DERLEME
DOI:10.4274/nts.galenos.2026.69885
Nucl Med Semin 2026;12:208-214

Nükleer Tıpta Teranostik ve Dozimetri Uygulamalarında Yapay Zekanın Rolü

The Role of Artificial Intelligence in Theranostic and Dosimetry Applications in Nuclear Medicine

İnci Uslu Biner

Eskişehir Osmangazi Üniversitesi Tıp Fakültesi, Nükleer Tıp Anabilim Dalı, Eskişehir, Türkiye

Öz

Modern moleküler görüntüleme modalitelerinin klinik kullanıma girmesiyle nükleer tıp görüntülemelerinde üretilen verinin hacmi ve karmaşıklığı hızla artmıştır. Yapay zeka (YZ) uygulamaları, teranostik iş akışında hasta seçiminden görüntü yorumlamaya, organ ve tümör segmentasyonuna, hastaya özgü dozimetriye ve tedavi yanıtının izlenmesine kadar geniş kapsamlı bir otomasyon potansiyeli sunmaktadır. YZ algoritmaları, tanısal moleküler görüntüleme verilerinin değerlendirilmesi ve tedavi sonrası hastaya özgü dozimetri uygulamalarının geliştirilmesine katkıda bulunabilir. Bu derlemede YZ'nin teranostik görüntüleme, otomatik segmentasyon, hızlı ve voksel düzeyinde dozimetri, prediktif dozimetri ve adaptif tedavi planlamasındaki rolü güncel literatür ışığında ele alınmaktadır.

Anahtar Kelimeler: Yapay zeka, derin öğrenme, teranostik, radyofarmasötik tedavi, radyasyon dozimetresi

Abstract

With the clinical integration of modern molecular imaging modalities, the volume and complexity of data generated in nuclear medicine have increased rapidly. Implementing artificial intelligence (AI) in the theranostic workflow offers the potential for comprehensive automation across patient selection, image interpretation, organ and tumor segmentation, personalized dosimetry, and treatment response monitoring. AI algorithms can support the evaluation of diagnostic molecular imaging data and the development of post-treatment personalized dosimetry. This review examines the role of AI in theranostic imaging, automated segmentation, accelerated voxel-level dosimetry, predictive dosimetry, and adaptive treatment planning.

Keywords: Artificial intelligence, deep learning, theranostics, radiopharmaceutical therapy, radiation dosimetry

Giriş

Pozitron emisyon tomografisi/bilgisayarlı tomografi (PET/BT), tek foton emisyon bilgisayarlı tomografi/BT (SPECT/BT) ve PET/manyetik rezonans görüntüleme gibi hibrit moleküler görüntüleme modalitelerinin klinik kullanıma girmesiyle üretilen verinin hacmi ve karmaşıklığı hızla artmıştır (1). Bu verilerin klinik faydaya dönüşmesi için nükleer tıp terminolojisinin ve veri toplama süreçlerinin standardizasyonu, araştırmaların ve teranostik uygulamaların gelişimi açısından önem taşımaktadır (2). Yapay zeka (YZ), makine öğrenimi (MÖ) ve derin öğrenme (DÖ) algoritmalarıyla çok parametreli klinik ve görüntüleme bulgularından biyobelirteçler türeterek hastaya özgü teranostik yaklaşımlara zemin hazırlamaktadır. Ancak, teranostik alanındaki YZ uygulamaları hala erken geliştirme aşamasındadır ve çeşitli zorluklar barındırmaktadır (3). RELAINCE kılavuzları, tanımlayıcı YZ sistemleri için retrospektif çalışmaların yeterli olduğunu, doğrudan klinik müdahale öneren preskriptif YZ algoritmaları için ise prospektif çalışmaların

Sorumlu Yazar/Corresponding Author
Dr. Öğr. Üyesi İnci Uslu Biner,
Eskişehir Osmangazi Üniversitesi Tıp Fakültesi, Nükleer Tıp Anabilim Dalı, Eskişehir, Türkiye
E-posta: inciuslu@yahoo.com **ORCID ID:** orcid.org/0000-0002-8460-6004

Geliş Tarihi/Received: 30.09.2026 **Kabul Tarihi/Accepted:** 04.11.2026 **Yayınlanma Tarihi/Publication Date:** 26.11.2026

Cite this article as/Atıf: Uslu Biner İ. The role of artificial intelligence in theranostic and dosimetry applications in nuclear medicine. Nucl Med Semin. 2026;12:208-214

Copyright© 2026 Yazar(lar). Türkiye Nükleer Tıp Derneği adına Galenos Yayınevi tarafından yayımlanmıştır.
Creative Commons Atıf-GayriTicari 4.0 (CC BY-NC 4.0) Uluslararası Lisansı ile lisanslanmış, açık erişimli bir makaledir.

Copyright© 2026 The Author(s). Published by Galenos Publishing House on behalf of Turkish Society of Nuclear Medicine.
This is an open access article under the Creative Commons Attribution Non-Commercial 4.0 International (CC BY-NC 4.0) License.

önerildiğini belirtmektedir (4). Gürültü giderilmesinden aktivite ölçümüne ve zaman-aktivite eğrilerinin üretimine uzanan aşamaların otomatikleştirilmesi, dozimetri veri akışını daha hızlı ve tekrarlanabilir hale getirebilir (5).

1. YZ Destekli Görüntüleme

1.1. Görüntü Rekonstrüksiyonu ve Görüntü Kalitesinin İyileştirilmesi

Düşük sayım istatistikleri, hasta hareketi ve kısaltılmış çekim süresi gürültüyü artırarak kantitatif doğruluğu olumsuz etkilemektedir. Bu durum, radyoligand tedavisi sonrasındaki seri SPECT görüntülemede belirgindir. Rydén ve ark. (6) DÖ tabanlı rekonstrüksiyon yaklaşımlarının ^{177}Lu SPECT görüntülerinde gürültüyü azaltıp görüntü kalitesini iyileştirerek, seyrek projeksiyonlardan yüksek kaliteli görüntü elde edilebileceğini ve görüntüleme süresinin belirgin biçimde azaltılabileceğini göstermiştir. Evrişimli sinir ağı [*convolutional neural network* (CNN)] ve U-Net tabanlı yaklaşımlar ^{177}Lu SPECT'te kantitatif doğruluğu artırabilmektedir (7). Düşük doz veya düşük sayımlı PET görüntülerinden standart doz kalitesinde görüntü elde etmeyi amaçlayan DÖ modelleri de geliştirilmiştir. Dört kat azaltılmış sayımla yürütülen, çok merkezli ve harici doğrulamalı bir çalışma, DÖ tabanlı yöntemlerin düşük sayımlı PET görüntülerinde görüntü kalitesini ve tanısal performansı koruyabildiğini göstermektedir (8). Görsel iyileştirme her zaman doğru kantitatif bilgi sağlamayabilir. Görüntü iyileştirme yöntemleri, görsel kalitenin yanı sıra kantitatif doğruluk üzerindeki etkileriyle de değerlendirilmelidir. Bu modellerin değerlendirilmesinde görüntü kalitesinin ve kantitatif doğruluğun uygun ölçütlerle ve dağılım dışı örneklerde de test edilmesi gerekmektedir (9). Üretken çekişmeli ağlar (*generative adversarial networks*, GAN) ve difüzyon tabanlı modeller bu alanda öne çıkmaktadır. Difüzyon tabanlı PET tutarlılık modeliyle düşük doz girdiden tam doz tüm vücut PET görüntüsü sentezlenmiş ve önceki yöntemlere göre daha düşük hesaplama maliyetiyle yüksek kaliteli görüntüler elde edilmiştir (10). Bu olumlu bulgulara karşın, sonuçların belirli bir çalışma düzenine ve veri kümesine ait olması nedeniyle eğitim dağılımı dışındaki (*out-of-distribution*) başka tarayıcılar, radyofarmasötikler ve hasta popülasyonlarındaki performansları ayrıca araştırılmalıdır (11). Üretken modellerde gerçeğe yakın görünen ancak anatomik ve işlevsel gerçekliği yanlış temsil eden içeriklerin sentezlenmesi (halüsinasyon), tanısal doğruluğu ve klinik güveni bozabilmektedir (12).

1.2. YZ Destekli Atenüasyon Düzeltmesi

Atenüasyon düzeltmesi, PET ve SPECT görüntülerinin doğru kantitatif değerlendirilmesi için önemlidir (13). Seri görüntülemede tekrarlanan PET/BT incelemeleri kümülatif radyasyon maruziyetine yol açabildiğinden, BT taramalarının azaltılması veya atlanması, bu maruziyeti azaltabilir (14). YZ tabanlı yöntemler anatomik bilgiden yararlanarak sentetik BT (psödo-BT) görüntüleri üretebilmektedir (15). Ayrıca, yapısal bilgi olmadan DÖ ile doğrudan atenüasyon düzeltilmiş görüntü tahmini de araştırılmaktadır (13). Bu yaklaşımın kantitatif performansı bölgeye göre değişebilmektedir. Wyatt ve ark. (16) sentetik atenüasyon düzeltmesinin yumuşak doku ve prostat lezyonlarında iyi kantitatif uyum gösterebildiğini, ancak kemik dokusundaki sapmaların dikkate alınması gerektiğini göstermiştir.

2. YZ ile Kantifikasyon

2.1. Otomatik Organ ve Tümör Segmentasyonu

Segmentasyon, hastaya özgü dozimetrinin önemli bir adımıdır. Bölge sınırlarındaki hatalar absorbe edilen doz tahminlerinde değişkenliğe yol açabilmektedir (17). Manuel segmentasyon zaman alıcıdır ve gözlemciler arası tutarlılığı düşüktür. PET/BT'de organ ve lezyon segmentasyonu için U-Net ve benzeri CNN mimarilerinin kullanımı yaygın olarak araştırılmaktadır (18). Prostat spesifik membran antijeni (PSMA) hedefli görüntüleme, YZ tabanlı segmentasyonun teranostikteki önemli örneklerinden biridir. ^{68}Ga-PSMA PET'te U-Net tabanlı modellerle intraprostatik tümör hacmi belirlenebilmektedir (19). Klinik uygulamaya bir örnek aPROMISE™ platformudur. Bu platform, PSMA PET görüntülerinde anatomik yapıları ve PSMA-pozitif lezyonları otomatik olarak segmente edip kantitatif olarak değerlendirerek standardizasyon sağlamayı amaçlar (20). Platformun radyolojik raporlamada standardizasyonu artırabileceği bildirilmiştir (21). Ancak bir veri setindeki iyi performans her koşulda aynı başarıyı garanti etmez. "Clever Hans" etkisinde model, biyolojik olarak anlamlı özellikler yerine veriye özgü ikincil ipuçlarını kullanabilir (22). Bu nedenle, segmentasyon modelleri farklı merkezlerden, cihazlardan, protokollerden ve hasta gruplarından bağımsız veri setleriyle değerlendirilmelidir (11).

2.2. Görüntü Kaydı ve Aktivite Kantifikasyonu

Dozimetrinin doğruluğu, farklı zamanlarda alınan görüntülerin hassas hizalanmasına bağlıdır (23). Solunum, bağırsak hareketliliği ve mesane doluluğu gibi etkenler

mekansal sapmalara yol açabilir. Deformabl kayıt organın şekil ve hacim farklarını hesaba katarken, rijit kayıt yalnızca rotasyon ve translasyonu düzeltir ve DÖ tabanlı kayıt daha fazla serbestlik derecesi sunar (24). Kayıt hataları, özellikle küçük hacimli lezyonlarda doz hesabı doğruluğunu doğrudan etkileyebilir (25).

3. YZ ile Radyasyon Dozimetrisi

3.1. Hastaya Özgü Dozimetri ve Geleneksel Yaklaşımlar

Sabit aktiviteye dayalı tedavi yaklaşımlarında, hastalar arasındaki biyokinetik farklılıklar nedeniyle uygulanan aynı aktivite farklı tümör ve normal doku dozlarına yol açabilmektedir (26). Hastaya özgü dozimetri, radyofarmasötiğin dağılımının belirlenmesi, aktivitenin zaman içindeki değişiminin modellenmesi ve absorbe dozun hesaplanmasını içerir (26). Uzun süredir temel yöntem olarak kullanılmakta olan *Medical Internal Radiation Dose* (MIRD) yaklaşımı, standart fantomlara dayandığından bireysel anatomik farklılıkları tam yansıtamayabilir (26). Voksel tabanlı dozimetri daha ayrıntılı değerlendirme sağlarken, Monte Carlo (MC) simülasyonları radyasyonun dokuyla etkileşimini daha gerçekçi modellemektedir (27). MC'nin yüksek hesaplama maliyeti, rutin klinik uygulamalarda kullanımını sınırlayabilmektedir. Bu nedenle YZ tabanlı yaklaşımlar, MC hesaplamalarının hızlandırılması ve klinik iş akışlarının daha verimli hale getirilmesi amacıyla araştırılmaktadır. MC ile üretilen referans doz haritaları, YZ tabanlı doz tahmin modellerinin geliştirilmesinde referans veri olarak kullanılabilmektedir. Bu yaklaşımlar, doz hesaplamalarının daha kısa sürede gerçekleştirilmesine olanak sağlayabilir (27,28). Kısa menzilli alfa yayıcılarla yürütülen hedefli alfa tedavisinde, özellikle kemik metastazlarına komşu kemik iliğinde doz birikiminin anlaşılması etkinlik ve güvenlik açısından kritiktir (29). Bu ölçekte yüksek doğruluklu MC platformları temel referans olmayı sürdürmektedir (27). MC referanslarıyla eğitilen YZ vekil modelleri (*surrogate models*), alfa dozimetrisinin hesaplama yükünü azaltma potansiyeli sunmakla birlikte başarıları henüz yeterince doğrulanmamıştır (30).

Alfa parçacıklarının kısa menzili ve bozunmanın stokastik doğası nedeniyle organ, hatta voksel düzeyindeki hesaplar, aktivitenin hücresel mikrodağılımını her zaman yansıtamayabilir (31). Tahmin doğruluğu ayrıca eğitim verisinin doku heterojenliğini ve görüntü çözünürlüğünü temsil etme düzeyine bağlıdır (32). Bu sınırlılık, ^{225}Ac ve ^{223}Ra gibi birden çok yavru radyonüklid üreten ve geri tepme nedeniyle yavru çekirdeklerin ana çekirdekten ayrılarak farklı biyodağılım gösterebildiği bozunma zincirlerinde belirgindir. Yalnızca ana çekirdeği modelleyen bir vekil model, yavru katkısını göz ardı ederek toplam dozun eksik tahmin edilmesine yol açabilir (29,33). Bozunma zinciri modellemesindeki bu eksiklik, YZ destekli dozimetrinin klinik güvenilirlik kazanması için ele alınması gereken temel açıklardan biri olarak tanımlanmaktadır (34). Bu nedenle, klinik dozimetri iş akışlarının standardizasyonu ve doğrulanması, hastaya özgü alfa tedavisinin klinik uygulamaya aktarılması için temel gerekliliklerdendir (30). Ayrıca alana ilişkin kanıt tabanı henüz olgunlaşmamıştır. Dozimetri odaklı YZ çalışmaları çoğunlukla teknik ve retrospektif düzeyde kalmakta olup bildirilen çalışmalar arasında prospektif olanların sayısı oldukça sınırlıdır ve dış doğrulama nadirdir (30). Bu nedenle alfa vekil modellerinin çıktılarıyla birlikte belirsizlik haritaları sunması ve bağımsız MC verileri ya da deneysel verilerle doğrulanması gerekmektedir (30,35).

3.2. Zaman-Aktivite Eğrileri ve Biyokinetik Modelleme

Absorbe dozun hesaplanması için aktivitenin zamanla değişiminin bilinmesi gerekir; bunun için yapılan çoklu görüntüleme, hasta uyumu ve iş yükü açısından güçlük oluşturur (3). YZ sınırlı sayıda zaman noktasından eksik noktaları veya doğrudan zaman-aktivite eğrisini tahmin ederek bu yükü azaltabilir (36). Tedavi öncesi görüntülerden doz tahmini de benzer biçimde iş yükünü azaltabilecek bir yaklaşımdır. Xue ve ark. (37), tedavi öncesi [^{68}Ga]Ga-PSMA-11 PET/BT görüntülerinden voksel düzeyinde doz dağılımını tahmin etmek için organ-doz kılavuzlu doğrudan projeksiyon ve 3D RPT DoseGAN adlı CNN tabanlı iki strateji önermiştir; her iki strateji de tedavi öncesi PET ile tedavi sonrası doz haritalarının dağılımları arasındaki farkı kapatmayı hedeflemektedir. Bu kavram kanıtı çalışmada [^{177}Lu]Lu-PSMA ile tedavi edilen 23 metastatik kastrasyona dirençli prostat kanseri hastasının 48 tedavi siklusu değerlendirilmiş ve 3D RPT DoseGAN referans doz haritasına göre voksel düzeyinde %1,7±%0,4 normalleştirilmiş kök ortalama kare hatası ile 0,94±0,03 yapısal benzerlik indeksi elde etmiştir. Ancak preterapötik PET tutulumu ile doz haritası arasındaki korelasyon organ düzeyinde orta düzeyde kalmıştır (böbrek r=0,77±0,14; karaciğer r=0,50±0,23; dalak r=0,58±0,26), bu da biyokinetik heterojenitenin tahmin doğruluğunu sınırladığını göstermektedir. Benzer biçimde, tedavi öncesi PET ölçümlerini ve klinik laboratuvar bulgularını

girdi olarak kullanan MÖ modelleri, organ düzeyinde doz tahmininde literatür popülasyon ortalamasına dayalı kestirimlere göre anlamlı ölçüde düşük hata sağlamıştır; en iyi modelde böbrek için ortalama mutlak yüzde hata %15,8±%13,2 iken popülasyon temelli tahminde %25,5±%17,3 olmuştur ($p<0,01$) (38).

Biyokinetik, tümör yükü, organ fonksiyonu ve bireysel farmakokinetikten etkilendiğinden, YZ tabanlı modellerin farklı hasta gruplarında dış doğrulaması önem taşır (30). Tek zaman noktalı dozimetri de verimli bir uygulama alanıdır. DÖ modelleri sınırlı veriden voksel düzeyinde doz dağılımını tahmin ederek çok zamanlı dozimetri gereksinimini azaltabilir (36).

3.3. Hızlı Absorbe Edilen Doz ve Voksel Dozimetrisi

MIRD tabanlı voksel S-değerlerinin veya görüntüleme verilerinin CNN ve U-Net tabanlı modellere girdi olarak verilmesiyle MC referans doz dağılımlarının tahmini araştırılmıştır (39). Bazı çalışmalarda, DÖ tabanlı yaklaşımların, lezyonların absorbe doz tahmininde %1,15±2,5 mutlak yüzde hata ile başarılı sonuçlar verdiği bildirilmiştir (32). Voksel dozimetrisi, dozun doku içindeki heterojen dağılımını değerlendirme olanağı sağladığından, tümör içinde farklı tutulum bölgeleri bulunan radyoligand tedavilerinde önemlidir (39). U-Net ailesinin uzun menzilli bağlamı yerel evrişimlerle yakalamakta zorlandığı heterojen dağılımlarda, öz-dikkat (*self-attention*) mekanizmasıyla çalışan transformer mimarileri öne çıkmaktadır: Mansouri ve ark. (32) ^{177}Lu-DOTATATE tedavisinde SPECT/BT görüntülerinden hastaya özgü doz haritası üreten hibrit bir derin transformer yaklaşımıyla, MC tabanlı çoklu voksel S-değeri hesabına öğrenilmiş bir düzeltme ekleyerek voksel düzeyinde başarılı sonuçlar bildirmişlerdir (32). Bu bulgu, olgu sayısının sınırlı olduğu dozimetri çalışmalarında transformer tabanlı yaklaşımların araştırılmasını desteklemektedir. Düşük teknik hata tek başına klinik yeterlilik anlamına gelmemekte olup tahmin edilen dozlar zorlu ve klinik olarak anlamlı olgularda referans yöntemleriyle karşılaştırılmalıdır (9).

4. Prediktif Dozimetri ve Tedavi Optimizasyonu

Prediktif dozimetri, tedavi öncesinde olası biyodağılımı ve alınacak dozu tahmin ederek standart aktiviteden hasta odaklı planlamaya geçişi sağlar (38). Tanısal görüntüleme ile terapötik biyodağılım arasındaki bağlantı, terapötik dozun öngörülmesi için değerli bir fırsat sunar (36). MÖ modellerinin tedavi öncesi verilerden tedavi sonrası dozimetriyi öngörebildiği (38), DÖ modellerinin tedavi öncesi PSMA PET/BT'den tedavi sonrası absorbe edilen lezyon dozlarını ve voksel düzeyinde doz dağılımlarını tahmin edebildiği bildirilmiştir (40). Amaç yalnızca "hangi hastaya tedavi verilmeli?" sorusuna yanıt vermek değil; kritik organ toksisitesini sınırlar içinde tutarken tümör dozunu optimize etmeye yönelik hastaya özgü aktivite belirleme için bir temel oluşturmaktır (38). Yazdani ve ark. (40) ^{68}Ga-PSMA-11 PET/BT'den elde edilen radyomik özellikleri klinik biyobelirteçlerle birleştirerek ^{177}Lu-PSMA-617 sonrası absorbe edilen dozları tahmin etmişlerdir. Olgunlaştığında, bu yaklaşım tahmin → bireyselleştirilmiş aktivite → tedavi → tedavi sonrası dozimetri → yanıt/toksisite değerlendirmesi → sonraki siklusun adaptasyonu şeklinde sürekli bir döngü kurabilir (30).

5. Tedavi Yanıtı, Toksisite ve Adaptif Tedavi

Kontrol PET/BT veya SPECT/BT görüntülemeleriyle farklı zaman noktalarındaki tümör yükü ve tutulumdaki değişimler, tedavi yanıtının değerlendirilmesine ve klinik yönetimin yönlendirilmesine katkı sağlayabilir (41). YZ ise bu görüntülerin otomatik ve tekrarlanabilir analizini destekleyerek yanıt değerlendirmesini standardize etme potansiyeline sahiptir. Nitekim Gutsche ve ark. (42), PSMA PET verilerinde üç radyomik özellik ile hasta yaşını birleştiren Random Forest modeliyle beş katlı çapraz doğrulamada 0,82 eğri altında kalan alan değeri elde etmiştir (42). Görüntüleme bulguları dozimetri ile birlikte değerlendirilmelidir. Kritik organ dozları sonraki aktivite kararlarını etkileyebilmekte olup, bazı çalışmalarda tümör tarafından absorbe edilen doz ile tedavi yanıtı arasında anlamlı ilişkiler bildirilmiştir (43). Yanıt-adaptif radyofarmasötik tedavi; erken tedavi sonrası görüntüleme, absorbe edilmiş doz, laboratuvar eğilimleri ve yanıt bilgisinin bir sonraki siklustan önce risk-yarar dengesini güncellediği boylamsal bir döngü olarak tanımlanmaktadır (30). Güncel YZ çalışmaları bu adımları nadiren prospektif olarak test etmekte; yakın vadedeki fırsatın tam otonomi yerine insan denetimli karar desteğinde olduğu bildirilmektedir (30). YZ'nin tedavi öncesi görüntülemeyi, tedavi sonrası dozimetriyi ve klinik sonuçları birlikte değerlendirmesi, "tedavi et → ölç → değerlendir → yeniden planla" şeklinde işleyen insan denetimli adaptif bir döngüyü mümkün kılabilecektir (30).

6. Klinik Uygulamanın Önündeki Engeller

Teranostik YZ literatüründeki çalışmaların önemli bir bölümü retrospektif tasarıma sahiptir (30,44). Merkezler arası cihaz, protokol, rekonstrüksiyon ve radyofarmasötik farklılıkları aynı modelin farklı sonuçlar vermesine yol

açabilir; bu nedenle segmentasyon, aktivite ölçümü ve doz tahmini modellerinin bağımsız ve çok merkezli veri setleriyle doğrulanması gereklidir (30). Teranostikte YZ uygulamalarını haritalayan kanıt incelemeleri de çalışmaların büyük çoğunluğunun ileri doğrulama veya karar-etki değerlendirmesine ulaşmadığını ve mevcut kanıtın otonom karar sistemlerinden ziyade insan denetimli ölçüm ve iş akışı yardımcılarını desteklediğini bildirmektedir (30). Algoritmik başarı ile fiziksel doğruluk birbirinden ayırt edilmelidir. Yüksek Dice benzerlik katsayısı, doğru absorbe dozun hesaplandığı anlamına gelmez; kabul ölçütleri geometrik metriklerle sınırlandırılmamalıdır (45). Bu kapsamda voksel düzeyindeki mutlak doz hatası öne çıkmaktadır. MC referansına göre DÖ modellerinde ortalama mutlak hata 0,05-0,15 Gy/GBq olarak bildirilmiştir (36). Doz-hacim histogramının belirleyici noktaları klinik eşdeğerlik düzeyini yansıtır (36). Doz farkı ve mesafe kriterlerini birlikte değerlendiren gamma analizi de doz dağılımlarının karşılaştırılmasında kullanılabilen ölçütlerden biridir (46). Belirsizliğin nicelleştirilmesi ve klinik düzeyde anlaşılır şekilde raporlanması, model güvenilirliğinin değerlendirilmesinde tamamlayıcı bir yaklaşımdır (47). Bir modelin çıktısında belirsizlik kestirimine yer vermesi ve belirsizliğin karar vermeyi güvenilir biçimde destekleyemeyecek kadar yüksek olduğu durumlarda tahminden kaçınabilmesi, güvenli klinik kullanım açısından önemli bir ilkedir (47). Bu yaklaşımın brakiterapi doz tahminindeki örneklerinde, modele bağlı (epistemik) ve veriye bağlı (aleatorik) belirsizliklerin ayrı olarak tahmin edilebildiği gösterilmiştir (35).

Veri standardizasyonu da kritiktir. Görüntüleme protokollerinin, rekonstrüksiyon yöntemlerinin ve veri formatlarının standartlaştırılması, modellerin merkezler arası daha güvenilir ve yeniden üretilebilir biçimde değerlendirilmesine katkı sağlayabilir (3). Hasta seçimi ve aktivite belirleme gibi klinik karar noktalarında YZ, klinisyenin yerini almaktan ziyade uzman değerlendirmesini destekleyen bir araç olarak ele alınmalıdır (3). Güvenilir bir YZ ekosistemi için stres testleri ve veri rezervi stratejileri benimsenmelidir (48).

Sonuç

YZ, teranostik uygulamalarda görüntüleme, ölçüm ve tedavi planlaması arasındaki bağı güçlendirmektedir (2). Rekonstrüksiyon, atenüasyon düzeltmesi, segmentasyon, kayıt ve aktivite ölçümünde sağlanan hız ve tutarlılık, hastaya özgü dozimetri için gereken verilerin elde edilmesini kolaylaştırır (3). Dozimetrideki en büyük katkılar zaman-aktivite eğrilerinin modellenmesi, biyokinetik tahmini, absorbe doz hesaplarının hızlandırılması ve voksel doz haritalarının üretilmesidir. MC referans doz haritalarıyla eğitilen DÖ ve transformer tabanlı modeller, yüksek doğrulukta tahminleri çok daha kısa sürede sunmaktadır (34). Gelecekte prediktif dozimetri, tedavi öncesinde terapötik biyodağılımı öngörerek "tahmin et → tedavi et → ölç → yeniden planla" biçiminde işleyen adaptif döngünün kurulmasına zemin hazırlayabilir (36). Ancak YZ'nin klinik değeri algoritmik performansla sınırlı kalmamalı; bu teknolojilerin klinik uygulamaya geçişinde çeşitli sınırlamalar ve zorluklar dikkate alınmalıdır (30). Sonuç olarak YZ, "görüntüle-ölç-tedavi et-yeniden değerlendir" döngüsünü hızlandırarak hastaya özgü, adaptif radyonüklid tedaviye geçişte önemli bir rol oynama potansiyeline sahiptir (36).

Dipnotlar

Çıkar Çatışması: Yazar tarafından çıkar çatışması bildirilmemiştir.

Finansal Destek: Yazar tarafından finansal destek alınmadığı bildirilmiştir.

Yapay Zeka (AI) Kullanım Beyanı: Metin düzenleme ve dil düzeltme desteği alınmıştır.

Kaynaklar

1. Wibmer AG, Hricak H, Ulaner GA, Weber W. Trends in oncologic hybrid imaging. Eur J Hybrid Imaging. 2018;2:1.
2. Saboury B, Bradshaw T, Boellaard R, et al. Artificial intelligence in nuclear medicine: opportunities, challenges, and responsibilities toward a Trustworthy Ecosystem. J Nucl Med. 2023;64:188-196.
3. Belge Bilgin G, Bilgin C, Burkett BJ, et al. Theranostics and artificial intelligence: new frontiers in personalized medicine. Theranostics. 2024;14:2367-2378.
4. Jha AK, Bradshaw TJ, Buvat I, et al. Nuclear medicine and artificial intelligence: best practices for evaluation (the RELAINCE guidelines). J Nucl Med. 2022;63:1288-1299.
5. Brosch-Lenz JF, Delker A, Schmidt F, Tran-Gia J. On the use of artificial intelligence for dosimetry of radiopharmaceutical therapies. Nuklearmedizin. 2023;62:379-388.
6. Rydén T, Van Essen M, Marin I, Svensson J, Bernhardt P. Deep-learning generation of synthetic intermediate projections improves ^{177}Lu SPECT images reconstructed with sparsely acquired projections. J Nucl Med. 2021;62:528-535.
7. Currie GM, Rohren E. The role of artificial intelligence in theranostics. J Nucl Med Technol. 2025;53(Suppl 1):82S-91S.

8. Chaudhari AS, Mittra E, Davidzon GA, et al. Low-count whole-body PET with deep learning in a multicenter and externally validated study. NPJ Digit Med. 2021;4:127. Erratum in: NPJ Digit Med. 2021;4:139.
9. Bradshaw TJ, Boellaard R, Dutta J, et al. Nuclear medicine and artificial intelligence: best practices for algorithm development. J Nucl Med. 2022;63:500-510.
10. Pan S, Abouei E, Peng J, et al. Full-dose whole-body PET synthesis from low-dose PET using high-efficiency denoising diffusion probabilistic model: PET consistency model. Med Phys. 2024;51:5468-5478.
11. Dexl J, Gatidis S, Früh M, et al. AutoPET Challenge on fully automated lesion segmentation in oncologic PET/CT imaging, part 2: domain generalization. J Nucl Med. 2026;67:481-488.
12. Xia M, Bayerlein R, Chemli Y, et al. On hallucinations in artificial intelligence-generated content for nuclear medicine imaging (the DREAM report). J Nucl Med. 2026;67:166-174.
13. Dong X, Lei Y, Wang T, et al. Deep learning-based attenuation correction in the absence of structural information for whole-body positron emission tomography imaging. Phys Med Biol. 2020;65:055011.
14. Hosono M, Takenaka M, Monzen H, Tamura M, Kudo M, Nishimura Y. Cumulative radiation doses from recurrent PET-CT examinations. Br J Radiol. 2021;94:20210388.
15. Liu F, Jang H, Kijowski R, Bradshaw T, McMillan AB. Deep learning MR imaging-based attenuation correction for PET/MR imaging. Radiology. 2018;286:676-684.
16. Wyatt JJ, Kaushik S, Cozzini C, et al. Evaluating a radiotherapy deep learning synthetic CT algorithm for PET-MR attenuation correction in the pelvis. EJNMMI Phys. 2024;11:10.
17. Kurkowska S, Dewaraja YK, Frey EC, Brosch-Lenz J, Sunderland J, Uribe C. An international study of factors affecting variability of dosimetry calculations, part 5: impact of segmentation methods. EJNMMI Phys. 2026;13:39.
18. Lopes L, Lopez-Montes A, Chen Y, et al. The evolution of artificial intelligence in nuclear medicine. Semin Nucl Med. 2025;55:313-327.
19. Kostyszyn D, Fechter T, Bartl N, et al. Intraprostatic tumor segmentation on PSMA PET images in patients with primary prostate cancer with a convolutional neural network. J Nucl Med. 2021;62:823-828.
20. Nickols N, Anand A, Johnsson K, et al. aPROMISE: a novel automated PROMISE platform to standardize evaluation of tumor burden in ^{18}F-DCFPyL images of veterans with prostate cancer. J Nucl Med. 2022;63:233-239.
21. Johnsson K, Brynolfsson J, Sahlstedt H, et al. Analytical performance of aPROMISE: automated anatomic contextualization, detection, and quantification of [^{18}F]DCFPyL (PSMA) imaging for standardized reporting. Eur J Nucl Med Mol Imaging. 2022;49:1041-1051.
22. Arias-Londoño JD, Godino-Llorente JI. Analysis of the Clever Hans effect in COVID-19 detection using chest X-Ray images and Bayesian deep learning. Biomedical Signal Processing and Control. 2024;90:105831.
23. Sjögreen-Gleisner K, Rueckert D, Ljungberg M. Registration of serial SPECT/CT images for three-dimensional dosimetry in radionuclide therapy. Phys Med Biol. 2009;54:6181-6200.
24. Oh S, Kim S. Deformable image registration in radiation therapy. Radiat Oncol J. 2017;35:101-111.
25. Grassi E, Fioroni F, Berenato S, et al. Effect of image registration on 3D absorbed dose calculations in ^{177}Lu-DOTATOC peptide receptor radionuclide therapy. Phys Med. 2018;45:177-185.
26. O'Donoghue J, Zanzonico P, Humm J, Kesner A. Dosimetry in radiopharmaceutical therapy. J Nucl Med. 2022;63:1467-1474.
27. Sarrut D, Arbor N, Baudier T, et al. The OpenGATE ecosystem for Monte Carlo simulation in medical physics. Phys Med Biol. 2022;67:184001.
28. Kontaxis C, Bol GH, Lagendijk JJW, Raaymakers BW. DeepDose: towards a fast dose calculation engine for radiation therapy using deep learning. Phys Med Biol. 2020;65:075013.
29. Hobbs RF, Song H, Watchman CJ, et al. A bone marrow toxicity model for ^{223}Ra alpha-emitter radiopharmaceutical therapy. Phys Med Biol. 2012;57:3207-3222.
30. Banala M, Ezuddin S, Foley M, Kuker R. Artificial intelligence across oncologic theranostics: evidence for patient stratification, dosimetry, and adaptive radiopharmaceutical therapy. Front Nucl Med. 2026;6:1935247.
31. Chouin N, Bardies M. Alpha-particle microdosimetry. Curr Radiopharm. 2011;4:266-280.
32. Mansouri Z, Salimi Y, Akhavanallaf A, et al. Deep transformer-based personalized dosimetry from SPECT/CT images: a hybrid approach for [^{177}Lu]Lu-DOTATATE radiopharmaceutical therapy. Eur J Nucl Med Mol Imaging. 2024;51:1516-1529.
33. Koniar H, Miller C, Rahmim A, Schaffer P, Uribe C. A GATE simulation study for dosimetry in cancer cell and micrometastasis from the 225Ac decay chain. EJNMMI Phys. 2023;10:46.
34. Woo SK. The role of artificial intelligence in advancing theranostics dosimetry for cancer therapy: a review. Nucl Med Mol Imaging. 2025;59:329-341.
35. Berumen F, Ouellet S, Enger S, Beaulieu L. Aleatoric and epistemic uncertainty extraction of patient-specific deep learning-based dose predictions in LDR prostate brachytherapy. Phys Med Biol. 2024;69:085026.
36. Shanmugiah J, Kim JS. Personalised dosimetry in nuclear medicine: bridging physics, biology and AI for next generation radiopharmaceutical therapy. Nucl Med Mol Imaging. 2026;60:221-249.
37. Xue S, Gafita A, Zhao Y, et al. Pre-therapy PET-based voxel-wise dosimetry prediction by characterizing intra-organ heterogeneity in PSMA-directed radiopharmaceutical theranostics. Eur J Nucl Med Mol Imaging. 2024;51:3450-3460.
38. Xue S, Gafita A, Dong C, et al. Application of machine learning to pretherapeutically estimate dosimetry in men with advanced

prostate cancer treated with ^{177}Lu-PSMA I&T therapy. Eur J Nucl Med Mol Imaging. 2022;49:4064-4072.

39. Yazdani E, Geramifar P, Karamzade-Ziarati N, Sadeghi M, Amini P, Rahmim A. Radiomics and artificial intelligence in radiotheranostics: a review of applications for radioligands targeting somatostatin receptors and prostate-specific membrane antigens. Diagnostics (Basel). 2024;14:181.
40. Yazdani E, Neizehbaz A, Karamzade-Ziarati N, et al. Transforming [^{177}Lu]Lu-PSMA-617 treatment planning: machine learning-based radiodosiomics and Swin UNETR using pretherapy PSMA positron emission tomography/computed tomography (PET/CT). Med Phys. 2025;52:e70030.
41. Yadav S, Lowery B, Tuchayi AM, et al. Impact of posttreatment SPECT/CT on patient management during ^{177}Lu-PSMA-617 radiopharmaceutical therapy. J Nucl Med. 2024;65:1395-1401.
42. Gutsche R, Gülmüs G, Mottaghy FM, et al. Multicentric ^{68}Ga-PSMA PET radiomics for treatment response assessment of ^{177}Lu-PSMA-617 radioligand therapy in patients with metastatic castration-resistant prostate cancer. Front Nucl Med. 2023;3:1234853.
43. Warfvinge CF, Gustafsson J, Roth D, et al. Relationship between absorbed dose and response in neuroendocrine tumors treated with [^{177}Lu]Lu-DOTATATE. J Nucl Med. 2024;65:1070-1075.
44. Kelly BS, Judge C, Bollard SM, et al. Radiology artificial intelligence: a systematic review and evaluation of methods (RAISE). Eur Radiol. 2022;32:7998-8007. Erratum in: Eur Radiol. 2022;32:8054.
45. Poel R, Rüfenacht E, Hermann E, et al. The predictive value of segmentation metrics on dosimetry in organs at risk of the brain. Med Image Anal. 2021;73:102161.
46. Hussein M, Clark CH, Nisbet A. Challenges in calculation of the gamma index in radiotherapy - towards good practice. Phys Med. 2017;36:1-11.
47. Kompa B, Snoek J, Beam AL. Second opinion needed: communicating uncertainty in medical machine learning. NPJ Digit Med. 2021;4:4.
48. Chen H, Tie Y, Cao X, Young GS, Xu X. Strategies for creation of data reserve and stress testing of medical AI products. BMJ Health Care Inform. 2024;31:e101184.