), BT tabanlı azalım düzeltilmesi, saçılma düzeltilmesi ve kolimatör-dedektör yanıt modellemesi ile yeniden yapılandırma parametreleri birlikte ele alınır. Bu bileşenlerden herhangi birindeki sapma, aktivite recovery ve arka plan değişkenliği üzerinden ölçülebilir kantitatif performansı bozar (Dickson et al., 2023; Ljungberg et al., 2016). Bu nedenle SPECT/BT'de optimizasyon, bilgi edinimden yeniden yapılandırmaya kadar uçtan uca tanımlı bir protokol

ve bu protokolün kantitatif hedeflere göre doğrulanması ile tamamlanmalıdır (Dickson et al., 2023).

PET/MR optimizasyonunda kritik nokta, MR tabanlı attenuasyon düzeltilmesinin (MRAC) doku sınıflaması/segmentasyonu ve distorsiyon/artefakt duyarlılığı nedeniyle PET kantifikasyonunda hataya neden olabilmesidir. Bu nedenle MRAC'nin doğrulanmasına yönelik kontroller (örn. referans BT-AC karşılaştırmaları, artefakt kontrol listeleri, coil/implant etkilerinin yönetimi) optimizasyonun ayrılmaz parçası olarak ele alınmalıdır (Canata, 2020). Ayrıca uzun MR sekansları hareket riskini artırabileceğinden, klinik amaca uygun sekans seçimi ve hareket yönetimi PET-MR hizalamasını ve PET kantitatif kararlılığını doğrudan etkiler (Canata, 2020). PET/MR'de en yüksek MR çözünürlüğü hedefi, tek başına optimizasyon kriteri değildir. Klinik amaç ve PET kantifikasyon güvenilirliği, süre/hareket riskiyle birlikte dengelenmelidir (Canata, 2020).

Optimizasyonun son ve vazgeçilmez aşaması doğrulama, kalite kontrol ve harmonizasyondur. Protokoldeki her anlamlı değişiklik (aktivite-süre, yeniden yapılandırma parametresi, BT-AC yaklaşımı, MRAC yöntemi vb.) ölçülebilir metriklerle doğrulanmalı; bazal performans ve zaman içi kararlılık, standardize test çerçeveleriyle izlenmelidir (NEMA, 2018; AAPM, 2019). Çok merkezli veya seri takip senaryolarında yeniden yapılandırma ve kantifikasyon penceresinin korunması için EARL benzeri harmonizasyon hedefleri belirleyici olabilir. Ancak özellikle PET/MR'de MRAC kaynaklı olası sapmaların akreditasyon sınırları dışında kalabileceği göz önünde bulundurularak yerel QA/QC ile ayrıca yönetilmesi gerekir (EARL, 2023). Sonuç olarak optimizasyon; bilgi edinme-düzeltilme-yeniden yapılandırma-hasta faktörleri arasında kurulan, hedef metriklerle tanımlanan ve QA/harmonizasyon ölçümleriyle kanıtlanan çok parametrelili bir mühendislik problemidir (Boellaard et al., 2015; AAPM, 2019; Dickson et al., 2023).

4. Sonuç

Bu bölümün temel sonucu, hibrit görüntülemelerde görüntü kalitesi ve kantitatif doğruluğun tek bir parametreyle değil; donanım, bilgi edinme, düzeltilme-yeniden yapılandırma zinciri ve kalite kontrol/kalite güvencesinin birlikte yönetildiği bütüncül bir sistem yaklaşımıyla sağlanabildiğidir. Klinik amaç (ör. lezyon saptama, tedavi yanıtı izleme, çok merkezli karşılaştırma) net tanımlanmadığında, görsel olarak iyi görüntünün her zaman güvenilir kantifikasyon anlamına gelmediği; tersine, kantitatif kararlılık için ölçülebilir hedef metrikler ve standardize raporlama gerekliliği ortaya çıkmaktadır. Bu nedenle optimizasyon, tek bir evrensel protokol arayışından çok, klinik göreve

göre seçilmiş hedef metrikleri sağlayan parametre setinin sürdürülebilir biçimde korunması olarak ele alınmalıdır.

Literatürde çok merkezli kantifikasyonun başarısı; standardize bilgi edinim-yeniden yapılandırma parametreleri, fantom temelli doğrulama ve çapraz-kalibrasyon zinciri ile ilişkilendirilmekte; bu yaklaşımın özellikle tedavi yanıtı ve takip çalışmalarında ölçümler arası sapmayı azalttığı gösterilmektedir. Benzer şekilde uluslararası harmonizasyon çerçeveleri, sistemler arası farklılıkların tamamen yok edilemeyeceğini ancak önceden tanımlı kabul aralıklarında tutulabileceğini vurgular. Bu bölümde sunulan çerçeve, söz konusu yaklaşımı hibrit sistemlerin özelinde hata kaynaklarıyla birlikte ele alarak genişletmektedir.

Bu alandaki başlıca kısıtlar; cihazlar arası donanımsal farklılıklar, yazılım/yeniden yapılandırma sürüm değişiklikleri, eksik veya heterojen protokol verisi, hastaya bağlı değişkenlerin (hareket, hareket, fizyolojik değişkenlik) tam temsil edememesidir. Ayrıca kantitatif çıktılarda belirsizliğin önemli bir kısmı yalnızca görüntüleme zincirinden değil; doz kalibratörü ölçümündeki sapmalar ve görüntü üzerindeki bölge seçimi gibi süreç değişkenlerinden de kaynaklanabilmektedir.

Bu nedenle ileride benzer çalışmalar yapacaklar için şu öneriler öne çıkmaktadır. Klinik amacı ve hedef metrikleri çalışmanın başında netleştirerek protokol serbestlik derecesini sınırlamak, bilgi edinim ve yeniden yapılandırma parametrelerini net bir şekilde raporlamak ve sürüm değişikliklerini kayıt altına almak, çapraz-kalibrasyonu düzenli aralıklarla doğrulamak ve fantom ölçümelerini referans izlem olarak kullanmak, hareket yönetimini (solunum, hasta hareketi) protokolün ayrılmaz parçası yapmak, foton azalım düzeltmesinin doğruluğunu özellikle metal/implant ve manyetik rezonans segmentasyon hataları açısından sistematik kontrol etmek, belirsizlik kaynaklarını standart bir kontrol listesi ile raporlamak gerekir. Bu yaklaşım, hem tek merkezde zaman içi kararlılığı hem de çok merkezli çalışmalarda karşılaştırmaları güçlendirerek hibrit görüntülemenin klinik karar destek değerini artıracaktır.

Kaynaklar

- American Association of Physicists in Medicine. (2019a). PET/CT acceptance testing and quality assurance (AAPM Report No. 126). Alexandria, VA: Author.
- American Association of Physicists in Medicine. (2019b). Performance evaluation of computed tomography systems (AAPM Report No. 233). Alexandria, VA: Author.
- American College of Radiology, American College of Nuclear Medicine, Society of Nuclear Medicine and Molecular Imaging, & Society for Pediatric Radiology. (2021). ACR–ACNM–SNMMI–SPR practice parameter for performing FDG-PET/CT in oncology (Revised 2021, Resolution 20).
- Boellaard, R. (2009b). Standards for PET image acquisition and quantitative data analysis. *Journal of Nuclear Medicine*, 50(Suppl 1), 11S–20S.
- Boellaard, R., Delgado-Bolton, R., Oyen, W. J. G., Giammarile, F., Tatsch, K., Eschner, W., ... Krause, B. J. (2015). FDG PET/CT: EANM procedure guidelines for tumour imaging: Version 2.0. *European Journal of Nuclear Medicine and Molecular Imaging*, 42(2), 328–354.
- Boellaard, R., Herrmann, K., Barrington, S. F., Cranston, I., Mottaghy, F. M., Hoekstra, C. J., Verzijlbergen, F. J. (2025). [18F] FDG PET/CT: EANM procedure guidelines for tumour imaging. *The EANM Journal*, 1, 100006.
- Catana, C. (2020). Attenuation Correction for Human PET/MRI Studies. *Physics in Medicine & Biology*
- Daube-Witherspoon, M. E., Karp, J. S., Casey, M. E., DiFilippo, F. P., Hines, H., Muehllehner, G., Simcic, V., Stearns, C. W., Adam, L., E., Kohlmyer, S., Sossi, V. (2002). PET performance measurements using the NEMA NU 2-2001 standard. *Journal of Nuclear Medicine*, 43(10), 1398–1409.
- Dewaraja, Y. K., Ljungberg, M., Green, A. J., Zanzonico, P. B., Frey, E. C., Bolch, W. E., Brill, A. B., Dunphy, M., Fisher, D. R., Howell, R. W., Meredith, R. F., Sgouros, G., Wessels, B. W. (2013). MIRD pamphlet No. 24: Guidelines for quantitative ¹³¹I SPECT in dosimetry applications. *Journal of Nuclear Medicine*, 54(12), 2182–2188.
- Dickson, J. C., Armstrong, I. S., Minguez Gabiña, P., Denis-Bacelar, A. M., Krizsan, A. K., Gear, J. M., Van den Wyngaert, T., de Geus-Oei, L.-F., & Herrmann, K. (2023). EANM practice guideline for quantitative SPECT-CT. *European Journal of Nuclear Medicine and Molecular Imaging*, 50, 980–995.
- EANM Forschungs GmbH. (2023). EARL PET/CT Accreditation User Manual (Version 4.2, May 2023). Vienna, Austria: EANM Forschungs GmbH.
- Heathcote, A., Wareing, A., & Meadows, A. (2010). CT instrumentation and principles of CT protocol optimisation. In P. Hogg & G. Testanera

- (Eds.), Principles and practice of PET/CT: Part 1: A technologists' guide. Vienna, Austria: European Association of Nuclear Medicine.
- Hogg, P., & Testanera, G. (2010). EANM technologists' guide: Principles and practice of PET/CT. Vienna, Austria: European Association of Nuclear Medicine.
- International Atomic Energy Agency. (2014). PET/CT atlas on quality control and image artefacts (IAEA Human Health Series No. 27; STI/PUB/1642). Vienna, Austria: IAEA.
- International Atomic Energy Agency. (2019). SPECT/CT atlas of quality control and image artefacts (IAEA Human Health Series No. 36; STI/PUB/1860). Vienna, Austria: IAEA.
- Kaalep, A., Sera, T., Oyen, W., Krause, B. J., Chiti, A., Liu, Y., & Boellaard, R. (2018). EANM/EARL FDG-PET/CT accreditation—Summary results from the first 200 accredited imaging systems. *European Journal of Nuclear Medicine and Molecular Imaging*, 45(3), 412–422.
- Keereman, V., Mollet, P., Berker, Y., Schulz, V., & Vandenberghe, S. (2013). Challenges and current methods for attenuation correction in PET/MR. *MAGMA*, 26(1), 81–98.
- Kinahan, P. E., Perlman, E. S., Sunderland, J. J., Subramaniam, R. M., Wollenweber, S. D., Turkington, Lodge, M. A., Boellaard, R., Obuchowski, N.A., Wahl, R. L. (2020). The QIBA profile for FDG PET/CT as an imaging biomarker measuring response to cancer therapy. *Radiology*, 294(2), 647–657.
- Koole, M., Armstrong, I., Krizsan, A. K., Stromvall, A., Visvikis, D., Sattler, B., Nekolla, S. G., Dickson, J., EANM Physics committee. (2023). EANM guidelines for PET-CT and PET-MR routine quality control. *Zeitschrift für Medizinische Physik*, 33(1), 103–113.
- Ljungberg, M., Celler, A., Konijnenberg, M. W., Eckerman, K. F., Dewaraja, Y. K., Sjögreen-Gleisner, K., Walrand, S. (2016). MIRD Pamphlet No. 26: Joint EANM/MIRD guidelines for quantitative ^{177}Lu SPECT applied for dosimetry of radiopharmaceutical therapy. *Journal of Nuclear Medicine*, 57(1), 151–162.
- Mehranian, A., Arabi, H., & Zaidi, H. (2016). Vision 20/20: Magnetic resonance imaging-guided attenuation correction in PET/MRI: Challenges, solutions, and opportunities. *Medical Physics*, 43(3), 1130–1155.
- Middlebrooks, T. (2021). PET/CT artefacts and pitfalls (Chapter 3). In A. Pietrzak (Ed.), *EANM Technologists' Guide: Advances in PET-CT Imaging* (pp. 31–80). Vienna, Austria: European Association of Nuclear Medicine.

- National Electrical Manufacturers Association. (2018a). Performance measurements of positron emission tomographs (PET) (NEMA Standards Publication NU 2-2018). Arlington, VA: Author.
- National Electrical Manufacturers Association. (2018b). Performance measurements of gamma cameras (NEMA Standards Publication NU 1-2018). Arlington, VA: Author.
- National Electrical Manufacturers Association. (2021a). Determination of signal-to-noise ratio (SNR) in diagnostic magnetic resonance imaging (NEMA Standards Publication MS 1-2008 [R2020]). Arlington, VA: Author.
- National Electrical Manufacturers Association. (2021b). Determination of two-dimensional geometric distortion in diagnostic magnetic resonance images (NEMA Standards Publication MS 2-2008 [R2020]). Arlington, VA: Author.
- National Electrical Manufacturers Association. (2021c). Determination of image uniformity in diagnostic magnetic resonance images (NEMA Standards Publication MS 3-2008 [R2020]). Arlington, VA: Author.
- Queiroz, M. A., Wollenweber, S. D., von Schulthess, G., Delso, G., & Veit-Habibach, P. (2014). Clinical image quality perception and its relation to NECR measurements in PET. *EJNMMI Physics*, 1, 103.
- Surasi, D. S., O'Malley, J., & Bhambhani, P. (2014). 18F-FDG PET/CT patient preparation: A review of the literature. *Journal of Nuclear Medicine Technology*, 42(1), 5–13.
- Teoh, E. J., McGowan, D. R., Macpherson, R. E., Bradley, K. M., & Gleeson, F. V. (2015). Phantom and clinical evaluation of the Bayesian penalized likelihood reconstruction algorithm Q.Clear. *Journal of Nuclear Medicine*, 56(9), 1447–1452.
- Tsutsui, Y., Awai, K., Kidera, D., et al. (2017). Edge artifacts in point spread function-based PET image reconstruction. *EJNMMI Physics*, 4, 24.
- Vali, R., Alessio, A., Balza, R., Borgwardt, L., Bar-Sever, Z., Czachowski, M., Jehanno, N., Kurch, L., Pandit-Taskar, N., Parisi, M., Piccardo, A., Seghers, V., Shulkin, B. L., Zucchetta, P., Lim, R. (2021). SNMMI Procedure Standard/EANM Practice Guideline on Pediatric 18F-FDG PET/CT for Oncology 1.0. *Journal of Nuclear Medicine*, 62(1), 99–110.
- Van der Vos, C. S., Arens, A. I. J., Hamill, J. J., Hofmann, C., Panin, V. Y., Meuwis, A. P. W., Visser, E. P., & de Geus-Oei, L.-F. (2017). Metal artifact reduction of CT scans to improve PET/CT attenuation correction. *Journal of Nuclear Medicine*, 58(11), 1867–1872.

Nükleer Tıpta Teknolojik Dönüşüm: Hibrit Ve Dijital Sistemler

Turan Şahmaran¹

Özet

Nükleer tıp, radyofarmasötiklerin vücuttaki dağılımını görüntüleyerek hastalıkları anatomik bulguların ötesinde fonksiyonel ve moleküler düzeyde değerlendirir. Bu bölüm, hibrit sistemlerin (SPECT/BT, PET/BT, PET/MR) ve yeni dedektör teknolojilerinin tanı sürecine etkisini derler. SPECT/BT’de BT tabanlı atenüasyon düzeltmesi, iteratif rekonstrüksiyon (MLEM/ OSEM) ve çözünürlük geri kazanımı; kontrastı artırır, artefaktları azaltır, çekim süresini kısaltır ve düşük doz protokollerini destekler. Dedektör tarafında PMT’den SiPM/APD ve CZT gibi yapılara geçiş, enerji ve zaman çözünürlüğünü iyileştirerek düşük aktiviteyle hızlı çekimleri mümkün kılar. Dijital PET/BT’de TOF ve çözünürlük iyileştirmeleri küçük lezyon saptanabilirliğini artırır. Uzun aksiyel görüş alanlı tüm vücut PET ve meme odaklı PEM, tek pozisyonda görüntüleme ve daha yüksek duyarlılık sunar. PET/MR’da MR-tabanlı atenüasyon düzeltmesinin sınırlılıkları ve derin öğrenme ile iyileştirme girişimleri tartışılır. Yapay zekâ destekli gürültü azaltma ve otomatik segmentasyonun iş akışını hızlandırabileceği vurgulanır. Bu yenilikler, daha erişilebilir, hızlı ve güvenli hasta yönetimini hedefler birlikte. Merkezler, altyapı, maliyet ve standardizasyon gereksinimlerini protokol seçiminde mutlaka değerlendirmelidir.

1.GİRİŞ

Nükleer tıp, hastalıkların tanı ve tedavisinde vücuda verilen radyofarmasötiklerin görüntülenmesine dayanan görüntüleme tetkikidir. Özellikle kanser, kardiyovasküler hastalıklar, nörolojik ve endokrinolojik bozuklukların değerlendirilmesinde; hastalığın yalnızca yapısal değil, fonksiyonel ve moleküler düzeyde incelenmesini sağlayarak klasik görüntüleme yöntemlerinden ayrılmaktadır. Bu yaklaşım, moleküler görüntüleme ve

1 Doç.Dr. Hatay Mustafa Kemal Üniversitesi, Kırıkkhan MYO, Orcid: 0000-0003-3708-6162, turansahmaran@mku.edu.tr

teranostik kavramlarının ortaya çıkmasıyla birlikte daha da önem kazanmıştır [Alqahtani, 2023; Powsner vd, 2021; Harkness-Brennan, 2023; Şahmaran vd, 2022; Şahmaran vd, 2025].

Son yıllarda nükleer tıpta kullanılan cihaz teknolojilerinde önemli bir dönüşüm yaşanmaktadır. Hibrit görüntüleme sistemleri olan Pozitron Emisyon Tomografi/Bilgisayarlı Tomografi (PET/BT), (Tek Foton Emisyonlu Bilgisayarlı Tomografi) SPECT/BT ve Pozitron Emisyon Tomografi/Manyetik Rezonans Görüntüleme (PET/MR) cihazları, anatomik ve fonksiyonel bilgiyi tek seansta birleştirerek tanısal doğruluğu belirgin şekilde artırmıştır. Bu sistemlere ek olarak; tüm vücut PET sistemleri, dijital dedektör teknolojileri, kadmiyum-çinko-tellür (CZT) tabanlı gama kameralar ve gelişmiş rekonstrüksiyon algoritmaları gibi yenilikler, daha yüksek uzaysal çözünürlük, daha düşük radyasyon dozu ve daha kısa çekim süreleri gibi klinik avantajlar sunmaktadır [Voss, 2023; Demir, 2014; Lecoq & Gundacker, 2021]. Dijital PET/BT sistemlerinde silikon fotodetektörler (SiPM) ve zaman-uçuşu (Time-of-Flight, TOF) teknolojisi kullanılması, sinyal-gürültü oranını ve küçük lezyonları saptama gücünü artırmakta; aynı zamanda düşük doz ve hızlı tarama imkânı sağlamaktadır. Benzer biçimde, CZT temelli dijital SPECT/BT sistemleri, fotonları doğrudan elektrik sinyaline dönüştürebilen yarıiletken dedektörleri sayesinde enerji çözünürlüğünü ve görüntü kalitesini iyileştirmekte, özellikle kardiyak ve onkolojik incelemelerde yeni olanaklar sunmaktadır [Lecoq & Gundacker, 2021; Yavuzkanat, 2016; Piemonte & Gola, 2019].

Donanımdaki bu gelişmelere ek olarak, yapay zekâ ve derin öğrenme tabanlı yazılım çözümleri de nükleer tıp cihaz teknolojilerinin ayrılmaz bir parçası hâline gelmektedir. Gürültü azaltma, düşük doz görüntülerin iyileştirilmesi, otomatik lezyon segmentasyonu ve hasta bazlı doz tahmini gibi uygulamalarda yapay zekâ destekli algoritmalar kullanılmakta; böylece hem tanısal performans artmakta hem de iş akışları hızlanmaktadır.

Bu çalışma kapsamında, nükleer tıpta yeni gelişen cihaz teknolojileri genel hatlarıyla ele alınacak; hibrit görüntüleme sistemleri, dijital dedektör teknolojileri, tüm vücut PET sistemleri, CZT tabanlı cihazlar ve yapay zekâ entegre yazılımlar ayrı başlıklar altında incelenecektir. Ayrıca bu teknolojilerin hasta güvenliği, görüntü kalitesi, işlem süreleri ve maliyet üzerindeki etkileri tartışılarak, gelecekte nükleer tıp pratiğinin nasıl şekillenebileceğine dair öngörüler sunulacaktır.

2. SPECT (Tek Foton Bilgisayarlı Tomografi) ve SPECT/BT (Tek Foton Bilgisayarlı Tomografi/Bilgisayarlı Tomografi)

SPECT görüntüleme, foton yayan radyoaktif maddelerin gama ışınlarının belirli bir zaman aralığında dedektör etrafında açısız olarak deteksiyonu ve matematiksel rekonstrüksiyon algoritmaları ile üç boyutlu görüntüler haline getirilmesi esasına dayanır. Bu sistemlerde kullanılan dedektörlerin büyük çoğunluğu, sodyum iyodür kristalinin talyum aktivasyonu ile oluşturulmuş NaI(Tl) sintilatörleridir. Gama fotonları kristale çarptığında, foton enerjisi görünür ışığa dönüştürülür; bu ışık fotoçoğaltıcı tüpler tarafından çoğaltılarak elektrik sinyaline dönüştürülür. Dedektörün enerji çözünürlüğü, kristalin ışık verimliliği ve fotoçoğaltıcı tüplerin gürültü özellikleri ile yakından ilişkilidir [Bouchareb vd, 2024; Matsuo vd, 2015; Madsen, 2007].

SPECT görüntü kalitesini belirleyen en önemli fiziksel bileşenlerden biri kolimatör tasarımıdır. Kolimatörler gama fotonlarını belirli bir geometrik yönde kabul ederek, görüntüdeki konum bilgisinin oluşturulmasını sağlar. Ancak bu süreç, fotonların büyük bölümünün soğrulmasına neden olduğu için, SPECT doğası gereği düşük sayım verimliliğine sahip olup görüntü kalitesi çoğunlukla “istatistiksel yetersizlik” nedeniyle sınırlanmaktadır. Modern sistemlerde kullanılan çok delikli paralel kolimatörler, çözünürlük ve duyarlılık arasında karmaşık bir fiziksel denge oluşturur. Bu nedenle SPECT görüntülerinin çözünürlüğü genellikle klinik PET görüntülerinden daha düşüktür [Delbeke vd, 2009; IAEA, 2008].

SPECT sistemlerinin BT ile entegre edilmesi hem anatomik eşleme hem de fiziksel düzeltme açısından önemli bir yenilik sunar. BT’den elde edilen doku zayıflama (attenuation) katsayıları, gama fotonlarının dokulardan geçerken maruz kaldığı enerji kaybını telafi etmek için kullanılır. Böylece doku derinliği nedeniyle enerji kaybına uğramış sinyallerin yapay olarak azaltılması engellenir ve kantitatif doğruluk artar. Ayrıca üç boyutlu rekonstrüksiyon algoritmalarının BT ile hizalanmış veriler üzerinden yürütülmesi, artefaktların azalmasına ve ince anatomik yapıların daha doğru şekilde lokalize edilmesine olanak sağlar [Ljungberg & Pretorius, 2018; Kinahan vd, 2003].

2.1. SPECT/BT’de Kullanılan Dedektör Teknolojileri

Son yıllarda dedektör teknolojilerinde önemli değişimler yaşanmış ve geleneksel PMT tabanlı sistemler yerine;

- Pozisyon duyarlı PMT’ler (PSPMT)
- Avalanche fotodiyotlar (APD)
- Silikon fotodiyotlar (SiPM)

d. Katı-hâl dedektörleri (CZT) kullanılmaya başlanmıştır.

2.2. SPECT/BT Görüntülemede Azalım Katsayısının Rolü

SPECT/BT sistemlerinin önemli bir avantajı, nükleer tıp görüntü verilerinin doğru bir şekilde azalım düzeltmesini sağlamasıdır. SPECT görüntülerinde doğası gereği var olan en büyük sorunlardan biri, insan vücudundaki fotonların kameraya ulaşmadan önce zayıflaması ve bunun da görüntülerde aktivitede belirgin bir azalmaya yol açmasıdır. BT'den elde edilen veriler bu azalımı gidermek için çok önemlidir. BT, doku azalımının yüksek kaliteli gösterimleri olan transmisyon haritaları olarak elde edilir ve bu nedenle azalım düzeltmesinin temelini oluşturur. Tüm doku tipleri boyunca azalım ölçümlerini içeren BT görüntüleri, filtered backprojection gibi tomografik yeniden yapılandırma teknikleri kullanılarak çapraz kesitli bir doku azalım katsayıları dizisi üretir. Bu katsayılar, BT numaralarına (Hounsfield birimleri) dönüştürülür ve suyun azalım katsayısına normalize edilerek standartlaştırılır. Azalım düzeltmesini gerçekleştirmek için, BT verilerinin SPECT radyonüklidinin enerjisiyle eşleşecek şekilde dönüştürülmesi gerekir. Tipik olarak BT'de kullanılan X-ışını demetinin etkin enerjisi (yaklaşık 70 keV) ile SPECT'te kullanılan radyonüklidin enerjisi (^{99}Tc için 140 keV) farklı olduğundan bu dönüşüm gereklidir. Bu dönüşüm genellikle, ölçülen BT numaralarını istenen enerjideki azalım katsayılarına bağlayan bilineer bir model kullanılarak yapılır. BT azalım katsayısı verileri, SPECT taraması için dilim bazında doku azalımını düzelten düzeltme faktörlerini belirlemek için kullanılır [Patton & Turkington, 2008; Kinahan vd, 2003].

2.3. SPECT/BT Görüntülemede Rekonstrüksiyon Algoritmaları

SPECT/BT'nin kullanılmasıyla birlikte, hesaplama gücünde ve yeniden yapılandırma algoritmalarında önemli bir artış meydana gelmiştir. Bu da SPECT görüntü kalitesinde fark edilir iyileştirmeler sağlamıştır. Özellikle maksimum olasılık beklenti maksimizasyonu (maximum likelihood expectation maximisation, MLEM) ve ardından sıralı alt kümeler beklenti maksimizasyonunun (ordered-subsets expectation maximisation, OSEM) geliştirilmesi, filtrelenmiş geri projeksiyon yöntemlerine kıyasla daha iyi gürültü kontrolü sağlamıştır. İteratif tekniklerin zorlukları arasında, görüntü gürültüsünü artırma ve nokta yayılım fonksiyonlarının uzamsal değişkenliğini şiddetlendirmedir. Bu sorunları çözmek ve görüntüdeki uzamsal bulanıklığı gidermek için çözünürlük geri kazanımı yöntemleri önerilmiştir [Garcia vd, 2011; Ritt vd, 2014]. Pek çok SPECT kamera üreticisi, bu çözünürlük geri kazanımı ve gürültü azaltma algoritmalarını ticari yazılım paketlerine entegre

etmiştir. Bu algoritmaların başlıcaları şunlardır [Knoll vd, 2012; O'Mahoney & Murray, 2013; Daou vd, 2003]:

Astonish (Philips Healthcare): OSEM tabanlıdır ve gürültü azaltma tekniklerini iteratif sürece dahil ederek projeksiyon verilerinin derinliğe bağlı çözünürlüğünü modeller. Ayrıca foton saçılması, azalım ve uzamsal çözünürlük değişimleri için düzeltmeler içerir. Bu sayede, geleneksel OSEM'e göre çözünürlük ve gürültüde önemli iyileşmeler sunar.

Flash3D (Siemens Healthineers): Hızlı iteratif OSEM yeniden yapılandırmasını 3D çözünürlük geri kazanımı ile birleştirir. Azalım ve saçılmayı telafi eden bu yöntem, özellikle kardiyak SPECT (Cardio-Flash) protokollerinde çekim sürelerini %33 ila %50 oranında kısaltabilmektedir.

Evolution (GE Healthcare): OSEM-RR modelini temel alır ve kolimatör deliği, kristal kalınlığı ve dedektör-hastaya uzaklık gibi çeşitli fiziksel parametreleri hesaplar.

Geniş Işınlı Yeniden Yapılandırma (Wide-Beam Reconstruction, WBR-UltraSPECT): Emisyon ve tespit sürecinin fizliğini ve geometrisini modelleyerek çözünürlük geri kazanımını amaçlar. WBR, çekim süresini kısaltırken görüntü kalitesini artırır ve hastanın radyasyon maruziyetini azaltır.

Kullanılan algoritma ve dedektör teknolojisine göre birçok SPECT sistemi geliştirilmiştir. Bu sistemler aşağıda verilmiştir.


2.4. D-SPECT Sistemleri

D-SPECT (Digital SPECT), geleneksel SPECT/BT sistemlerinden teknoloji açısından önemli farklılıklar gösteren, miyokard perfüzyon görüntülemesi için tasarlanmış özel bir dijital kalp kamerasıdır. Bu sistem, geleneksel sodyum iyodür (NaI) kristali yerine Kadminyum Çinko Tellür (Cadmium Zinc Telluride, CZT) gibi katı hal yarı iletken dedektörlerini kullanmaktadır. CZT gibi yarı iletken dedektörler, fotonları doğrudan elektrik sinyallerine dönüştürdüğünden daha yüksek enerji çözünürlüğü, daha hızlı yanıt süresi ve daha iyi pozisyon doğruluğu sunar. Bu gelişmeler, kardiyak SPECT sistemlerinde yüksek çözünürlüklü ve hızlı tarama olanağı sağlamıştır [Johnson vd, 2020; Allie vd, 2016; Duvall vd, 2012]. Şekil 1'de D-SPECT cihazının görüntüsü gösterilmiştir.



Şekil 1. D-SPECT Cihazı [Spectrum-dynamics, 2025].

D-SPECT, geleneksel SPECT’te olduğu gibi döner bir gantry kullanmaz. Bunun yerine, bir dizi çoklu iğne deliği kolimatör ile donatılmış sabit dedektörler kullanır. Bu sabit geometri, dedektörlerin sürekli olarak kalbe odaklanmasını sağlayarak, dönme hareketinin neden olduğu kayıpları ortadan kaldırır ve yüksek hassasiyet elde edilmesini sağlar. Yüksek hassasiyet ve verimli alım geometrisi sayesinde, D-SPECT, geleneksel SPECT’e göre çok daha kısa görüntüleme süreleri sunar (dakikalar içinde). Bu hız, hasta konforunu artırır, hareket artefaktları riskini azaltır ve daha verimli bir klinik iş akışı sağlar. 9 dikey dedektör kolonu vardır; her biri 1024 küçük dedektörden oluşur. Sistemin yüksek hassasiyeti, aynı görüntü kalitesini koruyarak veya hatta iyileştirerek, hastaya verilen radyofarmasötik dozunun düşürülmesine olanak tanır [Duvall vd, 2012; Slomka vd, 2009]. Şekil 2’ de D-SPECT kamerasının miyokarddan veri toplanmasını optimize etmek için kullandığı ROI merkezli teknik gösterilmiştir [Slomka vd, 2009].



Şekil 2. Miyokarddan veri toplanmasını optimize etmek için kullandığı ROI merkezli teknik [Spectrum-dynamics, 2025].

2.5. MyoSPECT Sistemleri

MyoSPECT, özellikle miyokard perfüzyon görüntülemesi için tasarlanmış, geleneksel SPECT sistemlerinden tamamen farklı bir dijital, katı hal dedektöre sahip kalp kamerasıdır. Bu teknolojinin çekirdeğinde, sistemin tamamen hareketsiz (sabit) olmasını sağlayan Alcyone teknolojisi yer alır. Alcyone teknolojisi, iki önemli yenilik sayesinde mümkün olmuştur: Geleneksel NaI kristali yerine kullanılan 76 adet hareketsiz CZT yarı iletken dedektör ve bu dedektörlerin önünde yer alan 19 çoklu iğne deliği (pinhole) kolimatör dizisi. Bu odaklı kolimasyon dizisi, kalbi çevrelemeye yetecek büyüklükteki bir hacme odaklanarak, çok kısa sürede daha fazla bilgi toplar ve kardiyak anatomiye büyük bir netlik ve hızla odaklanan bir kaliteli görüş alanı sağlar [Slomka vd, 2009]. Bu cihaz, kalbi üç boyutlu (3B) olarak tarayarak geleneksel SPECT'e göre önemli üstünlükler sunmaktadır. MyoSPECT, geleneksel SPECT kameralara kıyasla 5 ila 10 kat daha yüksek hassasiyet ve 2 kat daha iyi çözünürlük elde eder. Yüksek hassasiyet sayesinde, standart sistemlerin 12-15 dakikalık çekimleriyle aynı görüntü kalitesi, MyoSPECT'te sadece 2-3 dakikalık çekimlerle sağlanır. Bu hızlı tarama yeteneği, yüksek klinik verimlilik sağlar ve aynı zamanda hastanın hareket etme olasılığını azaltarak hareket artefaktları riskini düşürür. Sistem, neredeyse PET (Pozitron Emisyon Tomografisi) kalitesine yakın görüntüleme sunar. Yüksek hassasiyet, aynı zamanda düşük doz protokolleri ile çalışmaya imkân tanıyarak hastalar için daha güvenli bir kullanım sağlar. Ayrıca, MyoSPECT'in BT entegre versiyonu bulunmaktadır. Bu entegrasyon sayesinde, SPECT görüntüleme verilerinin güvenilirliğini artırmak için azalım düzeltilmesi de doğru bir şekilde sağlanabilmektedir [Funk vd, 2006]. Şekil 3'te MyoSPECT cihazının görseli gösterilmiştir.




Şekil 3. MyoSPECT cihazı [Gehealthcare, 2025].

2.6. CARDIARC Sistemleri

CardiArc (Canton, MI) tarafından geliştirilen bu sistem, dedektör ve kolimasyon yapısı kardiyak görüntüleme için özel olarak yeniden tasarlanmış, kardiyoloji SPECT kamerasıdır. Hastalar için konforu artırmak amacıyla dik pozisyonda görüntüleme sağlar. Cihazın dışarıdan görünen hareketli bir parçası olmaması, hasta için daha rahat bir deneyim sunar. Şekil 4 ve 5'te CARDIARC cihazı ve dizaynı gösterilmiştir.



Şekil 4. CARDIARC cihazı [Slomka vd, 2009].



Şekil 5. CardiArc kameranın tasarımı ve çalışma prensibi [Slomka vd, 2009].

CardiArc'ın sistemi, hastayı masa yerine bir sandalyeye oturtuyor ve sistemin dedektörleri, hastanın etrafında C şeklinde bir yay çizen bir düzende yer almaktadır. Çalışma sırasında ne sandalye ne de dedektör dizisi hareket etmemektedir; bunun yerine, dedektör dizisinin içindeki kolimatörler, sintilasyon olaylarını ölçmek için gereken farklı açılar üretmek üzere ileri geri hareket etmektedir. Dedektör olarak sodyum iyodür kristali kullanılmaktadır. Önceki CardiArc versiyonlarında kadmiyum çinko tellür katı hal dijital dedektörler kullanılmaktaydı [Duvall vd, 2012; Slomka vd, 2009; Funk vd, 2006].

180°'lik görüş alanını üç dedektörle kapsamaktadır. Farklı kolimasyon tekniğiyle hareket artefaktlarını azaltmayı hedefler. Kamera, foton tespiti için üç sabit NaI(Tl) kristali ve bunlara karşılık gelen 60 adet fotoçoğaltıcı tüp kullanır. Diyafram arkı, yatay kolimasyon için altı yuvaya (açıklığa) sahiptir ve görüntüleme sırasında sürekli döner. Tüm dedektör, pikselleri aynı anda kullanılır ve bu da birden fazla açıda görüntülemeye olanak tanır. Görüntüleme 2 dakikaya kadar düşebilir. Yapılan araştırmalarda, CardiArc sisteminin geleneksel çift başlı kameralara kıyasla görüntü kalitesinde 5 ila 10 kat iyileşme sağlayabildiği sonucu bildirilmiştir. Sistemin yeniden yapılandırılmış uzamsal çözünürlüğü ise (kaynağın açıklık yayına olan mesafesine bağlı olarak) 3.6 mm ile 7.8 mm arasında değişmektedir [Duvall vd, 2012; Slomka vd, 2009; Funk vd, 2006; O'Connor, 2005].

2.7. Cardius 3 (Digirad) Sistemleri

Sodero SPECT (Cleveland, OH) tarafından geliştirilen Cardius sistemleri, nükleer kardiyoloji alanındaki bir diğer özel SPECT kamera tasarımıdır. Bu sistemler, görüntü kalitesini artırmak ve hastanın hareket etme riskini azaltmak amacıyla tasarlanmış olup konfor odaklı bir görüntüleme çözümü sunmaktadır. Bu sistem CsI (Tl) ve fotodiyotlardan oluşan katı hal dedektörleri kullanarak, fotoçoğaltıcılarla donatılmış geleneksel kameralardan daha kompakt dedektör kafaları bulunmaktadır. Her dedektör kafası 21,2 x 15,8 cm uzunluğundadır ve ışığı dönüştürmek için kullanılan ayrı silikon fotodiyotlara bağlı 6,1 x 6,1 x 6 mm kalınlığında CsI(Tl) kristal dizisi içerir. Hasta oturur pozisyonda çekim yapılır ve bu sayede kol kaldırmaya gerek kalmaz. Çekim süresi yaklaşık 7.5 dakika, geliştirilmiş nSPEED algoritmasıyla 4 dakikaya kadar düşürülebilmektedir. Görüntü kalitesi yüksek ve çözünürlük 8.95 mm'dir. Bu sistemlerle ilgili standart çift başlı kameranın performansı ile karşılaştırılan raporlar yayınlanmış ve benzer kalitenin, çekim süresinde %38'lik bir azalmayla elde edilebileceği bulunmuştur [Slomka vd, 2009; Lewin & Hyun, 2005]. Şekil 6'da Cardius cihazı gösterilmiştir. Diğer sistem tasarımlarına göre daha açık ve daha küçük bir tasarıma daha fazla görüntüleme gücü sığdırır. 225 kg'a kadar olan hastaların görüntülenmesini sağlar. Dik tasarım, hasta giriş

ve çıkışını kolaylaştırır; ayrıca, dik konumun diyaframı alçaltması, kalp ve bağırsak arasında daha iyi bir ayırım sağlaması ve hem klinik kaliteyi hem de hekim güvenini artırması nedeniyle önemli bir klinik avantaj sunar.



Şekil 6. Cardius cihazı [Ovissolutions, 2025].


2.8. IQ-SPECT Sistemleri

SIEMENS tarafından geliştirilen IQ•SPECT sistemi, miyokard perfüzyon SPECT görüntülemesinde standart kameraların temel sınırlamalarını aşmak amacıyla tasarlanmış, ileri düzey bir teknolojik cihazdır. Bu sistem, geleneksel çift başlı dedektör yapısını korumakla birlikte, görüntüleme mekanizmasını tamamen değiştirerek yüksek performans sunmaktadır. IQ•SPECT'in en önemli kısmı, özel olarak tasarlanmış SMARTZOOM kolimatör teknolojisinin kullanılmasıdır. Bu odaklanmış kolimasyon sistemi, detektörlerin geleneksel dairesel yörünge yerine, kalbe çok yakın ve sıkı bir non-dairesel yörüngede hareket etmesini sağlar. Bu yakın ve odaklanmış geometri, görüntüleme sırasında kalbe odaklanarak çevredeki diğer organlardan gelen gereksiz sinyalleri minimize eder. Klasik SPECT'e göre 4 kat daha hızlı çekim yapılabilir ve 4 dakikada kalp taraması tamamlanabilir. Daha az radyasyon dozu ve daha kısa süre ile benzer görüntü kalitesi sağlar. Hem SPECT hem SPECT/BT sistemlerinde kullanılabilir [Vija vd, 2008; Nakajima vd, 2017; Meden vd, 2011; Corbett vd, 2010]. Şekil 7'de konvansiyonel SPECT ve IQ•SPECT'in karşılaştırılması verilmiştir. Şekil 8'de IQ•SPECT cihazı gösterilmiştir. SMARTZOOM kolimatör, görüş alanının (FOV) merkezine yakın bir noktada odaklama kolimatörünün büyütme özelliklerini kullanır. Görüş alanının kenarına doğru paralel delikli bir kolimatör gibi davranarak

kesintiyi azaltır. Bu sayede dedektörler, dört kat daha fazla hassasiyetle kalbe yaklaşabilir. Kalp bölgesini büyütürken çevre dokuları da kapsar. Böylece trunkasyon (görüş dışı kalma) artefaktlarını önler. Her bir kolimatör deliği (yaklaşık 48.000 adet) özel bir vektör haritası ile fabrikada ölçülür. Bu sayede daha fazla foton toplar ama çözünürlük düşmez [Vija vd, 2008; Nakajima vd, 2017; Meden vd, 2011; Corbett vd,2010]. Kalp her zaman kolimatörün en duyarlı noktasında kalır.

	Conventional ²			IQ•SPECT		
	Dose	Time	Image quality	Dose	Time	Image quality
Standard 	Standard	16-minute	Excellent	Standard	4-minute	Excellent
Pediatric 	Half	16-minute	Sub-optimal	Half	8-minute	Excellent
Bariatric 	Standard	16-minute	Sub-optimal	Standard	8-minute	Excellent


Şekil 7. Konvansiyonel SPECT ve IQ•SPECT'in karşılaştırılması [Siemens-healthineers, 2025]



Şekil 8. IQ•SPECT cihazı [Siemens-healthineers, 2025]

3. Pozitron Emisyon Tomografi/Bilgisayarlı Tomografi (PET/BT)


PET/BT, 2000'li yılların başından itibaren görüntüleme pratiğinde devrim yaratmıştır. Bu teknoloji sayesinde metabolik aktivite anatomik doğrulukla eşleştirilebilmektedir. PET fonksiyonel bilgi sağlarken, BT anatomik yapı ve atenüasyon düzeltmesi sunar. Hibrit sistemle iki yöntem aynı anda kullanılarak tanısal doğruluk artırılır. PET/BT iki farklı görüntüleme yöntemini birleştirir. PET kısmı, radyofarmasötiklerin yaydığı pozitronları algılayarak metabolik/fonksiyonel aktiviteyi gösterir. BT kısmı ise X-ışını tabanlı anatomik görüntüleme yapar ve PET verilerine konumsal doğruluk sağlar. Şekil 9'da PET/BT cihazı gösterilmiştir.




Şekil 9. PET/BT cihazı [Demir, 2015; Townsend vd, 2010].

PET'te pozitron yayan bir radyonüklid (örneğin F-18) vücuda enjekte edilir. Pozitron, elektronla yok olma (anihilasyon) reaksiyonu sonucu iki adet 511 keV gama fotonu üretir. PET dedektörleri, anihilasyon sonucu oluşan 511 keV foton çiftini aynı anda saptar. Bu fotonlar 180° karşılıklı yönlerde yayılarak dedektör halkasındaki sintilasyon kristaller tarafından eşzamanlı (coincidence) olarak tespit edilir. Böylece tespit edilen bu fotonlar görüntüye dönüştürülür. Şekil 10 ve 11'de anihilasyon ve LOR (Line of Response – eş cevap eğrisi) olayı gösterilmiştir. Çakışma (koincidans) devresi yalnızca 8-12 ns arasındaki belirlenmiş zaman penceresinde ulaşan fotonları geçerli sinyaller olarak tanır. Bu zaman aralığının dışında kalan (daha erken veya daha geç) fotonlar ise rastgele gürültü (gerçek olmayan sinyal) olarak reddedilir [Demir,

2014; Demirci & Kabasakal, 2018; Demir, 2015]. Zaman uçuşu (Time of Flight, TOF), iki 511 keV fotonun detektörlere ulaşma zaman farkını (Δt) ölçer. Bu fark sayesinde, olayın LOR üzerindeki konumu yaklaşık olarak belirlenebilir. TOF PET, klasik PET'e kıyasla daha doğru lokalizasyon ve daha yüksek sinyal gürültü oranı sağlar. Bu teknoloji özellikle büyük vücut çapına sahip hastalarda daha keskin ve gürültüsüz görüntüler elde edilmesine olanak tanır [Demir, 2015; Townsend vd, 2010].



Şekil 10. Anihilasyon olayı [Townsend vd, 2010].



Şekil 11. LOR olayı [Demir, 2015; Townsend vd, 2010].

3.1. PET/BT'de Kullanılan Kristaller ve Dedektörler

PET/BT de son yıllarda oldukça çeşitli kristaller kullanılmaktadır. Sıklıkla kullanılan özellikleri tablo 1 de özetlenmiştir.

Tablo 1. PET/BT de kullanılan kristaller ve özellikleri [Xie vd, 2024; Lecoq & Gundacker, 2021].

Özellik	NaI(Tl)*	CsI(Tl)**	BGO***	LSO ^s	LYSO ^{&}	GSO [#]
Yoğunluk (g/cm ³)	3.67	4.51	7.13	7.4	7.10	6.70
Etkin Atom Numarası	51	54	74	66	65	59
Hacimsel Durdurma Gücü	Düşük	Orta	Çok Yüksek	Yüksek	Yüksek	Yüksek
Işık Çıkışı (Foton/MeV)	38.000	52.000	8.200	30.000	32.000	8.000-10.000
Işık Çıkışı_NaI(Tl)'e göre	%100	%137	%22	%79	%84	%25
Bozunma Süresi	230 ns	1000 ns	300 ns	40 ns	41 ns	60 ns
Zaman Çözünürlüğü	Zayıf	Çok Zayıf	Zayıf	Mükemmel	Mükemmel	Çok İyi
Temel Kullanım Alanı	SPECT, Gama	SPECT	Geleneksel PET	PET/BT, PET/MR	PET/BT, PET/MR	PET/BT

Sodyum iyodür talyum, **Sezyum iyodür talyum, *Bizmut germanyum oksit, ^sLutesyum silikat oksit, [&]Lutesyum yitrium silikat oksit, [#]Gadolinyum ortosilikat*

Tablo 1’de verilen yoğunluk ve etkin atom numarası değerleri, kristalin gama fotonlarını durdurma yeteneğini belirler. Bu değerler ne kadar yüksekse, fotonlar o kadar iyi soğurulur ve daha verimli dedeksiyon sağlanır. Yoğunluğun yüksek olması ile daha ince kristallerin kullanılmasına olanak verirken ayrıca çözünürlüğü de arttırır. Fotonların kristalde soğurulma olasılığıdır. PET cihazları için oldukça önemli bir parametredir. Çünkü PET cihazlarında 0.511 MeV’lik yüksek gama fotonları kullanılmaktadır. BGO kristalinin hacimsel durdurma gücü iyi olsa da diğer özellikleri istenilen düzeyde olmadığından dolayı PET/BT sistemlerinde pek tercih edilmemektedir. Çoğu zaman NaI(Tl) kristalinin ışık çıkışı (yaklaşık 38.000 foton/MeV) referans olarak kabul edilir ve diğer kristallerin çıkışı buna göre yüzdelik olarak verilir. Yüksek ışık çıkışı daha iyi görüntü kalitesi ve daha kolay elektronik işleme sağlamaktadır. Bozunma süresi kristalin ışığı ne kadar hızlı ürettiği/sonlandırdığı ile ilgili bir diğer önemli parametredir. Daha kısa sürede bozunan kristal daha hızlı sinyal verir. Bu, PET sistemlerinde zaman çözünürlüğü için kritik bir değerdir. Zaman çözünürlüğü de aynı bozunma süresi gibi PET sistemlerinde oldukça önemlidir. Sinyallerin zamanlamasını doğru algılama yeteneğinin bir göstergesidir. TOF PET için oldukça en önemli parametrelerden biridir. Tablo 1’e göre PET/BT sistemlerinde, LSO ve LYSO gibi kristaller hem yüksek durdurma gücü hem de çok kısa bozunma süresi sayesinde diğer kristallere göre oldukça avantajlı seçeneklerdir. Bu kristaller, hızlı sinyal üretimi ve çok iyi zaman çözünürlüğü sayesinde daha kısa çekim süresi, daha düşük doz ve daha yüksek

görüntü kalitesi sağlamaktadır. Tablo 2’de PET/BT sistemlerinde kullanılan fotodiyotların özellikleri gösterilmiştir.


Tablo 2. PET/BT sistemlerinde kullanılan fotodiyotların özellikleri [Xie vd, 2024].

Özellik	PMT*	APD**	SiPM***
Temel Yapı	Vakum tüpü içerisinde elektronların dinotlara çarpması.	Ters gerilimle çalıştırılan özel bir fotodiyot.	Yüksek yoğunluklu mikron boyutunda binlerce küçük APD hücresinin birleştirilmesi.
Çalışma Modu	Vakum içerisinde elektronların çoğalması işlemi.	Yüksek gerilim altında çalışan tek bir silikon yapıli dedektör.	Her bir küçük APD hücresi, özel bir çalışma modu olan Geiger modunda çalışır.
Gerekli Voltaj	1000 V ve üzeri	200 V – 1500 V	20 V – 100 V
İç Kazanç	$10^5 - 10^7$	10 – 100	$10^5 - 10^6$
Manyetik Alandan Etkilenme	Çok yüksek-Güçlü manyetik alanda çalışmaz. Elektron demetinin yolu manyetik alan tarafında saparılır.	Çok Düşük	Etkilenmez

** foton çoğaltıcı tüp, ** avalans fotodiyotlar, *** silikon foton çoğaltıcı fotodiyotlar*

Foton çoğaltıcı tüpler (photon multiplier tube, PMT) yüksek iç kazanç ve iyi sinyal çoğaltma yeteneğine sahiptirler. Ancak yüksek voltaj gerektirmeleri ve manyetik alanlara karşı son derece duyarlı olmaları nedeniyle modern hibrit ve PET/MR sistemleri için önemli kısıtlamaları bulunmaktadır. Çalışma prensipleri vakum tüpü içinde elektron hızlandırılmasına dayandığı için çevresel faktörlere duyarlıdır. PET sistemlerinde uzun yıllar standart dedektör olarak kullanılmış olsalar da günümüzün gelişen teknolojisiyle birlikte son yıllarda tercih edilmemeye başlamışlardır. PMT’lerin kısıtlılıklarını aşmak için avalans fotodiyotlar (Avalanche Photodiodes, APD) sistemleri kullanılmaya başlanmıştır. Bu fotodiyotlar katı hal tabanlı olup, PMT’ye göre daha küçük, daha düşük manyetik alan hassasiyetine ve düşük kazançla sahiptir. Ancak, PMT’lere göre iç kazançlarının düşük olması ve bazı çalışma koşullarında gürültü performanslarının daha kötü olması, onları tek başına ideal bir alternatif olmaktan alıkoymaktadır. Silikon foton çoğaltıcı fotodiyotlar (silicon photomultipliers, SiPM), çok sayıda mikro-APD’nin paralel diziliminden oluşmuştur. Geiger modunda çalışan yapıları sayesinde, düşük çalışma voltajı

ve iyi bir zaman çözünürlüğü sağlar. Manyetik alandan etkilenmemeleri ve düşük voltajla çalışmaları oldukça önemli avantaj sağlamaktadır. Bu özellikleri sayesinde PET/MR sistemleri için ideal bir malzemedir [Townsend vd, 2010; Xie vd, 2024; Lecoq & Gundacker, 2021]. Şekil 12’de PMT, SİMP ve APD diyodları gösterilmiştir.



Şekil 12. APD (a), SİMP (b) ve PMT (c) fotodiyodları [radiologykey, 2025].

PET sistemi kullanılarak geliştirilen cihazlar son yıllarda kullanılmaya başlanmıştır. Bunlardan bazıları pozitron emisyon mamografi (Positron emission mammography, PEM) ve tüm vücut PET sistemidir. Bu sistemler ayrı başlık altında incelenmiştir.

3.2. Pozitron Emisyon Mamografi (Positron emission mammography, PEM)

PEM, meme görüntülemesi için kullanılan PET sistemidir. ^{18}F -FDG gibi pozitron yayan radyofarmasötiklerin tümör metabolizmasını hedefleyerek memeyi yüksek uzaysal çözünürlükle görüntüler. Geleneksel tüm vücut PET/BT’den farklı olarak, FOV’u memeyle sınırlıdır ve tipik olarak iki dedektör plakası arasında hafif kompresyonla (mamografiye benzer) ya da asılı meme için halka/geometrik sistemlerle tomografik veri toplar. Şekil 13’de PEM cihazı gösterilmiştir.



Şekil 13. PEM cihazı [İtnonline, 2025].

PEM cihazı, radyofarmasötüğün yaydığı gamma fotonlarının dedekte etme prensibini kullanır. Bu, gama kamera teknolojisinde kullanılan ve hassasiyeti sınırlayan kolimatöre olan ihtiyacı ortadan kaldırmaktadır. Böylece daha düşük radyasyon dozlarının kullanılmasına imkân sağlar. PEM, tüm vücut yerine sadece meme dokusunu hedef alarak görüntülemeye odaklanır. Çalışmalarda, ^{18}F -FDG dozu olarak 37 MBq, 74 MBq ve 185 MBq gibi düşük dozlar kullanılmıştır [Freitas vd, 2024; Keshavarz vd, 2020]. PEM, MR çekilemeyen (ör. şiddetli klostrofobi) hastalarda problem çözme amacıyla değerlendirilebilir. Ancak evreleme için sistemik değerlendirme gerektiğinden tek başına Tüm vücut-PET/BT'nin yerini tutmamaktadır. Yüksek uzaysal çözünürlük ile küçük odakların (özellikle > 1 cm) daha net gösterimi, meme kompresyonu sayesinde daha yüksek sayım verimliliği ve daha düşük aktivite ihtiyacı sağlamaktadır [Xie vd, 2024; Lecoq & Gundacker, 2021; Freitas vd, 2024; Keshavarz vd, 2020].


3.3 Tüm Vücut PET Sistemi (PET_EXPLORER)

PET EXPLORER, dünyanın ilk tüm-vücut PET/BT sistemi olarak, Pensilvanya Üniversitesi ve United Imaging Healthcare iş birliğiyle geliştirilmiştir. Amacı, PET görüntülemeye mevcut duyarlılığı yaklaşık 40 kat artırarak tüm vücudu tek seferde görüntüleyebilmektir. Cihazda çok sayıda dedektör kullanılarak vücuttan yayılan gama fotonları toplanır, yüksek duyarlılık sağlanır. Klasik PET cihazları 20-80 cm civarında FOV'a sahipken, EXPLORER'in 194 cm'lik FOV'u sayesinde tüm vücut tek pozisyonda görüntülenir. Bu geniş FOV sayesinde, klasik PET sistemlerinde olduğu gibi vücudun farklı bölümlerinin ardışık yatak pozisyonlarıyla taranması yerine, tek bir tarama ile tüm vücut görüntülenebilir. Bu da tarama süresini kısaltabilir

ve dozları azaltabilir. Şekil 14 ve 15’de PET EXPLORER cihazı ve FOV açıklığı gösterilmiştir.



Şekil 14. PET EXPLORER cihazı [Medicaldevice, 2025].



Şekil 15. PET EXPLORER ve FOV açıklığı [Auntminnie, 2025].

Uzun FOV tasarımı sayesinde, tarayıcı hassasiyetini büyük ölçüde artırır. Geleneksel PET sistemlerine kıyasla hassasiyette 15 ila 68 kat arasında bir artış sağlar. NEMA NU-2-2018 standartlarına göre ölçülen hassasiyeti 174 kcps/MBq’dır [Spencer vd, 2021; Badawi vd, 2019]. Sistem, LYSO kristallerinden yapılmış 564.480 kristal ve bunların okuyucuları olan SiPM teknolojisini kullanır. Toplamda 8 PET ünitesinden oluşur [Spencer vd, 2021; Badawi vd, 2019; Tang, 2019]. Hassas hizalama (<2 mm füzyon doğruluğu) sağlayan bir hasta yatağı ile entegre, 160 dilimli BT tarayıcısı ile birleştirilmiştir [Spencer vd, 2021]. Klasik 10–20 dakikalık taramalar, 15–30 saniyede tamamlanabilmektedir. Radyoaktif madde dozu oldukça düşük seviyelerde olup pediatrik ve araştırma

uygulamaları için büyük avantaj sağlamaktadır. Artan duyarlılık sayesinde izleyici madde aktivitesi 5–6 yarı ömür daha izlenebilmektedir. Her tarama da yaklaşık 1 TB veri üretebilir ve bu da güçlü bilgisayar altyapısı gerektirir. 500 000'den fazla kristal dedektörden oluştuğu için gelen sinyallerin senkronizasyonu gerekebilir. 2 metre uzunluğundaki dedektör halkasının soğutma, erişim ve bakım problemleri başlıca dezavantajları arasında yer almaktadır. Yüksek maliyetinden dolayı erişim kısıtlıdır buna karşın bir EXPLORER cihazı 6–8 klasik PET sisteminin iş yükünü karşılayabilmektedir [Spencer vd, 2021; Badawi vd, 2019; Tang, 2019; Tang vd, 2019].

Spencer ve ark. tarafından yapılan çalışmada, cihazın çok düşük dozda bile yüksek kalite görüntüler verdiğini doğrulamıştır. Çalışmalarda 10 kat daha düşük FDG aktivitesiyle elde edilen görüntüler, klinik olarak yeterli kalite sağlamıştır. Ayrıca, paralel sinyal toplama sayesinde hasta hareketlerinden kaynaklı artefaktlar azalmıştır [Spencer vd, 2021].


4. PET/MR Cihazı

PET kısmı, bir radyoaktif izotopun pozitron yayması, pozitron-elektron yok oluşu ile iki adet ~ 511 keV enerjili gama fotonunun 180° ayrılarak ortaya çıkması ve bu fotonların dedektör halkaları tarafından eş zamanlı olarak algılanması prensibine dayanır. MR kısmı, güçlü bir manyetik alan, radyo-frekans (RF) darbeleri ve manyetik alan gradyanlarının yardımıyla proton spinlerinin rezonans davranışını ölçer. Bu da doku iç yapısı, kontrast maddesi davranışı, fonksiyonel ve anatomik bilgi üretir.

PET/MR sistemlerinde amaç hem PET hem de MR verilerinin aynı anda ya da en azından aynı seansta elde edilmesidir. Bu sayede hareket artefaktlarının, hasta yeniden pozisyonlanmasının ve zaman kaymasının önüne geçilebilir. Şekil 16'da PET/MR cihazı gösterilmiştir.

PET/MR sistemlerinde yapılandırma iki temel şekildedir:

- Sıralı (sequential) sistem: PET ve MR ayrı cihazlar olarak ardışık şekilde kullanılır, ortak yatak ya da hasta transfer sistemi olabilir. Bu yapı daha kolay ve daha az entegrasyon gerektirir.
- Eşzamanlı (simultaneous) sistem: PET dedektörleri doğrudan MR gantri içinde yer alır; PET ve MR verisi aynı anda toplanır. Bu tasarım, maksimum entegrasyon ve tam zamanlı iç korelasyon sağlar ancak teknik zorlukları fazladır (manyetik uyumluluk, RF parazitleri, dedektör yerleşimi vs.).



Şekil 16. PET/MR cihazı [Ziegler & Delso, 2013].

PET/MR dedektörlerinde ışığın soğurulması ve sintilasyon üretimi için yoğun, yüksek Z_{eff} (etkin atom numarası) ve manyetik alana duyarlı olmayan kristaller gereklidir. Yaygın kullanılan kristaller arasında LSO ve LYSO bulunmaktadır. Bu kristaller kısa bozunma zamanına, yüksek ışık verimine ve manyetik alana karşı uyumludur. Alternatifler arasında Bizmut Germanat (BGO) gibi kristaller de geçmişte kullanılmıştır; ancak manyetik alana ve zaman çözünürlüğüne dair sınırlamaları vardır [Ziegler & Delso, 2013; Singnurkar vd, 2024].

MR cihazı, vücudu güçlü bir manyetik alan içine alır. Vücuttaki su ve yağ dokusunda bulunan hidrojen atomlarının protonları bu manyetik alana göre hizalanır. Ardından cihaza dışarıdan radyo frekans (RF) dalgaları gönderilerek bu hizalanmış protonların geçici olarak yön değiştirmesi sağlanır. RF dalgaları kesildiğinde, protonlar orijinal hizalanma durumlarına geri dönerken radyo sinyalleri yayarlar. MR cihazındaki özel sargılar (gradient bobinler) ve alıcı bobinler bu sinyalleri toplar. Bilgisayar, sinyallerin yoğunluğuna ve geri dönme sürelerine göre doku özelliklerini ayırt ederek, organların, yumuşak dokuların ve iskelet yapılarının yüksek çözünürlüklü anatomik ve fonksiyonel MR görüntüsünü oluşturur. PET/MR da kristal seçimi yapılırken, MR ortamında oluşabilecek manyetik duyarsızlık sorunlarını minimize edecek şekilde seçilmelidir. Ayrıca, dedektör bloklarında “Depth of Interaction (DOI)” ölçümü ya da kristal-piksel geometrisi optimizasyonu gibi gelişmelerle zaman/uzaysal çözünürlük iyileştirilmektedir. Geleneksel PET cihazında kullanılan PMT’ler manyetik alan varlığında çalışmakta güçlük çekerler. Bundan dolayı manyetik alana dayanıklı yarıiletken fotodiyotlar kullanılmaktadır. Bunlardan

en sık kullanılanları APD ve SiMP'lerdir. APD'ler zıt gerilim altında p-n birleşiminde taşınan yüklerin çığ etkisi ile sinyal üretir. MR ortamına uyumludur. SiPM ise Mikro-APD hücrelerinin paralel bağlı olduğu yapıdır. Daha yüksek kazanç, daha iyi zaman çözünürlüğü sunar. Ayrıca son yıllarda PET/MR sistemlerinde tercih edilen dedektör tiplerinden biridir. Dedektör modülleri kristal dizisi, optik bağlama, fotodiyot ve ön-okuma elektronığı şeklinde yapılandırılır. Özellikle MR ortamında kalıcı mıknatıs, gradyan bobinleri ve RF sistemlerinin yarattığı parazitler ve manyetik alan etkilerinden kaçınma için özel tasarım gerekmektedir. MR'da BT gibi doğrudan zayıflama haritası elde edilemediğinden özel MR-tabanlı yöntemler gereklidir. MR görüntülerinden kemik, hava, yumuşak doku ayrımı zor olduğundan dolayı PET sinyalinin doğru bir şekilde haritalanmasını etkiler. Derin öğrenme yaklaşımları bu alanda öne çıkmaktadır. MR, BT gibi doku yoğunluğunu doğrudan ölçen bir görüntüleme modu değildir; dolayısıyla gama fotonlarının zayıflamasını hesaplamak için gerekli olan haritayı (attenüasyon haritası) kendiliğinden üretemez. PET/MR, atenüasyon düzeltmesini MR görüntülerini kullanarak karmaşık algoritmalarla gerçekleştirir (45-47). Tablo 3'de PET/BT, SPECT/BT ve PET/MR cihazlarının özellikleri gösterilmiştir.

Bu algoritmalar aşağıda kısa şekilde verilmiştir.

- Doku Segmentasyonu: MR görüntüleri, yazılımlar aracılığıyla hava, yumuşak doku ve yağ gibi temel doku tiplerine ayrılır (segmentasyon).
- Kemik/Yoğun Doku Sorunu: Kemik dokusu MR'da zayıf sinyal verdiği için, özel teknikler ve doku atlasları kullanılır. Örneğin, beyin PET/MR'da normal anatomik yapılar temel alınarak kemik dokusu için sanal bir atenüasyon haritası oluşturulur.
- Harita Uygulaması: Oluşturulan bu tahmini yoğunluk haritası (mikro-harita), PET verilerine uygulanarak foton zayıflaması düzeltilir ve nicel (kantitatif) açıdan doğru PET görüntüleri elde edilir.

Tablo 3. PET/BT, SPECT/BT ve PET/MR cihazlarının özellikleri [Ziegler & Delso, 2013; Singnurkar vd, 2024].

Özellik	PET/BT	SPECT/BT	PET/MR
Uzaysal çözünürlük	Yüksek (4–6 mm)	Orta (8–12 mm)	Çok yüksek (MR ile <2 mm)
Fonksiyonel bilgi	Glukoz, reseptör, kan akımı	Perfüzyon, reseptör, fonksiyon	PET + MR metabolik + morfolojik
Radyasyon dozu	Orta	Orta	Düşük (MR radyasyon içermez)
Süre	15–30 dk	30–45 dk	45–90 dk
Maliyet	Yüksek	Düşük-Orta	Çok yüksek
Erişilebilirlik	Yaygın	Çok yaygın	Kısıtlı (büyük merkezlerde)

PET/MR cihazı MR bileşeninin sağladığı üstün yumuşak doku kontrastı sayesinde çok yüksek uzaysal çözünürlük ile en ayrıntılı anatomik bilgiyi sunmaktadır. PET/BT 4–6 mm ile yüksek çözünürlük sağlarken, SPECT/BT 8–12 mm ile daha orta bir uzaysal çözünürlüğe sahiptir. Fonksiyonel bilgi açısından, SPECT/BT perfüzyon ve reseptör bilgilerine odaklanırken, PET/BT glukoz metabolizması, reseptör ve kan akımı gibi fizyolojik süreçleri gösterir. PET/MR ise PET'in metabolik bilgisini, MR'ın morfolojik ve ilave fonksiyonel bilgileriyle birleştirerek en kapsamlı değerlendirmeyi sağlar. Ekonomik açıdan bakıldığında, cihazların maliyetleri erişilebilirliklerinde belirleyici bir faktördür. PET/MR, MR bileşeninin radyasyon içermemesi sayesinde toplam radyasyon dozunun düşük seviyede olmasıyla özellikle tekrarlanan taramalar ve pediyatrik hastalar için önemli bir güvenlik avantajı sağlar. Görüntüleme süresi açısından, PET/BT nispeten diğerlerine göre daha hızlıdır. Tablo 4'de PET/BT, SPECT/BT ve PET/MR cihazlarının uygulama alanları gösterilmiştir.

Tablo 4. PET/BT, SPECT/BT ve PET/MR cihazlarının uygulama alanları [Ziegler & Delso, 2013; Singnurkar vd, 2024; Delso & Ziegler, 2009; Zaidi & Alavi, 2007; Sönmezoğlu & Şahin, 2024; Demir, 2024].

Cihaz	Temel Klinik Uygulama Alanları	Tercih Edilme Nedenleri (Avantajları)
PET/BT	Onkoloji: Kanser evreleme, nüks tespiti, tedavi yanıtı değerlendirme (Baş-Boyun, Akciğer, Kolon, Meme, Lenfoma vb.) Kardiyoloji: Miyokard canlılığı Nöroloji: Demans türlerinin ayrımı (Alzheimer, FTD)	Hızlı Tarama: Tüm vücut taramada hızlıdır. Yüksek Çözünürlük: PET sinyalinin anatomik olarak doğru konumlandırma. Atenüasyon Düzeltme: PET verisi için güvenilir ve hızlı atenüasyon düzeltilmesi sağlar.
SPECT/BT	Kemik Sintigrafisi: Metastaz, enfeksiyon/inflamasyon (osteomyelit), travma. Endokrinoloji: Tiroid/paratiroid lezyonlarının lokalizasyonu. Kardiyoloji: Miyokard perfüzyon sintigrafisi (özellikle küçük lezyonlarda). Nöroloji: Beyin perfüzyon ve dopamin taşıyıcı görüntüleme (Parkinson).	Ucuzluk/Erişilebilirlik: PET'e göre daha uygun maliyetli ve daha yaygın erişilebilir. Geniş Radyofarmasötik Yelpazesi: Tek Foton yayan birçok izotop kullanabilme Doğru Lokalizasyon: SPECT'in fonksiyonel bilgisini BT ile anatomik olarak birleştirme.
PET/MR	Nöroloji: Epilepsi odak tespiti, beyin tümörleri, demans. Pelvik ve Baş-Boyun Tümörleri: Prostat, serviks, rektum kanserleri (MR'ın yumuşak doku kontrastı nedeniyle). Pediyatrik Onkoloji: Düşük radyasyon dozu avantajı nedeniyle çocuk hastalar.	Mükemmel Yumuşak Doku Kontrastı: Tümör, sinir, yumuşak doku lezyonlarında BT'den üstün detay. Düşük Radyasyon Maruziyeti: MR kısmı radyasyon içermediğinden, özellikle tekrarlanan taramalarda ve pediatrik hastalarda radyasyon dozu PET/BT'ye göre önemli ölçüde düşüktür.

5. Sonuç

Nükleer tıpta teknolojik dönüşümün ulaştırdığı temel sonuç, tanısal değerlerin artık yalnızca görüntü elde etme ile sınırlı değildir. Nicel doğruluk, tekrarlanabilirlik, hasta güvenliği ve iş akışı verimliliğinin teknoloji seçiminin ana belirleyicileri hâline gelmiştir. Hibrit görüntüler fonksiyonel veriyi anatomik bağlamla aynı seansta birleştirerek klinik kararların hedeflenmesini kolaylaştırırken, dijital dedektörler ve gelişmiş rekonstrüksiyonlar daha az doz daha kısa süre hedefini pratikte erişilebilir kılmıştır. Bu çıkarım, hibrit görüntülemenin klinik kararları güçlendirdiğini vurgulayan benzer derlemelerle

uyumludur. Ayrıca üretici bazlı iteratif rekonstrüksiyon raporlarında bildirilen çekim süresi kazanımlarıyla da paralellik gösterir. Örneğin bazı kardiyak SPECT protokollerinde çekim süresinin %33–%50 kısaldığı belirtilmesi, yazılım ekosisteminin donanım kadar kritik olduğunu göstermektedir. Tüm vücut PET tarafında, çok düşük aktiviteyle klinik olarak yeterli görüntü kalitesinin elde edilebildiğini bildiren çalışmalar, bu yaklaşımın pediatrik olgular, dinamik bütün-vücut izlem ve araştırma protokollerinde belirgin bir sıçrama potansiyeli taşıdığını destekler. Buna karşın yüksek veri üretimi, güçlü hesaplama/depoma altyapısı gereksinimi, soğutma-bakım zorlukları ve yüksek yatırım maliyeti gibi kısıtlar, teknolojinin yaygınlaşmasını merkezler arası eşitsizliğe açık hâle getirebilir. PET/MR'da MR-tabanlı atenüasyon düzeltmesinin karmaşıklığı standardizasyonu zorlaştıran temel engeldir; derin öğrenme yaklaşımları umut verici olsa da dış doğrulama, cihazlar arası uyumluluk ve yanlılık yönetimi zorunludur. Bu bölümün bir derleme niteliğinde olması, sonuçların klinik sonuçları yerine literatürde bildirilen teknik performans göstergelerine dayanması gibi doğal bir sınırlılık taşır; ayrıca teknoloji çok hızlı değiştiği için bulguların güncelliği zamanla azalabilir. İleride benzer çalışma yapacak araştırmacılara öneriler: (i) değerlendirmeyi çok merkezli ve standardize protokollerle yapmak; (ii) doz, süre ve maliyet-etkinlik ölçütlerini birlikte raporlamak; (iii) kantitatif metrikler için kalite kontrol şemaları tanımlamak; (iv) yapay zekâ modellerinde bağımsız test setleri ve şeffaf raporlama ile yanlılığı azaltmak; (v) bilişim altyapısı ile kullanıcı eğitimini başlangıçtan planlamak ve klinik uygunluğu izlemek. Sonraki adım, bu teknolojilerin gerçek yaşam verilerinde klinik sonuçları ve kaynak kullanımı üzerindeki etkisini karşılaştırmalı çalışmalarla ortaya koymaktır. Bu yaklaşım, teknolojik kazanımların klinik faydaya güvenilir biçimde tercüme edilmesini kolaylaştıracaktır.

Kaynaklar

- Allie, R., Hutton, B. F., Prvulovich, E., Bomanji, J., Michopoulou, S., & Ben-Haim, S. (2016). Pitfalls and artifacts using the D-SPECT dedicated cardiac camera. *Journal of Nuclear Cardiology*, 23(2), 301-310.
- Alqahtani, F. F. (2023). SPECT/CT and PET/CT, related radiopharmaceuticals, and areas of application and comparison. *Saudi Pharmaceutical Journal*, 31(2), 312-328.
- Badawi, R. D., Shi, H., Hu, P., Chen, S., Xu, T., Price, P. M., ... & Cherry, S. R. (2019). First human imaging studies with the EXPLORER total-body PET scanner. *Journal of Nuclear Medicine*, 60(3), 299-303.
- Bouchareb, Y., AlSaadi, A., Zabab, J., Jain, A., Al-Jabri, A., Phiri, P., ... & Sirasanagandla, S. R. (2024). Technological advances in SPECT and SPECT/CT imaging. *Diagnostics*, 14(13), 1431.
- Corbett, J., Meden, J., & Ficaro, E. (2010). Clinical validation of attenuation corrected cardiac imaging with IQ-SPECT SPECT/CT.
- Daou, D., Pointurier, I., Coaguila, C., Vilain, D., Benada, A. W., Lebtahi, R., ... & Le Guludec, D. (2003). Performance of OSEM and depth-dependent resolution recovery algorithms for the evaluation of global left ventricular function in 201Tl gated myocardial perfusion SPECT. *Journal of Nuclear Medicine*, 44(2), 155-162.
- Delbeke, D., Schöder, H., Martin, W. H., & Wahl, R. L. (2009, September). Hybrid imaging (SPECT/CT and PET/CT): improving therapeutic decisions. In *Seminars in nuclear medicine* (Vol. 39, No. 5, pp. 308-340). WB Saunders.
- Delso, G., & Ziegler, S. (2009). PET/MRI system design. *European journal of nuclear medicine and molecular imaging*, 36(Suppl 1), 86-92.
- Demir, M. (2014). Nükleer tıp fiziği ve klinik uygulamaları. İÜ Cerrahpaşa Tıp Fakültesi.
- Demir, M. (2015). Pozitron Emisyon Tomografi (PET) Fiziği. *Bulletin of Thoracic Surgery/Toraks Cerrahisi Bülteni*, 6(2).
- Demir, M. (2024). PET/MR Sistemleri: PET/BT'den Ne Farkı Var? *Nucl Med Semin*;10:206-212.
- Demirci, M., & Kabasakal, L. (2018). Prostat Kanserinde Lu-177 Prostat Spesifik Membran Antijeni Tedavisi review Lu-177 prostate specific membrane antigen therapy of metastatic castration resistant prostate cancer. *Nucl Med Semin*, 4, 245-250.
- Duvall, W. L., Sweeny, J. M., Croft, L. B., Ginsberg, E., Guma, K. A., & Henzlova, M. J. (2012). Reduced stress dose with rapid acquisition CZT SPECT MPI in a non-obese clinical population: Comparison to coronary angiography. *Journal of Nuclear Cardiology*, 19(1), 19-27.

- Freitas, V., Li, X., Scaranelo, A., Au, F., Kulkarni, S., Ghai, S., ... & Reznik, A. (2024). Breast cancer detection using a low-dose positron emission digital mammography system. *Radiology: Imaging Cancer*, 6(2), e230020.
- Funk, T., Kirch, D. L., Koss, J. E., Botvinick, E., & Hasegawa, B. H. (2006). A novel approach to multipinhole SPECT for myocardial perfusion imaging. *Journal of Nuclear Medicine*, 47(4), 595-602.
- Garcia, E. V., Faber, T. L., & Esteves, F. P. (2011). Cardiac dedicated ultrafast SPECT cameras: new designs and clinical implications. *Journal of Nuclear Medicine*, 52(2), 210-217.
- Harkness-Brennan, L. (2023). *An introduction to the physics of nuclear medicine*. IOP Publishing.
- <https://radiologykey.com/> (Erişim Tarihi: 10.12.2025)
- <https://spectrum-dynamics.com/products/d-spect-series/> (Erişim Tarihi: 10.12.2025)
- <https://www.auntminnie.com/clinical-news/molecular-imaging/article/15624674/pennpet-explorer-acquires-1st-human-images> (Erişim Tarihi: 10.12.2025)
- <https://www.gehealthcare.com/en-sg/courses/discovery-nm> (Erişim Tarihi: 10.12.2025)
- <https://www.itnonline.com/content/positron-emission-mammography-scanner-launched-europe> (Erişim Tarihi: 10.12.2025)
- <https://www.medicaldevice-network.com/projects/explorer-total-body-pet-scanner/?cf-view> (Erişim Tarihi: 10.12.2025)
- <https://www.ovissolutions.com/nuclear-imaging-cameras/digirad-cardius-3xpo/> (Erişim Tarihi: 10.12.2025)
- <https://www.siemens-healthineers.com/tr/molecular-imaging/options-and-upgrades/software-applications/iq-spect-technology> (Erişim Tarihi: 10.12.2025)
- International Atomic Energy Agency. (2008). *Clinical Applications of SPECT: New Hybrid Nuclear Medicine Imaging System*. IAEA.
- Johnson, R. D., Bath, N. K., Rinker, J., Fong, S., James, S. S., Pampaloni, M. H., & Hope, T. A. (2020). Introduction to the D-SPECT for technologists: workflow using a dedicated digital cardiac camera. *Journal of Nuclear Medicine Technology*, 48(4), 297-303.
- Keshavarz, K., Jafari, M., Lotfi, F., Bastani, P., Salesi, M., Gheisari, F., & Hemami, M. R. (2020). Positron Emission Mammography (PEM) in the diagnosis of breast cancer: A systematic review and economic evaluation. *Medical Journal of the Islamic Republic of Iran*, 34, 100.
- Kinahan, P. E., Hasegawa, B. H., & Beyer, T. (2003). X-ray-based attenuation correction for positron emission tomography/computed tomography

- scanners. In *Seminars in nuclear medicine* (Vol. 33, No. 3, pp. 166-179). WB Saunders.
- Kinahan, P. E., Hasegawa, B. H., & Beyer, T. (2003). X-ray-based attenuation correction for positron emission tomography/computed tomography scanners. In *Seminars in nuclear medicine* (Vol. 33, No. 3, pp. 166-179). WB Saunders.
- Knoll, P., Kotalova, D., Köchle, G., Kuzelka, I., Minear, G., Mirzaei, S., ... & Bergmann, H. (2012). Comparison of advanced iterative reconstruction methods for SPECT/CT. *Zeitschrift für medizinische Physik*, 22(1), 58-69.
- Lecoq, P., & Gundacker, S. (2021). SiPM applications in positron emission tomography: toward ultimate PET time-of-flight resolution. *The European Physical Journal Plus*, 136(3), 292.
- Lewin, H. C., & Hyun, M. C. (2005). 34.04 A clinical comparison of an upright triple-head digital detector system to a standard supine dual-head gamma camera. *Journal of Nuclear Cardiology*, 12(4), S113.
- Ljungberg, M., & Pretorius, P. H. (2018). SPECT/CT: an update on technological developments and clinical applications. *The British journal of radiology*, 91(1081), 20160402.
- Madsen, M. T. (2007). Recent advances in SPECT imaging. *Journal of Nuclear Medicine*, 48(4), 661-673.
- Matsuo, S., Nakajima, K., Onoguchi, M., Wakabayash, H., Okuda, K., & Kinuya, S. (2015). Nuclear myocardial perfusion imaging using thallium-201 with a novel multifocal collimator SPECT/CT: IQ-SPECT versus conventional protocols in normal subjects. *Annals of nuclear medicine*, 29(5), 452-459.
- Meden, J., Ficaro, E., & Corbett, J. (2011). Clinical comparison of four minute IQ-SPECT imaging with conventional parallel hole collimated SPECT/CT.
- Nakajima, K., Okuda, K., Momose, M., Matsuo, S., Kondo, C., Sarai, M., ... & Vija, A. H. (2017). IQ· SPECT technology and its clinical applications using multicenter normal databases. *Annals of Nuclear Medicine*, 31(9), 649-659.
- O'Connor, M. (2005). Evaluation of the CardiArc dedicated cardiac system (unpublished independent evaluation). Rochester, MN: Mayo Clinic.
- O'Mahoney, E., & Murray, I. (2013). Evaluation of a matched filter resolution recovery reconstruction algorithm for SPECT-CT imaging. *Nuclear medicine communications*, 34(3), 240-248.
- Patton, J. A., & Turkington, T. G. (2008). SPECT/CT physical principles and attenuation correction. *Journal of nuclear medicine technology*, 36(1), 1-10.

- Piemonte, C., & Gola, A. (2019). Overview on the main parameters and technology of modern Silicon Photomultipliers. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 926, 2-15.
- Powsner, R. A., Palmer, M. R., & Powsner, E. R. (2021). *Essentials of nuclear medicine physics, instrumentation, and radiation biology*. John Wiley & Sons.
- Ritt, P., Sanders, J., & Kuwert, T. (2014). SPECT/CT technology. *Clinical and Translational Imaging*, 2(6), 445-457.
- Singnurkar, A., Poon, R., & Metser, U. (2024). Head-to-head comparison of the diagnostic performance of FDG PET/CT and FDG PET/MRI in patients with cancer: a systematic review and meta-analysis. *American Journal of Roentgenology*, 223(3), e2431519.
- Slomka, P. J., Patton, J. A., Berman, D. S., & Germano, G. (2009). Advances in technical aspects of myocardial perfusion SPECT imaging. *Journal of nuclear cardiology*, 16(2), 255-276.
- Sönmezoğlu, K., & Şahin, O. E. (2024). PET/MR Görüntülerinin Değerlendirilmesinde Temel Esaslar. *Nucl Med Semin*; 10:213-232
- Spencer, B. A., Berg, E., Schmall, J. P., Omidvari, N., Leung, E. K., Abdelhafez, Y. G., ... & Cherry, S. R. (2021). Performance evaluation of the uEXPLORER total-body PET/CT scanner based on NEMA NU 2-2018 with additional tests to characterize PET scanners with a long axial field of view. *Journal of Nuclear Medicine*, 62(6), 861-870.
- Şahmaran T., Atılğan H. İ., Nur S., Şahutoğlu G., Yalçın H. (2022). Evaluation of the Occupational External Radiation Exposure of Personnel in Nuclear Medicine Practices. *Radiation Protection Dosimetry*, 198(5), 274-280.
- Şahmaran T., Nur S., Atılğan H. İ., Peker H. (2025). Dose Estimation for Indoor Radon, Occupational Radiation, and Electromagnetic Field Exposure in a Nuclear Medicine Department in Türkiye. *Health Physics*, 128,
- Tang, S. (2019). Dead time correction method for long axial field-of-view, whole-body PET scanner.
- Tang, S., Zhao, Y., Wang, J., Liu, Y., & Dong, Y. (2019, October). Geometric correction in normalization for long axial field-of-view, whole-body PET scanner. In *Poster presented at: 2019 IEEE Nuclear Science Symposium and Medical Imaging Conference*.
- Townsend, D., Weissleder, R., Ross, B. D., Rehemtulla, A., & Gambhir, S. S. (2010). *Imaging of structure and function with PET/CT. Molecular Imaging: Principles and Practice*, Ralph Weissleder, Brian D. Ross, Alnawaz Rehemtulla, Sanjiv Sam Gambhir, People's Medical Publishing House—USA, Shelton, CT, 10-28.

- Vija, H., Chapman, J., & Ray, M. (2008). IQ• SPECT Technology White Paper. Siemens Medical Solutions USA Molecular Imaging, 2008, 1-7.
- Voss, S. D. (2023). SPECT/CT, PET/CT and PET/MRI: oncologic and infectious applications and protocol considerations. *Pediatric Radiology*, 53(7), 1443-1453.
- Xie, J., Wang, H., Cherry, S. R., & Du, J. (2024). PET detectors based on multi-resolution SiPM arrays. *IEEE transactions on radiation and plasma medical sciences*, 8(5), 493-500.
- Yavuzkanat, N. (2016). Development of novel scintillation detection techniques for use in nuclear physics and medical applications (Doctoral dissertation, University of York).
- Zaidi, H., & Alavi, A. (2007). Current trends in PET and combined (PET/CT and PET/MR) systems design. *PET clinics*, 2(2), 109-123.
- Ziegler, S. I., & Delso, G. (2013). Technical and methodological aspects of PET/MR. *Clinical and Translational Imaging*, 1(1), 11-16.

Yapay Zekâ Destekli Ölçüm, Dozimetri ve Kalite Kontrol

Esil Kara¹

Özet

Yapay zekâ (YZ), makine öğrenimi (ML) ve derin öğrenme (DL) tabanlı yaklaşımlar, radyoterapi ve radyasyon güvenliği alanında ölçüm, dozimetri ve kalite kontrol süreçlerini dönüştürmeye başlamıştır. Modern radyoterapi uygulamalarının artan karmaşıklığı, cihaz performansının sürekliliğinin sağlanması, hastaya özgü kalite güvencesi gereksinimleri ve görüntü eşliğinde tedavilerin yaygınlaşması, geleneksel ölçüm ve periyodik kalite kontrol yaklaşımlarının sınırlarını belirgin hâle getirmiştir.

YZ, büyük ve çok boyutlu veri setlerinden anlamlı örüntüler çıkararak, cihaz davranışlarının izlenmesi, hastaya özel kalite güvencesinin ölçümsüz ya da azaltılmış ölçümle gerçekleştirilmesi, görüntüleme süreçlerinde doğruluğun artırılması ve Monte Carlo tabanlı doz hesaplamalarının klinik olarak uygulanabilir sürelerde yapılması gibi alanlarda güçlü çözümler sunmaktadır. Ayrıca hasta, çalışan ve çevresel radyasyon maruziyetinin izlenmesi ile anomali tespitine yönelik YZ tabanlı erken uyarı sistemleri, radyasyon güvenliğinde öngörüye dayalı bir yaklaşımın önünü açmaktadır. Bu bölümde, YZ'nin radyoterapide ölçüm, dozimetri, kalite kontrol ve radyasyon güvenliği alanlarındaki güncel uygulamaları, literatürdeki örnekler eşliğinde ele alınmakta; mevcut sınırlılıklar ve gelecekteki klinik entegrasyon potansiyeli tartışılmaktadır.

1.GİRİŞ

Yapay zekâ (YZ), insanın karar verme ve problem çözme süreçlerini taklit eden bilgisayar sistemlerinin geliştirilmesini amaçlayan bir bilgisayar bilimi alanıdır. YZ temelde yinelemeli optimizasyon (iterative optimization, IO) ve makine öğrenimi (machine learning, ML) olmak üzere iki sınıfa ayrılır.

1 Dr. Lösante Çocuk ve Yetişkin Hastanesi, Ankara, Orcid: 0000-003-0271-064X, esilkara@hotmail.com

MLin bir alt dalı olan derin öğrenme (deep learning, DL), insan beynindeki sinir ağlarını taklit eden çok katmanlı algoritmalar kullanarak büyük veri kümelerinden örüntüleri otomatik olarak öğrenebilmektedir (Hussein vd., 2018; Barragán-Montero vd., 2021).

Radyoterapi, kanser tedavisinin temel bileşenlerinden biri olup, hedeflenen tümör bölgesine yüksek doğrulukta radyasyon uygulanmasını ve çevre dokuların korunmasını gerektiren son derece hassas bir süreçtir (Gönültaş, 2022). Bu nedenle tedavi planlaması, doz hesaplaması, plan aktarımı ve hastaya özel doğrulama gibi birçok karmaşık aşamadan oluşur. Her aşama, tedavinin doğruluğunu ve hasta güvenliğini sağlamak için kapsamlı kalite güvence (QA) prosedürleri gerektirmektedir (Thompson vd., 2018; Huynh vd., 2020). Geleneksel QA yaklaşımları çoğunlukla belirli zamanlarda yapılan ölçümlere dayanmakta ve kliniklerde yıllar boyunca biriken büyük QA veri setleri genellikle sistematik olarak değerlendirilememektedir.

Son yıllarda ML ve YZ, radyoterapi alanında hem klinik uygulamalarda hem de araştırmalarda önemli bir araç hâline gelmiştir (Feng vd., 2018). Büyük veri kümelerinden öğrenen modeller sayesinde cihaz performansı, tedavi doğruluğu ve hastaya özel doz dağılımları önceden tahmin edilebilmekte; böylece ölçüm, dozimetri ve QA süreçlerinin geleneksel işleyişinin değişebileceği öngörülmektedir (Kalet vd., 2020). Özellikle YZ tabanlı algoritmalar tedavi cihazlarının performansını sürekli izleyerek tedavi parametrelerini doğrulamakta, böylece radyasyon uygulamasının planlandığı şekilde gerçekleşmesini sağlamakta ve hasta güvenliğine katkı sunmaktadır (Vandewinckele vd., 2020; Chan vd., 2020; Claessens vd., 2022; Kawamura vd., 2024).

Medikal fizik uzmanları açısından değerlendirildiğinde, giderek artan sayıda QA görevinin günlük klinik sorumluluklar içinde yer aldığı görülmektedir. AAPM TG-100 raporunda da vurgulandığı üzere, güvenli tedaviyi sağlayacak süreçlere öncelik verilmesi kritik öneme sahiptir (Huq vd., 2016). Bu nedenle, kompleks tedavi tekniklerinin yaygınlaşmasıyla birlikte QA verilerinden anlam çıkarabilmek, erken müdahale gerektiren durumları belirleyebilmek ve hataların oluşmadan önce önüne geçebilmek önemli bir gerekliliktir. Derin öğrenme modelleri, tedavi planlama sistemlerinden elde edilen doz dağılımlarını saniyeler içinde doğrulayabilen sanal QA uygulamalarıyla fiziksel ölçüm ihtiyacını azaltmakta; ayrıca cihazlardan elde edilen performans verilerini analiz ederek arızaları önceden tahmin eden öngörücü bakım olanağı sunmaktadır. Böylece klinik iş akışının kesintisiz, güvenli ve daha verimli bir şekilde sürdürülmesine önemli katkılar sağlamaktadır.

2. YZ ile Dozimetri Otomasyonu

Radyoterapi kalite güvencesi, hasta güvenliğinin ve tedavi etkinliğinin sağlanması açısından kritik öneme sahiptir. YZ, özellikle gelişmiş analiz ve otomasyon yetenekleri sayesinde bu alanı dönüştürme potansiyeline sahip güçlü bir araç olarak ortaya çıkmıştır. Klinik rutinde medikal fizikçiler tarafından yürütülen kalite kontrol ve kalite güvence testlerinin yerini tamamen YZ'nin alması henüz mümkün olmasa da ML tabanlı algoritmaların bu süreçleri destekleme ve iş yükünü azaltma ve belirli görevleri otomatikleştirme yönünde önemli ilerlemeler kaydettiği görülmektedir.

Radyoterapide kalite güvence faaliyetleri, plan kalite güvencesi dışında üç ana başlık altında değerlendirilebilir. Birincisi, cihaz kalite kontrolüdür; lineer hızlandırıcılar ve görüntüleme sistemleri gibi tedavi cihazlarının performansının belirli aralıklarla test edilmesini içerir. Bu testler uluslararası ve ulusal kılavuzlarda zorunlu olarak tanımlanmış olup, ölçümlerin nasıl yapılması gerektiğini belirleyen ayrıntılı düzenlemeler mevcuttur. İkincisi, hastaya özel kalite güvencedir (PSQA) ve çeşitli bilimsel topluluklar tarafından güçlü şekilde önerilmektedir. Bu kapsamda in-vivo dozimetri, bağımsız monitor unit (MU) hesaplamaları ve çeşitli dedektörlerle yapılan fiziksel doz ölçümleri yer almaktadır. YZ, özellikle ML algoritmaları, bu aşamalarda ölçüm sıklığını azaltmak anomalileri otomatik saptamak veya bazı durumlarda fiziksel ölçüm gerekliliğini ortadan kaldırmak amacıyla giderek daha fazla kullanılmaya başlanmıştır. Ancak bu yeni algoritmaların klinik pratikteki gerçek etkisi, güvenilirliği ve kullanıcı bağımlılığı hâlâ kapsamlı olarak araştırılmaktadır. (Smilowitz ve ark., 2015, McNutt ve ark., 2019, AAPM TG 26, AAPM Task Group 119, AAPM Task Group No. 218).

YZ modelleri, tedavi sırasında hem tedavinin izlenmesi hem de cihaz performansının değerlendirilmesi açısından önemli bir rol üstlenmektedir. Tedavi boyunca cihaz davranışını sürekli izleyerek planlanan tedavi protokolünden sapmaları anında tespit edebilmekte ve böylece tedavinin bütünlüğü ile tutarlılığının korunmasına katkı sağlamaktadır (Pillai vd., 2019; Vandewinckele vd., 2020; Chan vd., 2020). Bu yaklaşım, literatürde giderek daha fazla tartışılan “ölçümsüz QA” kavramının temelini oluşturmaktadır. Bu çerçevede, YZ modellerinin cihaz davranışını sürekli izlemesiyle geleneksel periyodik ölçümlere duyulan ihtiyacın azalabileceği, doğrulama fırsatlarının insan dikkatinin ötesine taşınabileceği öngörülmektedir.

YZ aynı zamanda hasta pozisyonlamasında da önemli katkılar sunmaktadır. Gelişmiş görüntü analiz algoritmaları sayesinde hastanın tedavi planına uygun şekilde hizalanması ve doğru pozisyonda tutulması sağlanarak milimetrik hassasiyet gerektiren tedavi süreçlerinde doğruluk artırılmaktadır. YZ

destekli pozisyonlama sistemleri ile geometrik hataların azalması, tedavinin doğruluğunu artırarak klinik sonuçları iyileştirmektedir.

Son olarak, kalite güvence süreçlerinin otomasyonu da YZ'nin önemli katkılarından biridir. Rutin kontrol ve doğrulama adımlarının otomatikleştirilmesi, insan hatasını azaltmakta, zamandan tasarruf sağlamakta ve güvenlik standartlarına daha tutarlı bir şekilde uyulmasını tanımaktadır. Nitekim literatürde, YZ destekli QA modellerinin bazı durumlarda standart QA prosedürleriyle eşdeğer veya daha iyi performans gösterdiği bildirilmiştir (Kalet ve ark., 2020). Bununla birlikte, YZ tabanlı otomasyon süreçlerinin artması beraberinde YZ sistemlerinin kendisi için QA yapılması gerekliliğini getirmiştir. Modellerin doğrulanması, klinik devreye alınması ve düzenli performans takibi, kullanılan algoritmanın mimarisi ve çözümüne göre değiştiğinden, bu alanda henüz standartlaşmış yöntemler bulunmamaktadır. Bu nedenle mevcut literatür, belirli bir model için kesin kurallar önermek yerine daha çok genel prensipler ve yaygın doğrulama yaklaşımlarına odaklanmaktadır (McNutt ve ark., 2019).

Özetle, YZ radyoterapi kalite güvencesini; tedavi ve cihaz izlemine iyileştirerek, hasta pozisyonlamasında hassasiyet sağlayarak ve otomatikleştirerek önemli ölçüde güçlendirmektedir. Bu gelişmelerin tamamı, daha etkin tedavi süreçlerine ve daha iyi hasta sonuçlarına katkıda bulunmaktadır (Pillai vd., 2019; Vandewinckele vd., 2020; Simon vd., 2021; Chen vd., 2022; Yang vd., 2022, Cakir T., 2024).

3. Cihaz Performans İzleme (Cihaz QA)

Radyoterapide kullanılan tedavi cihazlarının uzun dönemli kararlılığının değerlendirilmesi amacıyla cihaz kalite güvencesi (QA) belirli aralıklarla gerçekleştirilmekte olup, bu kapsamda elde edilen ölçüm verileri çoğu zaman çok boyutlu ve doğrusal olmayan yapılar göstermektedir (Li ve Chan, 2017, El Naqa vd., 2019).

Bu durum klasik yöntemlerle yorumlama sürecini zorlaştırmakta; gelişmiş algılama, örüntü tanıma ve tahmin yeteneklerine sahip YZ modellerini bu alanda değerli bir araç haline getirmektedir. Ayrıca modern tedavi uygulama ve izleme sistemlerinin karmaşıklığı arttıkça, güvenlik odaklı yaklaşımların YZ ile birleştirilmesi, potansiyel hataların ve cihaz performansındaki sapmaların daha erken ve daha yüksek doğrulukla tespit edilmesine olanak tanımaktadır [EU - Directorate General for Energy 2015, Vilaragut vd., 2015).

YZ uygulamalarının cihaz QA'deki en önemli katkılarından biri, cihaz davranışlarını hem iç sensör ve log dosyaları (MLC hızları, yaprak pozisyonları, motor akımları, gantri/kolimatör hızları vb.) hem de harici ölçüm sistemleri (doz accublandıkları, beam profile verileri, pozisyon sensörleri) üzerinden analiz

ederek potansiyel hataları yüksek seçicilikle öngörebilmesidir. Bu sayede beklenmeyen davranışlar daha kritik hale gelmeden önce tespit edilmekte, bakım süreçleri optimize edilmekte ve cihaz çalışma süresi (uptime) ile tedavi güvenilirliği önemli ölçüde artmaktadır (Pillai vd. 2019).

Bu alanda yapılan çalışmalar YZ'nin cihazın performansını tahmin etmesi, tutarsızlıkları saptaması ve bakım gereksinimlerini öngörmesi açısından güçlü bir potansiyele sahip olduğunu göstermektedir. Örneğin Li ve Chan (2017), lineer hızlandırıcının yıllar içindeki kararlılığını değerlendirmek amacıyla beş yıllık günlük QA verilerine yapay sinir ağı (ANN) tabanlı zaman serisi tahmin modeli uygulamıştır. Deneme-yanılma yöntemiyle optimize edilen ağ mimarisi (bir gizli katman, altı nöron, iki giriş gecikmesi), ışın simetrisi tahmininde ARIMA gibi geleneksel istatistiksel modellere göre daha yüksek doğruluk sağlamıştır. Bu çalışma, uzun dönemli QA verilerinden yararlanarak cihazdaki sapmaların kritik eşiklere ulaşmadan öngörülebileceğini göstermesi açısından öncüdür.

Zhao ve ark. (2020) ise yalnızca 10×10 cm² alan verisini kullanarak diğer alanlara ait PDD ve profil verilerini %1 doğrulukla tahmin eden bir ML modeli geliştirmiştir. 43 kabul testi ve yıllık QA ışın verisini analiz eden bu yaklaşım, tedavi planlama sistemleri (TPS) için kabul sürecindeki veri toplama işlemlerini büyük ölçüde hızlandırma ve lineer hızlandırıcıların periyodik QA ölçümelerini minimum sayıda ölçümle optimize etme potansiyeline sahip olduğunu ortaya koymuştur (Zhao vd., 2020).

Cihaz log dosyalarının YZ ile analiz edilmesi fikri ilk kez Carlson ve ark. (2016) tarafından ortaya konmuştur. Çalışmalarında çok yapraklı kolimatörün (MLC) pozisyon ve hız bilgileri kullanılarak doğrusal regresyon, rastgele orman ve kübizm modeli gibi farklı makine öğrenimi yöntemleri test edilmiştir. Elde edilen sonuçlar, kübizm modelinin MLC pozisyon hatalarını tahmin etmede diğer modellerden daha iyi performans gösterdiğini ortaya koymuştur. Bu bulgu, YZ'nin MLC sapmalarını erken aşamada saptayarak bakım planlamasına entegre edilebileceğini göstermektedir (Carlson vd., 2016).

Benzer şekilde Osman ve ark. (2020), tedavi sırasında oluşan MLC pozisyon hatalarını tahmin etmek amacıyla ANN tabanlı bir model geliştirmiş ve 400 log dosyasından yararlanmıştır. Bu ANN modeli, planlanan ve gerçekleşen konumlar arasındaki farkları analiz ederek MLC yaprak pozisyonlarını 0.0001 mm² gibi son derece düşük bir hata ile tahmin edebilmiştir. Bu seviyede doğruluk, gerçek zamanlı izleme ve hata önleme açısından önemli bir adım olarak değerlendirilmektedir (Osman vd., 2020).

Özetle, cihaz QA alanındaki tüm bu ML ve AI çalışmaları, tedavi cihazlarının performansını otomatik, hızlı ve yüksek doğrulukla izleyip tahmin ederek QA süreçlerini daha öngörülebilir ve verimli hale getirmeyi amaçlamaktadır. Birçok çalışma bu hedefe büyük ölçüde ulaşıldığını göstermekte olup, YZ'nin cihaz QA'de ilerleyen yıllarda daha merkezi bir rol üstleneceği öngörülmektedir.

4. Hasta Kalite Kontrollerinde YZ

Hasta-spesifik kalite güvencesi (PSQA), özellikle IMRT ve VMAT gibi yüksek düzeyde modülasyon içeren modern radyoterapi tekniklerinde tedavinin doğruluğunu güvence altına almak için uzun yıllardır kullanılan temel bir süreçtir. Geleneksel PSQA yaklaşımı, her tedavi planının özel olarak fiziksel bir ölçümle değerlendirilmesini gerektirdiğinden hem zaman alıcı hem de klinik kaynakları yoğun biçimde tüketen bir yapıya sahiptir. Gamma geçiş oranlarının cihaz performansındaki küçük mekanik sapmalara, plan karmaşıklığına ve ışın modellemesindeki farklılıklara duyarlı olması da bu iş yükünü artırmaktadır. Bu nedenle son yıllarda PSQA'nın otomasyonu ve ölçüm gereksiniminin azaltılması amacıyla YZ, ML ve DL tabanlı "virtual QA" yaklaşımları önemli bir araştırma alanı hâline gelmiştir.

Virtual QA kavramının literatürde ilk güçlü örnekleri Valdes ve arkadaşlarının çalışmalarında ortaya çıkmış; plan karmaşıklığı metriklerini kullanan Poisson regresyon modelleri ile fiziksel ölçüm yapılmadan gamma geçiş oranlarının tahmin edilebileceği gösterilmiştir. Bu çalışma, PSQA'nın salt ölçüm temelli bir süreç olmaktan çıkarılabileceğini ortaya koyması bakımından bir dönüm noktası niteliğindedir. Ardından geliştirilen modeller bu yaklaşımı genişleterek hem IMRT hem VMAT planlarında çok daha yüksek doğruluk düzeylerine ulaşmıştır (Valdes vd., 2016).

Ardından Li ve arkadaşlarının çalışmasında, 255 VMAT planı ile rastgele orman ve Poisson-Lasso modelleri karşılaştırılmış ve düşük gamma oranına sahip planların güvenilir şekilde tespit edilebildiğini göstermiştir (Li vd., 2019). Granville ve ekibi ise plan karmaşıklığına ek olarak cihaz kalite kontrol metriklerini modele dâhil ederek mekanik sapmaların PSQA sonuçları üzerindeki etkisini daha hassas biçimde yakalayabilen genişletilmiş bir sınıflandırıcı geliştirmiştir (Granville vd., 2019). Ono ve çalışma arkadaşları ArcCHECK temelli VMAT QA sonuçlarını ANN ve regresyon modelleriyle karşılaştırmış, yapay sinir ağlarının diğer yöntemlerden üstün performans sergilediğini göstermiştir (Ono vd., 2019).

Bununla birlikte, DL modellerinin devreye girmesiyle akı haritalarının ve doz dağılımlarının doğrudan kullanıldığı, manuel özellik çıkarımı gerektirmeyen daha ileri sanal QA yöntemleri geliştirilmiştir. Interian ve arkadaşları IMRT akı

haritalarından gamma değerlerini CNN tabanlı modellerle yüksek doğrulukla tahmin etmiş; Tomori ve çalışma ekibi de film tabanlı QA verilerinde benzer başarı elde etmiştir (Interian vd., 2018, Tomori vd. 2018). Daha da gelişmiş modellerde 3D doz dağılımlarından radyomik benzeri “dosimics” özellikleri çıkarılarak gradyan güçlendirme algoritmaları ile birleştirilmiş ve sanal QA değerlendirmesinin yalnızca 2D düzlemde değil, doz hacmi boyunca üç boyutlu olarak gerçekleştirilebileceği gösterilmiştir (Hirashima vd., 2020).

Görüntü tabanlı QA alanında elektronik portal görüntüleme cihazları (EPID)’in YZ ile entegrasyonu sanal QA alanında önemli bir ilerleme sağlamıştır. Mahdavi ve arkadaşları EPID akı haritalarını derin sinir ağına giriş verisi olarak kullanıp TPS’e oldukça yakın 2D doz dağılımları üretmeyi başarmıştır (Mahdavi vd. 2019). EPID tabanlı sanal QA’nın en geniş ölçekli uygulamalarından biri Sadowski ve ekibi tarafından gerçekleştirilmiş; 3000’den fazla VMAT planı kullanılarak geliştirilen karar ağaçları temelli modelin 2%/2 mm gamma kriteri için %91.6 özgüllükle doğru tahmin yapabildiği ve fiziksel PSQA ölçümlerinin yaklaşık %50 azaltılabileceği gösterilmiştir (Sadowski vd. 2022). Bu bulgu, EPID tabanlı yapay zekâ modellerinin yüksek klinik uygulanabilirlik potansiyeline işaret etmektedir.

Genel olarak literatür, ML ve DL modellerinin PSQA sonuçlarını yüksek doğrulukla tahmin ederek fiziksel ölçüm gereksinimini azaltabileceğini, gamma geçiş oranı düşük olma riski taşıyan planları önceden belirleyerek klinik iş akışını hızlandırabileceğini ve QA süreçlerini hızlı ve öngörülebilir hale getirebileceğini göstermektedir. EPID ve log-dosyası tabanlı yapay zekâ modelleri gerçek ölçüme en yakın sanal QA yaklaşımları olarak öne çıkarken, DL yöntemleri gelecekte hastaya özel QA’nın hacimsel ve ölçümsüz bir yapıya dönüşeceğinin sinyallerini vermektedir. Tüm bu gelişmeler, YZ destekli PSQA’nın modern radyoterapide yalnızca bir doğrulama aracı değil, tedavinin bütünlüğünü ve güvenliğini sürekli izleyen güçlü bir klinik karar destek sistemi hâline gelmekte olduğunu göstermektedir.

5. Görüntü Eşliğinde Radyoterapide YZ

Elektronik portal görüntüleme cihazları (EPID), uzun yıllardır radyoterapide alan doğrulama ve portal dozimetri için kullanılan standart araçlardır. Son yıllarda derin öğrenme tekniklerinin gelişmesiyle birlikte EPID, yalnızca iki boyutlu alan kontrolü sağlayan bir dedektör olmaktan çıkmış; aynı zamanda otomatik görüntü eşleştirme, hedef lokalizasyonu ve fraksiyon içi hareket izleme gibi görüntü eşliğinde radyoterapi (IGRT) süreçlerinde yapay zekâ destekli güçlü bir sensöre dönüşmüştür. EPID görüntülerinin düşük kontrastlı ve projeksiyon tabanlı yapısı klasik görüntü çıkartma yöntemleri için zorluk oluştururken,

YZ modelleri bu sınırlamayı büyük ölçüde ortadan kaldırmış ve hızlı, güvenilir ve kullanıcı bağımsız IGRT uygulamalarını mümkün kılmıştır.


Modern radyoterapi teknikleri olan IMRT ve VMAT'ın klinik uygulamaya girmesiyle birlikte, hedef hacimlerin yüksek doğrulukla ışınlanması ve kritik organların korunması daha da önemli hâle gelmiştir (Staffurth, 2010, Otto, 2008, Timmerman, 2009). Ancak planlama sırasında elde edilen anatomik bilgiler ile tedavi anındaki anatomik gerçeklik çoğu zaman tam olarak örtüşmez; bu nedenle geniş güvenlik marjları kullanılmakta ve bu durum doz konformitesini sınırlamaktadır (Xing vd. 2006, Verellen vd. 2007). IGRT'nin temel amacı, bu geometrik belirsizliği azaltmak ve hedefin gerçek zamanlı ya da fraksiyonlar arası konumunu doğrulayarak tedavinin planlandığı biçimde uygulanmasını sağlamaktır. Son yıllarda YZ, özellikle DL yaklaşımları, IGRT'nin kayıt, konturlama, hedef takibi, adaptif planlama ve kalite güvencesi dahil tüm aşamalarında, kaçınılmaz bir dönüşüm yaratmaya başlamıştır (Xing vd., 2020, Liu vd. 2019).

YZ uygulamaları içinde DL, görüntülerden otomatik olarak yüksek düzeyde soyut özellikler çıkarabilme gücü sayesinde IGRT'ye yeni bir boyut kazandırmıştır (LeCun vd., 2015). Bu yöntemler, çoklu modalite görüntü kaydının iyileştirilmesinden tek veya çift düzlemde elde edilen düşük kontrastlı X-ışını görüntülerinde işaretleyici olmaksızın tümör lokalizasyonuna kadar geniş bir yelpazede kullanılmaktadır (Xia vd., 2019, Fu vd., 2021, Zhao vd. 2019). DL modelleri 2D kV radyograflardan gerçek zamanlı konum doğruluğunu yüksek hassasiyetle elde edebildiğini göstermektedir. Böylece geçmişte yalnızca metal işaretleyici yerleştirilerek mümkün olan takip, girişimsel olmayan bir yaklaşımla gerçekleştirilebilir hâle gelmiştir. Üretken çekişgeli ağ (GAN) tabanlı görüntü sentezi tekniklerinin kullanılması ise gerçek kV projeksiyonlarını digital yeniden yapılandırılmış görüntü (DRR) görünümüne yaklaştırarak lokalizasyon doğruluğunu daha da artırabilmektedir (Dhont vd. 2020).

Üç boyutlu görüntüleme alanında YZ, özellikle konik ışınlı BT'nin (CBCT) sınırlamalarını aşmak açısından dikkate değerdir. CBCT'nin düşük HU doğruluğu ve artefaktlara duyarlılığı nedeniyle adaptif radyoterapi rutinde uygulanabilir değildi. Son yıllarda döngüsel üretken çelişkili ağ (CycleGAN) gibi DL yöntemleriyle CBCT'den sentetik CT (sCT) üretimi mümkün hâle gelmiş; böylece günlük anatomiye yansıtan, doz hesaplamaya uygun ve plan doğruluğunu değerlendirmede kullanılabilir görüntüler elde edilmiştir (Chen vd., 2020). sCT'nin planlama BT'sine yakın HU doğruluğu sağlaması CBCT tabanlı adaptif radyoterapiyi gerçekçi bir seçenek hâline getirmektedir. Ayrıca otomatik kontur tayini için geliştirilen DL modelleri, günlük anatomideki

değişimlere hızlı uyum sağlayarak manuel kontur çizimindeki zaman kaybını ortadan kaldırmaktadır (Elmahdy vd., 2019).

MR-Linac sistemlerinin klinik kullanıma girmesiyle birlikte, YZ'nın gerçek zamanlı adaptif radyoterapideki rolü daha da belirginleşmiştir. Gerçek zamanlı MR görüntülerinden tümör hareketinin çıkarılması, tümör takip modellerinin geliştirilmesi ve solunum kaynaklı varyasyonların yönetilmesi gibi kritik süreçlerde YZ tabanlı yaklaşımlar kullanılmaktadır. DL tabanlı hızlı MR rekonstrüksiyon teknikleri, yüksek hızda görüntü elde edilmesini sağlayarak ışınlanmanın anatomik değişimlere anlık olarak uyarlanabilmesine olanak tanımaktadır (Terpstra vd. 2020). Bunun bir uzantısı olarak, tek projeksiyonla hacimsel BT rekonstrüksiyonu gibi yenilikçi çalışmalar, X-ışını tabanlı sistemlerde de gerçek zamanlı 3D IGRT'nin mümkün olabileceğini göstermektedir (Shen vd. 2019).



Şekil 1. PubMed’de “Artificial intelligence + Radiotherapy + Image”, “Machine learning + Radiotherapy + Image” ve “Deep learning + Radiotherapy + Image” anahtar kelimeleriyle yapılan aramanın 2020–2025 yılları arasındaki yıllık sonuç dağılımı.

Şekil 1, PubMed’de, 2020–2025 yılları arasında YZ, ML ve DL temelli radyoterapi çalışmalarında belirgin ve sürekli bir artış olduğunu göstermektedir. Bu eğilim, görüntüleme temelli akıllı algoritmaların hem klinik kullanım hem de araştırma alanında hızla büyüyen bir etki yarattığını ortaya koymaktadır. Ancak tüm bu gelişmelere rağmen, YZ tabanlı IGRT henüz günlük klinik rutine tam olarak entegre edilememiştir. Bunun başlıca nedenleri arasında, derin öğrenme modellerinin yüksek hacimli ve iyi etiketlenmiş veri setlerine

gereksinim duyması, “kara kutu” nitelikleri nedeniyle klinik güvenlik ve yorumlanabilirlik açısından belirsizlikler içermesi, cihazlar arası genellenebilirlik sorunları ve düzenleyici onay süreçlerinin zorunluluğu yer almaktadır. (Zhao ve ark., 2021). Bununla birlikte mevcut literatür, YZ’nin tümör konumu, organ hareketi ve anatomik değişimlerin daha doğru modellenmesini sağlayarak belirsizlikleri azaltabileceğini, marjları daraltabileceğini ve normal doku dozunu azaltırken tümör kontrolünü artırabileceğini göstermektedir. Dolayısıyla YZ, IGRT’nin geleceğini şekillendiren temel bileşenlerden biri haline gelmiş ve adaptif radyoterapinin geniş ölçekte uygulanmasının anahtarı olarak görülmektedir.

6. Monte Carlo Simülasyonlarının Hızlandırılması

Monte Carlo (MC) doz hesaplama yöntemleri, radyoterapide ışınımın madde ile etkileşimini temel fizik yasalarına dayanarak modellemesi nedeniyle uzun süredir altın standart olarak kabul edilmektedir (Brualla vd., 2017). Foton ve elektronların her bir etkileşimini tek tek izleyerek enerji aktarımını hesaplaması, özellikle heterojen dokuların bulunduğu durumlarda analitik ya da yarı-analitik algoritmalara kıyasla üstün bir doğruluk sağlar. Akciğer, kemik ve yumuşak doku gibi farklı yoğunluk ve atom numarasına sahip ortamların bir arada bulunduğu klinik senaryolarda, MC yöntemleri doz dağılımının gerçekçi biçimde tahmin edilmesini mümkün kılar. Bu özellik, MC’yi hem tedavi planlama doğrulamalarında hem de yeni algoritmaların referans noktası olarak vazgeçilmez hale getirmiştir (Seco ve Verhaegen 2021).

Bununla birlikte MC hesaplamalarının en önemli dezavantajı, hesaplama süresinin çok uzun olmasıdır. Yüksek doğruluk elde edebilmek için çok sayıda parçacığın simüle edilmesi gerekir ve bu gereksinim Poisson istatistiği nedeniyle doğruluk arttıkça katlanarak büyür. Klinik ya da preklinik iş akışlarında kabul edilebilir gürültü seviyesine ulaşmak için genellikle 10^8 – 10^9 parçacık gerekir ve bu da tek bir doz hesabının onlarca dakika, hatta saatler sürmesine yol açabilir. Bu durum MC’nin rutin klinik planlama süreçlerine entegrasyonunu ciddi biçimde sınırlandırmış, kullanımını kısıtlamıştır (van Dijk vd., 2022). MC doz hesaplama hızını arttırmak amacıyla literatürde uzun yıllar boyunca donanım tabanlı hızlandırma stratejileri ön planda olmuştur. Daha hızlı donanımlar, çok çekirdekli merkezi işlem birimleri (CPU’lar), bilgisayar kümeleri, bulut tabanlı hesaplamalar (Ziegenhein vd., 2017), alan programlanabilir geçit dizileri (Abhyankar vd. 2019) veya grafik işlem birimi (GPU) tabanlı MC motorları kullanarak (Lee vd., 2010, Hissoiny vd., 2011) simülasyonlar hızlandırılmaya çalışılmıştır. Hesaplama sürelerinde önemli kazanımlar elde edilse de bu yaklaşımlar donanıma özgü sınırlamalar, model sadeleştirme gereksinimleri ve maliyet gibi faktörler nedeniyle her klinik ortamda sürdürülebilir bir çözüm

sunamamıştır (Jia vd., 2011, Abhyankar vd., 2019). Ayrıca, hız kazanımı çoğu zaman fiziksel süreçlerin basitleştirilmesi pahasına gerçekleşmiş ve bu durum doğruluk-hız dengesi açısından yeni tartışmaları beraberinde getirmiştir.

Son yıllarda, MC doz hesaplamalarının yüksek doğruluğunu klinik açıdan kabul edilebilir sürelerle birleştirmek amacıyla DL tabanlı yöntemler giderek artan bir ilgi görmektedir. Bu bağlamda DL, ya düşük istatistikli MC hesaplamalarından elde edilen doz dağılımlarındaki istatistiksel gürültüyü azaltarak MC doğruluğunu kısa sürede yeniden üretmekte ya da hasta görüntüleri ve tedaviye ait parametrelerden yola çıkarak MC'ye yakın doğrulukta doz dağılımlarını doğrudan tahmin edebilen bir araç olarak kullanılmaktadır.

İlk yaklaşım olan gürültü azaltma yönteminde, nispeten az sayıda parçacıkla (örneğin 10^6 parçacık) simüle edilen Monte Carlo doz haritalarındaki istatistiksel gürültünün derin öğrenme modelleri kullanılarak giderilmesi ve böylece daha yüksek hassasiyetle hesaplanan MC doz dağılımlarına yakın sonuçların elde edilmesi amaçlanmaktadır (Bai vd., 2021; Neph vd., 2021). Bu çalışmaların tamamında ağ girdisi olarak yalnızca doz matrisleri kullanılmış, eğitim verisine benzer özellikler taşıyan bağımsız test kümeleri üzerinde yüksek istatistikli MC sonuçlarıyla nitel ve nicel olarak karşılaştırılabilir doğrulukta doz dağılımları üretilmiştir. Söz konusu çalışmaların tümünde, evrimsel sinir ağları temel alınmış ve ağırlıklı olarak U-Net benzeri mimariler tercih edilmiştir (Ronneberger vd., 2015).

İkinci yaklaşımda ise DL yöntemleri, demet parametreleri, BT ve PET hacimleri ya da hasta geometrisine ait bilgileri girdi olarak kullanarak MC doz hesaplamalarının doğrudan yerine geçmeyi hedeflemektedir (Kontaxis vd., 2020; Lee vd., 2019; Bakx vd., 2021). Bu kapsamda geliştirilen çalışmaların büyük çoğunluğunda, yine U-Net benzeri evrimsel sinir ağları kullanılmıştır (Ronneberger vd., 2015). Bunun yanı sıra, özellikle derin ağların temsil gücünü artırmak amacıyla ResNet tabanlı mimarilerin tercih edildiği çalışmalar da literatürde yer almaktadır (Chen vd., 2019).

Bu iki yaklaşım birlikte değerlendirildiğinde, derin öğrenmenin Monte Carlo hızlandırma literatüründe hem tamamlayıcı hem de dönüştürücü bir rol üstlendiği görülmektedir. Gürültü azaltmaya dayalı yöntemler, Monte Carlo'nun fiziksel doğruluğunu koruyarak hesaplama süresini klinik olarak uygulanabilir seviyelere indirirken, Monte Carlo'nun yerine geçmeyi hedefleyen yaklaşımlar özellikle zaman kısıtının kritik olduğu adaptif ve çevrimiçi tedavi senaryoları için önemli bir potansiyel sunmaktadır. Bununla birlikte, ikinci yaklaşımın başarısı büyük ölçüde eğitim verisinin kapsamına ve modelin genellenebilirliğine bağlı olup, bu durum Monte Carlo tabanlı yöntemlerin kısa ve orta vadede referans standart konumunu koruyacağını düşündürmektedir.

Bu çerçevede güncel literatür, Monte Carlo'nun fiziksel doğruluğunu referans alan düşük istatistikli MC hesaplamalarının derin öğrenme ile desteklenmesi ya da derin öğrenme modellerinin yüksek doğruluklu MC verileriyle eğitilerek klinik iş akışlarında kullanılması yoluyla, MC'nin referans standart konumunu korurken hesaplama süresini klinik gereksinimlerle uyumlu hale getiren hibrit bir yaklaşımın giderek öne çıktığını göstermektedir (Kontaxis vd., 2020; van Dijk vd., 2022; Seco ve Verhaegen 2021).

7. Radyasyon Güvenliği

Radyasyon güvenliği, iyonlaştırıcı radyasyonun hasta, çalışan ve çevre üzerindeki potansiyel olumsuz etkilerinin sınırlandırılması amacıyla uluslararası otoriteler (ICRP, IAEA, UNSCEAR) tarafından tanımlanan prensipler çerçevesinde yürütülen kapsamlı bir süreçtir. Son yıllarda hem doz izleme sistemlerinin dijitalleşmesi hem de YZ tabanlı modellerin gelişimi, radyasyon güvenliğini yalnızca ölçülen veya raporlanan doz değerlerine dayanan pasif bir yaklaşımdan çıkararak, kişiselleştirilmiş, gerçek zamanlı ve öngörüye dayalı bir yapıya dönüştürmüştür. Bu bağlamda maruziyetlerin olasılık temelli biyolojik etkilerini, bireysel duyarlılıkları ve klinik bağlamı birlikte değerlendirerek potansiyel sağlık risklerini önceden tanımlamayı ve bu riskleri kabul edilebilir seviyelerde tutacak şekilde radyasyon korunmasının optimize edilmesini hedeflemektedir. Bu bölümde hasta, çalışan ve çevresel doz izleme yöntemleri ile, modern YZ temelli radyasyon güvenliği ve doz izleme yaklaşımları ele alınmaktadır.

7.1. Hasta Güvenliği: Tıbbi Uygulamalarda Doz İzleme

Yapay zekânın (YZ) medikal görüntüleme alanındaki kullanımı, klinik iş akışlarının verimliliğini artırırken hasta maruziyetini azaltmaya yönelik önemli avantajlar sunmaktadır. YZ tabanlı sistemler, görüntüleme protokollerinin optimize edilmesi ve tarama süreçlerinin otomasyonu sayesinde gereksiz veya tekrarlayan çekimlerin önüne geçerek hem hastaların gereksiz radyasyon dozuna maruz kalmasını hem de ilave maliyetlerin oluşmasını engelleyebilmektedir. Bunun yanı sıra, tarama ve görüntü işleme süreçlerinde kullanılan YZ algoritmaları, inceleme sürelerini kısaltarak görüntüleme hizmetlerine erişimi hızlandırmakta ve daha geniş hasta gruplarının zamanında değerlendirilmesine olanak sağlamaktadır. Bu uygulamalar, operatör kaynaklı hataların azaltılması ve görüntü kalitesinin daha tutarlı hâle getirilmesi yoluyla hem hastalar hem de radyoloji çalışanları açısından tanısal süreci iyileştirmektedir. Ayrıca hasta yaşı, klinik endikasyon ve kümülatif radyasyon maruziyeti gibi bireysel faktörleri dikkate alan YZ tabanlı risk değerlendirme modelleri, radyasyon risklerinin daha gerçekçi biçimde tahmin edilmesine katkı sağlayarak medikal

görüntüleme hasta güvenliğini ve radyasyondan korunma yaklaşımlarını güçlendirmektedir (Colvin vd., 2020).

Bu genel çerçevede içinde YZ uygulamaları, radyolojik görüntüleme hasta ve çalışan dozlarının azaltılmasında tamamlayıcı mekanizmalar üzerinden etkili olmaktadır. Floroskopi kılavuzlu endoskopik girişimlerde Bang ve arkadaşları, YZ destekli ultra hızlı kolimasyon ve otomatik ilgi alanı (ROI) tanımlama kullanan bir floroskopi sisteminin, konvansiyonel sistemlere kıyasla hem hasta doz alan çarpanını hem de sağlık personeline saçılan radyasyonu anlamlı düzeyde azalttığını göstermiştir. Bu yaklaşımda doz düşüşü, görüntü kalitesini bozmak yerine ışınlamanın yalnızca klinik olarak gerekli anatomik bölgeyle sınırlandırılması yoluyla sağlanmıştır (Bang vd., 2020).

Bilgisayarlı tomografide (BT) ise YZ'nin rolü ağırlıklı olarak doz optimizasyonu ve rekonstrüksiyon süreçlerinin iyileştirilmesi üzerinden şekillenmektedir. Gupta ve arkadaşları, YZ tabanlı rekonstrüksiyon ve doz optimizasyon yazılımlarının düşük doz protokollerinde gürültüyü etkin biçimde baskılayarak tanısal görüntü kalitesini koruyabildiğini, ancak farklı cihaz teknolojileri ve protokol varyasyonlarının YZ performansını doğrudan etkileyebildiğini vurgulamıştır. Bu bulgular, doz azaltımının yalnızca algoritmik çözümlerle değil, bütüncül bir sistem optimizasyonu yaklaşımıyla ele alınması gerektiğini ortaya koymaktadır (Gupta vd., 2022). Buna paralel olarak Meineke ve çalışma arkadaşları, makine öğrenmesi tabanlı modellerin hasta yaşı, cinsiyet, su eşdeğer çap, tarama protokolü ve cihaz bilgilerini kullanarak doz optimizasyon potansiyeli taşıyan BT incelemelerinin otomatik olarak saptanabildiğini göstermiştir. Bu yaklaşım, YZ'nin yalnızca görüntü rekonstrüksiyonunda değil, aynı zamanda kalite güvencesi ve protokol denetimi yoluyla da dozların düşürülmesine katkı sağladığını ortaya koymaktadır (Meineke vd., 2021).

Pozitron emisyon tomografisinde (PET) YZ uygulamaları ise esas olarak düşük sayım istatistiğine bağlı gürültünün azaltılması ile doz azaltımına katkı sağlamaktadır. Derin öğrenme tabanlı gürültü giderme yöntemleri, düşük aktivite veya kısa tarama süresiyle elde edilen verilerden tanısal olarak kabul edilebilir görüntü kalitesi üretebilmektedir. Buna ek olarak, sinogram veya görüntü alanında eğitilen öğrenilmiş rekonstrüksiyon modelleri, klasik iteratif algoritmalara kıyasla gürültü-çözünürlük dengesini daha etkin biçimde yöneterek klinik kullanım için yeterli görüntü kalitesine olanak tanımaktadır (Reader & Pan, 2023; Wang vd., 2023; Seyyedi vd., 2024).

YZ'nin doz azaltımındaki katkısı yalnızca görüntü kalitesiyle sınırlı olmayıp, hastaya özgü doz izleme ve hesaplama alanında da belirginleşmektedir. Berris ve arkadaşları, BT'de bireyselleştirilmiş organ dozu hesaplamasında

altın standart olarak kabul edilen MC simülasyonlarının yüksek iş gücü ve hesaplama süresi gereksinimine alternatif olarak, koşullu üretgen çekişmeli ağlar (conditional GAN) tabanlı bir yöntem önermiştir. Bu çalışmada yalnızca hastaya ait BT görüntülerini girdi olarak kullanan derin öğrenme modeli, hastaya özgü organ dozlarını gerçek zamana yakın sürede tahmin edebilmiş ve klinik iş akışına entegre edilebilecek hızlı ve otomatik bir doz izleme yaklaşımının fizibilitesini ortaya koymuştur (Berris vd., 2024).

Radyoterapi ve görüntüleme uygulamalarında hasta dozunun bireyselleştirilmiş ve gerçek zamanlı izlenmesi, radyasyon güvenliğinin en kritik bileşenlerinden biri hâline gelmiştir. Bu bağlamda Tsironi ve arkadaşları, toraks bölgesinde radyoterapi sırasında kullanılan CBCT gerçek zamanlı ve hastaya özgü organ dozimetriyi mümkün kılan ileri düzey bir YZ yaklaşımı tanımlamıştır. Torasik radyoterapi uygulanan 113 hastaya ait BT görüntülerinin kullanıldığı çalışmada, MC simülasyonları ile elde edilen organ-spesifik doz verileri YZ modellerinin eğitimi için referans olarak alınmıştır. Geliştirilen algoritmaların MC sonuçlarıyla karşılaştırılması, AI tahminleri ile simülasyonlar arasında yüksek uyum olduğunu göstermiş; ortalama doz sapmalarının %0,5–2,5 aralığında, maksimum sapmaların ise %9,4–21,2 aralığında olduğu raporlanmıştır. Bu bulgular, YZ tabanlı yaklaşımların MC yöntemlerine kıyasla çok daha hızlı olup klinik uygulamada kabul edilebilir doğruluk düzeyleri sunduğunu ortaya koymaktadır (Tsironi vd., 2024).

Tüm bu çalışmalar birlikte değerlendirildiğinde, YZ'nin tıbbi uygulamalarda doz azaltımı ve hasta dozu izlemine; hedefe yönelik ışınlama, düşük dozda yüksek kaliteli rekonstrüksiyon, veri temelli doz optimizasyonu ve kalite güvence eksenlerinde mümkün kıldığı görülmektedir.

7.2. Çalışan Güvenliği: Mesleki Doz İzleme Sistemleri

Radyasyonla çalışan personelin maruziyetinin doğru ve güvenilir biçimde izlenmesi, radyasyondan korunma programlarının temel bileşenlerinden biridir. Geleneksel çalışan dozimetri yaklaşımları çoğunlukla pasif kişisel dozimetrelere (TLD, OSL vb.) dayanmakta olup, enerji ve açı bağımlılığı, dedektör yanıtındaki belirsizlikler ve ölçümlerin genellikle retrospektif olarak değerlendirilmesi gibi sınırlılıklar içermektedir. YZ ve ML tabanlı yöntemler, bu problemleri aşarak çalışan dozunun daha doğru, öngörülebilir ve yönetilebilir olmasını sağlamaktadır.

Bu yaklaşımın önemli örneklerinden biri Hısıroğlu ve arkadaşlarının çalışmasıdır. Girişimsel kardiyolojiye özgü bir anjiyografi odası MC simülasyonları ile modellenmiş; personelin radyasyon kaynağına olan mesafesi, konumu, fiziksel özellikleri ve kullanılan X-ışını enerjisi gibi parametreler

kullanılarak kapsamlı bir doz veri seti oluşturulmuştur. Bu MC-tabanlı referans verilerle eğitilen gradyan güçlendirme, rastgele orman ve diğer ML algoritmalarının, personel dozunu yüksek doğrulukla tahmin edebildiği gösterilmiştir. Bu çalışma, YZ'nin çalışan doz yönetiminde yalnızca ölçüm değil, uygulama sırasındaki konum ve riskli senaryoların önceden belirlenmesi açısından da karar destek aracı olarak kullanılabileceğini göstermektedir (Hışiroğlu vd., 2025).

Buna tamamlayıcı olarak Pathan ve arkadaşları, kişisel dozimetri alanında YZ kullanımını ele alarak, klasik TLD sistemlerinin enerji ve açı bağımlılığından kaynaklanan belirsizliklerini azaltmayı hedeflemiştir. Çalışmada geliştirilen çok aşamalı ML yaklaşımı, $\text{CaSO}_4:\text{Dy}$ tabanlı TLD sinyallerinden foton enerjisinin sınıflandırılması, ortalama enerji tahmini ve kişisel doz eşdeğerinin $[\text{Hp}(10), \text{Hp}(0.07)]$ hesaplanmasını mümkün kılmıştır. Bu sayede geleneksel yöntemlere kıyasla doz tahminindeki sapmaların belirgin biçimde azaldığı ve YZ destekli kişisel dozimetri sistemlerinin rutin çalışan doz izlemede klinik olarak uygulanabilir olduğu gösterilmiştir (Pathan vd. 2024).

Elhaie ve çalışma arkadaşlarının derleme çalışması ise, çalışan doz yönetiminde YZ'nin daha geniş bir perspektifte değerlendirilmesi gerektiğini ortaya koymaktadır. Bu çalışmada ML tabanlı regresyon, sınıflandırma ve zaman serisi modellerinin; kişisel dozimetre verilerinin analizi, anormal maruziyetlerin otomatik tespiti ve çalışanlara ait toplam doz profillerinin çıkarılmasında etkin biçimde kullanılabileceği vurgulanmıştır (Elhaie vd., 2025).

Bu çalışmalar ile YZ'nin çalışan dozunun yönetiminde, kişisel dozimetri ölçüm doğruluğunun artırılması, doz tahmini ve anormal maruziyetlerin erken saptanması gibi amaçlar ile kullanılabileceğini ortaya koymuştur.

8. Doz İzleme Sistemleri ve Anomali Tespiti

İnsanların nükleer radyasyona maruziyetinin ana kaynakları doğal ve yapay radyasyon olmak üzere ikiye ayrılmaktadır. Yeryüzü, kozmik ışınlar ve doğal radionüklidlerin bozunumu nedeniyle her an doğal iyonizan radyasyona maruz kalmakta olup, bu maruziyet insanlara ulaşan toplam iyonizan radyasyon dozunun büyük bölümünü oluşturmaktadır ve görece sabit bir doz hızına sahiptir (Mettler vd., 2020). Buna karşın son on yıllarda tıbbi görüntüleme ve tedavi uygulamalarının yaygınlaşması, nükleer enerji üretimi, endüstriyel radyografi ve yapay radionüklidlerin kullanımı nedeniyle yapay radyasyon kaynaklı maruziyetler belirgin biçimde artmıştır. Bu bağlamda beta, X ve özellikle gama ışınları, insan yapımı radyasyonun başlıca bileşenleri olarak öne çıkmaktadır (Iha vd., 2021).

Radyasyondan korunma ve radyasyon güvenliği hem çalışanların hem de toplumun korunması açısından uzun süredir temel bir endişe alanı olmuştur. Bu nedenle radyasyon izleme sistemleri; endüstriyel tesislerde, hastanelerde, nükleer santrallerde ve acil durum senaryolarında önleyici ve müdahaleye yönelik kararların temelini oluşturmaktadır. Geleneksel radyasyon izleme yaklaşımları çoğunlukla sabit eşik değerlerine, manuel değerlendirmelere ve sınırlı sayıda ölçüm noktasına dayalıdır. Ancak karmaşık geometriler, değişken çevresel koşullar ve çoklu dedektörlerden elde edilen büyük veri hacimleri, bu yöntemlerin etkinliğini sınırlamaktadır.

Bu noktada YZ, radyasyon koruma alanında erken dönemlerden itibaren potansiyel bir çözüm olarak değerlendirilmiştir. YZ'nin radyasyon korumadaki ilk örneklerinden biri, Tan ve arkadaşları tarafından geliştirilen Radiation Advisor Expert System (RAES) olmuştur. RAES, radyasyon güvenliği konusunda karar desteği sağlamayı amaçlayan, kural-tabanlı bir uzman sistem olarak tasarlanmıştır. Sistem, tek seviyeli ve sınırlı karmaşıklığa sahip olmakla birlikte, kullanıcı dostu bir insan-makine arayüzü ile özellikle idari ve teknik personelin karar süreçlerini desteklemeyi hedeflemiştir. Yazarlar, bu çalışmayı radyasyon korumada AI kullanımının ilk adımlarından biri olarak tanımlamış ve gelecekte daha üst seviye, öğrenebilen sistemlere geçişin mümkün olduğunu vurgulamışlardır (Tan vd., 1989).

Günümüzde ise YZ veri ve öğrenmeye dayalı yaklaşımlar üzerinden radyasyon izleme alanında çok daha ileri uygulamalara ulaşmıştır. Bunun önemli bir örneği, Durbin ve arkadaşları tarafından geliştirilen **Gamma-ray Localization Aided with Machine-learning (GLAM)** yaklaşımıdır. Bu çalışmada, dört adet NaI(Tl) dedektörden oluşan bir dedektör dizisi kullanılarak, gama ışını yayan kaynakların konumunun k-en yakın komşu (k-NN) ML algoritması ile tahmin edilmesi amaçlanmıştır. GLAM sistemi, yalnızca toplam sayım oranlarını değil, aynı zamanda spektral özellikleri de giriş verisi olarak kullanarak daha yüksek doğruluk elde etmiştir. Simülasyon verileriyle eğitilen modelin, deneysel ölçümlerle uyumlu sonuçlar verebildiği; bir dakikalık ölçüm sürelerinde birkaç derecelik açısal hata ile kaynak lokalizasyonu yapabildiği gösterilmiştir (Durbin vd., 2022). Bu yaklaşım, YZ'nin çoklu dedektör verilerinden hızlı ve güvenilir kaynak tespiti yapabilme kapasitesini açık biçimde ortaya koymaktadır. Benzer şekilde, Fobar ve arkadaşları, nükleer arama ve güvenlik uygulamalarında kullanılan çoklu dedektör dizilerinde oluşan karmaşık yanıt fonksiyonlarını modellemek amacıyla zamansal evrişimli sinir ağlarını (TCN) kullanmıştır. Geliştirilen sistem, gama kaynağına yönelen birim vektörü yüksek doğrulukla tahmin edebilmiş ve arama sürelerinin önemli ölçüde azaltılabileceği gösterilmiştir (Fobar et al., 2022).

Çevresel alandaki radyasyon anomali kaynaklarının tespiti, radyasyon güvenliğinin sağlanmasında temel unsurlardan biridir. Ancak gerçek dünya koşullarında, arka plan radyasyon seviyelerinin sürekli değişkenlik göstermesi, algılama sürecinde düşük sinyal-gürültü oranlarına yol açabilmekte ve bu durum anomali oluşturan radyasyon kaynaklarının güvenilir biçimde tespit edilmesini zorlaştırmaktadır. Kontrollü bir laboratuvar ortamının dışında, arka plan gamma ışıını radyasyon seviyeleri dedeksiyon sistemleri için büyük ölçüde değişiklik gösterebilmektedir.

Çevresel gamma doz hızlarında anomali tespiti ile ilgili çalışmalar incelendiğinde, çalışmaların ölçüm altyapısından yapay zekâ tabanlı akıllı karar destek sistemlerine doğru evrildiği görülmektedir. Zigbee tabanlı kablosuz sensör ağlarıyla geliştirilen erken dönem çevresel radyasyon izleme sistemleri, gerçek zamanlı doz hızı ölçümü ve alarm üretimi açısından güçlü bir teknik altyapı sunsa da, anomali tespiti büyük ölçüde sabit eşiklere dayalı kalmış ve değişken doğal arka plan koşullarında yüksek yanlış alarm riski taşımaktadır (Bochen, 2022). Bu sınırlamayı aşmaya yönelik olarak geliştirilen YZ destekli erken uyarı yaklaşımları, çevresel gamma doz hızındaki artışların zaman serisi biçimini analiz ederek yağmur, rüzgâr ve radon yıkaması gibi çevresel etkilerden kaynaklanan yanlış alarmları gerçek radyolojik olaylardan ayırmayı hedeflemiş ve uzman bağımlılığını azaltmayı amaçlamıştır (Al saleh vd., 2020). Bununla birlikte, bu tür yöntemler çoğunlukla toplam doz hızı bilgisine dayanmakta ve spektral şekil değişimlerini sınırlı ölçüde kullanmaktadır. Büyük ölçekli ve gerçek saha koşullarında geliştirilen modern YZ yazılımları ise değişken arka plan koşullarında anomali tespitinin ancak büyük veri, alan uyarlaması ve sürekli öğrenme yaklaşımlarıyla güvenilir biçimde yapılabileceğini göstermiştir (Chen vd. 2025). Bu bağlamda ARAD (Autoencoder Radiation Anomaly Detection) modeli, çevresel radyasyon izleme alanında en bütüncül yaklaşımı sunarak, yalnızca arka plan gamma spektrumlarını öğrenen anomali tespiti gerçekleştirmekte; böylece önceden kaynak bilgisi gerektirmeden, değişimleri ve yağış kaynaklı radon artışlarının baskın olduğu dinamik çevresel koşullarda dahi düşük yanlış alarm oranlarıyla gerçek radyolojik anomalileri ayırt edebilmektedir (Ghawaly vd., 2022).

Sonuç olarak, doğal ve yapay kaynaklı iyonize radyasyona maruziyetin hem yaygınlığı hem de çeşitliliği, çevresel radyasyon izleme ve anomali tespitinin radyasyon güvenliği açısından kritik bir bileşen hâline geldiğini göstermektedir. Yapay zekâ (YZ) destekli sistemler hem çalışanların hem de toplumun korunması açısından radyasyonun konumu ve doz düzeylerini daha hassas biçimde belirleyebilmekte; bu veriler üzerinden anomali takibi gerçekleştirerek, maruziyetin halk sağlığını tehdit edebilecek seviyelere ulaşması durumunda erken uyarı mekanizmaları sağlayabilmektedir.

9. Sonuç

YZ, radyoterapide ölçüm, dozimetri ve kalite kontrol süreçlerini destekleyen tamamlayıcı bir araç olmanın ötesine geçerek, klinik iş akışlarını kolaylaştırıp, tedavi doğruluğunu artırma potansiyeline sahip stratejik bir bileşen hâline gelmiştir. Literatürdeki çalışmalar; YZ tabanlı modellerin cihaz performansını uzun dönemli ve sürekli izleyebildiğini, hastaya özgü kalite güvencesinde ölçüm gereksinimini azaltarak iş yükünü hafiflettiğini ve görüntü eşliğinde radyoterapide geometrik belirsizlikleri anlamlı ölçüde düşürdüğünü ortaya koymaktadır. DL destekli MC hızlandırma yaklaşımları ise yüksek doğruluk ve kısa hesaplama süresi dengesini mümkün kılarak adaptif ve gerçek zamanlı tedavi uygulamalarının önünü açmaktadır.

Radyasyon güvenliği alanında YZ, hasta ve çalışan dozlarının bireyselleştirilmiş biçimde izlenmesine, çevresel radyasyon seviyelerindeki anomalilerin erken tespitine ve öngörüye dayalı karar destek mekanizmalarının geliştirilmesine olanak sağlamaktadır.

Sonuç olarak, mevcut kanıtlar YZ ile radyoterapi ve radyasyon güvenliğinde ölçüm odaklı pasif yaklaşımlardan, veri odaklı, sürekli izleme ve öngörüye dayalı bir değişimin mümkün olduğunu göstermektedir. Gelecekte standartlaştırılmış doğrulama süreçleri, çok merkezli veri paylaşımı ve klinik geri besleme mekanizmalarının güçlenmesiyle birlikte, YZ tabanlı sistemlerin güvenilirliği artacak ve modern radyoterapi uygulamalarının ayrılmaz bir parçası hâline gelecektir.

Kaynaklar

- A. K. Jha, S. Mithun, V. Rangarajan, L. Wee, and A. Dekker, "Emerging role of artificial intelligence in nuclear medicine," *Nuclear Medicine Communications*, vol. 42, no. 6, pp. 592–601, 2021.
- Abhyankar, Y. S., Dev, S., Sarun, O. S., Saxena, A., Joshi, R., Darbari, H., ... & Buchsbaum, J. (2019). Monte Carlo Processing on a Chip (MCoC)-preliminary experiments toward the realization of optimal-hardware for TOPAS/Geant4 to drive discovery. *Physica Medica*, 64, 166-173.
- Al Saleh M, Finance B, Taher Y, Haque R, Jaber A, Bachir N. Introducing artificial intelligence to the radiation early warning system. *Environ Sci Pollut Res Int*. 2022 Feb;29(10):14036-14045. doi: 10.1007/s11356-021-16771-5. Epub 2021 Oct 2. PMID: 34601676.Chen, X., Wang, J., Qian, T. *et al*. An artificial intelligence cloud platform for OCT-based retinal anomalies screening system in real clinical environments. *npj Digit. Med*. 8, 559 (2025). <https://doi.org/10.1038/s41746-025-01959-7>
- American Association of Physicists in Medicine. AAPM's TG-46 Comprehensive QA for radiation oncology. *Med Phys* 1994;21:581–618.
- Bai, T., Wang, B., Nguyen, D., & Jiang, S. (2021). Deep dose plugin: towards real-time Monte Carlo dose calculation through a deep learning-based denoising algorithm. *Machine Learning: Science and Technology*, 2(2), 025033.
- Bakx, N., Bluemink, H., Hagelaar, E., van der Sangen, M., Theuws, J., & Hurkmans, C. (2021). Development and evaluation of radiotherapy deep learning dose prediction models for breast cancer. *Physics and imaging in radiation oncology*, 17, 65-70.
- Bang, J. Y., Hough, M., Hawes, R. H., & Varadarajulu, S. (2020). Use of artificial intelligence to reduce radiation exposure at fluoroscopy-guided endoscopic procedures. *Official journal of the American College of Gastroenterology | ACG*, 115(4), 555-561.
- Barragán-Montero, A., Javaid, U., Valdés, G., Nguyen, D., Desbordes, P., Macq, B., Willems, S., Vandewinckele, L., Holmström, M., Löfman, F., Michiels, S., Souris, K., Sterpin, E., & Lee, J. A. (2021). Artificial intelligence and machine learning for medical imaging: A technology review. *Physica medica: PM: an international journal devoted to the applications of physics to medicine and biology :6.6.Physics (AIFB)*, 83, 242–256. <https://doi.org/10.1016/j.ejmp.2021.04.016>.
- Berris T, Myronakis M, Stratakis J, Perisinakis K, Karantanis A, Damilakis J. Is deep learning-enabled real-time personalized CT dosimetry feasible using only patient images as input? *Phys Med*. 2024;122:103381. <https://doi.org/10.1016/j.ejmp.2024.103381>

- Bochen Zong. Design of Nuclear Radiation Monitoring System in Floor Exploration Based on Deep Learning Computational Intelligence and Neuroscience Volume 2022, Article ID 4351339, 10 pages <https://doi.org/10.1155/2022/4351339>
- Brualla L, Rodriguez M and Lallena A M 2017 Monte Carlo systems used for treatment planning and dose verification Strahlentherapie Onkologie 193 243–59
- Carlson JNK, Park JM, Park SY, Park JI, Choi Y, Ye SJ. A machine learning approach to the accurate prediction of multi-leaf collimator positional errors. Phys Med Biol 2016;61:2514–31. <https://doi.org/10.1088/0031-9155/61/6/2514>.
- Chan, M. F., Witztum, A., & Valdes, G. (2020). Integration of AI and machine learning in radiotherapyQA. Frontiers in artificial intelligence, 3. <https://doi.org/10.3389/frai.2020.577620>.
- Chen L, Liang X, Shen C, Jiang S, Wang J. Synthetic CT generation from CBCT images via deep learning. Med Phys 2020;47:1115-25.
- Chen, G., Cui, J., Qian, J., Zhu, J., Zhao, L., Luo, B., Cui, T., Zhong, L., Yang, F., Yang, G., Zhao, X., Zhou, Y., Geng, M., & Sun, J. (2022). Rapid Progress in Intelligent Radiotherapy and Future Implementation. Cancer investigation, 40(5), 425–436. <https://doi.org/10.1080/07357907.2022.2044842>.
- Chen, X., Men, K., Li, Y., Yi, J., & Dai, J. (2019). A feasibility study on an automated method to generate patient-specific dose distributions for radiotherapy using deep learning. Medical physics, 46(1), 56-64.
- Claessens, M., Oria, C. S., Brouwer, C. L., Ziemer, B. P., Scholey, J. E., Lin, H., Witztum, A., Morin, O., Naqa, I. E., Van Elmpt, W., & Verellen, D. (2022). Quality Assurance for AI-Based Applications in Radiation Therapy. Seminars in radiation oncology, 32(4), 421–431. <https://doi.org/10.1016/j.semradonc.2022.06.011>.
- Colvin, K. (2020) Artificial Intelligence and the Future of Radiography. EMJ Radiology, 1, 23-25. <https://doi.org/10.33590/emjradiol/20F0901>.
- Çakır, T. (2024). The Latest Innovative Approaches In Radiation Therapy.
- Dhont J, Verellen D, Mollaert I, Vanreusel V, Vandemeulebroucke J. RealDRR - Rendering of realistic digitally reconstructed radiographs using locally trained image-to-image translation. Radiother Oncol 2020;153:213-9.
- Durbin M, et al. Experimental tests of Gamma-ray Localization Aided with Machine-learning (GLAM) capabilities. Nuclear instruments & methods in physics research section a-accelerationers spectrometers detectors and accociated equipment 2022;1038(4):82.
- El Naqa I, Irrer J, Ritter TA, DeMarco J, Al-Hallaq H, Booth J, et al. Machine learning for automated quality assurance in radiotherapy: A proof of

- principle using EPID data description. *Med Phys* 2019;46:1914–21. <https://doi.org/10.1002/mp.13433>.
- Elhaie, M., Koozari, A., & Shahbazi-Gahrouei, D. (2025). Machine learning and neural network approaches for enhanced measuring and prediction of radiation doses. *Journal of Radiation Research and Applied Sciences*, 18(1), 101252.
- Elmahdy MS, Jagt T, Zinkstok RT, Qiao Y, Shahzad R, Sokooti H, Yousefi S, Incrocci L, Marijnen CAM, Hoogeman M, Staring M. Robust contour propagation using deep learning and image registration for online adaptive proton therapy of prostate cancer. *Med Phys* 2019;46:3329–43.
- EU - Directorate General for Energy. General guidelines on risk management in external beam radiotherapy. 2015.
- Ezzell G a., Burmeister JW, Dogan N, LoSasso TJ, Mechalakos JG, Mihailidis D, et al. IMRT commissioning: Multiple institution planning and dosimetry comparisons, a report from AAPM Task Group 119. *Med Phys* 2009;36:5359– 73. <https://doi.org/10.1118/1.3238104>.
- F. A. Mettler, M. Mahesh, M. Bhargavan-Chatfield et al., “Patient exposure from radiologic and nuclear medicine procedures in the United States: procedure volume and effective dose for the period 2006–2016,” *Radiology*, vol. 295, no. 2, pp. 418–427, 2020.
- Feng M, Valdes G, Dixit N, Solberg TD. Machine learning in radiation oncology: Opportunities, requirements, and needs. *Front Oncol* 2018;8:1–7. <https://doi.org/10.3389/fonc.2018.00110>.
- Fobar, D., Vanderlip, W. J., Koch, W., & Chapman, P. (2022). A machine learning approach to a multidetector array response function for nuclear search. *IEEE Transactions on Nuclear Science*, 69(8), 1939–1944.
- Fu Y, Wang T, Lei Y, Patel P, Jani AB, Curran WJ, Liu T, Yang X. Deformable MR-CBCT prostate registration using biomechanically constrained deep learning networks. *Med Phys* 2021;48:253–63.
- Gönültaş, L. E. V. E. N. T. (2022). *Tıbbi Radyasyon Fizikisi*. Akademisyen Kitabevi.
- Granville, D. A., Sutherland, J. G., Belec, J. G., and La Russa, D. J. (2019). Predicting VMAT patient-specific QA results using a support vector classifier trained on treatment plan characteristics and linac QC metrics. *Phys. Med. Biol.* 64:095017. doi: 10.1088/1361-6560/ab142c
- Gupta, R. V., Kalra, M. K., Ebrahimian, S., Primak, A., Bizzo, B., & Dreyer, K. J. (2022). *Complex relationship between artificial intelligence and CT radiation dose*. *Academic Radiology*, 29(11), 1709–1719.
- Hişiroğlu, K. A., Toker, O., Özşahin, M. T., & İçelli, O. (2025). Machine learning-based estimation of occupational radiation dose in interventional cardiology. *Radiation Protection Dosimetry*, ncaf064.

- Hirashima, H., Ono, T., Nakamura, M., Miyabe, Y., Mukumoto, N., Iramina, H., et al. (2020). Improvement of prediction and classification performance for gamma passing rate by using plan complexity and dosimetrics features. *Radiat. Oncol.* doi: 10.1016/j.radonc.2020.07.031. [Epub ahead of print].
- Hissoiny, S., Raaijmakers, A. J., Ozell, B., Després, P., & Raaymakers, B. W. (2011). Fast dose calculation in magnetic fields with GPUMCD. *Physics in Medicine & Biology*, 56(16), 5119.
- Huq MS, Fraass BA, Dunscombe PB, Gibbons JP, Ibbott GS, Mundt AJ, et al. The report of Task Group 100 of the AAPM: Application of risk analysis methods to radiation therapy quality management. *Med Phys* 2016;43:4078–13874. <https://doi.org/10.1118/1.2349696>.
- Hussein, M.; Heijmen, B.J.M.; Verellen, D.; Nisbet, A. (2018) Automation in intensity modulated radiotherapy treatment planning-A review of recent innovations. *Br. J. Radiol.*, 91, 20180270. <https://doi.org/10.1259/bjr.20180270>.
- Huynh, E., Hosny, A., Guthrie, C., Bitterman, D. S., Petit, S. F., Haas-Kogan, D. A., Kann, B., Aerts, H. J. W. L., & Mak, R. H. (2020). Artificial intelligence in radiation oncology. *Nature reviews. Clinical oncology*, 17(12), 771–781. <https://doi.org/10.1038/s41571-020-0417-8>.
- Interian, Y., Rideout, V., Kearney, V. P., Gennatas, E., Morin, O., Cheung, J., et al. (2018). Deep nets vs expert designed features in medical physics: An IMRT QA case study. *Med. Phys.* 45, 2672–2680. doi: 10.1002/mp.12890
- James M. Ghawaly, Andrew D. Nicholson, Daniel E. Archer, Michael J. Willis, Irakli Garishvili, Brandon Longmire, Andrew J. Rowe, Ian R. Stewart, Matthew T. Cook, Characterization of the Autoencoder Radiation Anomaly Detection (ARAD) model, *Engineering Applications of Artificial Intelligence*, Volume 111, 2022, 104761, ISSN 0952-1976, <https://doi.org/10.1016/j.engappai.2022.104761>.
- Jia, X., Gu, X., Graves, Y. J., Folkerts, M., & Jiang, S. B. (2011). GPU-based fast Monte Carlo simulation for radiotherapy dose calculation. *Physics in Medicine & Biology*, 56(22), 7017.
- Juan José Vilaragut, Rubén Ferro Fernández, Manuel Rodríguez Martí, Pedro Ortiz López, María Luisa Ramírez, Arturo Pérez Mulas, Marta Barrientos Montero, Fernando Somoano, José Miguel Delgado Rodríguez, Susana B. Papadópulos, Pedro Paulo Pereira Jr, Ramón JA. Probabilistic safety assessment (PSA) of the radiotherapy treatment process with an Electron Linear Accelerator (LINAC) for medical uses 2008:1–9.
- Kalet AM, Luk SMH, Phillips MH. Radiation therapy quality assurance tasks and tools: the many roles of machine learning. *Med Phys* 2020;47:e168–77. <https://doi.org/10.1002/mp.13445>.

- Kalet AM, Luk SMH, Phillips MH. Radiation therapy quality assurance tasks and tools: the many roles of machine learning. *Med Phys* 2020;47:e168–77. <https://doi.org/10.1002/mp.13445>.
- Kawamura, M., Kamomae, T., Yanagawa, M., Kamagata, K., Fujita, S., Ueda, D., Matsui, Y., Fushimi, Y., Fujioka, T., Nozaki, T., Yamada, A., Hirata, K., Ito, R., Fuji- ma, N., Tatsugami, E., Nakaura, T., Tsuboyama, T., & Naganawa, S. (2024). Revolutionizing radiation therapy: the role of AI in clinical practice. *Journal of radiation research*, 65(1), 1–9. <https://doi.org/10.1093/jrr/rrad090>.
- Kontaxis, C., Bol, G. H., Lagendijk, J. J. W., & Raaymakers, B. W. (2020). DeepDose: Towards a fast dose calculation engine for radiation therapy using deep learning. *Physics in Medicine & Biology*, 65(7), 075013.
- LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015;521:436-44
- Lee, A., Yau, C., Giles, M. B., Doucet, A., & Holmes, C. C. (2010). On the utility of graphics cards to perform massively parallel simulation of advanced Monte Carlo methods. *Journal of computational and graphical statistics*, 19(4), 769-789.
- Lee, M. S., Hwang, D., Kim, J. H., & Lee, J. S. (2019). Deep-dose: a voxel dose estimation method using deep convolutional neural network for personalized internal dosimetry. *Scientific reports*, 9(1), 10308.
- Li Q, Chan MF. Predictive time-series modeling using artificial neural networks for Linac beam symmetry: an empirical study. *Ann N Y Acad Sci* 2017;1387:84–94. <https://doi.org/10.1111/nyas.13215>.
- Li, J., Wang, L., Zhang, X., Liu, L., Li, J., Chan, M. F., et al. (2019b). Machine learning for patient-specific quality assurance of VMAT: prediction and classification accuracy. *Int. J. Rad. Oncol. Biol. Phys.* 105, 893–902. doi: 10.1016/j.ijrobp.2019.07.049
- Liu F, Yadav P, Baschnagel AM, McMillan AB. MR-based treatment planning in radiation therapy using a deep learning approach. *J Appl Clin Med Phys* 2019;20:105-14.
- Mahdavi SR, et al. Use of artificial neural network for pre- treatment verification of intensity modulation radiation therapy fields. *Br J Radiol.* 2019;92(1102):20190355. <https://doi.org/10.1259/bjr.20190355>.
- McNutt TR, Moore KL, Wu B, Wright JL. Use of big data for quality assurance in radiation therapy. *Semin Radiat Oncol* 2019;29:326–32. <https://doi.org/10.1016/j.semradonc.2019.05.006>.
- Meineke, A., Rubbert, C., Sawicki, L. M., Thomas, C., Klosterkemper, Y., Appel, E., ... Boos, J. (2021). Machine learning-based detection of CT examinations with dose optimization potential. *European Radiology*, 31, 3705–3713.

- Miften M, Olch A, Mihailidis D, Moran J, Pawlicki T, Molineu A, et al. Tolerance limits and methodologies for IMRT measurement-based verification QA: Recommendations of AAPM Task Group No. 218. *Med Phys* 2018;45:e53–83. <https://doi.org/10.1002/mp.12810>.
- Neph, R., Lyu, Q., Huang, Y., Yang, Y. M., & Sheng, K. (2021). DeepMC: a deep learning method for efficient Monte Carlo beamlet dose calculation by predictive denoising in magnetic resonance-guided radiotherapy. *Physics in Medicine & Biology*, 66(3), 035022.
- Ono, T., Hirashima, H., Iramina, H., Mukumoto, N., Miyabe, Y., Nakamura, M., et al. (2019). Prediction of dosimetric accuracy for VMAT plans using plan complexity parameters via machine learning. *Med. Phys.* 46:382303832. doi: 10.1002/mp.13669
- Osman, A. E., Maalej, N. M., & Jayesh, K. (2020). Prediction of the individual multileaf collimator positional deviations during dynamic IMRT delivery priori with artificial neural network. *Medical Physics*, 47(4), 1421-1430.
- Otto K. Volumetric modulated arc therapy: IMRT in a single gantry arc. *Med Phys* 2008;35:310-7.
- Pathan, M. S., Pradhan, S. M., Selvam, T. P., & Sapra, B. K. (2024). A multi-stage machine learning algorithm for estimating personal dose equivalent using thermoluminescent dosimeter. *Machine Learning: Science and Technology*, 5(1), 015011.
- Pillai M, Adapa K, Das SK, Mazur L, Dooley J, Marks LB, et al. Using artificial intelligence to improve the quality and safety of radiation therapy. *J Am Coll Radiol* 2019;16:1267–72. <https://doi.org/10.1016/j.jacr.2019.06.001>.
- Reader AJ, Pan B. AI for PET image reconstruction. *Br J Radiol.* 2023;96(1150):20230292.
- Ronneberger O, Fischer P and Brox T 2015 U-net: Convolutional networks for biomedical image segmentation International Conference on Medical Image Computing and Computer-assisted Intervention (Cham: Springer) pp 234–41
- Sadowski, B., Milewska, K., & Ginter, J. (2022). Machine Learning Based Prediction of Gamma Passing Rate for VMAT Radiotherapy Plans. *Journal of Personalized Medicine*, 12(12), 2071.
- Seco J and Verhaegen F 2021 Monte Carlo Techniques in Radiation Therapy: Applications to Dosimetry, Imaging, and Preclinical Radiotherapy (Boca Raton, FL: CRC Press)
- Seyyedi, N., Ghafari, A., Seyyedi, N., & Sheikhzadeh, P. (2024). Deep learning-based techniques for estimating high-quality full-dose positron emission tomography images from low-dose scans: a systematic review. *BMC Medical Imaging*, 24(1), 238.

- Shen L, Zhao W, Xing L. Patient-specific reconstruction of volumetric computed tomography images from a single projection view via deep learning. *Nat Biomed Eng* 2019;3:880-8.
- Simon, L., Robert, C., & Meyer, P. (2021). Artificial intelligence for quality assurance in radiotherapy. *Cancer radiotherapie : journal de la Societe francaise de radiotherapie oncologique*, 25(6-7), 623–626. <https://doi.org/10.1016/j.can-rad.2021.06.012>.
- Smilowitz JB, Das IJ, Feygelman V, Fraass BA, Kry SE, Marshall IR, et al. AAPM Medical Physics Practice Guideline 5.a.: Commissioning and QA of treatment planning dose calculations - megavoltage photon and electron beams. *J Appl Clin Med Phys* 2015;16:14–34.
- Staffurth J; Radiotherapy Development Board. A review of the clinical evidence for intensity-modulated radiotherapy. *Clin Oncol (R Coll Radiol)* 2010;22:643-57.
- Tan, C.L., Pang, C.M., Chan, Y.C. and Starkey, C. (1989) 'Applications of artificial intelligence in radiation protection', *International Journal of Computer Applications in Technology*, Vol. 2, No. 3, pp. 166- 170.
- Teo, P. T., Hwang, M. S., Shields, W., Kosterin, P., Jang, S. Y., Heron, D. E., ... & Huq, M. S. (2019). Application of TG-100 risk analysis methods to the acceptance testing and commissioning process of a Halcyon linear accelerator. *Medical physics*, 46(3), 1341-1354.
- Terpstra ML, Maspero M, d'Agata F, Stemkens B, Intven MPW, Lagendijk JJW, van den Berg CAT, Tijssen RHN. Deep learning-based image reconstruction and motion estimation from undersampled radial k-space for real-time MRI-guided radiotherapy. *Phys Med Biol* 2020;65:155015.
- Thompson, R. F., Valdes, G., Fuller, C. D., Carpenter, C. M., Morin, O., Aneja, S., Lindsay, W. D., Aerts, H. J. W. L., Agrimson, B., Deville, C., Jr, Rosenthal, S. A., Yu, J. B., & Thomas, C. R., Jr (2018). Artificial intelligence in radiation oncology: A specialty-wide disruptive transformation?. *Radiotherapy and oncology : journal of the European Society for Therapeutic Radiology and Oncology*, 129(3), 421–426.<https://doi.org/10.1016/j.radonc.2018.05.030>.
- Timmerman R, Xing L. Image Guided and Adaptive Radiation Therapy. Baltimore Lippincott Williams & Wilkins; 2009.
- Tomori, S., Kadoya, N., Takayama, Y., Kajikawa, T., Shima, K., Narazaki, K., et al. (2018). A deep learning-based prediction model for gamma evaluation in patient-specific quality assurance. *Med. Phys.* 45, 4055–4065. doi: 10.1002/mp.13112
- Tsironi F, Myronakis M, Stratakis J, Sotiropoulou V, Damilakis J. Organ dose prediction for patients undergoing radiotherapy CBCT chest examina-

- tions using artificial intelligence. *PhysMed*. 2024;119:103305. <https://doi.org/10.1016/j.cjmp.2024.103305>
- Valdes, G., Scheuermann, R., Hung, C. Y., Olszanski, A., Bellerive, M., and Solberg, T. D. (2016). A mathematical framework for virtual IMRT QA using machine learning. *Med. Phys.* 43, 4323–4334. doi: 10.1118/1.4953835
- van der Horst A, Wognum S, Dávila Fajardo R, de Jong R, van Hooft JE, Fockens P, van Tienhoven G, Bel A. Interfractional position variation of pancreatic tumors quantified using intratumoral fiducial markers and Daily cone beam computed tomography. *Int J Radiat Oncol BiolPhys* 2013;87:202-8.
- van Dijk RHW, Staut N, Wolfs CJA, Verhaegen F. A novel multichannel deep learning model for fast denoising of Monte Carlo dose calculations: preclinical applications. *Phys Med Biol*. 2022 Aug 8;67(16). doi: 10.1088/1361-6560/ac8390. PMID: 35938467.
- Vandewinckele, L., Claessens, M., Dinkla, A., Brouwer, C., Crijns, W., Verellen, D., & van Elmpt, W. (2020). Overview of artificial intelligence-based applications in radiotherapy: Recommendations for implementation and quality assurance. *Radiotherapy and oncology : journal of the European Society for Therapeutic Radiology and Oncology*, 153, 55–66.<https://doi.org/10.1016/j.radonc.2020.09.008>.
- Verellen D, De Ridder M, Linthout N, Tournel K, Soete G, Storme G. Innovations in image-guided radiotherapy. *Nat Rev Cancer* 2007;7:949-60.
- Wang, Y. R., Qu, L., Sheybani, N. D., Luo, X., Wang, J., Hawk, K. E., ... & Daldrup-Link, H. E. (2023). AI transformers for radiation dose reduction in serial whole-body PET scans. *Radiology: Artificial Intelligence*, 5(3), e220246.
- Wu B, Zhang P, Tsirakis B, Kanchaveli D, LoSasso T. Utilizing historical MLC performance data from trajectory logs and service reports to establish a proactive maintenance model for minimizing treatment disruptions. *Med Phys* 2019;46:475–83. <https://doi.org/10.1002/mp.13363>.
- Xia KJ, Yin HS, Wang JQ. A novel improved deep convolutional neural network model for medical image fusion. *Cluster Comput* 2019;22:1515-27.
- Xing L, Giger ML, Min JK. *Artificial Intelligence in Medicine: Technical Basis and Clinical Applications*. London, UK: Academic Press; 2020.
- Xing L, Thorndyke B, Schreibmann E, Yang Y, Li TE, Kim GY, Luxton G, Koong A. Overview of image-guided radiation therapy. *Med Dosim* 2006;31:91-112.
- Yang, X., Li, S., Shao, Q., Cao, Y., Yang, Z., & Zhao, Y. Q. (2022). Uncertainty-guided man-machine integrated patient-specific quality assurance. *Radiotherapy and oncology : journal of the European Society for The-*

- therapeutic Radiology and Oncology, 173, 1–9. <https://doi.org/10.1016/j.radonc.2022.05.016>.
- Zhao W, Shen L, Han B, Yang Y, Cheng K, Toesca DAS, Koong AC, Chang DT, Xing L. Markerless Pancreatic Tumor Target Localization Enabled By Deep Learning. *Int J Radiat Oncol Biol Phys* 2019;105:432-9.
- Zhao, W., Patil, I., Han, B., Yang, Y., Xing, L., & Schüler, E. (2020). Beam data modeling of linear accelerators (linacs) through machine learning and its potential applications in fast and robust linac commissioning and quality assurance. *Radiotherapy and Oncology*, 153, 122-129.
- Zhao, W., Shen, L., Islam, M. T., Qin, W., Zhang, Z., Liang, X., ... & Li, X. (2021). Artificial intelligence in image-guided radiotherapy: a review of treatment target localization. *Quantitative imaging in medicine and surgery*, 11(12), 4881.
- Ziegenhein, P., Kozin, I. N., Kamerling, C. P., & Oelfke, U. (2017). Towards real-time photon Monte Carlo dose calculation in the cloud. *Physics in Medicine & Biology*, 62(11), 4375.

Radyoterapi Tedavi Planlama Konturlamasında Yapay Zeka

Hikmettin Demir¹

Özet

Bu bölümde radyoterapi tedavi planlama sürecinde yapay zekâ (YZ) ve özellikle derin öğrenme (DL) tabanlı otomatik konturlama yaklaşımlarının hali hazırdaki durumu, klinik uygulamadaki potansiyelleri ve sınırlılıkları ele alınmaya çalışılmıştır. Radyasyon onkolojisinin multi disiplinli ve yüksek doğruluk gerektirmesi, hedef hacimlerin ve risk altındaki organların (OAR) doğru ve tutarlı şekilde konturlanmasını önemli hale getirmektedir. Geleneksel manuel konturlama süreçleri oldukça zaman alıcı, gözlemciye göre değişen ve klinik iş yükünü önemli derecede artırıcı süreçlerdir. Bundan dolayı, derin öğrenme tabanlı oto-segmentasyon yöntemleri, doğruluk ve verimlilik açısından önemli kolaylıklar sağlayarak klinik iş akışının iyileştirilmesine katkı sağlamaktadır. Ancak YZ tabanlı sistemlerin performansı; görüntüleme protokollerindeki olası farklılıkları, hastaya has özellikleri, kurumlara özgü klinik uygulamaları ve konturlama kılavuzları arasındaki uyumsuzlukları nedeniyle farklılık gösterebilmektedir. Ayrıca, yaygın olarak kullanılan geometrik değerlendirme metriklerinin klinik sonuçlarla sınırlı ilişki göstermesi, YZ çıktılarının dikkatli biçimde yorumlanmasını gerektirmektedir. Bu nedenle, YZ tabanlı oto-segmentasyon sistemlerinin kliniğe adaptasyonu, kapsamlı doğrulama, düzenli kalite kontrol (QA) süreçleri ve uzman eşliğinde, aşamalı bir bakış açısı gerektirmektedir.

1.GİRİŞ

Yapay zekâ (YZ), insan zekâsını yerine geçmek üzere tasarlanmış, veri odaklı bir ajandır. YZ kavramının, insanların zahmetli ve çok zaman alan görevleri yapmasına yardımcı olabilecek robot düşüncesinden doğduğu kabul edilmektedir. Son zamanlarda hem bilgisayar donanımları hem de yazılım alanlarındaki gelişmeler, insan katkısı olmaksızın belirli karmaşık görevlerde

1 Doç.Dr. Yüzüncü Yıl Üniversitesi, hikmettindemir@yyu.edu.tr, Orcid : 0000-0002-1171-4821

üstün performans ortaya koyabilen YZ ajanlarının geliştirilmesini mümkün kılmıştır. Buna paralel olarak, verinin artması ve bu verilerin paylaşılmasının kolaylaşması, makine öğrenmesi (ML) ve derin öğrenme (DL) yöntemleri aracılığıyla YZ'nin sürekli gelişimini teşvik etmiştir(Fu et al., 2021).

YZ'nin alt alanı olan makine öğrenimi (ML), verilerle eğitilen algoritmalar ve istatistiksel tekniklerle makinelerin yapay zekâya ulaşmasını sağlar; bu eğitim süreci, makine öğrenimi tarafından verilen kararları yönlendirir ve deneyim kazanıldıkça nihai çıktının iyileştirilmesine yardımcı olur(Nguyen et al., 2019). Görüntülerin otomatik segmentasyonuna yönelik denetimli ML yöntemleri, genellikle eğitim örnekleri üzerinden görüntüye ilişkin ön bilgileri bütünleştiren öngörücü bir modelin eğitilmesini ve ayarlanmasını kapsar. ML, daha önceki verileri incelemek ve analiz etmek için istatistiksel araçlardan yararlanır; görüntü temsilleri ise belirli bir segmentasyon görevine uyarlanmış, önceden tanımlanmış filtrelerden oluşturulur. ML teknikleri görüntü örnekleriyle daha verimli ve daha az karmaşık bir yapıya sahip olsa da, çoğu zaman derin öğrenme (DL) teknikleriyle karşılaştırıldığında doğruluk düzeyi aynı olmaz(Seo et al., 2020). DL, başlangıçta insan beyninin nöral öğrenmeyi taklit etmek üzere tasarlanmış, ML'nin bir alt kümesidir. ML'nin segmentasyon sürecinde işe yarar özelliklerin kullanıcı tarafından belirlenmesinin gerektiği durumunun aksine DL'de bu özellikler insan müdahalesi olmadan ağ tarafından belirlenir(Fu et al., 2021).

Radyasyon onkolojisi; tıp, biyoloji, fizik ve mühendislik gibi disiplinler arası uzmanlık gerektiren kanser tedavisi bölümüdür. Normal bir radyoterapi iş akışı; tıbbi görüntüleme, tanı, reçeteleme, simülasyon, konturlama, tedavi planlaması, tedavi kalite kontrol ve tedavi uygulamasından oluşur. Son yıllardaki teknolojik gelişmeler sayesinde radyoterapi uygulamaları giderek daha karmaşık hâle gelmiş ve insan-makine etkileşimlerinde bir bağımlılık ortaya çıkmıştır. Klinik işleyişte her adım, kendine özgü teknik zorlukları olan, oldukça uzmanlaşmış süreçler içerir. Bununla birlikte, radyasyon onkoloğu, tıbbi fizikçi, tıbbi dozimetrist ve radyoterapi teknikerinden oluşan geniş bir ekibin manuel veriye duyduğu ihtiyaç, hastaların sınırlı bir tedavi süreciyle sonuçlanmaktadır. Görüntü kılavuzluğunda radyoterapinin yaygınlaşması, kısa sürede analiz edilmesi gereken çok büyük miktarda görüntünün ortaya çıkmasında neden olmuştur. Ancak insanlar, zaman kısıtları nedeniyle geniş hacimli verileri inceleme ve analiz etme konusunda yeterli zamana sahip değildirler. Makinalar ise tekrar eden iş yüklerinin büyük bir kısmını insanlarla paylaşacak şekilde eğitilebilir ve buda hızlı ve nitelikli sağlık hizmeti kapasitesini artırabilir. Derin sinir ağlarının ortaya çıkışından bu yana, radyoterapinin farklı zorlukların üstesinden gelmek için çok sayıda yapay zekâ temelli yöntem önerilmiştir. YZ destekli radyoterapideki oldukça hızlı gelişmeler göz önüne

alındığında, radyoterapinin verimliliği ve etkinliği gelecekte uygulanacak akıllı otomasyon yöntemleri ile önemli ölçüde artırılabilir(Fu et al., 2021).

Tıp, kanser genetiği ve görüntüleme alanındaki ilerlemeler sonucunda sağlık profesyonellerinin yorumlaması gereken çok modellenli veri kaynaklarının ortaya çıkmasıyla, yapay zekâ bu verilerden yararlanmak için rol almaya başlamıştır(Howell, Corrado, & DeSalvo, 2024). Yapay zekâ, son dönemde hem endüstride hem de akademideki popüler kavramlardan biri hâline gelmiştir. Modern teknoloji terimi olarak bilinen YZ, başlangıçta insan gibi düşünüp davranabilen, fakat bunu yaparken rasyonelliği de koruyan bir kavram olarak algılanmıştır. Bilgisayar bilimi alanlarında YZ; üzerinden bilgi alan ve belirli hedeflere ulaşma olasılığını üst düzeye çıkarmak için gerekli eylemde bulunan algoritmaların ve sistemlerin incelenmesi olarak tanımlanmaktadır. Hesaplama parametreleri hızlarındaki artışlar ile veri toplama ve paylaşma kapasitelerinin genişlemesi sayesinde, özellikle derin öğrenmeye dayalı çok sayıda YZ tekniği ve algoritması son birkaç yıl içinde yayımlanmıştır. Bu tekniklerdeki hızlı patlamaların ardından, YZ yaşamımızın neredeyse her alanına irmiş ve yaşam biçimimizi hızla etkilemeye ve dönüştürmeye başlamıştır. Radyasyon onkolojisi alanında da YZ etkisi, radyoterapi klinik çalışma akışının çeşitli bileşenlerinde otomatik destek süreçleriyle temellenmiştir: hedef hacim ve doku segmentasyonu, tedavi planlaması, radyoterapi uygulamaları ve tedavi yanıtının değerlendirilmesi(Norvig & Russell, 1995; Poole, Mackworth, & Goebel, 1998; C. Wang, Zhu, Hong, & Zheng, 2019).

Radyoterapi tedavi planlaması, özellikle de intensity modulated radiotherapy (IMRT) gibi inverse tedavi planlamaları, tamamlanması saatler hatta günler kadar sürebilen zahmetli bir süreçtir. İş akışı, hedef hacim çakışması ve risk altındaki organlara (OAR) ilişkin kısıtlamalar dâhil olmak üzere dozometrik gereklilikler gibi aşamalarla başlar. Her bir olgunun özel gereksinimlerine göre bir planlamacı; tedavi radyasyon enerjisi, ışın sayısı, açıları gibi temel planlama parametreleri hakkında kararlar verir. En temel düzeyde kabul edilebilir bir planın oluşturulması görece hızlı olsa bile, bir tedavi planının iyileştirilmesi çok daha karmaşıktır ve çoğunlukla planlamacılar ile tedavi planlama sistemi (TPS) arasında çok sayıda tekrarlamalı işlemler gerektirir. Ayrıca, hekimler de ortaya çıkarılan ilk plan sonuçlarına göre tedavi planının iyileştirilmesi amacıyla planlamacılarla birçok kez etkileşimde bulunabilirler. Bu etkileşimlerin tekrar ve tekrar olabiliyor olması, önemli ölçüde insan emeği ve oldukça fazla zaman gerektirebilmektedir(C. Wang et al., 2019).

Yazılımlar sayesinde otomatik tedavi planlamaları (ATP), özellikle tedavi planlama sistemleri (TPS) ile yürütülen tekrarlı işlemler gibi insan etkileşimlerini genelde azaltarak tedavi planı oluşturma sürelerini önemli ölçüde

kısaltmışlardır. Böylece planlamacılar, bireysel olarak optimize edilmiş tedavi planlamaları için daha uygun doz dağılımını araştırmaya daha fazla zaman ayırarak daha faydalı sonuçlara ulaşabilmekteler. Ayrıca, artan verimlilik; daha yenilikçi tedavi planlama stratejileri, tedavi sürecinin izlenmesine yönelik yeni yöntemler ve tedavi uygulama aşamaları dâhil olmak üzere klinik uygulama süreçlerinde sistemsel değişimleri de mümkün kılabilir (Foy et al., 2017; Hansen et al., 2016; Mori, Kaneda, Hagiwara, Ishiguchi, & Ishiguchi, 2016; Zarepisheh et al., 2014).

Verimliliğin yanında, ATP tedavi plan kalitesinde ve hata oranlarında da iyileştirmeleri beraberinde getirmiştir. Geleneksel tedavi planlamaları, dozimetrik ve klinik aşamaları araştıran deneme-yanılma temelli bir süreç olduğundan, sonuç plan kalitesi hem planlamacının tecrübesine ve kabiliyetine hem de planlama için ayrılabilen zamana bağlıdır. Çeşitli hastalık bölgelerinde yapılan birçok ATP çalışması, manuel planlara kıyasla daha tutarlı bir tedavi planı kalitesi bildirmiştir. Bu nedenledir ki ATP, gelişmiş tedavi planlama uzmanlığını daha geniş ölçekte erişilebilir kılarak sağlık hizmetlerindeki eksiklikleri domine etme potansiyeline sahiptir (Boylan & Rowbottom, 2014; Hussein et al., 2016; Y. Wang, Heijmen, & Petit, 2017).

Bazı çalışmalar yapay zeka tarafından oluşturulan tedavi planlarının klinik olarak kabul edilebilir olduğunu bildirmiş olsa da, diğer bazı çalışmalarda kabul edilebilir kalite ve güvenliği sağlamak için ATP'nin temel düzeyde insan müdahalesi veya ayarlaması gerektiğini bildirmişler. Plan güvenliği ve kalitesi açısından insan parametresinin tedavi planlamasının merkezinde yer alması gerektiği açıkça ortadadır; ancak yapay zekâ temelli tedavi planlama algoritmalarının önemli hedeflerinden biri, tedavi planı kalitesini artırmaya katkı sunmaktır. Bu alanda birçok yeni yaklaşım içeren çalışmalar yapılmaktadır (Gintz et al., 2016; Speer et al., 2017).

2. Radyoterapi Tedavi Planlama Konturlamasında Yapay Zeka

Radyasyon onkolojisi klinik iş akışının temel aşamalarından biri, tedavisi planlanan hedef hacimlerin, belirli doz kısıtlamalarına sahip risk altındaki organlardan (OAR) grafiksel olarak ayrımı sürecidir. Bu süreç; OAR'lerin, gros tümör hacminin (GTV), klinik hedef hacminin (CTV) ve son aşamada planlanan hedef hacmin (PTV) üç boyutlu olarak tanımlanmasını içermektedir. Bu aşamaların hepsi, yapay zekâ tekniklerinin kullanılmasıyla etkin bir şekilde konturlanabilir veya en az fayda olarak bu teknikler tarafından desteklenebilir (Erdur et al., 2025).

İlk ortaya çıktıklarında oto-segmentasyon teknikleri büyük ölçüde yoğunluk analizleri, şekil modelleme ve atlas tabanlı yöntemler gibi geleneksel yöntemlere

dayanıyordu. Zamanında yenilikçi olmanın yanında, bu geleneksel yöntemler özellikle karmaşık anatomik yapı çeşitlilikleri ve farklı kanser türleri ile karşılaşıldığında doğruluk, verimlilik ve uyarlanabilir olmak açısından çeşitli zorluklarla karşılaşmıştır(Samarasinghe et al., 2021).

Derin öğrenme modellerinin, özellikle evrimsel sinir ağlarının (CNN'ler) ortaya çıkmasıyla oto-segmentasyon yaklaşımlarında belirgin bir yaklaşım değişimi yaşanmıştır. Çok katmanlı ileri beslemeli sinir ağları olarak CNN'ler, gizli katmanlar aracılığıyla düşük düzeyli görüntü özelliklerini ortaya çıkarabilmekte ve ilerleyen katmanlarda daha yüksek düzeyli özellikleri öğrenerek daha doğru ve güvenilir segmentasyon sonuçları elde edebilmektedir. Bu ilerleme, hassasiyetin daha da önem taşıdığı radyoterapi tedavi planlaması için son derece önemli bir gelişme olmuştur(Harrison et al., 2022; Men, Dai, & Li, 2017).

Derin öğrenme tabanlı modeller, radyoterapi planlamasının çeşitli aşamalarında (özellikle risk altındaki organların (OAR) ve klinik hedef hacimlerin (CTV) segmentasyonunda) önemli bir potansiyel olarak ortaya çıkmıştır. Bu modeller genellikle daha önceden incelenmiş, uzmanlar tarafından doğrulukları teyit edilmiş tedavi konturlarını kullanmak suretiyle geliştirilmekte ve çoğu OAR için klinik konturlara oldukça yakın sonuçlar ürettikleri doğrulanmıştır. Bununla birlikte, anatomik değişkenliği daha yüksek olan yapılarda segmentasyon doğruluğunun ise azaldığı gözlemlenmektedir ki bu durum bize, performansın iyileştirilmesi için daha kapsamlı eğitim verilerine veya daha yenilikçi eğitim yaklaşımlarına ihtiyaç olduğunu göstermektedir(Ibragimov & Xing, 2017; Wong, Huang, Giambattista, et al., 2021).

Bu derin öğrenme modellerinin klinik uygulama akışlarına entegrasyonu önemli bir aşama olarak karşımıza çıkmaktadır. Yapılan son çalışmalar, bu modellerin merkezi sinir sistemi, baş ve boyun, prostat ve rektum kanserleri dâhil olmak üzere bazı kanser türlerinde klinik iş akışlarında pratik olarak uygulanabildiğini ortaya koymuşlar. Bu entegrasyon, derin öğrenme modellerinin radyoterapi tedavi planlamasının verimliliğini tutarlılığını ve katkısını artırma potansiyelini göstermiş, aynı zamanda sürekli iyileştirme ve doğrulamanın önemini vurgulamıştır(Erdur et al., 2025; Korte et al., 2021; Wong, Huang, Wells, et al., 2021).

Yapay zekâ, özellikle de derin öğrenme tabanlı otomatik konturlama sistemleri, geleneksel otomatik yöntemlere kıyasla daha belirgin doğruluk artışları göstermiştir ve birçok kurum mevcut ticari YZ konturlama sistemlerini klinik işleyişe entegre edebilmek amacıyla değerlendirmeye başlamıştır. Kontur doğruluğunu analiz etmek için Dice benzerlik katsayısı (DSC) ve Hausdorff mesafesi (HD) gibi geometrik metrikler sıklıkla kullanılan parametrelerdir;

ancak bu metriklerin, konturların klinik olarak kabul edilebilirliği veya dozimetristik sonuçlarla güçlü bir ilişki göstermediği de bilinmektedir (Kawula et al., 2022; Rong et al., 2024).

YZ tabanlı yöntemler, kontur segmentasyonu için gerekli insan katkısını önemli ölçüde ortadan kaldırma potansiyelleri nedeniyle hızla dikkat çekmişlerdir. Üreticiler, çeşitli bağımsız YZ modülleri geliştirmiş veya YZ modüllerini klinik planlama araçlarına eklemlemiştir. Bu ticari platformların çoğu, daha önceden eğitilmiş organ-spesifik segmentasyon modelleri sunmasına rağmen, derin öğrenme ağ sistemleri, algoritmaların performansı ya da klinik uygulamadaki kısıtlılıkları ve zorlukları konusunda şeffaf görülmemektedirler. Radyoterapi alanında otomatik kontur segmentasyonu ile ilgili bilgisayar algoritmaları, çeşitli gelişim aşamalarından geçmiştir (Rong et al., 2023).

3. YZ tabanlı oto-segmentasyonun klinik açıdan değerlendirilmesi

3.1. Klinik değişkenliklere bağlı zorluklar ve sınırlılıklar

YZ tabanlı oto-segmentasyonun başarılı bir şekilde uygulanması, görüntü elde etme protokolleri, tedavi planlama süreçleri ve konturlama yönergeleri dâhil olmak üzere bütün klinik bileşenlerde standardizasyona büyük oranda bağlıdır. Bunun yanında, klinik iş akışının her aşamasında heterojenlik ve değişkenlik bulunabilmektedir (Rong et al., 2023).

3.2. Görüntü kalitesi ve edinim parametrelerindeki varyasyonlar

YZ tabanlı oto-segmentasyon çalışmalarının büyük çoğunluğu bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) verilerine odaklanmıştır. Görüntü kalitesindeki ve görüntü tarama parametrelerindeki değişkenlikler, YZ modellerinin performansını etkileyebilmektedir. Çoğu ticari model, standart uyum metrikleriyle doğrulanmıştır. Ancak yayımlanan performans sonuçları, her zaman geniş bir yelpazedeki klinik senaryolara uygulanabilir olmak durumunda olmayabilir. Örneğin, tedavi planlaması için genellikle kontrastsız BT görüntüleri kullanılırken; lenf nodları, damar yapıları ve organların daha iyi görselleştirilmesi için kullanılan kontrastlı BT görüntüleri hedef hacim ve organ konturlamaları için tercih edilmektedir. Çoğu zaman, ticari YZ modellerinin kontrastlı BT görüntüleri kullanıp kullanmadığı açıkça belirtilmemektedir. Bu nedenle, kontrastlı BT görüntülerinin verilerinin elde edilmesinde, model oluşturma ve doğrulama aşamalarında, klinik değerlendirme süreçlerinde ve model temelli konturlamaya olan direk veya dolaylı katkılarına ne zaman ve nasıl ele alınması gerektiği dikkate alınmalıdır (Kavur et al., 2021; Rister, Yi, Shivakumar, Nobashi, & Rubin, 2020).

MRG tabanlı oto-segmentasyon ise daha da zordur; çünkü MRG taramaları aynı kurum içinde iken bile kullanılan görüntüleme sekanslarına bağlı olarak çok daha yüksek düzeyde değişkenlik gösterebilmektedir. Bu nedenle, ideal sonuçlar elde edebilmek için oto-segmentasyon modelleri kapsamlı biçimde doğrulanmalı ve kurumun klinik uygulamalarını yansıtan kurum, özel bir veri seti ile yeniden eğitilmeli veya en azından ince ayar (fine-tuning) yapılmalıdır [99]. Bazı ticari YZ ürünlerinin üreticilerinin eğitim veri setine ilişkin detaylı bir açıklama (kullanılan görüntüleme modalitesi, olgu sayısı ve kontur kalitesi dâhil olmak üzere) sunmaları önerilmektedir. Böylece son kullanıcı durumundakiler, kendi kurumlarının görüntü veri özellikleri ile üreticilerin kullandığı veri setleri arasındaki potansiyel farklılıkları ile ilgili daha iyi bilgi sahibi olabilirler (Rister et al., 2020; Tajbakhsh et al., 2016).

3.3. Kurumlara özgü klinik protokollerdeki ve hasta özelliklerindeki farklılıklar

Homojen görüntüleme protokolleri ve tarama parametreleri temin edilse bile, kurum içi ve kurumlar arası immobilizasyon pozisyonlam, hastanın kurulum aksesuarları ve/veya immobilizasyon cihazları (örneğin kompresyonlu veya kompresyonsuz) gibi değişkenlikler nedeniyle yapay zekâ algoritmalarının genellenmesi zordur. Klinikler arası farklılıklar, hasta popülasyonlarının istenen düzeyde eşleşmemesi durumunda daha da belirgin hâle gelebilir (örneğin, vücut kitle indekslerindeki farklılıkları, implantlı hasta oranları gibi) (Guy, Weiss, & Rosu-Bubulac, 2020; Men et al., 2019).

YZ modellerinin klinik adaptasyonu, kesin (definitive) tedavi ile postoperatif olgular, organ boyutu (mesane boşluğu, doluluğu), rektal balon ve eksternal cihazların (abdominal kompresyon, hastaya has boluslar) kullanımı gibi geniş bir klinik senaryo çeşitliliğini hesaba katmalıdır. Yakın zamanda yapılan bir çalışmada, klinik veriler ile bilgilendirilmiş bir YZ modelinden elde edilen 115 prostat hastasına ait segmentasyon sonuçları analiz edilmiş ve nadir görülen klinik durumlarda çok sayıda hata modu saptanmıştır. Bunlara örnek olarak, kalça protezi, daha önceki brakiterapiden kaynaklı izler, rektal balon içindeki hava ve fazla dolu mesane gösterilebilir (Duan et al., 2023). Bu gibi nedenlerden dolayı, klinik kullanıcıların bu tür olası klinik hata senaryolarını hesaba katması veya mümkünse YZ modellerini bu özel durumlar için tekrar eğitmeleri önerilmektedir.

3.4. Konturlama stilleri ve kılavuzlarındaki farklılıklar

Geliştirilen derin öğrenme (DL) modellerinin, farklı kurumlara veya hatta farklı hekimlere ait verilere uygulandığında performans kaybı yaşayabileceği gösterilmiştir; bunun temel nedeni ise konturlama stilleri veya kılavuzları

arasındaki farklılıklardır(Balagopal et al., 2021). Üretici firmalar tarafından eğitilen modellerin, kurum içi uzmanlardan, sözleşmeli kullanıcılardan veya halka açık veri kaynaklarından elde edilen geniş çeşitlilikte eğitim veri setlerini içerdiği iddia edilmektedir. Fakat bu durum, eğitimde kullanılan konturların kökenine bağlı olarak, modelin organ konturlarını nasıl segmentlediğinde bilinmeyen çeşitliliklerin ortaya çıkmasına neden olabilir.

Örneğin, farklı YZ modellerince üretilen oral kavite, beyin sapı ve kalp konturlarında, özellikle oral kavite konturlarında kayda değer farklılıklar göstermektedir. Bu farklılıklar ağız boşluğundaki hava hacminin kontura dahil edilme oranı ve kaudal sınırın belirlenmesi açısından dikkat çekicidir. Beyin sapı ve kalp konturlarında da bu organların sınırlarında önemli farklılıklar görülmektedir. Bu varyasyonlara katkı eğitim veri setlerinin oluşturulmasında kullanılan konturlama kılavuzlarındaki farklılıklardan kaynaklandığı açıktır. Yapılan sistematik bir derleme, 2000 yılından bu yana radyoterapi konturlama kılavuzlarıyla ilgili bir çok kılavuzun yayımlandığını, bunların ise az bir kısmının klinik çalışmalar için geliştirildiğini ve zaman içinde de artan bir eğilim gösterdiğini ortaya koymuştur(Lin et al., 2020). Bu nedenledir ki klinik çalışmaların protokollerinde uzlaşıya dayalı kılavuzların tercih edilmesi önerilmektedir. Bunun yanında, klinik bir çalışma kapsamındaki kurumların, YZ modellerini uygulamaya başlamadan konturlama kılavuzlarına uyumu değerlendirmeleri yapmaları gerekmektedir.

3.5. Uygulama Aşamaları ve QA

Ticari YZ tabanlı bir modelin klinik uygulamaya geçirilmesi; dayanıklılık, veri heterojenliği, klinik uygulamalardaki farklılıklar ve gözlemciler arası yorum farklılıkları gibi çeşitli engellerle karşılaşılabilir(Balagopal et al., 2021; Caravatta et al., 2014; Simpson et al., 2019; Udupa et al., 2022; Wong et al., 2020). Bazı ticari modellerce üretilen konturların diğerlerine kıyasla daha düşük nitelikte olabilir; ancak bu durum, söz konusu modellerin her klinik olgu için yetersiz olduğu anlamına gelmez. Genellenebilir olma eksikliği çok faktörlü bir sorundur ve genellikle eğitim veri setlerindeki kısmi farklılıklardan kaynaklanmaktadır; buna görüntü kontrastı, tarama protokollerindeki parametreler, hasta konumlandırma yöntemi ve immobilizasyon yöntemleri gibi faktörler dahildir. Bundan dolayı, bir YZ modelinin klinik veya kalite kontrol amacıyla kullanmadan önce bazı hususları dikkate almak gerekir. Bunlar; yapay zeka modelinin kapsamlı şekilde değerlendirilmesi ve uygun bir şekilde uygulamaya konulması, var olan planlama iş akışına entegrasyonunun sağlanması, vakaya özgü arızaların erken tespiti için düzenli kalite kontrol programlarının kurulmasıdır(Claessens, Oria, et al., 2022; Vandewinckele et al., 2020). Güvenilir bir klinik uygulama için, model performansına, klinik ihtiyaçlara ve hekime dayalı kabul

kriterlerinin benimsenmesi gerekmektedir. Sistemin uygulama süreci, tüm paydaşların katılımıyla tekrarlamalı olmalıdır(Duan et al., 2023). YZ tabanlı oto-segmentasyon modellerinin klinik uygulamada devreye alınması, çeşitli zorluklar ve sınırlılıklar dikkate alınarak aşamalı bir şekilde yürütülmelidir. Birinci aşamada, farklı anatomik bölgelerden geriye dönük olarak belirlenmiş bir hasta kohortu üzerinde manuel ve model tarafından oluşturulan konturların bire bir karşılaştırılması şeklinde olabilir. Bu bize, özellikle tedavi planlaması sonuçlarını etkileyebilecek ayrıntıların bulunduğu bölgeler için model segmentasyonunun dikkatle değerlendirilmesini sağlar. Böylece, hekimlerin ve planlamacıların yayımlanmış değerlendirme metriklerini modelin görsel ve geometrik sonuçlar ile ilişkilendirmelerine imkan verir. Gözlemciler arası veya gözlemci içi değerlendirme çalışmaları, model performansını değerlendirirken başvurulabilecek bir başlangıç durumu sağlanabilir. Son kullanıcılar model performansından emin olduktan sonra, YZ tabanlı modellerin OAR oto-segmentasyonu için prospektif açıdan kullanılması uygun bir başlangıç olabilir. Bu durumda, oluşturulan konturların kontrol edilmesi, gerektiğinde düzenlenmesi ve dozimetristler ve/veya hekimler tarafından teyit edilmesi gerekmektedir(Wong et al., 2020).

Güvenilir bir YZ modelinin olmadığı durumda, manuel segmentasyonların kullanılmasına devam edilecektir. Fakat bir YZ modeli yeniden kullanılmaya başlansa bile, özellikle erken benimseme aşamalarında ve/veya ideal olmayan görüntülerde, YZ tarafından oluşturulan konturların gözden geçirilmesi ve düzeltilmesi esnasında dikkatli olmak gerekir. Oto-segmentasyonun kalite kontrolü (QA), duruma göre QA ve rutin QA modelden oluşur(Claessens, Oria, et al., 2022; Vandewinckele et al., 2020). Olguya özgü QA, oto-segmentasyon güvenilirliğini teyit etmek ve gerektiğinde düzeltmek için gerçekleştirilen işlemleri içerir. Literatürde istatistiksel tabanlı bazı yöntemler, makine öğrenimi modelleri ve derin öğrenme modellerine bağlı otomatik QA araçları geliştirilmiştir. Fakat bu araçlar olguya has QA'nın manuel olarak yapılmasının yerini tutmaz(Altman et al., 2015; Chen et al., 2020; Claessens, Vanreusel, et al., 2022). Rutin model QA ise modelin geçerli ve öngörüldüğü şekilde dayanıklı olup olmadığının periyodik olarak kontrol edilmesini amaçlar. Doğrulanmış bir YZ modeli, klinik bir takım senaryo değişkenlikleri nedeniyle geçersiz duruma düşebilir. Bu nedenle, oto-segmentasyonun model tarafından oluşturulmuş primer sonuçları ile sonradan düzenlenmiş konturlar arasındaki nicel ve nitel farklılıkların periyodik olarak değerlendirilmesi ve uygulama aşamasında tanımlanan başlangıç verileri ile karşılaştırılmalıdır. Bununla beraber, süreç boyunca bir hata modu listesi oluşturmak ve bunu da ilgili vakalarda kontur kalitesini teyit etme sırasında kullanmak gerekir. Klinisyenler ve diğer paydaşların, YZ modelinin kısıtlılıkları konusunda yeterince bilgilendirilmiş ve

eğitilmiş olmaları önemlidir. Klinik ekip, konturların son halinin klinik olarak uygunluğunu sağlamak amacıyla ihtiyaç duyulduğunda ek düzenlemeler ve değerlendirmeler için hazır olmalıdır(Rong et al., 2023).

4. Sonuç

Yapay zekâ ve derin öğrenme tabanlı otomatik konturlama yöntemleri, radyoterapi tedavi planlamasında verimliliği artırmada, gözlemciye bağlı değişiklikleri azaltma ve klinik iş yükünü hafifletme açısından güçlü bir potansiyele sahiptirler. Özellikle kritik organ ve hedef hacim segmentasyonunda elde edilen sonuçlar, YZ destekli yaklaşımların geleneksel yöntemlere göre daha tutarlı ve zaman açısından avantajlı olduğunu göstermektedir. Bununla birlikte, bu teknolojilerin klinik uygulamalarda tamamen otonom bir çözüm olarak sunulması şimdilik mümkün görülmemektedir.

YZ modellerinin genellenebilirliği; görüntüleme kalitesi, hasta popülasyonundaki farklılıklar, klinik protokoller ve konturlamadan kaynaklı farklılıklar gibi çok sayıda sebepten etkilenmektedir. Bu durum, YZ tabanlı oto-segmentasyonun mutlaka insan gözetiminde kullanılmasını ve klinik karar destek aracı olarak düşünülmesi gerekir. Güvenli ve sürdürülebilir bir klinik entegrasyon için, modele has değerlendirme, kuruma özel doğrulama çalışmaları ve rutin kalite kontrol programlarının sistematik biçimde uygulanması oldukça önem taşımaktadır.

Sonuç olarak, yapay zekâ destekli oto-segmentasyon sistemleri radyoterapi klinik iş akışında önemli bir rol üstlenme potansiyeline sahip olmakla birlikte, bu potansiyelin efektif ve güvenli hayata geçirilebilmesi; klinik uzmanlık, belli standartlara yaklaşmış protokoller ve sürekli kalite kontrol süreçleri ile desteklenen bir insan makine iş birliğine bağlıdır.

Kaynaklar

- Altman, M., Kavanaugh, J., Wooten, H., Green, O., DeWees, T., Gay, H., . . . Mutic, S. (2015). A framework for automated contour quality assurance in radiation therapy including adaptive techniques. *Physics in Medicine & Biology*, 60(13), 5199.
- Balagopal, A., Morgan, H., Dohopolski, M., Timmerman, R., Shan, J., Heitjan, D. F., . . . Garant, A. (2021). Psa-net: Deep learning-based physician style-aware segmentation network for postoperative prostate cancer clinical target volumes. *Artificial Intelligence in Medicine*, 121, 102195.
- Boylan, C., & Rowbottom, C. (2014). A bias-free, automated planning tool for technique comparison in radiotherapy-application to nasopharyngeal carcinoma treatments. *Journal of Applied Clinical Medical Physics*, 15(1), 213-225.
- Caravatta, L., Macchia, G., Mattiucci, G. C., Sainato, A., Cernusco, N. L., Mantello, G., . . . Boz, G. (2014). Inter-observer variability of clinical target volume delineation in radiotherapy treatment of pancreatic cancer: a multi-institutional contouring experience. *Radiation Oncology*, 9(1), 198.
- Chen, X., Men, K., Chen, B., Tang, Y., Zhang, T., Wang, S., . . . Dai, J. (2020). CNN-based quality assurance for automatic segmentation of breast cancer in radiotherapy. *Frontiers in oncology*, 10, 524.
- Claessens, M., Oria, C. S., Brouwer, C. L., Ziemer, B. P., Scholey, J. E., Lin, H., . . . Van Elmpt, W. (2022). *Quality assurance for AI-based applications in radiation therapy*. Paper presented at the Seminars in radiation oncology.
- Claessens, M., Vanreusel, V., De Kerf, G., Mollaert, I., Löfman, F., Gooding, M. J., . . . Verellen, D. (2022). Machine learning-based detection of aberrant deep learning segmentations of target and organs at risk for prostate radiotherapy using a secondary segmentation algorithm. *Physics in Medicine & Biology*, 67(11), 115014.
- Duan, J., Vargas, C. E., Yu, N. Y., Laughlin, B. S., Toesca, D. S., Keole, S., . . . Feng, X. (2023). Incremental retraining, clinical implementation, and acceptance rate of deep learning auto-segmentation for male pelvis in a multiuser environment. *Medical physics*, 50(7), 4079-4091.
- Erdur, A. C., Rusche, D., Scholz, D., Kiechle, J., Fischer, S., Llorián-Salvador, Ó., . . . Peeken, J. C. (2025). Deep learning for autosegmentation for radiotherapy treatment planning: State-of-the-art and novel perspectives. *Strahlentherapie und Onkologie*, 201(3), 236-254. doi:10.1007/s00066-024-02262-2
- Foy, J. J., Marsh, R., Ten Haken, R. K., Young, K. C., Schipper, M., Sun, Y., . . . Matuszak, M. M. (2017). An analysis of knowledge-based planning for stereotactic body radiation therapy of the spine. *Practical radiation oncology*, 7(5), e355-e360.

- Fu, Y., Zhang, H., Morris, E. D., Glide-Hurst, C. K., Pai, S., Traverso, A., . . . Shen, C. (2021). Artificial intelligence in radiation therapy. *IEEE transactions on radiation and plasma medical sciences*, 6(2), 158-181.
- Gintz, D., Latifi, K., Caudell, J., Nelms, B., Zhang, G., Moros, E., & Feygelman, V. (2016). Initial evaluation of automated treatment planning software. *Journal of Applied Clinical Medical Physics*, 17(3), 331-346.
- Guy, C. L., Weiss, E., & Rosu-Bubulac, M. (2020). Characterization of respiration-induced motion in prone versus supine patient positioning for thoracic radiation therapy. *Advances in Radiation Oncology*, 5(3), 466-472.
- Hansen, C. R., Bertelsen, A., Hazell, I., Zukauskaitė, R., Gyldenkerne, N., Johansen, J., . . . Brink, C. (2016). Automatic treatment planning improves the clinical quality of head and neck cancer treatment plans. *Clinical and translational radiation oncology*, 1, 2-8.
- Harrison, K., Pullen, H., Welsh, C., Oktay, O., Alvarez-Valle, J., & Jena, R. (2022). Machine learning for auto-segmentation in radiotherapy planning. *Clinical Oncology*, 34(2), 74-88.
- Howell, M. D., Corrado, G. S., & DeSalvo, K. B. (2024). Three epochs of artificial intelligence in health care. *Jama*, 331(3), 242-244.
- Hussein, M., South, C. P., Barry, M. A., Adams, E. J., Jordan, T. J., Stewart, A. J., & Nisbet, A. (2016). Clinical validation and benchmarking of knowledge-based IMRT and VMAT treatment planning in pelvic anatomy. *Radiation Therapy and Oncology*, 120(3), 473-479.
- Ibragimov, B., & Xing, L. (2017). Segmentation of organs-at-risks in head and neck CT images using convolutional neural networks. *Medical physics*, 44(2), 547-557.
- Kavur, A. E., Gezer, N. S., Barış, M., Aslan, S., Conze, P.-H., Groza, V., . . . Özkan, S. (2021). CHAOS challenge-combined (CT-MR) healthy abdominal organ segmentation. *Medical image analysis*, 69, 101950.
- Kawula, M., Purice, D., Li, M., Vivar, G., Ahmadi, S.-A., Parodi, K., . . . Kurz, C. (2022). Dosimetric impact of deep learning-based CT auto-segmentation on radiation therapy treatment planning for prostate cancer. *Radiation Oncology*, 17(1), 21.
- Korte, J. C., Hardcastle, N., Ng, S. P., Clark, B., Kron, T., & Jackson, P. (2021). Cascaded deep learning-based auto-segmentation for head and neck cancer patients: organs at risk on T2-weighted magnetic resonance imaging. *Medical physics*, 48(12), 7757-7772.
- Lin, D., Lapen, K., Sherer, M. V., Kantor, J., Zhang, Z., Boyce, L. M., . . . Gillespie, E. F. (2020). A systematic review of contouring guidelines in radiation oncology: Analysis of frequency, methodology, and delivery of consensus recommendations. *International Journal of Radiation Oncology* Biology* Physics*, 107(4), 827-835.

- Men, K., Boimel, P., Janopaul-Naylor, J., Cheng, C., Zhong, H., Huang, M., . . . Ben-Josef, E. (2019). A study of positioning orientation effect on segmentation accuracy using convolutional neural networks for rectal cancer. *Journal of Applied Clinical Medical Physics*, 20(1), 110-117.
- Men, K., Dai, J., & Li, Y. (2017). Automatic segmentation of the clinical target volume and organs at risk in the planning CT for rectal cancer using deep dilated convolutional neural networks. *Medical physics*, 44(12), 6377-6389.
- Mori, Y., Kaneda, N., Hagiwara, M., Ishiguchi, T., & Ishiguchi, T. (2016). Dosimetric study of automatic brain metastases planning in comparison with conventional multi-isocenter dynamic conformal arc therapy and gamma knife radiosurgery for multiple brain metastases. *Cureus*, 8(11).
- Nguyen, G., Dlugolinsky, S., Bobák, M., Tran, V., Lopez Garcia, A., Heredia, I., . . . Hluchý, L. (2019). Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*, 52(1), 77-124.
- Norvig, P., & Russell, S. J. (1995). *Artificial intelligence a modern approach*: Prentice hall.
- Poole, D., Mackworth, A., & Goebel, R. (1998). Computational intelligence and knowledge. *Computational intelligence: a logical approach*, 1(1), 1-22.
- Rister, B., Yi, D., Shivakumar, K., Nobashi, T., & Rubin, D. L. (2020). CT-ORG, a new dataset for multiple organ segmentation in computed tomography. *Scientific Data*, 7(1), 381.
- Rong, Y., Chen, Q., Fu, Y., Yang, X., Al-Hallaq, H. A., Wu, Q. J., . . . Latifi, K. (2023). NRG Oncology assessment on AI deep-learning based auto-segmentation for radiotherapy: current development, clinical consideration, and future direction. *International journal of radiation oncology, biology, physics*, 119(1), 261.
- Rong, Y., Chen, Q., Fu, Y., Yang, X., Al-Hallaq, H. A., Wu, Q. J., . . . Latifi, K. (2024). NRG oncology assessment of artificial intelligence deep learning-based auto-segmentation for radiation therapy: current developments, clinical considerations, and future directions. *International Journal of Radiation Oncology* Biology* Physics*, 119(1), 261-280.
- Samarasinghe, G., Jameson, M., Vinod, S., Field, M., Dowling, J., Sowmya, A., & Holloway, L. (2021). Deep learning for segmentation in radiation therapy planning: a review. *Journal of Medical Imaging and Radiation Oncology*, 65(5), 578-595.
- Seo, H., Badii Khuzani, M., Vasudevan, V., Huang, C., Ren, H., Xiao, R., . . . Xing, L. (2020). Machine learning techniques for biomedical image segmentation: an overview of technical aspects and introduction to state-of-art applications. *Medical physics*, 47(5), e148-e167.

- Simpson, A. L., Antonelli, M., Bakas, S., Bilello, M., Farahani, K., Van Ginneken, B., . . . Menze, B. (2019). A large annotated medical image dataset for the development and evaluation of segmentation algorithms. *arXiv preprint arXiv:1902.09063*.
- Speer, S., Klein, A., Kober, L., Weiss, A., Yohannes, I., & Bert, C. (2017). Automation of radiation treatment planning: evaluation of head and neck cancer patient plans created by the Pinnacle3 scripting and auto-planning functions. *Strahlentherapie und Onkologie*, 193(8), 656-665.
- Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2016). Convolutional neural networks for medical image analysis: Full training or fine tuning? *IEEE transactions on medical imaging*, 35(5), 1299-1312.
- Udupa, J. K., Liu, T., Jin, C., Zhao, L., Odhner, D., Tong, Y., . . . Kotia, T. (2022). Combining natural and artificial intelligence for robust automatic anatomy segmentation: Application in neck and thorax auto-contouring. *Medical physics*, 49(11), 7118-7149.
- Vandewinckele, L., Claessens, M., Dinkla, A., Brouwer, C., Crijns, W., Verellen, D., & van Elmpt, W. (2020). Overview of artificial intelligence-based applications in radiotherapy: Recommendations for implementation and quality assurance. *Radiotherapy and Oncology*, 153, 55-66.
- Wang, C., Zhu, X., Hong, J. C., & Zheng, D. (2019). Artificial intelligence in radiotherapy treatment planning: present and future. *Technology in Cancer Research & Treatment*, 18, 1533033819873922.
- Wang, Y., Heijmen, B. J., & Petit, S. F. (2017). Prospective clinical validation of independent DVH prediction for plan QA in automatic treatment planning for prostate cancer patients. *Radiotherapy and Oncology*, 125(3), 500-506.
- Wong, J., Fong, A., McVicar, N., Smith, S., Giambattista, J., Wells, D., . . . Alexander, A. (2020). Comparing deep learning-based auto-segmentation of organs at risk and clinical target volumes to expert inter-observer variability in radiotherapy planning. *Radiotherapy and Oncology*, 144, 152-158.
- Wong, J., Huang, V., Giambattista, J. A., Teke, T., Kolbeck, C., Giambattista, J., & Atrchian, S. (2021). Training and validation of deep learning-based auto-segmentation models for lung stereotactic ablative radiotherapy using retrospective radiotherapy planning contours. *Frontiers in oncology*, 11, 626499.
- Wong, J., Huang, V., Wells, D., Giambattista, J., Giambattista, J., Kolbeck, C., . . . Alexander, A. (2021). Implementation of deep learning-based auto-segmentation for radiotherapy planning structures: a workflow study at two cancer centers. *Radiation Oncology*, 16(1), 101.

- Zarepisheh, M., Long, T., Li, N., Tian, Z., Romeijn, H. E., Jia, X., & Jiang, S. B. (2014). A DVH-guided IMRT optimization algorithm for automatic treatment planning and adaptive radiotherapy replanning. *Medical physics*, 41(6Part1), 061711.

Brakiterapide Yapay Zeka 8

Talat Aksu¹

Özet

Yapay zekâ (YZ), özellikle makine öğrenimi ve derin öğrenme yöntemleri ile tıp alanında daha fazla öneme sahip olmaktadır. Radyasyon onkolojisi alanında da kullanılmaya başlanmıştır. Bu alandaki mevcut yayınların büyük bölümü YZ'nin eksternal radyoterapideki uygulamalarına odaklanmış olup, brakiterapideki rolü çok daha az incelenmiştir. Bu bölümde, YZ'nin brakiterapide nasıl kullanıldığı ve gelecekteki potansiyel kullanım alanları anlatılacaktır.

YZ araçlarının brakiterapi sürecinde hasta seçimi, tedavi planlaması, iş akışının optimize edilmesinden tedavinin tamamlanmasına kadar neredeyse tüm aşamalarında yarar sağlayabileceği gösterilmiştir. YZ kullanımı, kişisel değişkenliği azaltarak işlem süresini kısaltmıştır. Böylece daha standart, daha doğru ve verimli planlar yapılabilmektedir. Doğrudan işlevsel katkılarının yanı sıra, görüntüleme ve ilişkili bilim alanlarındaki YZ temelli gelişmeler de brakiterapi uygulamalarının etkisini arttırmaktadır.

Son yıllarda brakiterapiye yönelik ilgi dünya çapında yeniden artmıştır; bunun bir nedeni, IMRT ve stereotaktik radyoterapi gibi modern eksternal radyoterapi tekniklerinin brakiterapinin benzersiz geometrik avantajlarını ve yüksek konformalitesini tam olarak sağlayamamasıdır. Uluslararası meslek örgütlerinin eğitim ve farkındalığı artırmaya yönelik girişimleri de bu canlanmayı desteklemiştir. YZ'nin rutin uygulamalara entegre edilmesi, iş akışlarını sadeleştirerek ve klinisyenlerin iş yükünü azaltarak bu gelişmeleri daha da güçlendirebilir.

Bu potansiyele rağmen, pratik uygulamaları sınırlı hasta sayıları ve kısa çalışma süreleriyle kısıtlıdır. Algoritmaların sürekli olarak iyileştirilmesi gereksinimi, geniş popülasyonlarda güçlü doğrulama ihtiyacı ve tedavi güvenliğinin nihai sorumluluğunun klinisyenlerde olması, dikkate alınması gereken önemli noktalar. YZ'nin brakiterapi pratiğini ve kabul edilebilirliğini ne ölçüde ileriye taşıyacağını belirlemek için daha geniş kapsamlı prospektif çok merkezli çalışmalar gereklidir.

1 Öğr.Gör.Dr., Ondokuz Mayıs Üniversitesi Tıp Fakültesi Radyasyon Onkolojisi Anabilim Dalı, Orcid: 0000-0003-4588-0489, talataksu@gmail.com,

1. GİRİŞ

Brakiterapi (BT), radyasyon kaynağının tümörün içine veya yakınına yerleştirildiği özel bir tedavi biçimidir (Vieira vd., 2002). Brakiterapi, özellikle serviks ve prostat kanserinin radyoterapisinde etkili tekniklerden biridir (Pötter vd., 2011; Weishaupt vd., 2022). BT’de radyasyon kaynağının tümör bölgesine son derece hassas biçimde yerleştirilebilmesi mümkündür. BT tedavisinin dik doz gradyanı ve radyasyon kaynağının doz dağılımındaki hızlı düşüş sayesinde tümör bölgesinde lokal olarak yüksek doz uygulanabilir (Zhang vd., 2020).

Görüntü kılavuzlu brakiterapi (IGBT), prostat kanseri, serviks kanseri ve diğer hastalıklarda yaygın olarak kullanılmakta olup, tümöre daha iyi doz verip toksisiteyi azaltmaktadır (Banerjee vd., 2017; Rijkmans vd., 2014). IGBT, tümör çevresindeki riskli organları (OAR) eksternal radyoterapiden (EBRT) daha etkili bir şekilde korur. (Jia & Albuquerque, 2022)

Brakiterapinin birçok avantajı olmasına rağmen, doz optimizasyonu, tedavi planlaması ve gerçek zamanlı adaptasyon gibi süreçlerde zorluklar bulunmaktadır. Son yıllarda yapay zekâ (YZ), tıbbın çeşitli alanlarında önemli ilerlemeler göstermiş ve radyasyon onkolojisi için yeni gelişmeler olmaktadır (Sahiner vd., 2019). Örneğin, derin öğrenme (DL) modelleri; tomografi görüntülerinin konturlanması gibi görevleri gerçekleştirebilmektedir (Anwar vd., 2018; Kayalibay vd., 2017; Mohan vd., 2021). Ancak DL, verilerden karmaşık özellikleri ve yapıları öğrenmek için çok katmanlı sinir ağlarını kullanan makine öğreniminin (ML) bir alt alanıdır (Jia vd., 2019). DL, model girişlerinde kullanılacak uygun özelliklerin verilerden manuel olarak çıkarılmasını gerektiren geleneksel ML yöntemlerinden farklıdır (Litjens vd., 2017). Bu manuel süreç oldukça zaman alıcıdır ve pratik klinik uygulamalarda pek uygun değildir.

Buna karşılık DL, derin sinir ağları (DNN) kullanarak giriş ve çıktı arasındaki ilişkiyi uçtan uca öğrenebilmekte; bu sayede karmaşık veri yapıları ve dönüşümleri daha esnek bir şekilde işleyebilmektedir (Jia & Albuquerque, 2022).

Brakiterapi alanında da iş akışlarını otomatikleştirmek, geliştirmek ve optimize etmek amacıyla DL kullanımına yönelik ilgi giderek artmaktadır. Bu bölümde, son beş yıl içinde brakiterapide yapay zekâ (makine öğrenimi ve derin öğrenme) uygulamalarının mevcut durumunu gözden geçirilecektir.

2. Görüntü İşleme

2.1. Görüntü İyileştirme

Tıp alanında görüntü iyileştirme, görüntü netliğinin artırılması, artefaktların azaltılması ve klinik tanı ile analizde önemli olan anatomik ya da patolojik yapıların vurgulanması gibi amaçlarla tıbbi görüntülerin kalitesini artırmaya hizmet eder. Görüntü iyileştirme genellikle görüntü kalitesini artırmanın ilk adımıdır.

Manyetik rezonans görüntüleme (MRI) ve bilgisayarlı tomografi (BT) sırasında metal artefaktlarını azaltmak için Rao ve arkadaşları, servikal kanser brakiterapisinde ortopedik Metal Artifact Reduction (OMAR) sekansını uygulamıştır (Rao vd., 2017).

Huang ve arkadaşları, servikal BT görüntülerindeki metal artefaktlarını azaltmak için evrimsel sinir ağı (CNN) tabanlı derin artık öğrenme yöntemi RL-ARCNN'yi geliştirmiştir (Huang vd., 2018). Bu çalışmada, RL-ARCNN'nin eğitilmesi için metal artefaktlarını simüle eden bir servikal BT görüntü veri seti oluşturulmuştur. Önerilen yöntem, simüle edilmiş artefakt içeren test görüntülerinde 38.09 tepe sinyal-gürültü oranı (PSNR) elde ederek başarılı bir artefakt azaltma performansı göstermiştir. Artık öğrenmenin PSNR değeri (38.09), normal öğrenmeye göre (37.79) daha yüksek bulunmuş, bu da CNN tabanlı artık öğrenmenin etkili artefakt azaltımı sağladığını göstermiştir. RL-ARCNN'nin metal artefaktlarını belirgin biçimde azaltarak metal bölgelerinin yakınındaki ince yapıları geri kazandırdığı ve herhangi bir ek işleme gerek duymadığı gösterildiğinden, klinik iş akışına uygun bir yöntemdir.

Zaridis ve arkadaşları, prostat ve prostat çevresi yapıların konturlama performansını iyileştirebilen bölgesel uyarlanabilir bir manyetik rezonans görüntü iyileştirme yaklaşımını (RACLAHE) incelemiştir (Zaridis vd., 2023). Çalışmada RACLAHE, beş farklı CNN modelinin konturlama performansına etkisini değerlendirmek üzere dört popüler görüntü iyileştirme yöntemi ile karşılaştırılmıştır. Önerilen RACLAHE yöntemi, farklı prostat bölgelerinde Dice skorlarında %3–9 arasında ortalama artış sağlayarak geniş bir CNN model grubunda anlamlı performans kazanımları göstermiş ve modeller arası değişkenliği minimumda tutmuştur.

2.2. Görüntü Eşleştirilmesi

Görüntü kaydının doğruluğu ve sağlamlığı, tıbbi görüntüleme analizindeki temel görevler arasındadır (Onofrey vd., 2015). Günümüzde, doğru bir multimodal görüntü kaydı hâlâ zorlu bir süreçtir ve geleneksel görüntü kaydı, uygun özelliklerin çıkarılmasına dayanan yinelemeli bir optimizasyon sürecidir

(Shen vd., 2019). Bu işlem çoğu zaman oldukça uzun sürmektedir. Son yıllarda, derin öğrenme (DL) tabanlı yapay zekâ (YZ) görüntü kaydı alanında son derece başarılı sonuçlar elde etmiş, kayıt için gereken süreyi büyük ölçüde azaltmıştır (Boveiri vd., 2020; Fu vd., 2020).

Gerçek zamanlı ultrason (US) görüntülerinin iğne yerleştirme ve konturlama amacıyla kullanılması, yüksek doz hızlı (HDR) prostat brakiterapisinde sıklıkla ilk tercih edilen görüntü kılavuzlama yöntemidir; bu yaklaşım tedavi planlama kalitesini artırabilir. Ancak US görüntüleri düşük doku kontrastı ile sınırlıdır ve yerleştirilen iğneler artefaktlara yol açarak görüntü kalitesini düşürür. US'ye kıyasla MRI daha yüksek yumuşak doku kontrastı sunar ve prostat içindeki bazı lezyonları daha iyi tespit edebilir (Türkbey vd., 2019). Bu nedenle HDR prostat tedavisi sırasında sıklıkla görüntü kaydı kullanılmaktadır (Zhao, Ni vd., 2023).

Chen ve arkadaşları, prostat için multimodal görüntü kaydı problemini çözmek amacıyla yeni bir konturlama temelli kayıt çerçevesi önermiştir (Chen vd., 2021). Bu çerçeve, iki konturlama ağı ve bir deformasyon tabanlı kayıt ağından oluşmakta olup, metal artefaktları içeren tedavi planı US görüntüleri ile prostat MR görüntülerini zayıf denetimli bir kayıt stratejisi kullanarak otomatik olarak hizalamaktadır. Manuel prostat kontur kaydı ile karşılaştırıldığında Dice benzerlik katsayısı (DSC), kütle merkezi mesafesi (COM), Hausdorff mesafesi (HD) ve ortalama simetrik yüzey mesafesi (ASSD) metriklerinde iyileşme sağlanmıştır.

Zhao ve arkadaşları, baş ve boyun kanseri radyoterapisinde BT-MR ve MR-MR kayıt doğruluğunu artırmayı hedefleyen Patch-RegNet adlı hiyerarşik bir esnek (deformable) görüntü kaydı (DIR) çerçevesi geliştirmiştir (Zhao, Chen vd., 2023). Elde edilen sonuçlar, Patch-RegNet'in DSC ve ortalama yüzey mesafesi (MSD) açısından hem geleneksel DIR yöntemlerinden hem de diğer DL tabanlı DIR çerçevelerinden belirgin şekilde daha üstün olduğunu göstermiştir.

2.2. Görüntü Eşleştirilmesi

Görüntü kaydının doğruluğu ve sağlamlığı, tıbbi görüntüleme analizindeki temel görevler arasındadır (Onofrey vd., 2015). Günümüzde, doğru bir multimodal görüntü kaydı hâlâ zorlu bir süreçtir ve geleneksel görüntü kaydı, uygun özelliklerin çıkarılmasına dayanan yinelemeli bir optimizasyon sürecidir (Shen vd., 2019). Bu işlem çoğu zaman oldukça uzun sürmektedir. Son yıllarda, derin öğrenme (DL) tabanlı yapay zekâ (YZ) görüntü kaydı alanında son derece başarılı sonuçlar elde etmiş, kayıt için gereken süreyi büyük ölçüde azaltmıştır (Boveiri vd., 2020; Fu vd., 2020).

Gerçek zamanlı ultrason (US) görüntülerinin iğne yerleştirme ve konturlama amacıyla kullanılması, yüksek doz hızlı (HDR) prostat brakiterapisinde sıklıkla ilk tercih edilen görüntü kılavuzlama yöntemidir; bu yaklaşım tedavi planlama kalitesini artırabilir. Ancak US görüntüleri düşük doku kontrastı ile sınırlıdır ve yerleştirilen iğneler artefaktlara yol açarak görüntü kalitesini düşürür. US'ye kıyasla MRI daha yüksek yumuşak doku kontrastı sunar ve prostat içindeki bazı lezyonları daha iyi tespit edebilir (Türkbey vd., 2019). Bu nedenle HDR prostat tedavisi sırasında sıklıkla görüntü kaydı kullanılmaktadır (Zhao, Ni vd., 2023).

2.3. Riskli Organların Konturlanması

Konturlama tedavi planlaması, görüntü kaydı ve diğer uygulamalar için de temel bir görevdir. Tümör bölgesinde yüksek doz bölgesi (HDR) elde etmek ve sağlıklı dokular ile çevredeki anatomik yapıların radyasyona maruz kalmasını en aza indirmek açısından büyük önem taşır. Yapılan son çalışmaların sonuçları genellikle klinik değerlendirmelerle yüksek uyum göstermiş ve tedavi başarısını artırmıştır. Ayrıca, bu yöntemlerle hasta tedavisi için gereken bekleme süresi belirgin şekilde azaltılmıştır.

Prostat brakiterapisinde Kliniksel Tümör Hacmi (CTV)'nin doğru konturlanması oldukça zorlu bir süreçtir. Şekil modellerine dayalı DL yöntemleri, ultrason kılavuzlu brakiterapide etkili ve doğru CTV konturlama için potansiyel sunmaktadır. Girum ve arkadaşları, transrektal ultrason kılavuzlu cerrahi sırasında prostat CTV'sinin tespitini araştırmıştır (Girum vd., 2020). İntraoperatif TRUS görüntülerinde CTV'yi otomatik olarak saptayan sağlam bir yöntem geliştirilmiştir. Dice benzerlik katsayısı (DSC) önceki DL yöntemlerine göre %7'den fazla iyileşmiş ve 3D Hausdorff mesafesi (HD) 6.9 mm azalmıştır. Ayrıca düşük düzeyli özelliklerin ve önceden bilinen şekil bilgisinin öğrenilmesinin, kanal özellikleriyle kalibrasyonun DL yöntemlerinin tıbbi görüntü konturlamaundaki performansını önemli ölçüde artırabileceği belirtilmiştir.

HDR brakiterapide çevresinde yüksek doz gradyanı bulunan HR-CTV'nin doğru konturlama, çevrimiçi tedavi planlamasının zaman açısından yoğun doğası nedeniyle özellikle kritiktir. Li ve arkadaşları, jinekolojik kanserlerde HR-CTV'nin hızlı ve tekrarlanabilir konturlama için kendini yapılandıran entegre bir yaklaşım önermiştir (Li vd., 2022). nnU-Net kapsamında 2D U-Net, 3D U-Net ve 3D-Cascade U-Net olmak üzere üç mimari eğitilmiş ve daha sonra entegre edilmiştir. Bu entegre yapı, optimal ağı otomatik olarak seçerek manuel yapılandırma gereksinimini azaltmıştır. Nicel değerlendirmelerde 3D-Cascade U-Net, en yüksek konturlama doğruluğunu göstermiştir.

OAR konturlamaunun doğruluğu, tedavi planlamasının etkinliği ve güvenliği ile doz hesaplamalarının doğruluğu açısından kritik öneme sahiptir. Tümörleri ve komşu risk yapılarını daha doğru tanımlamak amacıyla, Mohammadi ve arkadaşları HDR brakiterapide OAR konturlarını hızlı ve tekrarlanabilir şekilde otomatik olarak çizen derin evrimsel sinir ağı (DCNN) tabanlı bir yöntem önermiştir (Mohammadi vd., 2021). ResU-Net modeli, geleneksel U-Net ile karşılaştırıldığında tüm dozimetri parametrelerinde daha iyi sonuçlar elde etmiş; mesane, rektum ve sigmoid kolon için sırasıyla %5.8, %4.9 ve %4.2 iyileşme sağlamıştır.

Orlando ve arkadaşları, geleneksel U-Net modelini modifiye ederek denetimli DL tabanlı prostat konturlama yöntemi geliştirmiştir (Orlando vd., 2020). Bu yöntem, farklı ultrason cihazlarından elde edilen 3D TRUS görüntülerine uygulanabilir. Ancak çalışma yalnızca belirli bir veri seti üzerinde doğrulanmıştır; bu nedenle daha geniş klinik uygulamalar için ek araştırmalar gerekebilir.

Zhang ve arkadaşları, servikal kanser brakiterapisinde BT temelli risk altındaki organların yüksek doğruluk ve verimlilikle otomatik konturlama için DSD-UNET yöntemini önermiştir (Zhang vd., 2020). DSD-UNET, tüm yapılar için 3D U-Net'ten daha üstün performans göstermiştir. Ayrıca, otomatik oluşturulan DSD-UNET konturlarının şekil, hacim ve konum açısından altın standart (GT) konturlarıyla daha yüksek uyum gösterdiği bildirilmiştir.

2.4. Aplikatör Konturlama ve Rekonstrüksiyonu

BT'de (brakiterapi) aplikatörün konturlaması ve rekonstrüksiyonu, kaynak konumunun vücut içindeki yerini belirleyebilir. Bu işlem, radyasyon dozunun daha iyi planlanmasına yardımcı olur ve tedavinin tümör alanını etkin şekilde kapsamasını sağlarken çevredeki sağlıklı dokuların aldığı radyasyonu en aza indirir. Tıbbi görüntüleme teknolojisinin gelişmesiyle birlikte otomatik konturlama ve rekonstrüksiyon teknikleri tedavinin verimliliğini ve güvenliğini artırmaktadır (Jiang vd., 2021).

Önceki intrakaviter aplikatör çalışmalarında, basit eşikleme ve kümeleme algoritmaları kullanılarak aplikatörlerin otomatik dijitalleştirilmesi mümkün olmuştur (Deufel vd., 2020). Bu yöntemler verimliliği artırmış olsa da hâlâ daha fazla optimizasyon ve iyileştirme için alan bulunmaktadır. Weishaupt ve arkadaşları, sagittal BT görüntüleri üzerinde (geleneksel aksiyal görüntüler yerine) U-Net modeline dayalı aplikatör otomatik konturlama önermiş ve bu yöntem tüm kesişen aplikatörleri güvenilir şekilde ayırarak manuel konturlama milimetreden daha küçük düzeyinde uyum sağlamıştır (Weishaupt vd., 2022).

Serviks brakiterapi tedavi planlamasında BT görüntülerinde aplikatörlerin otomatik konturlama ve rekonstrüksiyonu için U-Net modelini temel almıştır (Hu vd., 2021). Çalışmanın sonuçlarına göre, 10 hastada DSC, HD95 ve rekonstrüksiyon süresi sırasıyla 0.89, 1.66 mm ve 17.12 saniye olarak bulunmuştur. Manuel ve otomatik rekonstrüksiyon arasındaki doz farkı, yüksek riskli klinik hedef hacmi (HR-CTV) için D90%'ın %0.29'u, riskli organlar için ise D2cc'nin %2.64'ünden daha az olup, yöntemin doğruluk ve verimliliğini göstermiştir. Lokal ileri tümörlerin tedavisinde, tümörün büyük boyutu ve komşu servikal dokulara sık invazyon nedeniyle geleneksel brakiterapi hedef alanı yeterince kapsayamayabilir; bu durum kötü tümör kontrolüne veya nükse yol açabilir (Zhang vd., 2023). İnterstisyel brakiterapi yöntemi ise hedef alanı daha iyi çevreleyerek tedavi etkinliğini artırabilmektedir (Kirisits vd., 2006).

Jung ve arkadaşları, BT görüntülerinde CNN tabanlı model kullanarak iğne konturlama yapmış, ardından segment edilen voksel kümelerini aynı anda gruplayıp optimizasyon yöntemi ile iğnenin merkez hattı trajektörünü oluşturmuştur (Jung vd., 2019). Bulgular, önerilen yöntemin hem iğne ucu konumu hem de genel iğne trajektöründe gerçek duruma kıyasla 1 mm'den daha az fark gösterdiğini ortaya koymuştur. Zhang ve arkadaşları, 3B TRUS görüntülerinde çoklu iğneleri segment ederek çoklu iğne lokalizasyonunu U-Net tabanlı bir modelle gerçekleştirmiştir (Zhang, Lei vd., 2020). Bu yaklaşım, HDR prostat brakiterapisinin kalitesini ve etkinliğini daha da artırabilecek gerçek zamanlı planlama doz değerlendirme araçlarının geliştirilmesine zemin hazırlamaktadır. Wang ve arkadaşları da ultrason tabanlı konturlama kullanmış ancak çalışmalarında brakiterapi iğnelerini görüntülerden segment etmek ve iğne uçlarını belirlemek için iki farklı derin öğrenme ağı kullanmışlardır (Wang vd., 2020). Bunlardan ilki, modifiye edilmiş bir derin U-Net olup iğneyi ultrason görüntüsünden segment ederken; ikincisi VGG-16 tabanlı bir derin evrimsel ağ olup iğne ucu konumunu tahmin etmek için kullanılmıştır.

3. Doz hesaplama ve optimizasyon

Radyoterapinin en önemli yönlerinden biri optimal dozun belirlenmesidir. Radyasyon ile vücut arasındaki etkileşimin ve soğurulan dozun doğru hesaplanması Monte Carlo (MC) yöntemiyle gerçekleştirilebilir. Ancak MC yöntemlerinin uygulanması zaman açısından uzun sürdüğü için kliniklerde uygulanması zor olabilir. Mao ve arkadaşları, MC yöntemlerini kullanarak klinik hedef hacim (CTV) ve risk altındaki organların (OAR) doz dağılımlarını hızlı bir şekilde hesaplayan RapidBrachyDL adlı derin öğrenme (DL) tabanlı bir model önermiştir (Mao, Pineau, Keyes & Enger, 2020). Sonuçlar, yöntemin hesaplama verimliliğini anlamlı ölçüde artırdığını ve MC yöntemine oldukça yakın doğruluk sağladığını göstermiştir. Villa ve arkadaşları, prostat

brakiterapisinde hızlı ters planlama için DL tabanlı bir Monte Carlo yöntemi önermiştir (Villa, Bert, Valeri, Schick & Visvikis, 2021). Bu yöntem, GPU tabanlı Monte Carlo simülasyonu ile oluşturulan bir veri tabanını kullanarak prostat ve OAR için doz dağılımını hızlı şekilde tahmin eder. Deneysel bulgular, yöntemin hem verimli hem de doğru olduğunu, ayrıca klinik uygulama için potansiyel taşıdığını göstermiştir. Akhavanallaf ve arkadaşları ise hasta özelinde doz dağılımı verilerini MC yöntemiyle oluşturmuş ve bu verileri bir derin sinir ağı (DNN) modelinin eğitimi için kullanmıştır (Akhavanallaf vd., 2021). Çalışmanın sonuçları, DNN tabanlı bu yöntemin hem hesaplama süresi hem de doz hesaplama doğruluğu açısından geleneksel TG-43 yönteminden daha iyi performans gösterdiğini, ayrıca TG-43'ün aşırı basitleştirmelerini aştığını ortaya koymuştur.

Hızlı doz hesaplama için DL tabanlı MC yöntemlerinin yanı sıra, bazı araştırmacılar harici radyoterapide kullanılan bilgi tabanlı doz tahmin modellerini brakiterapiye de uygulamıştır (Cortes vd., 2022; Kallis vd., 2021; Shiraishi & Moore, 2016; Yusufaly vd., 2020). Doz hesaplamanın ötesinde yapay zekâ, doz optimizasyonunda da başarılı sonuçlar göstermektedir. Ghosh ve arkadaşları, transfer öğrenmesi ve modifiye edilmiş bir U-Net modeli kullanarak brakiterapi sırasında aplikatör yerleşiminin neden olduğu uterin deformasyonu tahmin eden ilk çalışma olmuştur (Ghosh, Punithakumar, Huang, Menon & Boulanger, 2022). Model, brakiterapi öncesi (pre-BT) MR görüntülerini kullanarak aplikatör yerleştirildikten sonraki MR anatomisini tahmin etmektedir. Bu çerçevenin uygulanması, hekimlerin aplikatör yerleştirilmeden önce daha etkin kararlar almasını sağlar; bu durum kişiselleştirilmiş brakiterapinin verimliliğini artırırken dozimetri sonuçlarını da iyileştirir. Önceki çalışmalarda LACC brakiterapisinde MR görüntüsüne dayalı anatomik değişiklikleri optimize etmek için DL kullanan bir yaklaşım bulunmamaktaydı.

Shen ve arkadaşları radyoterapi planlama optimizasyonunu otomatikleştirmek üzere ağırlık ayarlama politika ağı (WTPN) geliştirmiştir (Shen, Gonzalez vd., 2019). WTPN, tedavi planlarının doz-hacim histogramlarını analiz ederek organlara ait ağırlık faktörlerini ayarlamak için insan planlamacının karar verme mantığını taklit eder. Geleneksel manuel yöntemlerle karşılaştırıldığında WTPN'in tedavi hedeflerini etkili biçimde öğrendiği ve ağırlık ayarlama sürecini yönlendirdiği gösterilmiştir; plan kalitesinde ortalama %10,7'lik bir iyileşme sağlanmıştır. Bu bulgu, derin pekiştirmeli öğrenmenin tedavi plan optimizasyonundaki potansiyelini ortaya koyarken, gelecekteki klinik uygulamalar için yeni bir yön de sunmaktadır. Ancak çalışmanın sınırlılıkları da vardır; algoritmanın genellenebilirliği ve uzun dönem klinik sonuçları daha fazla araştırılmalıdır.

Pu ve arkadaşları derin pekiştirmeli öğrenmeyi (DRL) kullanarak akıllı tedavi planlayıcı ağı (ITPN) geliştirmiştir (Pu, Jiang, Yang, Hu & Liu, 2022). Bu sistemi IPSA (inverse planning simulated annealing) algoritmasıyla karşılaştırmışlar ve ITPN'nin öğrendiği yerleşim süresi (dwell time) ayarlama stratejileri sayesinde daha yüksek kaliteli planlar üretebildiğini göstermiştir. Bu sistem, HDR brakiterapide dwell time'ı doğrudan belirleyebilen ilk yapay zekâ sistemidir ve DRL ile optimizasyon probleminin çözülebileceğini ortaya koymaktadır.

Geleneksel makine öğrenimi (ML) yöntemleri de brakiterapi tedavisinde geniş kullanım alanına sahiptir. Nicolae ve arkadaşları, prostat implantasyonu için ML tabanlı bir planlama algoritması olan PIPA sistemini geliştirmiş ve bunu 30. gündeki dozimetri sonuçlarıyla birlikte geleneksel manuel planlarla karşılaştırmıştır (Nicolae vd., 2017). Bulgular, düşük doz hızlı (LDR) prostat brakiterapisinde PIPA kullanımının önemli ölçüde zaman tasarrufu sağlayabileceğini ve dozimetri açısından herhangi bir dezavantaj oluşturmadığını göstermiştir. Nicolae ve arkadaşları daha sonra yaptıkları faz I randomize çalışmada PIPA ile geleneksel teknik arasında prostat D90%, V100%, rektal V100% veya rektal D1cc açısından anlamlı fark olmadığını bildirmiştir (Nicolae vd., 2020). Buna karşın planlama süresi PIPA sistemi için yalnızca 2.38 ± 0.96 dakika iken, geleneksel teknik için bu süre 43.13 ± 58.70 dakika bulunmuştur; bu belirgin fark, PIPA'nın zaman verimliliğindeki avantajını göstermektedir.

4. Kalite güvenliği

Brakiterapi işleminin doğasında bulunan karmaşıklık, güçlü kalite kontrol (QA) önlemlerini zorunlu kılmaktadır. Yapay zekâ, bu QA süreçlerini otomatikleştirmek amacıyla kullanılmaya başlanmıştır. Fan ve çalışma arkadaşları, brakiterapi planlarının doğrulanma sürecine derin öğrenme teknolojisini dâhil eden ilk araştırmacılar olmuştur (Fan, Xing & Yang, 2021). Araştırmacılar, temelini Inception ağından alan bir regresyon modeli geliştirmiştir. Bu model, mevcut ve doğrulanmış brakiterapi tedavi planlarından öğrenmekte; radyasyon kaynağının konumu ve tedavi planı içindeki uygulama süresi gibi parametreleri dikkate almaktadır. Modelin eğitimi, doğrulaması ve testinde toplam 130 serviks kanseri olgusu kullanılmıştır. Çalışma, lokal ileri serviks kanseri (LACC) brakiterapisinde OVH tabanlı kalite güvencesinin potansiyelini ortaya koymuş ve çok merkezli QA çalışmalarına temel oluşturmuştur.

Li ve çalışma arkadaşları, U-Net mimarisini geliştirerek Sıkıştırma ve Dikkat Mekanizması Ağı (SE_AN) adını verdikleri bir model önermiştir (Li vd., 2023). SE_AN modeli, serviks kanserli hastalarda uygulanan HDR-

BT'nin üç boyutlu doz dağılımını tahmin etmek amacıyla kullanılmış ve sonuçlar geleneksel U-Net ve Kademeli U-Net (Cascade U-Net) modelleri ile karşılaştırılmıştır. Bulgular, SEAN modelinin gerçek klinik tedavi dozuna en yakın tahminleri ürettiğini ve klinik doz dağılımının özelliklerini daha doğru bir şekilde yeniden oluşturabildiğini göstermiştir. Bu modelin tedavi planlama verimliliğini artırması, plan kalitesini güvence altına alması ve farklı merkezler ile klinisyenler arasındaki planlama tutarlılığını güçlendirmesi beklenmektedir. Ayrıca SEAN modelinin HDR-BT tedavi planlama sürecinin optimizasyonuna ve kalite kontrol süreçlerinin iyileştirilmesine katkı sunacağı öngörülmektedir.

5. Takip tahmini

Brakiterapi uygulamasını takiben radyasyon kaynaklı hasarın değerlendirilmesi ve öngörülmesi, çok sayıda hasta ve tedavi parametresini içeren karmaşık ve çok değişkenli bir problem olarak ortaya çıkmaktadır. Geleneksel tek değişkenli toksisite tahmin modelleri, çoklu faktör etkileşimlerini bütüncül bir şekilde açıklamada yetersiz kalmıştır. Derin öğrenme ve makine öğrenimi yaklaşımlarının gelişmesiyle birlikte, tedavi sonrası komplikasyon riskinin daha kapsamlı ve daha doğru bir biçimde tahmin edilmesi mümkün hâle gelmiş; böylece prognoz değerlendirmelerinin doğruluğu artırılabilmiştir.

Serviks kanseri brakiterapisi prognozu açısından, Zhen ve çalışma arkadaşları (2017) rektal doza dayalı radyasyon toksisitesini tahmin etmek için derin evrişimli sinir ağı (DCNN) ve transfer öğrenmesi kullanan ilk fizibilite çalışmasını gerçekleştirmiştir. Modelin kavite yapısına sahip diğer riskli organlara (OAR) da uyarlanabilir olması dikkat çekmekle birlikte, küçük veri seti nedeniyle daha geniş veri kümeleriyle doğrulamaya ihtiyaç duyulmaktadır.

Bir yıl sonra Chen ve çalışma arkadaşları (2018), aynı veri setini kullanarak destek vektör makinesi (SVM) modeli ile ardışık özellik seçimi (SFS) algoritmasını birleştiren SVM-SFS yaklaşımını geliştirmiş ve toksisite tahmin doğruluğunu artırmıştır. Bu çalışma, OAR doz kontrolü ve komplikasyon tahmini için makine öğrenimi tabanlı yöntemlerin uygulanabilirliğini desteklemiştir.

Ayrıca Tian ve çalışma arkadaşları (2019), lokal ileri jinekolojik maligniteli hastalarda brakiterapi sonrası fistül oluşumunu tahmin etmek için SBS ve SFBS algoritmaları ile birleştirilmiş SVM modelleri geliştirmiştir. Yedi özellik içeren model, fistül riskini tatmin edici doğrulukla tahmin etmiş; ancak yalnızca tek merkezde test edildiği için prospektif doğrulama gereklidir. Bu çalışmalarda, veri dengesizliğini azaltmak ve aşırı uyumu önlemek amacıyla SMOTE yöntemi kullanılmıştır (Chawla vd., 2002).

Abdalvand ve arkadaşları (2022), 111 LACC hastasında LASSO, Ridge, SVM ve random forest (RF) yöntemlerini kullanarak sağkalım ve tedavi yanıtını tahmin eden modeller geliştirmiş ve değerlendirmiştir. AUC, duyarlılık (SEN), özgüllük (SPE) ve genel doğruluk gibi göstergelerle yapılan analizlerde, özellikle fiziksel ve dozimetri parametrelerini birleştiren RF modelinin en yüksek performansı sağladığı gösterilmiştir.

Prostat kanseri prognozu açısından, Valdes ve çalışma arkadaşları (2018) kurtarma amaçlı yüksek doz hızlı brakiterapi (sHDRB) uygulanan hastalarda biyokimyasal başarısızlık (BF) riskini tahmin etmek için makine öğrenimi yöntemlerini kullanmıştır. Karar ağacı (DT), lojistik regresyon (LR) ve RF modelleri karşılaştırıldığında, biyopsi çekirdeklerinde %35'in üzerinde pozitiflik oranı olan ve hastalıksız intervalı 4.1 yıldan kısa olan hastalarda BF riskinin belirgin şekilde daha yüksek olduğu bulunmuştur.

6. Tartışma

Yapay zekâ, kanser radyoterapisi alanında büyük ilgi görmüş olup brakiterapi de bunun istisnası değildir. Brakiterapide doğru, verimli ve güvenli tedavi sağlayan teknolojik altyapının arkasında zahmetli ve zaman alıcı süreçler bulunmaktadır. Yapay zekâ uygulamaları bu süreçlerde gereken zamanı azaltabilir ve doğruluğu artırabilir. Bu bölümde görüntü işleme, doz hesaplama ve optimizasyon, kalite güvencesi ve takip (follow-up) tahmini gibi alanlarda yapay zekâya ilişkin literatür özetlenmiş ve brakiterapi süreçlerinin çoğunda yapay zekânın yaygın biçimde kullanılmaya başlandığı görülmüştür.

Yapay zekâ veriye dayalıdır ve denetimli öğrenme genellikle büyük ve etiketli veri setleri gerektirir. Ancak pek çok makine öğrenimi ve bilgisayarlı görü uygulamasında etiket gürültüsü (label noise), derin öğrenme modellerinin performansını olumsuz etkileyebilmektedir. Etiket gürültüsünün etkilerini azaltmak amacıyla Karimi ve arkadaşları (2020) üç farklı tıbbi görüntüleme veri setinde çeşitli stratejileri karşılaştırmalı olarak değerlendirmiş ve bu yöntemlerin gürültülü etiket sorununu etkili şekilde azaltabildiğini göstermiştir. Wang, Yu ve çalışma arkadaşları (2023) SemiMAR adını verdikleri yarı denetimli bir öğrenme çerçevesi önermiş ve bu çerçevenin denetimli ve denetimsiz öğrenmenin avantajlarını birleştirerek metal artefakt azaltımı (MAR) performansını artırdığını; ayrıca doku ayrıntılarını mevcut yöntemlerden daha iyi koruduğunu bildirmiştir. Du ve arkadaşları (2023) ise UDAMAR adlı yarı denetimli bir derin öğrenme yöntemi geliştirmiş; bu yöntem simüle edilmiş verilerle eğitilmiş modellerin gerçek BT görüntülerinde yaşadığı alan uyumsuzluğu (domain discrepancy) sorununu denetimsiz alan uyarlaması (UDA) tekniğiyle azaltmıştır. Bu iki yarı denetimli yaklaşımın ortak özelliği,

etiketlenmemiş verilerden yararlanarak modellerin genellenebilirliğini artırmasıdır. Bu yöntemler henüz doğrudan brakiterapi görüntü işlemeye uygulanmamış olsa da gelecekte BT senaryolarına uyarlanabilecek potansiyele sahiptir.

Aplikatör rekonstrüksiyonu brakiterapide kritik bir adımdır ve doğruluğu tedavi sonuçlarını doğrudan etkiler. Klinik uygulamada fizikçiler aplikatörleri çoğunlukla manuel olarak rekonstrükte etmek zorunda olduğundan bu işlem hem zaman alıcıdır hem de gözlemciler arasında değişkenlik yaratır. Bu nedenle bazı araştırmacılar, derin öğrenme algoritmalarını kullanarak aplikatör rekonstrüksiyonunu otomatikleştirmiş ve algoritmaların manuel rekonstrüksiyonla benzer doğrulukta, ancak çok daha yüksek verimlilikte sonuç verdiğini göstermiştir (Shaaer vd., 2022). Diğer araştırmacılar multimodal görüntü hizalama teknikleri kullanarak görüntü kalitesini iyileştirmiş ve bu sayede rekonstrüksiyon doğruluğunu artırmıştır (Islam vd., 2021; Zhu vd., 2021). Bununla birlikte, mevcut çalışmalar sınırlı veri setleriyle test edildiğinden klinik uygulamaya geçiş için daha geniş kapsamlı doğrulama çalışmalarına ihtiyaç duyulmaktadır.

Derin öğrenme teknikleri hasta bekleme sürelerini azaltabilir; ancak oluşturulan tedavi planlarının kalite açısından doğrulanması da zorunludur. Uluslararası Radyolojik Koruma Komisyonu (ICRP) ve Uluslararası Atom Enerjisi Ajansı (IAEA) raporlarına göre, brakiterapideki hataların büyük kısmı insan kaynaklı hesaplama hatalarından, küçük bir kısmı ise makine veya hesaplama sistemlerinden kaynaklanmaktadır (IAEA, 2000). HDR brakiterapinin başarısı büyük ölçüde tedavi planlarının kalite güvencesine bağlıdır; bu nedenle etkili QA önlemleri kritik öneme sahiptir. Nitekim brakiterapi QA'sı üzerine uzun süredir çalışmalar yürütülmektedir (Bidmead vd., 2004; Kubo vd., 1998). Cai ve çalışma arkadaşları, tedavi planlama sisteminden verileri otomatik olarak çekerek standartlaştırılmış QA raporları üreten bir HDR brakiterapi kalite kontrol süreci geliştirmiştir (Cai vd., 2019). Yapay zekânın brakiterapi QA'sındaki rolüne ilişkin çalışmalar henüz sınırlı olmakla birlikte, DL modellerinin tedavi planlarının bağımsız doğrulanmasında kullanılabileceği ve QA süreçlerine yeni bir yaklaşım getirebileceği düşünülmektedir. Brakiterapi güvenliğinde bir diğer önemli konu, tedavi sırasında radyasyon kaynağının gerçek zamanlı olarak izlenmesidir. Nakajima ve çalışma arkadaşları (2023), BT işaret görüntülerini kullanarak kaynak konumunu yüksek doğrulukla belirleyebilen bir sistem geliştirmiş ve bu sistemin mevcut görüntü kılavuzlu brakiterapi ekipmanlarına kolayca entegre edilebildiğini göstermiştir.

Derin öğrenme tabanlı yapay zekâ yöntemleri brakiterapi alanında hâlen erken aşamadadır. Brakiterapiye özgü çalışma koşulları nedeniyle DL modelleri

için kullanılabilir veri setleri genellikle sınırlıdır. Bu durum modellerin performansını ve genellenebilirliğini kısıtlayabilir. Bazı çalışmalar veri artırma tekniklerini kullansa da, bu yaklaşımlar rastgele görüntü manipülasyonları nedeniyle hatalara yol açabilir veya eğitim-test uyumsuzluğu oluşturabilir (Bharati vd., 2022). Gelecekte, büyük ve yüksek kaliteli anotasyon içeren kamuya açık veri setlerinin geliştirilmesi, gözlemci değişkenliğini azaltmak ve veri tutarlılığını sağlamak açısından kritik olacaktır. DL modellerinin “kara kutu” yapısı ise brakiterapi açısından özellikle önemlidir; çünkü model çıktıları doğrudan hastanın tedavisini ve güvenliğini etkiler. Bu nedenle modelin yorumlanabilirliğini ve güvenilirliğini artıracak yöntemlere ihtiyaç vardır; örneğin odaklanılan bölgelerin görselleştirilmesi, duyarlılık analizleri veya adversaryal testler gibi. Ayrıca DL modellerinin klinik kullanım için gerekli onay süreçlerinden geçebilmesi adına geniş ölçekli klinik doğrulama çalışmaları gerekmektedir.

Brakiterapide MRI’nın oldukça önemlidir. MRI, BT’ye kıyasla belirgin yumuşak doku kontrastı avantajı sunar ve klinik tedavi için kritik bilgiler sağlar. EMBRACE-I prospektif çalışması, MRI kılavuzlu intrakaviter brakiterapinin (IGBAT) ileri evre serviks kanserlerinde uzun dönem lokal kontrolü sürdürdüğünü ve organ toksisitesini azalttığını göstermiştir (Pötter vd., 2021). Bu bulgular, gelecekteki klinik uygulamalar için önemli bir referans oluşturmaktadır. Bu nedenle yapay zekâ ile MRI’nın entegrasyonu, tedavi etkinliğini artırmak, komplikasyonları azaltmak ve genel verimliliği yükseltmek amacıyla güncel bir araştırma odağı hâline gelmiştir. Klinik deneyimlerin artmasıyla birlikte, yapay zekânın brakiterapi alanındaki kullanımının daha da yaygınlaşması beklenmektedir.

7. Sonuç

Yapay zekâ, brakiterapi alanında dikkate değer bir dönüşüm potansiyeli taşımaktadır. Gelişmiş görüntü işleme yöntemleri, otomatik konturlama, doğru ve hızlı doz hesaplama yaklaşımları ve optimizasyon algoritmalarının entegrasyonu sayesinde yapay zekâ, brakiterapi süreçlerinin doğruluğunu ve tutarlılığını önemli ölçüde artırmaktadır. Bu teknolojiler, yalnızca tedavi planlarının daha güvenilir şekilde hazırlanmasına olanak vermekle kalmamakta; aynı zamanda hastaya özgü anatomik ve klinik özelliklerin daha doğru değerlendirilmesini sağlayarak kişiselleştirilmiş tedavi uygulamalarının önünü açmaktadır.

Yapay zekâ tabanlı uygulamaların adaptif tedavi stratejilerine katkısı, özellikle karmaşık tümör topografisine sahip olgularda klinisyenlere daha esnek ve etkin müdahale olanağı sunmaktadır. Ayrıca işlem sürelerinin kısalması,

planlamanın standartlaştırılması ve insan kaynaklı hataların azaltılması gibi avantajlar, klinik iş akışlarının verimliliğini belirgin biçimde artırmaktadır. Bu gelişmeler, brakiterapinin klinik sonuçlarını güçlendirme potansiyeline sahip bir teknolojik dönüşümü işaret etmektedir.

Gelecekte daha geniş ve çok merkezli veri setlerinin oluşturulması, yapay zekâ modellerinin genellenebilirliğini artıracaktır. Bununla birlikte yapay zekâ sistemlerinin şeffaflık, güvenilirlik ve klinik doğrulama aşamalarının güçlendirilmesi, bu teknolojilerin yaygın klinik kullanımını destekleyecektir. Yapay zekâ, brakiterapiye yalnızca teknik bir yenilik olarak değil, tedaviyi daha güvenli, daha etkili ve daha bireyselleştirilmiş hâle getirecek bir paradigma değişimi olarak katkı sağlamaktadır. Bu nedenle yapay zekâ destekli brakiterapinin gelecekte çok daha rafine, erişilebilir ve hasta odaklı tedavi seçenekleri sunacağı öngörülebilmektedir.

Kaynaklar

- Abdalvand, N., et al. (2022). Machine learning-based prediction of treatment response in locally advanced cervical cancer. *Brachytherapy*.
- Akhavanallaf, A., et al. (2021). Deep neural network-based Monte Carlo brachytherapy dose calculation. *Medical Physics*.
- Anwar, S. M., et al. (2018). Medical image analysis using convolutional neural networks. *Pattern Recognition*.
- Banerjee, R., et al. (2017). Image-guided brachytherapy in cervical cancer. *Brachytherapy*.
- Bharati, S., et al. (2022). Data augmentation pitfalls in medical imaging. *Computerized Medical Imaging and Graphics*.
- Bidmead, M., et al. (2004). Quality assurance in brachytherapy. *British Journal of Radiology*.
- Boveiri, H. R., et al. (2020). Deep learning-based deformable image registration in medicine. *Artificial Intelligence in Medicine*.
- Cai, B., et al. (2019). Automated HDR brachytherapy QA reporting system. *Medical Physics*.
- Chawla, N. V., et al. (2002). SMOTE: Synthetic Minority Oversampling Technique. *Journal of Artificial Intelligence Research*.
- Chen, L., et al. (2021). Segmentation-assisted multimodal registration for prostate brachytherapy. *Medical Physics*.
- Chen, Z., et al. (2018). SVM-SFS model for rectal toxicity prediction in brachytherapy. *Physics in Medicine & Biology*.
- Cortes, J., et al. (2022). Knowledge-based dose prediction for brachytherapy. *Radiotherapy and Oncology*.
- Deufel, C. L., et al. (2020). Automatic digitization of intracavitary brachytherapy applicators. *Journal of Applied Clinical Medical Physics*.
- Du, J., et al. (2023). UDAMAR: Unsupervised domain adaptation for metal artifact reduction. *Medical Physics*.
- Fan, J., et al. (2021). Deep learning-based quality verification in brachytherapy. *Medical Physics*.
- Fu, Y., et al. (2020). Deep learning for medical image registration. *Computerized Medical Imaging and Graphics*.
- Ghosh, S., et al. (2022). Predicting uterine deformation after applicator insertion using deep learning. *Medical Physics*.
- Girum, K., et al. (2020). Automatic prostate CTV detection on TRUS using DL. *Medical Physics*.
- Hu, Q., et al. (2021). Automatic applicator segmentation and reconstruction for cervical brachytherapy. *Physics in Medicine & Biology*.

- Huang, Y., et al. (2018). CNN-based deep residual network for cervical CT metal artifact reduction. *IEEE Access*.
- IAEA. (2000). Radiological accidents in brachytherapy. International Atomic Energy Agency Report.
- Islam, M., et al. (2021). Multimodal image fusion to improve brachytherapy reconstruction accuracy. *Medical Physics*.
- Jia, X., & Albuquerque, K. (2022). Soft tissue imaging and delineation in brachytherapy. *Seminars in Radiation Oncology*.
- Jia, X., et al. (2019). Machine learning and deep learning in radiation oncology. *Physics in Medicine & Biology*.
- Jiang, Y., et al. (2021). Applicator segmentation and reconstruction in brachytherapy. *Medical Physics*.
- Jung, H., et al. (2019). CNN-based needle segmentation for HDR prostate brachytherapy. *Medical Physics*.
- Kallis, K., et al. (2021). Knowledge-based planning for brachytherapy. *Medical Physics*.
- Karimi, D., et al. (2020). Reducing label noise impact in deep learning for medical imaging. *Medical Image Analysis*.
- Kayalibay, B., et al. (2017). CNN-based segmentation of medical imaging data. *arXiv preprint*.
- Kirisits, C., et al. (2006). GEC-ESTRO recommendations for interstitial brachytherapy in gynecology. *Radiotherapy and Oncology*.
- Kubo, H. D., et al. (1998). AAPM report on HDR brachytherapy quality assurance. *Medical Physics*.
- Li, K., et al. (2022). nnU-Net ensemble for rapid HR-CTV segmentation. *Radiotherapy and Oncology*.
- Li, S., et al. (2023). SE_AN model for 3D dose prediction in HDR brachytherapy. *Physics in Medicine & Biology*.
- Litjens, G., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*.
- Mao, S., et al. (2020). RapidBrachyDL: Deep learning-based Monte Carlo dose calculation. *Medical Physics*.
- Mohammadi, M., et al. (2021). Automated OAR segmentation for HDR brachytherapy. *Brachytherapy*.
- Mohan, R., et al. (2021). Deep learning applications in medical image segmentation. *Medical Physics*.
- Nakajima, M., et al. (2023). Real-time source position verification in brachytherapy. *Radiotherapy and Oncology*.

- Nicolae, A., et al. (2017). Machine learning-based prostate LDR brachytherapy planning (PIPA). *Brachytherapy*.
- Nicolae, A., et al. (2020). Phase I RCT of PIPA vs manual planning in prostate brachytherapy. *Brachytherapy*.
- Onofrey, J., et al. (2015). Medical image registration: principles and applications. *Medical Image Analysis*.
- Orlando, J., et al. (2020). U-Net-based prostate segmentation in TRUS imaging. *Medical Physics*.
- Pötter, R., et al. (2011). Advances in cervical cancer brachytherapy. *Radiotherapy and Oncology*.
- Pötter, R., et al. (2021). EMBRACE-I results: MRI-guided adaptive brachytherapy. *Radiotherapy and Oncology*.
- Pu, Y., et al. (2022). Intelligent treatment planning using deep reinforcement learning. *Medical Physics*.
- Rao, Y., et al. (2017). O-MAR MRI sequences for artifact reduction in cervical brachytherapy. *Brachytherapy*.
- Rijkman, E., et al. (2014). MRI-guided brachytherapy outcomes in cervical cancer. *Radiotherapy and Oncology*.
- Sahiner, B., et al. (2019). AI in radiology: applications and pitfalls. *Journal of the American College of Radiology*.
- Shaaer, A., et al. (2022). Automated applicator reconstruction via deep learning. *Medical Physics*.
- Shen, C., et al. (2019). Weighting Tuning Policy Network for RT planning. *Physics in Medicine & Biology*.
- Shen, D., et al. (2019). Deep learning for deformable image registration. *Medical Image Analysis*.
- Shiraishi, S., & Moore, K. (2016). Knowledge-based planning: methods and applications. *Medical Physics*.
- Tian, Z., et al. (2019). Predicting fistula formation after brachytherapy using SVM models. *Brachytherapy*.
- Turkbey, B., et al. (2019). MRI advances for prostate cancer imaging. *Radiology*.
- Valdes, G., et al. (2018). Machine learning prediction of biochemical failure after salvage HDR brachytherapy. *International Journal of Radiation Oncology, Biology and Physics*.
- Vieira, S., et al. (2002). Fundamental concepts in brachytherapy. *BIOLOGY-PARIS-WEGMANN-M*.
- Villa, S., et al. (2021). Deep learning Monte Carlo dose estimation in prostate brachytherapy. *Physics in Medicine & Biology*.

- Wang, L., et al. (2020). Deep learning for needle segmentation and tip detection in ultrasound. *Medical Physics*.
- Wang, Y., et al. (2023). SemiMAR: Semi-supervised metal artifact reduction. *IEEE Transactions on Medical Imaging*.
- Weishaupt, A., et al. (2022). Automatic applicator segmentation using U-Net. *Medical Physics*.
- Yusufaly, T., et al. (2020). Knowledge-based dose prediction in radiotherapy. *Physics in Medicine & Biology*.
- Zaridis, I., et al. (2023). MRI enhancement to improve prostate segmentation. *Medical Physics*.
- Zhang, L., et al. (2023). Interstitial brachytherapy for locally advanced cervical cancer. *Gynecologic Oncology*.
- Zhang, W., et al. (2020). DSD-UNET for organ segmentation in cervical brachytherapy. *Medical Physics*.
- Zhao, W., et al. (2023). Patch-RegNet for multimodal deformable image registration. *Medical Image Analysis*.
- Zhen, X., et al. (2017). DCNN-based prediction of rectal toxicity in cervical cancer radiotherapy. *Radiotherapy and Oncology*.
- Zhu, J., et al. (2021). Multimodal registration improvements for applicator reconstruction. *Medical Physics*.

Otomatik Tedavi Planlama Sistemleri (Atps)

Mehmet Hakan Doğan¹

Özet

Otomatik Tedavi Planlama Sistemleri (Automatic Treatment Planning Systems, ATPS), radyasyon onkolojisi yapay zekâ (YZ) tabanlı dönüşümün en önemli bileşenlerinden biri hâline gelmiştir. Bilgi tabanlı planlama (Knowledge-Based Planning, KBP), derin öğrenme (Deep Learning, DL) tabanlı doz tahmini ve tam otomatik optimizasyon motorlarındaki gelişmeler, planlayıcıya yüksek derecede bağımlı manuel iş akışlarından daha hızlı, standart ve tekrarlanabilir planlama süreçlerine geçişi mümkün kılmıştır. Bu sistemler, geçmişte klinik olarak onaylanmış planlardan ve hasta anatomilerinden öğrenerek dozimetri tutarlılığını artırmakta, planlama sürelerini belirgin biçimde azaltmakta ve adaptif radyoterapi gibi zaman kısıtlı klinik senaryoları desteklemektedir.

Bu çalışmada, ATPS'nin temel bileşenleri ayrıntılı olarak ele alınmış; KBP yaklaşımlarının prensipleri, ticari uygulamaları ve klinik kazanımları tartışılmıştır. Devamında DL tabanlı otomatik planlama yaklaşımları, özellikle voksel bazlı doz tahmini yapan U-Net ve DenseNet gibi mimariler bağlamında değerlendirilmiştir. DL tabanlı doz tahmin modellerinin, BT görüntüleri ve yapı maskeleri kullanarak hasta-özel, pürüzsüz ve klinik açıdan uygulanabilir doz dağılımları üretebildiği; bu tahminlerin ters planlama sürecine güçlü bir ön bilgi (prior) sağlayarak optimizasyonu daha kararlı ve verimli hâle getirdiği vurgulanmıştır.

Ayrıca tam otomatik planlama hatları kapsamında otomatik konturlama, ışın geometrisi seçimi, doz tahmini, optimizasyon ve otomatik kalite kontrol (QA) modüllerinin entegrasyonu ele alınmış; IMRT, VMAT ve proton/parçacık tedavilerinde kullanılan modern optimizasyon motorları incelenmiştir. Özellikle DL tabanlı robust doz tahmini ve Bayesçi optimizasyon yaklaşımlarının, proton tedavisinde menzil ve anatomik belirsizliklere karşı daha dayanıklı planlar oluşturma potansiyeli sunduğu gösterilmiştir. Son

1 Dicle Üniversitesi Tıp Fakültesi Radyasyon Onkolojisi Ana Bilim Dalı, ORCID: 000000205527587, mhdogan@dicle.edu.tr

olarak ATPS'nin klinik performansı, sınırlamaları ve geleceğe yönelik gelişim alanları tartışılarak, yapay zekâ destekli otomatik planlamanın radyoterapide kişiselleştirilmiş ve adaptif tedavi yaklaşımlarının temel yapı taşlarından biri hâline geldiği ortaya konmuştur.

1. GİRİŞ

Otomatik tedavi planlama sistemleri (Automatic Treatment Planning Systems-ATPS), radyasyon onkolojisinde yapay zekâ (YZ) tabanlı dönüşümün en önemli uygulama alanlarından birini oluşturmaktadır. Son on yılda bilgi tabanlı planlama (Knowledge-Based Planning, KBP), derin öğrenme (Deep Learning, DL) tabanlı doz tahmin yaklaşımları ve tamamen otomatik optimizasyon motorlarının gelişimi, planlayıcıya bağımlı manuel iş akışlarından daha standart, tekrarlanabilir ve yüksek kaliteli radyoterapi planlarına geçişi mümkün kılmıştır (Fogliata vd, 2017; Delaney & Barton, 2015).

Geleneksel manuel tedavi planlaması; doz-hacim hedeflerinin yinelenmeli olarak ayarlanmasını, planlanan hedef hacim (Planning Target Volume-PTV) ile risk altındaki organlar (Organ at Risk-OAR) arasındaki denge kararlarını, çok yapraklı kolimatör (Multi Leaf Collimator-MLC) konfigürasyonlarını ve ışın geometrilerinin seçimini gerektirir. Bu süreç hem zaman alıcıdır hem de planlayıcının deneyimine yüksek derecede bağımlıdır. Sonuç olarak plan kalitesi planlayıcılar ve merkezler arasında değişkenlik gösterebilmekte, bu durum klinik standardizasyonu sınırlamaktadır (Heijmen vd, 2018).

YZ destekli ATPS'ler, geçmişte onaylanmış planlardan, anatomik varyasyonlardan ve doz dağılımlarından öğrenerek planlama sürecini otomatikleştirmeyi ve standardize etmeyi amaçlar. Bu sistemler, planlama sürelerini önemli ölçüde azaltırken dozimetri tutarlılığını artırmakta ve hızlı plan revizyonlarına olanak tanıyarak adaptif radyoterapi iş akışlarını desteklemektedir (Babier vd, 2020)]. Varian RapidPlan, RayStation KBP modülleri ve 3D U-Net tabanlı DL sistemleri gibi ticari ve yarı-ticari çözümler, özellikle OAR korunması ve genel plan kalitesi açısından deneyimli planlayıcılarla karşılaştırılabilir sonuçlar bildirmiştir (Kazemifar vd, 2019; Moore ,2019 &Hussein vd, 2016).

2. Bilgi Tabanlı Planlama (KBP)

Bilgi tabanlı planlama, YZ destekli otomatik planlamanın klinikte en erken benimsenen ve en yaygın kullanılan yaklaşımlarından biridir. KBP sistemleri, daha önce klinik olarak onaylanmış geniş plan kütüphanelerinden elde edilen anatomik ve dozimetrik bilgileri kullanarak istatistiksel veya makine öğrenimi tabanlı modeller oluşturur. Bu modeller, yeni bir hastaya

ait geometrik özellikler üzerinden elde edilebilir, doz-hacim histogramlarını ((Dose Volume Histogram-DVH) ve optimizasyon hedeflerini öngörmeyi amaçlar (Zarepisheh vd, 2019).

2.1. KBP'nin Temel İlkeleri

KBP modelleri genellikle aşağıdaki girdilerden yararlanır:

- PTV–OAR mesafeleri ve örtüşme hacmi histogramları gibi anatomik tanımlayıcılar,
- Önceki planlardan elde edilen DVH noktaları ve doz düşüş metrikleri gibi dozimetrik özellikler,
- Rastgele destek vektör regresyonu ve temel bileşen analizi (PCA) tabanlı regresyon modelleri gibi makine öğrenimi algoritmaları.

Bu girdilerden türetilen DVH tahminleri, tedavi planlama sisteminde (TPS) optimizasyon hedeflerinin başlatılmasında kullanılır ve manuel ince ayar gereksinimini belirgin şekilde azaltır. Literatürde KBP kullanımının, planlama süresini yaklaşık %60–80 oranında azalttığı, buna karşın plan kalitesini koruduğu veya iyileştirdiği gösterilmiştir (Varian Medical Systems & RaySearch Laboratories).

2.2. Ticari KBP Platformları

Klinik pratikte yaygın olarak kullanılan KBP platformları arasında Varian RapidPlan ve RayStation KBP modülleri öne çıkmaktadır. RapidPlan, hasta geometrisine özgü DVH tahminleri üretmek için PCA ve regresyon ağaçlarını birleştiren bir yaklaşım kullanır (Elekta Technical Reports). RayStation KBP ise IMRT ve VMAT planlarında optimizasyon hedeflerini önceden belirlemek için makine öğrenimi regresyon modellerinden yararlanır (Zhang vd, 2020). Firmalar tarafından geliştirilen araştırma odaklı KBP modülleri ise atlas tabanlı öğrenme ve geometrik doz kestirimine ağırlık vermektedir (Kearney vd, 2020).

2.3. Derin Öğrenme Tabanlı Otomatik Planlama

DL yaklaşımları, ATPS kapasitesini yalnızca DVH tahmini ile sınırlı bir araç olmaktan çıkararak, doğrudan voksel bazlı doz tahmini ve tam otomatik plan üretimine uzanan kapsamlı bir çerçeveye dönüştürmüştür. Bu dönüşüm, radyoterapi planlamasında insan müdahalesini azaltmayı, planlama süresini kısaltmayı ve plan kalitesini daha tutarlı hâle getirmeyi amaçlayan güncel klinik gereksinimlerle doğrudan ilişkilidir.

Özellikle evrişimli sinir ağları (Convolutional Neural Networks, CNN), radyoterapi planlamasında anatomik bilgi ile doz dağılımı arasındaki karmaşık

doğrusal olmayan ilişkileri öğrenme konusunda yüksek başarı göstermiştir. Bu bağlamda üç boyutlu U-Net mimarileri, çok katmanlı kodlayıcı-çözücü yapıları sayesinde hem lokal anatomik detayları hem de global doz desenlerini aynı anda modelleyebilmekte ve voksel düzeyinde üç boyutlu doz dağılımlarını yüksek doğrulukla tahmin edebilmektedir. Son yıllarda ise transformatör tabanlı modellerin, uzun menzilli mekânsal ilişkileri daha etkin bir şekilde yakalayabilmesi sayesinde, özellikle karmaşık anatomilere sahip baş-boyun ve toraks bölgelerinde doz tahmin performansını daha da iyileştirdiği bildirilmiştir (Ibragimov & Xing, 2017; Fan vd, 2020).

Bu DL tabanlı modeller genellikle bilgisayarlı tomografi (BT) görüntüleri, hedef hacimler ve risk altındaki organlara ait segmentasyon maskeleri ile eğitilmekte; böylece hasta-özel anatomik özelliklere duyarlı doz tahminleri üretilebilmektedir. Elde edilen doz dağılımları, klasik bilgiye dayalı planlama (knowledge-based planning) yöntemlerine kıyasla daha yüksek mekânsal çözünürlükte bilgi sunarak optimizasyon sürecinin daha bilinçli ve yönlendirilmiş bir şekilde yürütülmesine olanak tanımaktadır (Nguyen vd, 2019).

Derin öğrenme tabanlı otomatik planlama yaklaşımlarının bir diğer önemli avantajı, klinik iş akışına entegrasyon kolaylığıdır. Eğitim süreci tamamlandıktan sonra doz tahminleri saniyeler mertebesinde üretilebilmekte ve bu durum özellikle adaptif radyoterapi ve çevrim içi (online) planlama senaryolarında kritik bir zaman kazanımı sağlamaktadır. Böylece DL tabanlı ATPS çözümleri, yalnızca planlama verimliliğini artırmakla kalmayıp, aynı zamanda daha standardize ve tekrarlanabilir tedavi planlarının klinik uygulamaya kazandırılmasına katkı sunmaktadır (Kontaxis 2015 vd, 2015).

2.3.1. Doz Tahmin Modelleri

Derin öğrenme (Deep Learning, DL) tabanlı otomatik tedavi planlama yaklaşımları, radyoterapide planlama sürecinin hızlandırılması ve standartlaştırılması açısından son yıllarda önemli bir dönüşüm yaratmıştır. Bu yaklaşımlar çoğunlukla **iki aşamalı bir mimari** izlemekte olup, ilk aşamada doz dağılımının doğrudan tahmini, ikinci aşamada ise bu tahminin ters planlama sürecine entegrasyonu hedeflenmektedir. Bu yapı, klasik manuel planlamanın deneyime dayalı ve yinelemeli doğasını büyük ölçüde ortadan kaldırarak daha sistematik ve tekrarlanabilir bir iş akışı sunmaktadır.

U-Net tabanlı mimariler, aşağı ve yukarı örnekleme katmanları arasındaki atlama bağlantıları (skip connections) sayesinde hem lokal hem de global anatomik bilgiyi koruyarak doz dağılımının uzamsal sürekliliğini sağlamaktadır. DenseNet tabanlı ağlar ise yoğun bağlantı yapıları sayesinde özellik tekrarını azaltmakta ve daha derin ağların etkin biçimde eğitilmesine olanak

tanınmaktadır. Bu mimariler, hedef hacimlerin (PTV) yeterli doz alması ile risk altındaki organların (OAR) korunması arasındaki karmaşık dengeyi aynı anda öğrenebilmekte ve bu dengeyi hasta-özel doz tahminlerine yansıtabilmektedir (Fan et al, 2020). Bu yönüyle DL tabanlı doz tahmin yaklaşımları, klasik bilgiye dayalı planlama (Knowledge-Based Planning, KBP) yöntemlerine kıyasla anatomik varyasyonlara daha esnek ve genellenebilir çözümler sunmaktadır.

Doz tahmin sürecinde ağırlar, genellikle büyük ölçekli ve kürasyonlu klinik veri setleri ile eğitilmektedir. Eğitim verileri; BT görüntüleri, yapı konturları, reçete dozları ve klinik olarak onaylanmış tedavi planlarını içermektedir. Uygun kayıp fonksiyonları (örneğin ortalama mutlak hata, doz-hacim histogramı tabanlı metrikler veya hibrit kayıp fonksiyonları) kullanılarak ağırların yalnızca doz değerlerini değil, aynı zamanda doz gradyanlarını ve pürüzsüzlük özelliklerini de öğrenmesi sağlanmaktadır. Bu sayede elde edilen doz tahminleri, klinik açıdan kabul edilebilir, gerçekçi ve fiziksel olarak uygulanabilir doz dağılımları sunmaktadır.

DL tabanlı doz tahmin modellerinin önemli bir katkısı, yalnızca nihai plan kalitesini öngörmekle sınırlı kalmamalarıdır. Aynı zamanda bu tahminler, optimizasyon sürecine güçlü bir **ön bilgi (prior)** sağlayarak ters planlama algoritmalarının daha etkin çalışmasına yardımcı olmaktadır. Bu durum, özellikle karmaşık anatomik bölgelerde ve çok sayıda OAR'ın yer aldığı vakalarda belirgin avantajlar sağlamaktadır (Kearney vd, 2018).

İkinci aşamada ise DL modelleri tarafından tahmin edilen üç boyutlu doz dağılımı, **ters planlama (inverse planning)** sürecini başlatmak veya yönlendirmek amacıyla tedavi planlama sistemi (Treatment Planning System, TPS) optimizasyon motoruna aktarılmaktadır. Tahmin edilen doz dağılımı, optimizasyon hedefleri ve kısıtları için başlangıç noktası olarak kullanılarak optimizasyon süresini anlamlı ölçüde kısaltmakta ve algoritmanın lokal minimumlara takılma riskini azaltmaktadır (Sheng et al, 2021). Bu yaklaşım, klasik optimizasyon süreçlerinde sıkça karşılaşılan parametre ayarlama zorluklarını da büyük ölçüde ortadan kaldırmaktadır.

DL destekli bu iki aşamalı yapı sayesinde, planlayıcıya olan bağımlılık azalmakta ve plan kalitesi daha tutarlı hâle gelmektedir. Özellikle farklı planlayıcılar arasında görülen subjektif karar farklılıklarının minimize edilmesi, klinik standartların korunması açısından önemli bir kazanım olarak değerlendirilmektedir (Sheng et al, 2021). Ayrıca bu yaklaşım, yüksek hasta hacmine sahip merkezlerde planlama iş yükünün azaltılmasına ve klinik verimliliğin artırılmasına katkı sağlamaktadır.

Literatürde yer alan çok sayıda çalışmada, prostat, akciğer ve baş-boyun kanserleri başta olmak üzere farklı anatomik bölgelerde DL tabanlı doz tahminine dayalı otomatik planların, manuel olarak oluşturulan planlara kıyasla **benzer veya daha iyi hedef kapsamı** sağladığı ve buna ek olarak **OAR dozlarının anlamlı düzeyde azaltılabildiği** gösterilmiştir (Craft et al, 2012). Bazı çalışmalarda, özellikle parotis, spinal kord ve rektum gibi doz hassasiyeti yüksek organlarda istatistiksel olarak anlamlı iyileşmeler rapor edilmiştir. Bu bulgular, DL tabanlı doz tahmin modellerinin yalnızca zaman kazandıran yardımcı araçlar değil, aynı zamanda plan kalitesini doğrudan artıran temel bileşenler olduğunu ortaya koymaktadır.

Klasik IMRT ve VMAT uygulamalarında DL tabanlı doz tahmin modelleri, planlama süresini anlamlı biçimde kısaltırken aynı zamanda hedef hacim kapsamı ve risk altındaki organların korunumu açısından daha tutarlı sonuçlar elde edilmesini sağlamaktadır. Bu durum, planlayıcılar arası varyasyonun azaltılması ve klinik protokollerin daha standart biçimde uygulanabilmesi açısından önemli bir kazanım olarak değerlendirilmektedir. Ayrıca bu modeller, optimizasyon sürecine güçlü bir ön bilgi sunarak lokal minimumlara takılma riskini azaltmakta ve yüksek kaliteli planların daha az iterasyonla elde edilmesine olanak tanımaktadır.

DL tabanlı doz tahmininin sunduğu en önemli avantajlardan biri de **adaptif radyoterapi** senaryolarındaki etkinliğidir. Fraksiyonlar arası anatomik değişimler, kilo kaybı, tümör regresyonu veya iç organ hareketleri gibi faktörler, sabit planlara dayalı tedavi yaklaşımlarında doz dağılımının klinik hedeflerden sapmasına neden olabilmektedir. Bu bağlamda doz tahmin modelleri, güncel hasta anatomisine hızlı biçimde uyarlatabilen hasta-özel doz dağılımlarının oluşturulmasını mümkün kılarak adaptif planlamanın klinik uygulanabilirliğini artırmaktadır. Özellikle çevrim içi (online) adaptif radyoterapi uygulamalarında, zaman kısıtları göz önünde bulundurulduğunda, DL tabanlı hızlı ve güvenilir doz tahmini kritik bir bileşen hâline gelmektedir.

Geleceğe yönelik olarak değerlendirildiğinde, doz tahmin modellerinin **biyolojik doz kavramları, fonksiyonel görüntüleme verileri ve gerçek zamanlı adaptasyon stratejileri** ile entegrasyonu, radyoterapide kişiselleştirilmiş tedavi yaklaşımlarını daha ileri bir düzeye taşıma potansiyeline sahiptir. Fonksiyonel MR, PET ve hipoksi haritaları gibi biyolojik bilgilerin doz tahmin sürecine dâhil edilmesi, yalnızca anatomik değil biyolojik olarak da optimize edilmiş doz dağılımlarının oluşturulmasına olanak tanıyabilir. Bunun yanı sıra gerçek zamanlı görüntüleme ve hızlı hesaplama altyapıları ile desteklenen DL modelleri, tedavi sırasında ortaya çıkan ani anatomik veya

fizyolojik değişimlere anlık yanıt verebilen adaptif stratejilerin geliştirilmesini mümkün kılabilir.

Sonuç olarak DL tabanlı doz tahmin modelleri, radyoterapide yalnızca bir otomasyon aracı olmanın ötesine geçerek, planlama kalitesini artıran, klinik karar süreçlerini destekleyen ve hasta-özel tedaviyi mümkün kılan temel bir teknoloji hâline gelmektedir. Bu modellerin sürekli gelişen yapay zekâ algoritmaları ve artan klinik veri birikimi ile birlikte, gelecekte radyoterapi planlamasının vazgeçilmez yapı taşlarından biri olarak daha merkezi bir rol üstlenmesi beklenmektedir.

2.3.2. Tam Otomatik Planlama Hatları

Gelişmiş otomatik tedavi planlama sistemleri (Automated Treatment Planning Systems, ATPS), radyoterapi planlamasını birbirinden bağımsız ve çoğu zaman manuel müdahaleye dayalı adımlar bütünü olmaktan çıkarak **uçtan uca entegre, kapalı döngü (closed-loop) bir iş akışı** hâline dönüştürmektedir. Bu yaklaşımda otomatik konturlama, ışın açısı ve alan konfigürasyonu seçimi, derin öğrenme (Deep Learning, DL) tabanlı doz tahmini, otomatik optimizasyon ve otomatik plan kalite kontrolü (Quality Assurance, QA) modülleri tek bir planlama hattı içerisinde ardışık ve uyumlu biçimde birleştirilmektedir. Böylece insan müdahalesine duyulan gereksinim en aza indirilirken, planlama sürecinin hız, tutarlılık ve tekrarlanabilirlik açısından belirgin biçimde iyileştirilmesi hedeflenmektedir.

Tam otomatik planlama hatlarının ilk ve en kritik basamağını genellikle **DL tabanlı otomatik konturlama sistemleri** oluşturmaktadır. Bu sistemler, planlama BT'si ve gerektiğinde MR veya PET gibi multimodal görüntüleri kullanarak hedef hacimleri (GTV, CTV, PTV) ve OAR yüksek doğruluk ve kısa süre içerisinde segmente edebilmektedir. Özellikle U-Net türevi derin sinir ağları, karmaşık anatomik yapılarda bile tutarlı kontur sonuçları üreterek planlama sürecinin en zaman alıcı ve planlayıcı bağımlılığı en yüksek adımlarından birini büyük ölçüde ortadan kaldırmaktadır. Otomatik konturlama sonuçlarının standartlaştırılması, sonraki planlama aşamalarının güvenilirliği açısından da temel bir ön koşul oluşturmaktadır.

Konturlamayı takiben, **ışın açısı seçimi ve alan geometrilerinin belirlenmesi** aşaması gelmektedir. Bu adım, klasik manuel planlamada büyük ölçüde planlayıcının deneyimine ve sezgisel kararlarına dayanırken, tam otomatik planlama hatlarında kural tabanlı algoritmalar veya geçmiş klinik plarlardan öğrenen yapay zekâ (YZ) modelleri aracılığıyla gerçekleştirilmektedir. Özellikle VMAT ve karmaşık IMRT vakalarında, ark sayısı, ark başlangıç ve bitiş açıları, kolimatör rotasyonu ve alan açıklıkları gibi parametreler otomatik olarak

optimize edilerek planlayıcıya bağımlılık önemli ölçüde azaltılmaktadır. Bu yaklaşım hem planlama süresini kısaltmakta hem de plan kalitesinin planlayıcılar arasında daha tutarlı olmasını sağlamaktadır.

Planlama hattının bir sonraki aşamasında **DL tabanlı doz tahmin modelleri** devreye girmektedir. Bu modeller, hasta anatomisine özgü üç boyutlu doz dağılımını saniyeler mertebesinde öngörebilmekte ve bu tahminleri optimizasyon süreci için güçlü bir başlangıç noktası olarak sunmaktadır. Tahmin edilen doz dağılımı, hedeflenen PTV kapsamı ile OAR korunması arasındaki dengeyi daha erken aşamada kurmayı mümkün kılarak optimizasyon sürecinin daha kararlı ve verimli ilerlemesini sağlamaktadır. Böylece ters planlama algoritmaları, rastgele veya sezgisel başlangıç koşulları yerine klinik açıdan anlamlı bir referans üzerinden çalıştırılabilmektedir.

Bunu takiben **otomatik optimizasyon modülleri**, doz tahminini referans alarak ışın ağırlıkları, MLC yaprak pozisyonları, segment yoğunlukları ve diğer optimizasyon parametrelerini iteratif olarak iyileştirmektedir. Bu süreçte gradyan tabanlı yöntemler, çok amaçlı optimizasyon algoritmaları veya pekiştirmeli öğrenme tabanlı yaklaşımlar kullanılabilmekte; böylece PTV–OAR dengesi klinik önceliklere uygun şekilde sağlanmaktadır. Otomatik optimizasyonun en önemli kazanımlarından biri, manuel ayarlama gereksinimini minimize ederek planlama sürecinin standartlaştırılmasına katkıda bulunmasıdır.

Tam otomatik planlama hatlarının ayırt edici ve tamamlayıcı bileşenlerinden biri de **otomatik plan kalite kontrolü (QA) modülleri**dir. Bu modüller, oluşturulan planları önceden tanımlanmış klinik protokoller, doz kısıtları ve geçmişte onaylanmış yüksek kaliteli planlarla sistematik olarak karşılaştırmaktadır. DVH metrikleri, doz homojenliği, konformite indeksleri ve OAR maksimum/ortalama dozları gibi parametreler otomatik olarak analiz edilmekte; potansiyel hatalar veya suboptimal sonuçlar erken aşamada tespit edilebilmektedir. Bazı gelişmiş sistemlerde, anomali tespiti için makine öğrenmesi tabanlı QA algoritmaları da kullanılmaktadır. Bu sayede planın klinik kullanıma uygunluğu, insan değerlendirmesine ek olarak **nesnel ve standardize edilmiş ölçütlerle** doğrulanmış olmaktadır.

Literatürde bildirilen çalışmalara göre, bu tür **entegre ve tam otomatik planlama hatları**, hasta başına planlama süresini birkaç dakikanın altına indirebilmekte ve özellikle yüksek hızlı **adaptif radyoterapi** uygulamalarını mümkün kılmaktadır (Tseng vd, 2020). Bu kazanım, günlük anatomik değişimlere yanıt verebilen çevrim içi adaptif radyoterapi senaryolarında kritik öneme sahiptir. Ayrıca hasta sayısının fazla olduğu merkezlerde, ATPS kullanımı planlama iş yükünü azaltarak klinik kaynakların daha etkin kullanılmasına olanak tanımaktadır.

Sonuç olarak tam otomatik planlama hatları, radyoterapide iş akışını yeniden tanımlayan dönüştürücü bir yaklaşım sunmaktadır. Bu sistemler, yalnızca hız ve verimlilik artışı sağlamakla kalmayıp, plan kalitesinin standartlaştırılması, insan kaynaklı varyasyonların azaltılması ve adaptif tedavi stratejilerinin klinik pratiğe entegrasyonu açısından da önemli avantajlar sunmaktadır. Bu bağlamda ATPS'nin, gelecekte radyoterapi planlamasının temel bileşenlerinden biri hâline gelmesi beklenmektedir.

2.4. IMRT, VMAT ve PBS için Optimizasyon Motorları

YZ destekli optimizasyon motorları, geleneksel olarak manuel ve yinelemeli şekilde ayarlanan planlama hedeflerini otomatikleştirerek planlayıcı bağımlılığını azaltır.

2.4.1. IMRT ve VMAT Optimizasyonu

IMRT (Intensity-Modulated Radiotherapy) ve VMAT (Volumetric Modulated Arc Therapy) teknikleri, radyoterapide yüksek doz konformitesi ve kritik organ korunumu sağlayabilen ileri tedavi yöntemleri olarak öne çıkmaktadır. Ancak bu tekniklerin sunduğu yüksek serbestlik derecesi, planlama sürecini son derece karmaşık hâle getirmekte ve çok sayıda parametrenin eşzamanlı olarak optimize edilmesini gerektirmektedir. Geleneksel planlama yaklaşımlarında bu süreç büyük ölçüde deneme-yanılma esasına dayalı olup, planlayıcının deneyimine ve bireysel tercihlerine bağımlı kalmaktadır. Bu durum hem planlama süresinin uzamasına hem de planlayıcılar arası belirgin varyasyonlara yol açabilmektedir.

Son yıllarda geliştirilen modern otomatik optimizasyon yaklaşımları, IMRT ve VMAT planlamasında bu sınırlılıkların aşılmasını hedefleyerek daha sistematik, tekrarlanabilir ve verimli çözümler sunmaktadır. Bu bağlamda güncel otomatik optimize ediciler; gradyan tabanlı optimizasyon yöntemleri, çok amaçlı evrimsel algoritmalar ve hedef hacim (PTV) ile risk altındaki organlar (OAR) arasındaki karmaşık denge ilişkisini öğrenebilen pekiştirmeli öğrenme (Reinforcement Learning, RL) tabanlı ajanlardan yararlanmaktadır (Giantsoudi vd, 2019). Bu yöntemler, klinik hedeflerin matematiksel olarak daha açık biçimde tanımlanmasına ve optimizasyon sürecinin insan müdahalesinden bağımsız olarak yürütülmesine olanak sağlamaktadır.

Gradyan tabanlı optimizasyon yöntemleri, IMRT ve VMAT planlamasında en yaygın kullanılan algoritmalar arasında yer almaktadır. Bu yaklaşımlar, tanımlanan doz-hedef fonksiyonlarının matematiksel türevlerini kullanarak ışın ağırlıkları, MLC (multileaf collimator) yaprak pozisyonları ve segment yoğunluklarını iteratif olarak günceller. Hesaplama açısından görece hızlı olmaları

ve deterministik bir yapı sunmaları, bu yöntemlerin klinik uygulamalarda tercih edilmesinin başlıca nedenlerindendir. Bununla birlikte, IMRT ve VMAT planlarında sıklıkla karşılaşılan çok sayıda rekabet eden klinik hedefin (örneğin PTV doz homojenliği ile OAR doz kısıtları arasındaki çelişkiler) varlığı, bu yöntemlerin lokal minimumlara takılma riskini artırmaktadır. Özellikle karmaşık anatomik bölgelerde, başlangıç koşullarına duyarlılık önemli bir dezavantaj olarak öne çıkmaktadır.

Bu sınırlamaları aşmak amacıyla geliştirilen çok amaçlı evrimsel algoritmalar, IMRT ve VMAT planlamasında güçlü bir alternatif yaklaşım sunmaktadır. Evrimsel algoritmalar, biyolojik evrim süreçlerinden esinlenerek oluşturulan popülasyon tabanlı optimizasyon yöntemleri olup, aynı anda birden fazla hedef fonksiyonun optimize edilmesine olanak tanımaktadır. Bu algoritmalar, farklı OAR–PTV denge çözümlerini içeren Pareto-optimal plan setleri oluşturarak, klinisyenlere plan seçimi aşamasında daha geniş ve esnek bir karar alanı sunmaktadır (Giantsoudi vd, 2019). Böylece planlama süreci yalnızca tek bir “en iyi” çözüme indirgenmek yerine, klinik önceliklere göre uyarlanabilir çok sayıda kabul edilebilir planın değerlendirilmesine imkân tanımaktadır. Bu yaklaşım, özellikle karmaşık baş-boyun ve pelvis vakalarında klinik karar verme sürecini destekleyici bir araç olarak önem kazanmaktadır.

Son yıllarda ise pekiştirmeli öğrenme tabanlı optimizasyon yaklaşımları, IMRT ve VMAT planlamasında giderek artan bir ilgi görmektedir. RL modelleri, planlama sürecini ardışık karar adımlarından oluşan bir öğrenme problemi olarak ele almakta ve her optimizasyon adımında elde edilen doz dağılımını bir ödül (reward) fonksiyonu aracılığıyla değerlendirmektedir. Bu ödül fonksiyonları genellikle PTV doz kapsamı, doz homojenliği, OAR doz kısıtlarının sağlanma derecesi ve klinik öncelikler gibi çok sayıda parametreyi birlikte içermektedir. Sistem, zaman içinde bu ödül geri bildirimleri sayesinde hangi optimizasyon adımlarının daha iyi klinik sonuçlara yol açtığını öğrenerek karar stratejisini geliştirmektedir.

RL tabanlı yaklaşımların en önemli avantajlarından biri, deneyimli planlayıcıların klinik tercihlerini ve stratejilerini dolaylı olarak öğrenebilme yeteneğidir. Bu sayede ışın ağırlıkları, segment yoğunlukları ve optimizasyon parametreleri, önceden tanımlanmış sabit kurallar yerine öğrenilmiş politikalar doğrultusunda otomatik olarak ayarlanabilmektedir. Literatürde, RL tabanlı modellerin deneyimli planlayıcılar tarafından oluşturulan ışın ağırlık konfigürasyonlarına oldukça benzer sonuçlar ürettiği, bazı vakalarda ise özellikle OAR korunumu açısından daha üstün doz dağılımları sağlayabildiği bildirilmiştir (Fredriksson, 2012). Ayrıca bu modellerin, adaptif radyoterapi

uygulamalarında değişen anatomik koşullara daha hızlı uyum sağlayabildiği de vurgulanmaktadır.

Tüm bu gelişmeler, IMRT ve VMAT planlamasında otomatik optimizasyonun yalnızca planlama süresini kısaltmakla kalmadığını, aynı zamanda plan kalitesini daha tutarlı hâle getirdiğini ve planlayıcılar arası varyasyonu belirgin biçimde azalttığını göstermektedir. Yapay zekâ destekli optimizasyon motorları, standartlaştırılmış klinik hedeflerin daha güvenilir biçimde sağlanmasına katkıda bulunurken, insan kaynaklı hataların ve subjektif kararların etkisini de minimize etmektedir. Dolayısıyla bu sistemler, özellikle yüksek hasta hacmine sahip merkezlerde, çok disiplinli ekiplerin iş yükünü azaltarak klinik iş akışının sürdürülebilirliğini desteklemekte ve adaptif radyoterapi gibi ileri uygulamaların rutin klinik pratiğe entegrasyonunda kritik bir rol üstlenmektedir.

2.4.2. Proton ve Parçacık Tedavi Planlaması

Proton ve diğer parçacık tedavi teknikleri, radyoterapide yüksek doz konformitesi ve çevre normal dokuların etkin biçimde korunması açısından foton temelli yöntemlere kıyasla önemli avantajlar sunmaktadır. Bu avantajların temelinde, yüklü parçacıkların dokuda ilerlerken enerjilerini büyük oranda hedef derinlikte bıraktıkları **Bragg piki** fenomeni yer almaktadır. Bragg piki sayesinde, hedef hacmin distalinde dozun hızlı biçimde düşmesi sağlanarak, özellikle kritik organların hedef hacme yakın konumlandığı klinik senaryolarda belirgin doz kazanımları elde edilebilmektedir. Bununla birlikte bu fiziksel üstünlük, proton ve parçacık tedavilerinde planlama sürecini daha hassas ve karmaşık hâle getirmektedir.

Günümüzde proton tedavisinde yaygın olarak kullanılan **proton kalem demet taraması (Pencil Beam Scanning, PBS)** tekniği, yüksek doz şekillendirme esnekliği sunmasına karşın çeşitli belirsizlik kaynaklarına son derece duyarlıdır. Hasta konumlandırma hataları, solunum ve iç organ hareketleri, doku heterojeniteleri, BT yoğunluk dönüşüm hataları ve zaman içinde ortaya çıkan anatomik değişimler, proton menziline sapmalara yol açabilmektedir. Bu menzil belirsizlikleri, hedef hacimde yetersiz doz kapsamı veya kritik organlarda beklenmeyen doz artışları ile sonuçlanabilmektedir. Dolayısıyla proton tedavi planlamasında **sağlamlık (robustness)** kavramı, yalnızca plan kalitesini değil aynı zamanda tedavinin klinik güvenliğini belirleyen temel bir kriter hâline gelmiştir.

Klasik proton planlama yaklaşımlarında sağlamlık, genellikle belirli senaryolar altında (örneğin $\pm$ konum hataları ve $\pm$ menzil belirsizlikleri) gerçekleştirilen **senaryo tabanlı robust optimizasyon** yöntemleri ile ele

alınmaktadır. Ancak bu yöntemler, senaryo sayısının artmasıyla birlikte ciddi hesaplama yükü oluşturmakta ve klinik iş akışını yavaşlatabilmektedir. Ayrıca senaryo seçiminin sınırlı olması, gerçek klinik varyasyonların tamamının yeterince temsil edilememesi riskini de beraberinde getirmektedir.

Bu noktada **derin öğrenme (Deep Learning, DL)** tabanlı yaklaşımlar, proton ve parçacık tedavi planlamasında karşılaşılan bu zorlukların üstesinden gelmek amacıyla giderek daha fazla ilgi görmektedir. DL tabanlı sistemler, büyük ölçekli klinik veri setlerinden hasta anatomisi, doku yoğunluk dağılımları ve önceki tedavi planları arasındaki karmaşık ilişkileri öğrenebilmektedir (Barragan vd, 2019). Bu sayede olası menzil sapmalarını, geometrik belirsizlikleri ve anatomik varyasyonları dolaylı olarak hesaba katan **sağlam doz dağılımlarını** önceden tahmin edebilmekte ve bu doğrultuda optimal spot yerleşimi ile spot ağırlıklarının belirlenmesini desteklemektedir (Sterpin vd, 2024).

DL tabanlı robust doz tahmini yaklaşımlarının önemli bir avantajı, klasik optimizasyon algoritmalarına kıyasla hesaplama süresini belirgin biçimde azaltmasıdır. Eğitim aşaması tamamlandıktan sonra, bu modeller yeni bir hasta için kısa sürede klinik olarak kabul edilebilir doz dağılımları üretebilmekte ve planlama sürecinin hızlandırılmasına katkı sağlamaktadır. Ayrıca bu sistemler, planlayıcı deneyimine olan bağımlılığı azaltarak plan kalitesinin daha tutarlı hâle gelmesine yardımcı olmaktadır. Literatürde DL tabanlı proton planlama modellerinin, senaryo tabanlı robust optimizasyon sonuçlarıyla karşılaştırıldığında benzer ya da bazı durumlarda daha üstün hedef kapsaması ve OAR korunumu sağlayabildiği bildirilmiştir (Sterpin vd, 2024).

Proton ve diğer parçacık tedavi tekniklerinde belirsizliklerin yalnızca geometrik ve fiziksel faktörlerle sınırlı olmaması, optimizasyon sürecinin daha kapsamlı biçimde ele alınmasını gerekli kılmaktadır. Bu bağlamda **Bayesçi optimizasyon yöntemleri**, belirsizliklerin istatistiksel olarak modellenmesine olanak tanıyan güçlü bir çerçeve sunmaktadır. Bayesçi yaklaşımlarda, proton menzil hataları, hasta içi anatomik değişimler, fraksiyonlar arası varyasyonlar ve hatta biyolojik etkinlikteki farklılıklar olasılıksal dağılımlar üzerinden temsil edilmektedir. Optimizasyon süreci, bu olasılıksal modeller doğrultusunda beklenen riskin minimize edilmesi veya klinik hedeflerin en yüksek olasılıkla sağlanması prensibine göre yönlendirilmektedir (Cagni vd, 2017).

Bayesçi optimizasyonun en önemli katkılarından biri, yalnızca fiziksel doz dağılımının değil, aynı zamanda **biyolojik doz belirsizliklerinin** de hesaba katılabilmesidir. Özellikle proton ve ağır iyon tedavilerinde, göreceli biyolojik etkinlik (Relative Biological Effectiveness, RBE) değerlerinin sabit kabul edilmesi önemli bir belirsizlik kaynağıdır. Bayesçi çerçeve, RBE'deki olası değişkenlikleri istatistiksel olarak modelleyerek, biyolojik etkin dozun daha

güvenilir biçimde optimize edilmesini mümkün kılmaktadır. Bu yaklaşım, ileri düzey parçacık tedavilerinde biyolojik etkilerin tedavi planlamasına entegrasyonu açısından önemli bir adım olarak değerlendirilmektedir (Cagni vd, 2017).

Sonuç olarak, **DL tabanlı robust doz tahmini** ile **Bayesçi optimizasyon yaklaşımlarının** entegrasyonu, proton ve parçacık tedavi planlamasında daha güvenilir, hasta-özel ve klinik açıdan tutarlı planların üretilmesini mümkün kılmaktadır. Bu yöntemler, hem hesaplama verimliliğini artırmakta hem de belirsizliklere karşı daha dayanıklı planların oluşturulmasına katkı sağlamaktadır. Özellikle **adaptif proton tedavisi**, fraksiyonlar arası anatomik değişimlerin yönetimi ve gelecekteki **biyolojik olarak yönlendirilmiş parçacık tedavisi** uygulamalarında bu yaklaşımların merkezi bir rol üstlenmesi beklenmektedir. Yapay zekâ destekli bu ileri optimizasyon stratejileri, proton ve parçacık tedavilerinin klinik güvenliğini ve etkinliğini daha da artırma potansiyeline sahiptir.

2.5. Otomatik Planlamanın Klinik Performansı

Literatürde yer alan çok sayıda sistematik derleme ve karşılaştırmalı çalışma, YZ tabanlı APTS kullanımının daha tutarlı planlar, daha kısa planlama süreleri ve çoğu durumda manuel planlara kıyasla daha iyi OAR korunması sağladığını ortaya koymuştur (Liu vd, 2020). Baş-boyun kanserlerinde KBP kullanımının parotis bezlerinin ortalama dozunu %10–25 oranında azalttığı bildirilmiştir (Krayenbuehl vd, 2015). DL tabanlı planlama yaklaşımları ise klinik standartlara göre $\pm\%1$ sapma içinde tutarlı PTV kapsamı sağlamıştır (Younge vd, 2018).

2.6. Sınırlamalar ve Zorluklar

APTS'nin klinik uygulamalarındaki temel zorluklar arasında yüksek kaliteli ve temsil edici eğitim verilerine olan bağımlılık, merkezler arası protokol farklılıkları nedeniyle sınırlı genellenebilirlik ve klinik kullanım için gerekli düzenleyici doğrulama süreçleri yer almaktadır (Sherer vd, 2021). Ayrıca otomasyon yanlılığı, yani klinisyenlerin YZ çıktılarının doğruluğunu yeterince sorgulamadan kabul etmesi riski, dikkatle ele alınması gereken önemli bir konudur (Shiraishi vd 2015).

2.7. Gelecek Yönelimleri

Gelecekte APTS alanında insan–YZ iş birliğine dayalı etkileşimli planlama arayüzlerinin geliştirilmesi, federated learning yaklaşımları ile merkezler arası veri paylaşımı olmadan model performansının artırılması ve tedavi sırasında

gerçek zamanlı adaptif planlamanın klinik rutine entegrasyonu beklenmektedir. Ayrıca radyomik özelliklerin ve biyolojik doz-yanıt modellerinin ATPS ile bütünleştirilmesi, kişiselleştirilmiş radyoterapi planlamasında önemli bir adım olarak görülmektedir (Mcintosh vd, 2021; Li vd, 2023; Kawabata vd, 2022; Yue vd, 2022)

3. Sonuç

Otomatik Tedavi Planlama Sistemleri (ATPS), radyoterapi planlamasında manuel, deneyime dayalı ve zaman alıcı iş akışlarının yerini; daha hızlı, standartlaştırılmış ve tekrarlanabilir yaklaşımlarla değiştiren dönüştürücü bir teknoloji olarak öne çıkmaktadır. Bilgi tabanlı planlama ve derin öğrenme tabanlı doz tahmin modelleri, planlayıcıya olan bağımlılığı azaltırken hedef hacim kapsamı ve risk altındaki organ korunumu açısından daha tutarlı ve hasta-özel planların üretilmesini mümkün kılmaktadır.

Özellikle derin öğrenme tabanlı doz tahmini, optimizasyon sürecine güçlü bir ön bilgi sağlayarak planlama verimliliğini artırmakta, lokal minimumlara takılma riskini azaltmakta ve adaptif radyoterapi gibi zaman kısıtlı klinik senaryolarda önemli avantajlar sunmaktadır. Tam otomatik planlama hatlarının gelişimiyle birlikte otomatik konturlama, optimizasyon ve kalite kontrol modüllerinin entegrasyonu, klinik iş akışını daha güvenilir ve sürdürülebilir hâle getirmektedir.

Sonuç olarak ATPS, radyoterapide planlama kalitesini artıran bir otomasyon aracı olmanın ötesinde, kişiselleştirilmiş ve adaptif tedavi yaklaşımlarının klinik pratiğe entegrasyonunu destekleyen temel bir yapı taşı hâline gelmiştir. Gelecekte yapay zekâ tabanlı modellerin gelişimi ve klinik veri birikiminin artmasıyla birlikte, ATPS'nin radyoterapi planlamasında daha merkezi bir rol üstlenmesi beklenmektedir.

Kaynaklar

- Fogliata, A., Reggiori, G., Stravato, A., Lobefalo, F., Franzese, C., Franceschini, D., Tomatis, S., Mancosu, P., Scorsetti, M., & Cozzi, L. (2017). *RapidPlan head and neck model: the objectives and possible clinical benefit*. **Radiation Oncology**, 12, 73. <https://doi.org/10.1186/s13014-017-0808-x>
- Delaney, G. P., & Barton, M. B. (2015). *Evidence-based estimates of the demand for radiotherapy*. **Clinical Oncology**, 27(2), 70–76. <https://doi.org/10.1016/j.clon.2014.10.005>
- Heijmen, B., Voet, P., Fransen, D., Penninkhof, J., Milder, M., Akhlat, H., ... & Verbakel, W. F. A. R. (2018). *Fully automated, multi-criterial planning for volumetric modulated arc therapy – An international multi-center validation for prostate cancer*. **Radiotherapy and Oncology**, 128(2), 343–348. <https://doi.org/10.1016/j.radonc.2018.06.023>
- Babier, A., Mahmood, R., McNiven, A. L., Diamant, A., Chan, T. C. Y., ... & McIntosh, C. (2020). *Knowledge-based automated planning with three-dimensional generative adversarial networks*. **Medical Physics**, 47(??), 297–306. <https://doi.org/10.1002/mp.12930>
- Kazemifar, S., McGuire, S., Timmerman, R., Wardak, Z., Nguyen, D., Park, Y., Jiang, S., & Owringi, A. (2019). *MRI-only brain radiotherapy: Assessing the dosimetric accuracy of synthetic CT images generated using a deep learning approach*. **Radiotherapy and Oncology**, 136, 56–63. <https://doi.org/10.1016/j.radonc.2019.03.026>
- Moore, K. L. (2019). *Automated radiotherapy treatment planning*. **Seminars in Radiation Oncology**, 29(3), 209–218. <https://doi.org/10.1016/j.semradonc.2019.02.003>
- Hussein M, et al. Radiother Oncol. Hussein, M., South, C. P., Barry, M. A., Adams, E. J., Jordan, T. J., Stewart, A. J., & Nisbet, A. (2016). *Clinical validation and benchmarking of knowledge-based IMRT and VMAT treatment planning in pelvic anatomy*. **Radiotherapy and Oncology**, 120(3), 473–479. <https://doi.org/10.1016/j.radonc.2016.08.006>
- Zarepisheh, M., Hong, L., Zhou, Y., Oh, J. H., Mechalakos, J. G., Hunt, M. A., Mageras, G. S., & Deasy, J. O. (2019). *Automated intensity modulated treatment planning: The expedited constrained hierarchical optimization (ECHO) system*. **Medical Physics**, 46(7), 2944–2954. <https://doi.org/10.1002/mp.13572>
- Varian Medical Systems. (n.d.). *RapidPlan™: Knowledge-based treatment planning*. Palo Alto, CA: Varian Medical Systems.
- RaySearch Laboratories. (n.d.). *Knowledge-based planning (KBP) documentation*. Stockholm, Sweden: RaySearch Laboratories.
- Elekta. (n.d.). *R&D technical reports*. Stockholm, Sweden: Elekta AB. Retrieved from <https://www.elekta.com>

- Zhang, L., Li, X., Sheng, Y., Chang, Y., Yin, F-F, Ge, Y., ... *et al.* (2020). *Automatic IMRT planning via static field fluence prediction (AIP-SFFP): a deep learning algorithm for real-time prostate treatment planning*. **Physics in Medicine & Biology**, **65**(17), 175014. <https://doi.org/10.1088/1361-6560/ab9a70>
- Kearney, V., Chan, J. W., Valdes, G., Solberg, T. D., & Yom, S. S. (2020). *The application of artificial intelligence in the IMRT planning process for radiotherapy*. **Radiotherapy and Oncology**, **147**, 43–55. <https://doi.org/10.1016/j.radonc.2020.02.020>
- Ibragimov, B., & Xing, L. (2017). *Segmentation of organs-at-risk in radiotherapy: A review of deep learning methods*. **Medical Physics**, **44**(2), e1–e23. <https://doi.org/10.1002/mp.12161>
- Fan, J., Wang, J., Chen, Z., Hu, C., Zhang, Z., & Hu, W. (2020). *Automatic treatment planning based on three-dimensional dose distribution predicted from deep learning*. **Radiotherapy and Oncology**, **147**, 121–129. <https://doi.org/10.1016/j.radonc.2020.03.012>
- Nguyen, D., Jia, X., Sher, D., Lin, M. H., Iqbal, Z., Liu, H., & Jiang, S. (2019). *3D radiotherapy dose prediction on head and neck cancer patients with a hierarchically densely connected U-net deep learning architecture*. **Physics in Medicine & Biology**, **64**(6), 065020. <https://doi.org/10.1088/1361-6560/ab039b>
- Kontaxis, C., Bol, G. H., Lagendijk, J. J. W., & Raaymakers, B. W. (2015). *Towards fast online adaptive radiotherapy: automatic planning for multiple treatment sites*. **Physics in Medicine & Biology**, **60**(18), 6985–7003. <https://doi.org/10.1088/0031-9155/60/18/6985>
- Barragán-Montero, A. M., Nguyen, D., Lu, W., Lin, M.-H., Norouzi-Kandalan, R., Geets, X., & Sterpin, E. (2019). *Three-dimensional dose prediction for VMAT using deep learning: A feasibility study*. **Physica Medica**, **59**, 22–29. <https://doi.org/10.1016/j.cjmp.2019.02.017>
- Barragán-Montero, A. M., Nguyen, D., Lu, W., Lin, M. H., Norouzi-Kandalan, R., Geets, X., & Sterpin, E. (2021). *Three-dimensional dose prediction for radiotherapy using deep learning: A systematic review*. **Radiotherapy and Oncology**, **159**, 185–198. <https://doi.org/10.1016/j.radonc.2021.03.014>
- Kearney, V., Chan, J. W., Haaf, S., Descovich, M., & Solberg, T. D. (2018). *DoseNet: A volumetric dose prediction algorithm using 3D fully-convolutional neural networks*. **Physics in Medicine & Biology**, **63**(23), 235022. <https://doi.org/10.1088/1361-6560/aac9f7>
- Sheng, Y., Li, T., Wang, J., Zhang, J., & Yin, F-F (2021). *Automatic treatment planning for head and neck cancer using deep learning-based dose prediction*. **Medical Physics**, **48**(9), 5520–5531. <https://doi.org/10.1002/mp.15106>

- Craft, D., McQuaid, D., Wala, J., Chen, W., Salari, E., & Bortfeld, T. (2012). *Multicriteria optimization methods for radiotherapy treatment planning. Physics in Medicine & Biology*, 57(5), 1219–1237. <https://doi.org/10.1088/0031-9155/57/5/1219>
- Tseng, H., Lee, H., Chen, Y., Wang, Y., & Li, S. (2020). *Deep learning-based automated radiotherapy treatment planning for prostate cancer. Medical Physics*, 47(9), 4041–4052. <https://doi.org/10.1002/mp.14377>
- Giantsoudi, D., Ziegenhein, P., Jiang, S., & Paganetti, H. (2019). *Intensity modulated proton therapy treatment planning using deep learning-based dose prediction. Medical Physics*, 46(10), 4266–4277. <https://doi.org/10.1002/mp.13730>
- Fredriksson, A. (2012). *A characterization of robust radiation therapy treatment planning methods—from expected value to worst case optimization. Radiotherapy and Oncology*, 104(2), 154–160. <https://doi.org/10.1016/j.radonc.2012.06.010>
- Sterpin, E., et al. (2024). *Robustness evaluation of pencil beam scanning proton therapy plans accounting for geometric and range uncertainties. Radiotherapy and Oncology*, 176, 110409. <https://doi.org/10.1016/j.radonc.2024.110409>
- Cagni, E., Botti, A., Micera, R., Galeandro, M., Sghedoni, R., Orlandi, M., ... & Heijmen, B. J. (2017). *Automation in intensity-modulated radiotherapy treatment planning: Recent innovations and feasibility studies. Radiotherapy & Oncology*, 125(3), 375–378. <https://doi.org/10.1016/j.radonc.2017.10.035>
- Liu, Z., Chen, X., Men, K., Yi, J., & Dai, J. (2020). *A deep learning model to predict dose–volume histograms of organs at risk in radiotherapy treatment plans. Medical Physics*, 47(11), 5467–5481. <https://doi.org/10.1002/mp.14394>
- Krayenbuehl, J., Norton, I., Studer, G., & Guckenberger, M. (2015). *Evaluation of an automated knowledge based treatment planning system for head and neck. Radiation Oncology*, 10(1), 226. <https://doi.org/10.1186/s13014-015-0533-2>
- Younge, K. C., Marsh, R. B., Owen, D., Geng, H., Xiao, Y., Spratt, D. E., Foy, J., Suresh, K., Wu, Q. J., Yin, F.-F., Ryu, S., & Matuszak, M. M. (2018). *Improving quality and consistency in NRG Oncology Radiation Therapy Oncology Group 0631 for spine radiosurgery via knowledge-based planning. International Journal of Radiation Oncology Biology Physics*, 100(4), 1067–1074. <https://doi.org/10.1016/j.ijrobp.2017.12.276>
- Sherer, M. V., Lin, D., Elguindi, S., Duke, S., Tan, L.-T., Cacicedo, J., Dahele, M., & Gillespie, E. F. (2021). *Metrics to evaluate the performance of auto-segmentation for radiation treatment planning: A critical review. Ra-*

- radiotherapy & Oncology**, **160**, 185–191. <https://doi.org/10.1016/j.radonc.2021.05.003>
- Shiraishi, S., Tan, J., Olsen, L. A., & Moore, K. L. (2015). *Knowledge-based prediction of plan quality metrics in intracranial stereotactic radiosurgery*. **Medical Physics**, **42**(2), 908–917. <https://doi.org/10.1118/1.4906183>
- McIntosh, C., Conroy, L., Tjong, M. C., Cheung, J., ... & Deasy, J. O. (2021). *Clinical integration of machine learning for curative-intent radiation treatment of patients with prostate cancer*. **Nature Medicine**, **27**(6), 999–1005. <https://doi.org/10.1038/s41591-021-01359-w>
- Li, Y., Cai, W., Xiao, F., Ding, S., & Cao, W. (2023). *Simultaneous dose distribution and fluence prediction for nasopharyngeal carcinoma IMRT*. **Radiotherapy & Oncology**, **18**(110), Article 110. <https://doi.org/10.1186/s13014-023-02401-0>
- Kawabata, F., Kamomae, T., Okudaira, K., Komori, M., ... & Naganawa, S. (2022). *Development of a high-resolution two-dimensional detector-based dose verification system for tumor-tracking irradiation in the CyberKnife system*. **Journal of Applied Clinical Medical Physics**, **23**, e13645. <https://doi.org/10.1002/acm2.13645>
- Yue, M., Xue, X., Wang, Z., & Qin, W. (2022). *Dose prediction via distance-guided deep learning: Initial development for nasopharyngeal carcinoma radiotherapy*. **Radiotherapy & Oncology**, **170**, 198–204. <https://doi.org/10.1016/j.radonc.2022.03.012>

**Tıbbi Radyasyon Cihazları:
Klinik Uygulamalar ve Yapay Zekâ Tabanlı Yaklaşımlar**

Editörler:

Dr. Öğr. Üyesi Süreyya NUR

Doç. Dr. Turan ŞAHMARAN