DERLEME
DOI:10.4274/nts.galenos.2026.03522
Nucl Med Semin 2026;12:174-185

Nükleer Tıpta Yapay Zeka Envanteri

Artificial Intelligence Inventory in Nuclear Medicine

Sertaç Asa

İstanbul Üniversitesi-Cerrahpaşa, Cerrahpaşa Tıp Fakültesi, Nükleer Tıp Anabilim Dalı, İstanbul, Türkiye

Öz

Yapay zeka (YZ) nükleer tıpta artık yalnızca araştırma laboratuvarlarının konusu olmaktan çıkmış; veri toplamadan raporlamaya kadar iş akışının hemen her basamağında kendine yer bulmuştur. Ne var ki bu alana adım atmak isteyen bir nükleer tıp hekimi için asıl güçlük, hangi aracın hangi basamakta, hangi koşullarda ve hangi lisans statüsüyle kullanılabileceğini toplu halde gösteren bir kaynağın bulunmamasıdır. Bu derlemede nükleer tıpta kullanılabilecek YZ yazılımlarını açık kaynak kodlu ve ticari ürünler olmak üzere iki grupta envanterlemeyi ve bu envanteri beş basamaklı bir iş akışı çerçevesine (veri toplama, ön işleme, segmentasyon, özellik çıkarımı, model geliştirme ve analiz) yerleştirmeyi amaçladık. Her iki grupta da çok sayıda olgunlaşmış araç mevcuttur ve bunlar birbirinin rakibinden çok tamamlayıcısıdır. Açık kaynak araçlar ücretsizdir, kullanıcı tarafından değiştirilebilir, algoritmaları incelenebilir ve veri tamamen kurumun kontrolünde kalır; buna karşılık büyük çoğunluğunun *Conformité Européenne* ya da *Food and Drug Administration* onayı yoktur ve kurumsal teknik destekten yoksundurlar. Ticari çözümler klinik sistemlere entegrasyon, düzenleyici uyum ve teknik destek sağlar; ancak lisans bedeli gerektirir, özelleştirme üreticinin izin verdiği ölçüyle sınırlıdır ve algoritmalar çoğu zaman kapalıdır. Etiketli verinin azlığı, merkezler arasındaki standardizasyon farkları, kişisel verilerin korunmasına ilişkin yükümlülükler, tıbbi cihaz yazılımı sınıflandırması, PACS uyumu, açıklanabilirlik ve grafik işlem birimi altyapısı gereksinimi her iki grup için de ortak sorunlardır. Önümüzdeki yıllarda temel modellerin, çok modaliteli analizin, büyük dil modeli destekli raporlamanın ve federe öğrenmenin bu envanteri önemli ölçüde değiştirmesi beklenmektedir. Bugün için nükleer tıp

Abstract

Artificial intelligence (AI) has moved beyond the research laboratory in nuclear medicine and now has a place at nearly every step of the imaging workflow, from data collection to reporting. For a nuclear medicine physician wishing to enter this field, however, the main difficulty is the absence of a single resource showing which tool can be used at which step, under what conditions, and with what licensing status. In this review we aimed to inventory the AI software available to nuclear medicine in two groups, open-source and commercial, and to place this inventory within a five-step workflow framework (data collection, preprocessing, segmentation, feature extraction, and model development and analysis). Both groups contain a large number of mature tools, and the two are complementary rather than competing. Open-source tools are free of charge, can be modified by the user, have algorithms that can be inspected, and leave the data entirely under institutional control; on the other hand, most of them lack Conformité Européenne or Food and Drug Administration approval and come without institutional technical support. Commercial solutions offer integration with clinical systems, regulatory compliance, and technical support, but they require licence fees, allow customization only to the extent permitted by the manufacturer, and their algorithms are usually closed. Scarcity of labelled data, differences in standardization between centres, obligations arising from personal data protection, classification as medical device software, PACS compatibility, explainability, and the need for graphics processing unit infrastructure are problems shared by both groups. In the coming years, foundation models, multimodal analysis, large language model-assisted reporting, and federated learning are expected to change this inventory considerably. For the present, the

Sorumlu Yazar/Corresponding Author
Doç. Dr. Sertaç Asa, İstanbul Üniversitesi-Cerrahpaşa, Cerrahpaşa Tıp Fakültesi, Nükleer Tıp Anabilim Dalı, İstanbul, Türkiye
E-posta: sertacasa@gmail.com **ORCID ID:** orcid.org/0000-0003-4060-9331
Geliş Tarihi/Received: 02.10.2026 **Kabul Tarihi/Accepted:** 04.11.2026 **Yayınlanma Tarihi/Publication Date:** 26.11.2026
Cite this article as/Atıf: Asa S. Artificial intelligence inventory in nuclear medicine. Nucl Med Semin. 2026;12:174-185

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.

pratiğine önerebileceğimiz yaklaşım, araştırma ve yöntem geliştirmede açık kaynak araçların, rutin klinik kullanımda ise onaylı ticari çözümlerin tercih edildiği hibrit bir modeldir.

Anahtar Kelimeler: Yapay zeka, nükleer tıp, derin öğrenme, yazılım, pozitron emisyon tomografisi-bilgisayarlı tomografi

approach we would recommend for nuclear medicine practice is a hybrid model in which open-source tools are preferred for research and method development and approved commercial solutions for routine clinical use.

Keywords: Artificial intelligence, nuclear medicine, deep learning, software, positron emission tomography computed tomography

Giriş

Nükleer tıp, ürettiği verinin doğası gereği yapay zeka (YZ) uygulamaları için elverişli bir alandır. Pozitron emisyon tomografi (PET) ve tek foton emisyon bilgisayarlı tomografi (SPECT) ile elde ettiğimiz görüntüler, fonksiyonel bilgi taşıyan yarı kantitatif veri kümeleridir. Günlük pratikte bu veriyi çoğunlukla standartlaştırılmış tutulum değeri (SUV_{maks}) gibi tek bir noktaya indirgenmiş ölçütlerle özetleriz; oysa görüntünün içinde bundan çok daha fazlası vardır. Sorun, bu bilgiyi elle çıkarılmaya çalışıldığında işin hem uzun sürmesi hem de sonucun büyük ölçüde ölçümü yapan kişiye bağlı kalmasıdır (1).

Bu darboğazı en iyi hacim temelli parametreler üzerinden anlatabiliriz. Lenfomada metabolik tümör hacmi (MTV) ve total lezyon glikolizinin (TLG) sağkalım ve tedavi yanıtı açısından güçlü prognostik değer taşıdığı yıllardır bilinmektedir; buna rağmen bu parametreler rutin raporlarımızda kendine yer bulamamıştır (2). Yaygın hastalığı olan bir olguda onlarca lezyonu tek tek elle çizmek günlük iş yükü içinde mümkün değildir. Yaygın metastatik prostat kanserinde prostat spesifik membran antijeni (PSMA) PET ile ölçülen toplam tümör hacmi için de aynı durum geçerlidir (3). Otomatik segmentasyonun nükleer tıp için önemi, bu parametreleri günlük kullanımda uygulama potansiyeline sahip olmasından kaynaklanmaktadır.

Derin öğrenmenin son on yılda iki ve üç boyutlu görüntü analizinde gösterdiği başarı (4,5) nükleer tıbba da hızla yansımıştır. Bugün segmentasyondan kantifikasyona, görüntü kalitesinin iyileştirilmesinden doz ve çekim süresinin azaltılmasına, atenüasyon düzeltmeden dozimetriye, prognostik modellemeden otomatik raporlamaya uzanan geniş bir uygulama alanı bulunmaktadır (6). Avrupa Nükleer Tıp Derneği (EANM) yayımladığı görüş belgesinde YZ'nin alana kalıcı biçimde yerleştiğini kabul etmiş, entegrasyonun nasıl olması gerektiğini ve kullanım amaçlarını tanımlamıştır (7). Amerikan Nükleer Tıp ve Moleküler Görüntüleme Derneği ise algoritma geliştirme ve değerlendirme için iyi uygulama ilkelerini iki ayrı belgede yayımlamıştır (8,9). Konunun etik boyutu da literatürde ayrıca tartışılmaktadır (10).

Buna karşın hangi yazılımın ne iş yaptığı, hangisinin klinikte kullanılabileceği, hangisinin yalnızca araştırma amaçlı olduğu konusunda derli toplu bir kaynak bulmak güçtür. YZ'nin nükleer tıptaki klinik uygulamalarını ele alan çok sayıda derleme vardır; ancak bunların çoğu klinik endikasyonlar ya da yöntemler etrafında kurgulanmıştır. Araçların kendisini, iş akışındaki yerlerine ve lisans durumlarına göre listeleyen çalışma ise azdır.

Bu derlemede, nükleer tıpta kullanılabilecek YZ yazılımlarının güncel bir envanterini sunmayı amaçladık. Envanteri açık kaynak kodlu ve ticari ürünler olmak üzere iki eksende düzenledik; her iki grubu da beş basamaklı iş akışı üzerinden ele aldık, ardından iki grubu karşılaştırarak alana yeni başlayanlar için bir yol haritası önerdik. Envanter Kasım 2026 itibarıyla kamuya açık lisans ve düzenleyici bilgilere dayanmaktadır; yazılımlar sık güncellendiğinden kullanım öncesinde güncel durum doğrulanmalıdır.

Nükleer Tıp Hekimi için Temel Kavramlar ve Altyapı

Açık kaynak yazılım, kaynak kodu herkesin inceleyebildiği, değiştirebildiği ve dağıtabildiği yazılımdır. Nükleer tıp alanındaki örneklerin çoğu *Berkeley Software Distribution* (BSD) veya Apache türü izin verici lisanslarla dağıtılır; bu da araştırma amaçlı kullanımı, çoğu durumda da ticari kullanımı serbest bırakır. Açık kaynak yazılımı yalnızca ücretsiz olan yazılımdan ayırmak gerekir: ücretsiz (*freeware*) yazılımların kaynak kodu kapalıdır ve lisansları değiştirme ya da yeniden dağıtma hakkı tanımaz; LIFEx ve Google Colab bu gruptadır (Tablo 1).

Kapalı kaynak (ticari) yazılımda kod gizlidir; kullanıcı, doğrulanmış, düzenleyici onayı almış ve teknik destekle birlikte sunulan bir ürünü lisanslar. Aradaki fark yalnızca maliyet farkı değildir. Açık kaynak bir araçta çıktının üzerindeki bütün kontrol, ama aynı zamanda bütün sorumluluk kullanıcıya aittir; ticari üründe ise doğrulama yükünün önemli bir kısmını üretici üstlenmiştir.

Tablo 1. Envanterdeki yazılımların lisans türü, ücret durumu ve doğrulanabilen düzenleyici statüsü (Kasım 2026 itibarıyla)

Yazılım	İşlev	Lisans türü	Açık kaynak	Ücret/erişim	FDA 510(k)	CE (üretici beyanı)
Açık kaynak kodlu ve ücretsiz araçlar (tıbbi cihaz olarak sunulmazlar)						
PyDicom	Veri erişimi (DICOM okuma, anonimleştirme)	MIT	Evet	Ücretsiz	—	—
dcm4che/dcm4chee	Veri erişimi (araştırma arşivi)	MPL 1.1/GPL v2/ LGPL v2.1 (üçlü lisans); bileşene göre değişebilir	Evet	Ücretsiz	—	—
OHIF Viewer	Veri erişimi (web görüntüleyici)	MIT	Evet	Ücretsiz	—	—
SimpleITK	Ön işleme	Apache 2.0	Evet	Ücretsiz	—	—
SimpleElastix/elastix	Kayıtlama	Apache 2.0	Evet	Ücretsiz	—	—
ComBat (neuroCombat)	Harmonizasyon	MIT (Python/MATLAB); Artistic 2.0 (R)	Evet	Ücretsiz	—	—
3D Slicer	Segmentasyon, kantifikasyon, platform	BSD türevi (Slicer lisansı)	Evet	Ücretsiz	—	—
ITK-SNAP	Segmentasyon (manuel/yarı otomatik)	GPL v3	Evet	Ücretsiz	—	—
MONAI	Segmentasyon (derin öğrenme çerçevesi)	Apache 2.0	Evet	Ücretsiz	—	—
nnU-Net	Segmentasyon (kendini yapılandıran çerçeve)	Apache 2.0	Evet	Ücretsiz	—	—
MOOSE	Segmentasyon (tüm vücut PET/BT)	Kod: Apache 2.0; model: CC BY 4.0	Evet	Ücretsiz; ayrıca ticari sürüm	—	—
TotalSegmentator	Segmentasyon (BT/MR anatomik yapılar)	Apache 2.0 (açık görevler); bazı ek modeller ayrı lisanslı	Evet	Açık görevler ücretsiz ve ticari kullanıma açık; ek modellerde ticari kullanım lisansa bağlı	—	—
PyRadiomics	Özellik çıkarımı (radyomik)	BSD 3-clause	Evet	Ücretsiz	—	—
IBEX	Özellik çıkarımı (radyomik)	Creative Commons Attribution	Evet (MATLAB kodu)	Ücretsiz	—	—
AMIDE	Görüntüleme ve kantifikasyon	GPL v2	Evet	Ücretsiz	—	—
PyTorch	Model geliştirme	BSD 3-clause	Evet	Ücretsiz	—	—
TensorFlow	Model geliştirme	Apache 2.0	Evet	Ücretsiz	—	—
scikit-learn	Model geliştirme (klasik makine öğrenmesi)	BSD 3-clause	Evet	Ücretsiz	—	—
Weka/Orange/KNIME	Model geliştirme (görsel arayüz)	GPL v3 (Orange: v3 ve sonrası; KNIME: ek izinlerle)	Evet	Ücretsiz; ücretli kurumsal eklentiler olabilir	—	—

Tablo 1. Devamı

Yazılım	İşlev	Lisans türü	Açık kaynak	Ücret/erişim	FDA 510(k)	CE (üretici beyanı)
RStudio (Posit)	İstatistiksel modelleme	AGPL v3 (açık kaynak sürüm)	Evet	Ücretsiz; ayrıca ticari sürüm	—	—
Ücretsiz kullanılabilen ancak açık kaynak kodlu olmayan araçlar						
LIFEx	Özellik çıkarımı (radyomik), ComBat harmonizasyonu	Tescilli; araştırma kullanımı lisansı	Hayır (yalnızca nesne kodu; değiştirme ve yeniden dağıtma yasak)	Araştırma için ücretsiz; ticari kullanım ayrı lisansla	—	—
Google Colab	Model geliştirme (bulut GPU erişimi)	Tescilli bulut hizmeti	Hayır	Ücretsiz katman; ücretli planlar	—	—
Ticari ürünler						
aPROMISE/PYLARIFY AI (EXINI/Lantheus)	PSMA PET lezyon saptama ve kantifikasyon	Ticari lisans	Hayır	Lisans bedeli	K211655 (2021)	Var (2021)
Siemens syngo.via (MI uygulamaları)	Görüntüleme, kantifikasyon, iş akışı	Ticari lisans	Hayır	Lisans bedeli	K242275 (syngo. via MI Workflows, 2024)	—
Hermes Hermia (Voxel Dosimetry)	Kantifikasyon, dozimetri	Ticari lisans	Hayır	Lisans bedeli	K243919 (Voxel Dosimetry, 2025; ilk izin: K191216, 2019)	Var (MDR, Sınıf IIb, 2024)
MIM Software (SurePlan MRT)	Kantifikasyon, segmentasyon, dozimetri	Ticari lisans	Hayır	Lisans bedeli	K182624 (MRT Dosimetry, 2018)	Var (2020)
PMOD (Bruker)	Kinetik modelleme, kantifikasyon, dozimetri	Ticari lisans; yalnızca araştırma amaçlı (RUO)	Hayır	Lisans bedeli	— (RUO; tıbbi cihaz olarak sunulmaz)	— (RUO)
Philips IntelliSpace Portal/AI Manager	Görüntüleme, kantifikasyon, YZ uygulama platformu	Ticari lisans	Hayır	Lisans bedeli	K162025 (IntelliSpace Portal 9.0, 2016); AI Manager'ı kapsamaz	—
Canon AiCE (Cartesion Prime PET/BT)	Derin öğrenme temelli rekonstrüksiyon	Ticari lisans (cihaza bağlı)	Hayır	Cihaz / lisans bedeli	K203314 (Cartesion Prime V10.8, AiCE-i for PET, 2021)	—

Tablo 1. Devamı

Yazılım	İşlev	Lisans türü	Açık kaynak	Ücret/erişim	FDA 510(k)	CE (üretici beyanı)
United Imaging uAI (HYPER DLR)	Derin öğrenme temelli rekonstrüksiyon ve gürültü azaltma	Ticari lisans (cihaza bağlı)	Hayır	Cihaz/lisans bedeli	K193210 (HYPER DLR, 2020)	—
Subtle Medical SubtlePET	Düşük sayımlı PET gürültü azaltma	Ticari lisans	Hayır	Lisans bedeli	K182336 (2018)	Var (2018)

Düzenleyici bilgiler Kasım 2026 itibarıyla kontrol edilmiştir. FDA 510(k) izinlerinin K-numaraları FDA *Premarket Notification* veri tabanında (accessdata.fda.gov) doğrudan sorgulanabilir; her izin yalnızca belirtilen ürün, sürüm ve amaçlanan kullanım için geçerlidir ve platformun tamamına ya da sonraki sürümlere genellenemez. CE işaretine ilişkin bilgiler üretici duyurularına dayanmaktadır. Avrupa Birliği'nin EUDAMED veri tabanında piyasadaki cihazların kaydı Kasım 2026'ya, sertifika bilgilerinin yüklenmesi Mayıs 2027'ye kadar sürdüğünden, CE statüsü bu derlemenin hazırlandığı sırada bağımsız olarak sorgulanamamıştır

—: Bağımsız olarak doğrulanabilen bilgi bulunamadı; bu ifade onayın bulunmadığı anlamına gelmez. Açık kaynak ve ücretsiz araçlar ile yalnızca araştırma amaçlı (RUO) sunulan ticari yazılımlar tıbbi cihaz olarak sunulmadığından çıktıları yalnızca araştırma amacıyla kullanılmalıdır. Türkiye'de klinik kullanım öncesinde ürünün güncel ÜTS kaydı ayrıca kontrol edilmelidir. Lisans bilgileri ilgili projelerin resmi depo ve web sayfalarından alınmıştır; kullanılacak sürümün lisans metni ayrıca kontrol edilmelidir. AGPL: GNU *Affero General Public License,* BSD: *Berkeley Software Distribution,* CC BY: *Creative Commons Attribution,* CE: *Conformité Européenne,* DLR: *Deep learning reconstruction,* FDA: *Food and Drug Administration,* GPL: GNU *General Public License,* LGPL: GNU *Lesser General Public License,* MDR: *Medical Device Regulation* (AB Tıbbi Cihaz Tüzüğü), MIT: *Massachusetts Institute of Technology* lisansı, MPL: *Mozilla Public License,* MRT: *Molecular radiotherapy,* RUO: *Research use only* (yalnızca araştırma amaçlı), ÜTS: Ürün takip sistemi, PET: Pozitron emisyon tomografi, MR: Manyetik rezonans, BT: Bilgisayarlı tomografi, YZ: Yapay zeka

Makine öğrenmesi, bilgisayarın veriden istatistiksel örüntüler çıkararak yeni örneklere genelleme yapabilmesini sağlayan yöntemlerin ortak adıdır. Hepimizin aşina olduğu lojistik regresyon aslında bu ailenin en basit üyesidir; yapay sinir ağlarındaki "yapay nöron" kavramı da temelde buna dayanır. Destek vektör makineleri, rassal orman (*random forest*) ve gradyan artırma yöntemleri bu ailenin diğer sık kullanılan üyeleridir. Bu yöntemlerin ortak özelliği, kullanıcının önceden tanımladığı değişkenlerle (yaş, evre, hasta grubu, SUV_{maks}, MTV gibi) çalışmalarıdır.

Derin öğrenme ise hangi özelliklerin önemli olduğunu verinin kendisinden öğrenen çok katmanlı yapay sinir ağlarını kullanır. Buradaki "derin" sözcüğü, ağın art arda dizilmiş çok sayıda gizli katmandan (*hidden layer*) oluşmasını ve her katmanın bir öncekinin çıktısından giderek daha soyut temsiller öğrenmesini anlatır. Görüntü verisinde uzun süredir baskın olan mimari evrişimli sinir ağlarıdır (CNN); bu ağlar kenar, doku ve şekil gibi özellikleri, kullanıcının elle tanımladığı özniteliklere ihtiyaç duymadan kendileri öğrenir (4). Son yıllarda ise üretken dil modellerinin temelindeki transformer mimarisinin görüntüye uyarlanmış hali olan vision transformer temelli yöntemler tıbbi görüntülemede CNN'lere ciddi bir alternatif olarak öne çıkmaktadır (11).

Günlük kullanım açısından kabaca şöyle özetleyebiliriz: tablo halindeki klinik veri için klasik makine öğrenmesi, ham görüntü için derin öğrenme daha uygundur. Bununla birlikte ikisini birleştiren hibrit yaklaşımlar giderek yaygınlaşmaktadır.

Bir modelin başarısını değerlendirebilmek için iki kavramı daha bilmek gerekir. Referans doğru (*ground truth*), mutlak gerçek olmasa da gerçeğe en yakın kabul edilen referans değeridir; segmentasyonda genellikle deneyimli bir gözlemcinin elle yaptığı çizimle ya da birden fazla gözlemcinin uzlaşısıyla oluşturulur. Referans doğrunun kalitesi modelin ulaşabileceği tavanı belirler; özensiz etiketlenmiş veriyle eğitilen bir model o hataları da öğrenir ve aynı hataları tekrarlar. Dice benzerlik katsayısı ise iki hacim arasındaki örtüşmeyi 0 ile 1 arasında bir değerle ifade eder ve segmentasyon literatürünün standart ölçütü haline gelmiştir (12). Ancak Dice tek başına yanıltıcı olabilir. Küçük bir lezyonda birkaç voksellik kayma skoru belirgin biçimde düşürür, oysa bu kaymanın klinik karara hiçbir etkisi olmayabilir. Bu yüzden Dice'ın yanında yüzey mesafesi ölçütlerinin ve asıl önemlisi klinik uç noktaların (MTV farkı, SUV farkı, evre değişimi gibi) da raporlanması gerektiğini düşünüyoruz.

YZ algoritmalarının çalışması için yeterli işlem gücü de gerekir. Merkezi işlem birimi (CPU) karmaşık ve sıralı işlerde üstündür; grafik işlem birimi (GPU) ise binlerce küçük işlem çekirdeğini paralel çalıştırır. Tüm vücut PET/bilgisayarlı tomografi (BT) gibi üç boyutlu bir hacimde milyonlarca evrişim işleminin aynı anda yapılması gerektiğinden GPU, CPU'ya göre daha hızlıdır; bu paralel işlem gücüne pratikte NVIDIA'nın CUDA katmanı üzerinden erişilir.

Nükleer Tıpta YZ İş Akışı

Konusu ne olursa olsun, nükleer tıpta YZ temelli bir çalışma kabaca beş aşamadan geçer ve her aşamada farklı bir araç ailesi devreye girer (Şekil 1).

Deneyimlerimize göre bir projede en çok zaman alan basamak, çoğu kişinin tahmin edeceğinin aksine,



Şekil 1. Nükleer tıpta yapay zeka temelli bir çalışmanın beş aşamalı iş akışı. Veri toplama aşamasında PET/BT veya SPECT/BT verisi DICOM formatında elde edilir, arşivden çekilir, seçilir ve anonimleştirilir; ön işleme aşamasında yeniden örnekleme, yoğunluk normalizasyonu, kayıtlama, gürültü azaltma, sentetik görüntü üretimi ve merkezler arası harmonizasyon uygulanır; segmentasyon aşamasında organ ve/veya lezyon üç boyutlu olarak sınırlandırılır; özellik çıkarımı aşamasında SUV türevleri, MTV, TLG, lezyon sayısı ve yayılım ölçütleri ile radyomik doku öznitelikleri hesaplanır; model ve analiz aşamasında sınıflandırma, sağkalım tahmini, tedavi yanıtı öngörüsü veya absorbe doz hesabı yapılır
PET/BT: Pozitron emisyon tomografisi/bilgisayarlı tomografi, SPECT: Tek foton emisyon bilgisayarlı tomografi, DICOM: *Digital Imaging and Communications in Medicine,* SUV: Standartlaştırılmış tutulum değeri, MTV: Metabolik tümör hacmi, TLG: Total lezyon glikolizi

veri toplama basamağıdır. Çok zaman noktalı dozimetri çalışmalarında ve tedavi öncesi/sonrası karşılaştırmalarda kayıtlama atlanamayan bir adımdır. Kantitatif nükleer tıbbın asıl darboğazı ise segmentasyondur.

Bu tablo, sık duyduğumuz "en iyi yazılım hangisi" sorusunu da yeniden düşünmeyi gerektirir. Her aşamanın kendi araçları olduğundan, soruyu belirli bir aşama için hangi aracın daha uygun olduğu biçiminde sormak daha doğrudur.

Açık Kaynak Kodlu Yazılım Envanteri

Bu bölümde açık kaynak araçları yukarıda tanımladığımız beş aşamaya göre sıraladık. Araçların aşamalara dağılımı eşit değildir; segmentasyon ve model geliştirme basamaklarında çok sayıda olgunlaşmış seçenek varken veri erişimi ve harmonizasyon basamaklarında seçenekler hala sınırlıdır (Şekil 2). Yazılımların lisans ve düzenleyici statüleri Tablo 1'de özetlenmiştir.

Veri Erişimi ve Yönetimi (Aşama 1)

PyDicom, *Digital Imaging and Communications in Medicine* (DICOM) dosyalarının Python içinde okunması, üstverilerinin düzenlenmesi ve anonimleştirilmesi için kullanılan temel kütüphanedir; açık kaynak bir nükleer tıp iş akışının hemen her zaman ilk halkasını oluşturur (13). dcm4che/dcm4chee, kurum içinde bir araştırma arşivi kurmak için kullanılan, Java tabanlı ve üretim ortamında uzun süredir kendini kanıtlamış bir pakettir (14). Klinik PACS'a dokunmadan ayrı bir araştırma arşivi kurmanın hem veri güvenliği hem de iş yükü açısından daha sağlıklı olduğunu düşünüyoruz. OHIF Viewer ise tarayıcı üzerinden çalışan, eklentilerle genişletilebilen web tabanlı bir görüntüleyicidir (15). Bu aşamada sonucu belirleyen, hangi aracın seçildiğinden çok anonimleştirme ve arşivleme sürecinin en baştan doğru kurgulanmasıdır.

Ön İşleme, Kayıtlama ve Harmonizasyon (Aşama 2)

Simple Insight Segmentation and Registration Toolkit (SimpleITK), ITK kütüphanesinin sadeleştirilmiş bir arayüzüdür; yeniden örnekleme, filtreleme, yoğunluk düzeltme ve maske işlemleri gibi ön işleme adımlarının çoğu bu araçla yapılabilir (16). Kayıtlama gerektiğinde *SimpleElastix* ve temelindeki elastix, rijit ve deforme edilebilir kayıtlamayı yapılandırma dosyaları üzerinden erişilebilir kılar; farklı zamanlarda çekilmiş görüntülerin ortak bir anatomik referansa hizalanmasında kullanılabilir (17).

Çekişmeli üretici ağlar (GAN) ve eşleşmemiş veriyle çalışabilen CycleGAN türevleri ise düşük sayımlı görüntüden tanısal kalitede görüntü üretme, BT olmadan atenüasyon düzeltme haritası sentezleme ve merkezler arasındaki görüntü karakteristiği farklarını giderme gibi problemlerde kullanılmaktadır (18,19).

Genomik alanından uyarlanan ComBat yöntemi, PET verisinde rekonstrüksiyon sonrası harmonizasyon için doğrulanmış ve LIFEx yazılımına entegre edilmiştir (20). Çok merkezli bir çalışmada ön işlemeyi isteğe bağlı bir iyileştirme olarak görmemek gerekir; sonuçların merkezler arasında karşılaştırılabilir olması büyük ölçüde bu basamağa bağlıdır.



Şekil 2. Açık kaynak kodlu yazılım envanterinin iş akışı aşamalarına göre dağılımı. Her sütunda ilgili aşamada kullanılan başlıca araçlar ve bu araçların temel işlev alanı gösterilmiştir: veri erişimi ve arşivleme (PyDicom, dcm4che, OHIF Viewer), ön işleme ve kayıtlama (SimpleITK, SimpleElastix, GAN temelli yöntemler, ComBat), segmentasyon (3D Slicer, ITK-SNAP, MONAI, nnU-Net, MOOSE, TotalSegmentator), özellik çıkarımı (PyRadiomics, LIFEx, IBEX, AMIDE) ve model geliştirme (PyTorch, TensorFlow, scikit-learn, Weka, Orange, KNIME, Google Colab)
DICOM: *Digital Imaging and Communications in Medicine,* OHIF: *Open Health Imaging Foundation,* GAN: Çekişmeli üretici ağ, MOOSE: *Multi-organ Objective Segmentation,* LIFEx: *Local Image Features Extraction,* IBEX: *Imaging Biomarker Explorer,* AMIDE: *A Medical Image Data Examiner.*

Segmentasyon (Aşama 3)

Açık kaynak dünyasının en zengin olduğu basamak segmentasyondur.

3D Slicer, 1998'den bu yana geliştirilen, BSD lisanslı ve çapraz platform çalışan bir tıbbi görüntü işleme platformudur (21). DICOM, NIfTI ve NRRD formatlarını okur; PET/BT füzyonu, çok düzlemli yeniden yapılandırma ve üç boyutlu hacim işleme yapabilir. Eklenti kataloğunda iki yüzü aşkın modül vardır; nükleer tıp açısından öne çıkanlar MTV/TLG hesabı için PET-IndiC ve PETTumorSegmentation, radyomik için SlicerRadiomics ve dozimetri için OpenDose3D'dir. Arayüzü ilk bakışta zorlayıcı olabilir ve öğrenme eğrisi diktir; yine de bir nükleer tıp hekiminin tek satır kod yazmadan bu süreçlerin tamamını yürütebileceği en yetkin platformun 3D Slicer olduğunu düşünüyoruz.

ITK-SNAP daha dar kapsamlıdır, ancak manuel ve yarı otomatik çizimde hızlıdır; pratikte en çok, derin öğrenme modellerinin eğitimi ve doğrulaması için referans doğru maskeleri üretmekte kullanılır (22).

MONAI, PyTorch üzerine kurulu, tıbbi görüntülemeye özgü dönüşümler, kayıp fonksiyonları ve metrikler içeren bir kütüphanedir (23). no-new-U-Net (nnU-Net) ise ön işleme, ağ yapılandırması, eğitim ve son işleme adımlarını veri kümesinin özelliklerinden otomatik olarak türeten, kendi kendini yapılandıran bir çerçevedir (24).

Multi-organ Objective Segmentation, tüm vücut FDG PET/BT görüntülerinde çok sayıda organ ve dokuyu otomatik olarak segmente etmek için geliştirilmiştir; özgün doğrulama çalışmasında 120 doku sınıfı tanımlanmış ve ortalama simetrik yüzey mesafesinin voksel boyutu (2 mm) içinde kaldığı bildirilmiştir (25). TotalSegmentator ise rutin klinik pratikten örneklenmiş 1204 BT incelemesiyle eğitilmiştir ve BT görüntülerinde 104 anatomik yapıyı segmente edebilir (26).

Mimari düzeyde üç seçenekten söz edilebilir. Klasik U-Net düşük-orta düzeyde veriyle ve düşük hesaplama yüküyle çalışır; buna karşılık küresel bağlamı iyi yakalayamaz ve elle ayar gerektirir (5). nnU-Net aynı CNN temelini korur, ama yapılandırmayı otomatikleştirir; kullanımı kolaydır, hesaplama yükü ise belirgin biçimde fazladır. Büyük dil modellerinde kullanılan transformer mimarisine dayanan Swin-UNet, dikkat mekanizması sayesinde küresel bağlamı iyi modeller; ne var ki çok fazla veri ister ve hiperparametre uzayı karmaşıktır, dolayısıyla kısıtlı veri setlerinde her zaman avantaj sağlamayabilir (27).

Özellik Çıkarımı (Aşama 4)

PyRadiomics, tıbbi görüntülerden şekil, histogram ve doku özniteliklerini çıkaran, hem bağımsız hem de 3D Slicer arayüzü üzerinden kullanılabilen bir platformdur; Python ortamında yürütülen radyomik çalışmalarının büyük çoğunluğu bu kütüphaneye dayanır (28). LIFEx ise

programlama bilgisi gerektirmeyen grafik arayüzüyle PET, SPECT, manyetik rezonans, BT ve ultrason görüntülerinden aynı öznitelik ailelerini hesaplar; nükleer tıp hekimi için giriş eşiği en düşük seçenek budur (29). Ancak LIFEx açık kaynak kodlu değildir; araştırma amaçlı ücretsiz dağıtılır, lisansı değiştirme ve yeniden dağıtma hakkı vermez ve ticari kullanım ayrı lisans gerektirir.

Özellik çıkarımı basamağında asıl mesele standardizasyondur. Görüntü Biyobelirteci Standardizasyon Girişimi (IBSI) çeşitli radyomik özniteliği tanımlamış ve bunların dijital fantom üzerindeki referans değerlerini yayımlamıştır (30). Bu standarda uyulmadığında farklı yazılımların aynı lezyon için hesapladığı öznitelik değerleri birbiriyle karşılaştırılamaz hale gelir. Bu nedenle radyomik çalışma planlayan bir ekibin ilk sorması gereken sorulardan biri, kullanacağı yazılımın IBSI uyumlu olup olmadığıdır.

Model Geliştirme ve Analiz (Aşama 5)

PyTorch ve TensorFlow, derin öğrenme modellerinin geliştirildiği ve eğitildiği iki temel kütüphanedir (31,32). Klasik makine öğrenmesi için Python ekosisteminin standart kütüphanesi scikit-learn'dür (33). Kod yazmak istemeyenler için Weka, Orange ve KNIME gibi görsel arayüzlü seçenekler de vardır. RStudio biyoistatistiksel modelleme ve sağkalım analizinde hala vazgeçilmezdir; Google Colab ise kurumunda uygun donanım bulunmayan gruplara bulut üzerinden GPU erişimi sağladığı için özellikle ilgi çekicidir. Yalnız şunu vurgulamak isteriz: kimliği belirlenebilir hasta verisinin bu tür bulut ortamlarında işlenmesi, kurum politikası, etik kurul izni, veri işleme koşulları ve KVKK uyumu ayrıca değerlendirilmeden yapılmamalıdır.

Ticari Uygulamaların Envanteri

Ticari ürünler, açık kaynak araçlardan farklı olarak tek tek algoritmalar yerine paketlenmiş iş akışları sunar; sürüm yönetimi, teknik destek ve PACS entegrasyonu bu paketin parçasıdır. Nükleer tıpta öne çıkan başlıca platformlar aPROMISE (PYLARIFY AI), Siemens syngo.via, Hermes Hermia, MIM Software, PMOD, Philips IntelliSpace/AI Manager, Canon Vitrea (AiCE), United Imaging uAI ve Subtle Medical SubtlePET olarak sıralanabilir.

Görüntüleme ve Kantifikasyon

Bu platformların sunduğu işlevlere topluca bakıldığında ortak bir örüntü görülür: incelemenin türüne göre otomatik yerleşim seçimi, otomatik ya da yarı otomatik organ ve lezyon segmentasyonu, otomatik kayıtlama ve füzyon, otomatik kantifikasyon ve klinik karar desteği, derin öğrenme temelli görüntü iyileştirme ve yapılandırılmış rapor üretimi hemen hepsinde bir biçimde yer alır.

Bu işlevlerin en olgunlaştığı alan prostat kanseri görüntülemesidir. aPROMISE, düşük doz BT bileşeni üzerinde derin öğrenmeyle organları segmente eden, ardından PSMA PET üzerinde patolojik olması muhtemel lezyonları saptayıp kantifiye eden bir tıbbi cihaz yazılımıdır (34,35). Analitik doğrulama çalışmalarında otomatik ve manuel segmentasyonlar arasında yüksek uyum bildirilmiştir (35). Yarı otomatik olarak ölçülen PSMA tümör hacminin ileri evre hastalıkta sağkalımla ilişkili olduğu da gösterilmiştir (3).

Onkoloji dışındaki uygulamalar da hızla çoğalmaktadır. Miyokard perfüzyon SPECT'te derin öğrenme temelli modellerin obstrüktif koroner arter hastalığını öngörmede geleneksel perfüzyon defekti ölçütlerinden daha başarılı olduğu çok merkezli çalışmalarda gösterilmiştir (36,37). Nörolojide FDG PET temelli otomatik sınıflandırma modelleri Alzheimer tipi demansın erken tanısında görsel değerlendirmeye katkı sağlamaktadır (38). Onkolojik PET'te ise lezyonları tutulum düzeyine göre şüpheli ya da şüpheli değil olarak sınıflandırabilen CNN temelli yaklaşımlar, rapor öncesinde bir ön tarama işlevi görebilmektedir (39).

Görüntü iyileştirme tarafında SubtlePET, düşük sayımlı PET görüntülerinde derin öğrenme temelli gürültü azaltma için kullanılan ve bu alanda FDA izni bulunan yazılımlardan biridir (40). Daha az aktiviteyle ve daha kısa sürede çekim yapabilmek, özellikle pediatrik olgularda ve klostrofobik hastalarda günlük pratikte gerçek bir kolaylık sağlayabilir.

Dozimetri

Radyoligand tedavilerinin yaygınlaşmasıyla birlikte dozimetri modülleri ticari platformları birbirinden ayıran bileşenlerden biri haline gelmiştir. Hermia, MIM ve PMOD gibi ürünler çok zaman noktalı SPECT/BT veya PET/BT serilerinin otomatik hizalanmasını, organların otomatik segmentasyonunu, zaman-aktivite eğrisinden kümülatif aktivite hesabını, absorbe doz haritası üretimini ve organ bazında dozimetri raporlamasını tek bir iş akışı içinde sunar (41). Bu zincirin en zahmetli halkası öteden beri organ segmentasyonuydu; bunun otomatikleşmesi, dozimetriyi seçilmiş olgulardan rutin uygulamaya taşıyabilecek bir gelişmedir. Ancak PMOD üretici tarafından yalnızca araştırma amaçlı (research use only, RUO) sunulmaktadır (Tablo 1).

Kısacası ticari ürünlerin asıl katkısı, var olan algoritmaları doğrulama, sürüm kontrolü, PACS entegrasyonu ve teknik destekle bir araya getirip klinikte güvenle kullanılabilir hale getirmeleridir.

Açık Kaynak ile Ticari Ürünlerin Karşılaştırmalı Değerlendirmesi

İki grup arasındaki farkları sekiz başlık altında toplamak mümkündür.

Maliyet en görünür farktır: Açık kaynak araçlar ücretsizdir, ticari çözümler ise lisans bedelinin yanında çoğu zaman yıllık bakım ya da sürüm yenileme ücreti ister. Kurulum açık kaynakta teknik altyapı ve çoğunlukla komut satırı bilgisi gerektirirken ticari ürünler kullanıma hazır gelir. Özelleştirme açık kaynakta sınırsızdır; ticari üründe üreticinin izin verdiği parametrelerle sınırlı kalır. En keskin ayrım regülasyon başlığındadır. Açık kaynak araçların büyük bölümü tıbbi cihaz olarak sertifikalandırılmamıştır ve dokümantasyonlarında yalnızca araştırma amaçlı oldukları açıkça yazar; ticari ürünlerde ise tıbbi cihaz statüsü ürüne, modüle, sürüme, endikasyona ve ülkeye göre değişir, bu yüzden kullanım öncesinde ürünün güncel düzenleyici belgelerine mutlaka bakılmalıdır. Destek açık kaynakta topluluk forumlarına, ticari üründe sözleşmeli teknik desteğe dayanır. Güncelleme açık kaynakta süreklidir ama sürüm kararlılığı değişkendir; ticari üründe periyodik ve doğrulanmıştır. Klinik kullanım açısından açık kaynak araçlar araştırma odaklıdır, ticari ürünler ise klinik kullanıma hazır sunulur. Veri gizliliği açık kaynakta tamamen kurumun kontrolündedir; bulut tabanlı ticari çözümlerde ise sağlayıcının veri işleme politikasına bağlıdır.

Pratikte ayrım şurada belirginleşir: Açık kaynak bir araçla hesaplanan MTV değeri bir araştırma verisi olarak yayımlanabilir; aynı değer hasta raporuna yazıldığında ise onaysız bir yazılımın çıktısına dayanan klinik bir karar haline gelir. Bu yüzden iki grubu birbirinin rakibi olarak görmüyoruz. Yöntem geliştirme, hipotez üretme ve akademik yayın için açık kaynak, hasta yönetimini doğrudan etkileyen rutin kararlar için onaylı ticari çözüm, bugün için makul bir iş bölümüdür (Şekil 3).

Zorluklar ve Dikkat Edilmesi Gereken Noktalar

Veri kalitesi: Alanın en temel darboğazı etiketli verinin azlığıdır. Doğru referansı üretmek zaman ister ve gözlemciler arası değişkenlik taşır. Cihaz, rekonstrüksiyon protokolü, açlık süresi, kan şekeri düzeyi ve enjeksiyon-görüntüleme aralığındaki farklılıklar yüzünden bir merkezde iyi çalışan bir model başka bir merkezde beklenmedik biçimde başarısız olabilir. EANM'nin FDG PET/BT prosedür kılavuzundaki standardizasyon ilkelerine ve EARL akreditasyon çerçevesine uymak bu nedenle YZ çalışmaları için de bir ön koşuldur (42,43). Çok merkezli çalışmalarda EARL uyumlu rekonstrüksiyonların kullanılması, merkezler arası değişkenliği azaltmanın en pratik yoludur.

Veri gizliliği: Türkiye'de 6698 sayılı Kişisel Verilerin Korunması Kanunu'na göre sağlık verisi özel nitelikli kişisel veridir; araştırma amaçlı kullanımda anonimleştirme ve etik kurul onayı zorunludur (44). Burada sık gözden kaçan nokta, DICOM üstverisinden hasta adını silmenin tek başına yeterli olmadığıdır. Kurum adı, cihaz seri numarası, çekim tarihi ve saati, hatta yüz yapısının yeniden oluşturulmasına olanak veren baş-boyun BT verisi de yeniden kimliklendirme riski taşır.

Regülasyon: Klinik karar sürecine giren bir algoritma tıbbi cihaz yazılımı (SaMD) olarak sınıflandırılır ve dolayısıyla CE/FDA süreçlerine tabidir (45). Bu sınıflandırma, araştırma ortamında rahatlıkla kullandığımız bir aracın çıktısını hasta raporuna taşımak istediğimizde karşımıza çıkan asıl eşiktir.

Klinik entegrasyon: PACS uyumluluğu, çıktının rapora aktarılabilmesi ve klinisyenin araca duyduğu güven, teknik performanstan bağımsız engellerdir. Yüksek bir Dice skoru, sonucu okuyan hekimin o sonuca güvenmesini kendiliğinden sağlamaz. Gözlemimiz, kullanıcının çıktıyı hızla düzeltebildiği yarı otomatik iş akışlarının tam otomatik olanlara göre çok daha kolay benimsendiği yönündedir.

Açıklanabilirlik ve raporlama: Derin öğrenme modellerinin "kara kutu" niteliği, hatalı bir çıktının neden üretildiğini izlemeyi güçleştirir. Açıklanabilir YZ yaklaşımları bu boşluğu kapatmaya çalışsa da, üretilen ısı haritalarının (modelin görüntüde nereye "baktığını" gösteren haritalar) klinik olarak nasıl yorumlanacağı hala tartışmalıdır (1). Yayın düzeyinde ise *Checklist for Artificial Intelligence in Medical Imaging* (CLAIM) kontrol listesi tıbbi görüntülemede YZ çalışmaları için asgari raporlama standardını tanımlar; tez ya da makale planlayan ekiplerin bu listeyi işin başında gözden geçirmesini öneririz (46).

Teknik altyapı ve sürdürülebilirlik: Bir YZ sistemini kliniğe entegre etmek yazılımı satın alıp kurmakla bitmez. Donanım, personel eğitimi ve modelin zaman içinde bozulmasını önleyecek periyodik bakım ciddi kaynak ister. Kamera, çekim protokolü ya da rekonstrüksiyon yöntemi değiştiğinde model, alışık olduğu piksel ve gürültü

Açık kaynak araçlar	Ölçüt	Ticari ürünler
Ücretsiz	**Maliyet**	Lisans ve bakım bedeli
Teknik bilgi gerektirir	**Kurulum**	Kullanıma hazır gelir
Sınırsız özelleştirme	**Özelleştirme**	Kısıtlı özelleştirme
Çoğunlukla tıbbi cihaz onayı (CE/FDA) yok	**Düzenleyici onay**	Tıbbi cihaz onayı (CE/FDA) var
Topluluk desteği	**Teknik destek**	Sözleşmeli teknik destek
Sürekli güncelleme	**Güncelleme**	Periyodik güncelleme
Araştırma odaklı	**Klinik kullanım**	Rutin klinik kullanım
Kurum kontrolünde	**Veri gizliliği**	Sağlayıcı kontrolünde

Şekil 3. Açık kaynak araçlar ile ticari ürünlerin sekiz ölçütte karşılaştırmalı değerlendirmesi. Maliyet, kurulum, özelleştirme, düzenleyici onay, teknik destek, güncelleme, klinik kullanım ve veri gizliliği başlıklarında iki grubun birbirini tamamlayan üstünlük ve sınırlılıkları gösterilmiştir. Düzenleyici statünün ürün, modül, sürüm, amaçlanan kullanım ve ülkeye göre değişebileceği dikkate alınmalıdır
CE: *Conformité Européenne,* FDA: *Food and Drug Administration*

dağılımını kaybeder ve fark edilmeden hatalı sonuçlar üretmeye başlayabilir; literatürde bu duruma veri kayması denir. Bu yüzden YZ modellerinin de tıpkı gama kamera ve PET/BT cihazları gibi düzenli kalite kontrolden geçmesi gerekir. Buradaki güçlükler teknik olmaktan çok örgütseldir; sürdürülebilirlik hekim, medikal fizikçi ve bilgi işlem ekiplerinin birlikte çalışmasına bağlıdır.

Gelecek Perspektifi ve Başlangıç için Yol Haritası

Temel modeller (*foundation models*), çok büyük veriyle ön eğitim aldıktan sonra az sayıda örnekle yeni bir göreve uyarlanabilen mimarilerdir. Tıbbi görüntüye uyarlanmış Segment Anything türevleri, her görev için ayrı model eğitme ihtiyacını azaltabilir (47). Çok modaliteli YZ, PET, BT, klinik veri, patoloji ve genomik bilgiyi tek bir modelde birleştirerek kişiye özgü prognoz tahmini yapmayı hedefler. Büyük dil modellerinin klinik bilgiyi başarıyla kodlayabildiği gösterilmiştir (48); bu modeller serbest metin raporları yapılandırılmış formata dönüştürme gibi somut görevlerde de denenmeye başlanmıştır (49). Federe öğrenme ise merkezler arasında veri paylaşmadan ortak model eğitimine olanak tanır ve gizlilik ile veri hacmi arasındaki gerilimi çözmenin en umut verici yollarından biri olarak görünmektedir (50).

Alana yeni giren asistan ve uzmanlar için önerimiz, önce klasik makine öğrenmesinin, sonra derin öğrenmenin öğrenilmesidir. Kendi verisiyle kurulmuş basit bir lojistik regresyon modeli, hazır bir derin öğrenme modelini çalıştırmaktan çok daha öğreticidir. Bundan sonraki adımlar mevcut yazılımların neyi yapıp neyi yapamadığını anlamak, mühendislik fakülteleri ve YZ merkezleriyle donanım ve kodlama konusunda iş birliği kurmak ve disiplinler arasında ortak bir dil geliştirmektir.

Sonuç

Nükleer tıpta YZ bugün tek bir teknolojiden çok, iş akışının her basamağına yayılmış bir araç ekosistemi olarak karşımızda durmaktadır. Açık kaynak araçlar araştırma için güçlü, esnek ve ücretsizdir; ticari çözümler ise klinik entegrasyon ve düzenleyici uyum açısından belirgin üstünlük sağlar. İkisinin birlikte kullanıldığı hibrit bir model bugün için en makul yaklaşım gibi görünmektedir. Bu modelin işleyebilmesi GPU altyapısına

erişime, kodlama desteğine ve mühendislik disiplinleriyle kurulacak kalıcı iş birliklerine bağlıdır. Gelecek çalışmalar için öncelikli gördüğümüz başlıklar; açık kaynak segmentasyon araçlarının Türkiye'deki merkezlerden gelen verilerle bağımsız olarak dış doğrulamasının yapılması, radyomik çalışmalarda IBSI uyumluluğunun ve CLAIM kontrol listesinin standart olarak raporlanması ve federe öğrenmeye dayalı çok merkezli iş birliklerinin kurulmasıdır.

Dipnotlar

Çıkar Çatışması: Yazar tarafından çıkar çatışması bildirilmemiştir.

Finansal Destek: Yazar tarafından finansal destek alınmadığı bildirilmiştir.

Kaynaklar

1. Visvikis D, Lambin P, Beuschau Mauridsen K, et al. Application of artificial intelligence in nuclear medicine and molecular imaging: a review of current status and future perspectives for clinical translation. Eur J Nucl Med Mol Imaging. 2022;49:4452-4463.
2. Barrington SF, Mikhaeel NG, Kostakoglu L, et al. Role of imaging in the staging and response assessment of lymphoma: consensus of the International Conference on Malignant Lymphomas Imaging Working Group. J Clin Oncol. 2014;32:3048-3058. Erratum in: J Clin Oncol. 2016;34:2562.
3. Seifert R, Herrmann K, Kleesiek J, et al. Semiautomatically quantified tumor volume using ^{68}Ga-PSMA-11 PET as a biomarker for survival in patients with advanced prostate cancer. J Nucl Med. 2020;61:1786-1792.
4. LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521:436-444.
5. Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation. In: Navab N, Hornegger J, Wells WM, Frangi AF, editors. Medical image computing and computer-assisted intervention - MICCAI 2015. Cham: Springer; 2015. p. 234-241.
6. Balaji V, Song TA, Malekzadeh M, Heidari P, Dutta J. Artificial intelligence for PET and SPECT image enhancement. J Nucl Med. 2024;65:4-12.
7. Hustinx R, Pruim J, Lassmann M, Visvikis D. An EANM position paper on the application of artificial intelligence in nuclear medicine. Eur J Nucl Med Mol Imaging. 2022;50:61-66.
8. 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.
9. 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.
10. Currie G, Hawk KE, Rohren EM. Ethical principles for the application of artificial intelligence (AI) in nuclear medicine. Eur J Nucl Med Mol Imaging. 2020;47:748-752.
11. Aburass S, Dorgham O, Al Shaqsi J, Abu Rumman M, Al-Kadi O. Vision transformers in medical imaging: a comprehensive review of advancements and applications across multiple diseases. J Imaging Inform Med. 2025;38:3928-3971.
12. Zou KH, Warfield SK, Bharatha A, et al. Statistical validation of image segmentation quality based on a spatial overlap index. Acad Radiol. 2004;11:178-189.
13. Mason D. SU-E-T-33: pydicom: an open source DICOM library. Med Phys. 2011;38:3493.
14. Warnock MJ, Toland C, Evans D, Wallace B, Nagy P. Benefits of using the DCM4CHE DICOM archive. J Digit Imaging. 2007 Nov;20(Suppl 1):125-129.
15. Ziegler E, Urban T, Brown D, et al. Open health imaging foundation viewer: an extensible open-source framework for building web-based imaging applications to support cancer research. JCO Clin Cancer Inform. 2020;4:336-345.
16. Lowekamp BC, Chen DT, Ibáñez L, Blezek D. The design of SimpleITK. Front Neuroinform. 2013;7:45.
17. Klein S, Staring M, Murphy K, Viergever MA, Pluim JP. elastix: a toolbox for intensity-based medical image registration. IEEE Trans Med Imaging. 2010;29:196-205.
18. Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks. Commun ACM. 2020;63:139-144.
19. Zhu JY, Park T, Isola P, Efros AA. Unpaired image-to-image translation using cycle-consistent adversarial networks. In: 2017 IEEE International Conference on Computer Vision (ICCV); 2017; Venice, Italy. IEEE; 2017. p. 2242-2251.
20. Orlhac F, Boughdad S, Philippe C, et al. A Postreconstruction harmonization method for multicenter radiomic studies in PET. J Nucl Med. 2018;59:1321-1328.
21. Fedorov A, Beichel R, Kalpathy-Cramer J, et al. 3D Slicer as an image computing platform for the Quantitative Imaging Network. Magn Reson Imaging. 2012;30:1323-1341.
22. Yushkevich PA, Piven J, Hazlett HC, et al. User-guided 3D active contour segmentation of anatomical structures: significantly improved efficiency and reliability. Neuroimage. 2006;31:1116-1128.
23. Cardoso MJ, Li W, Brown R, et al. MONAI: an open-source framework for deep learning in healthcare. arXiv. 2022. [Preprint]
24. Isensee F, Jaeger PF, Kohl SAA, Petersen J, Maier-Hein KH. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. Nat Methods. 2021;18:203-211.
25. Shiyam Sundar LK, Yu J, Muzik O, et al. Fully automated, semantic segmentation of whole-body ^{18}F-FDG PET/CT images based on data-centric artificial intelligence. J Nucl Med. 2022;63:1941-1948.
26. Wasserthal J, Breit HC, Meyer MT, et al. TotalSegmentator: robust segmentation of 104 anatomic structures in CT images. Radiol Artif Intell. 2023;5:e230024.
27. Cao H, Wang Y, Chen J, et al. Swin-Unet: UNet-like pure transformer for medical image segmentation. In: Computer vision - ECCV 2022 workshops. Cham: Springer; 2023. p. 205-218.

28. van Griethuysen JJM, Fedorov A, Parmar C, et al. Computational radiomics system to decode the radiographic phenotype. Cancer Res. 2017;77:e104-e107.
29. Nioche C, Orlhac F, Boughdad S, et al. LIFEx: a freeware for radiomic feature calculation in multimodality imaging to accelerate advances in the characterization of tumor heterogeneity. Cancer Res. 2018;78:4786-4789.
30. Zwanenburg A, Vallières M, Abdalah MA, et al. The image biomarker standardization initiative: standardized quantitative radiomics for high-throughput image-based phenotyping. Radiology. 2020;295:328-338.
31. Abadi M, Barham P, Chen J, et al. TensorFlow: a system for large-scale machine learning. In: Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16); 2016; Savannah, GA, USA. Berkeley (CA): USENIX Association; 2016. p. 265-283.
32. Paszke A, Gross S, Massa F, et al. PyTorch: an imperative style, high-performance deep learning library. In: Advances in neural information processing systems 32 (NeurIPS 2019). Red Hook (NY): Curran Associates; 2019. p. 8024-8035.
33. Pedregosa F, Varoquaux G, Gramfort A, et al. Scikit-learn: machine learning in Python. J Mach Learn Res. 2011;12:2825-2830.
34. Eiber M, Herrmann K, Calais J, et al. Prostate cancer molecular imaging standardized evaluation (PROMISE): Proposed miTNM classification for the interpretation of PSMA-ligand PET/CT. J Nucl Med. 2018;59:469-478. Erratum in: J Nucl Med. 2018;59:992.
35. 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.
36. Betancur J, Commandeur F, Motlagh M, et al. Deep Learning for prediction of obstructive disease from fast myocardial perfusion SPECT: a multicenter study. JACC Cardiovasc Imaging. 2018;11:1654-1663.
37. Slomka PJ, Miller RJ, Isgum I, Dey D. Application and translation of artificial intelligence to cardiovascular imaging in nuclear medicine and noncontrast CT. Semin Nucl Med. 2020;50:357-366.
38. Ding Y, Sohn JH, Kawczynski MG, et al. A deep learning model to predict a diagnosis of Alzheimer disease by using ^{18}F-FDG PET of the brain. Radiology. 2019;290:456-464.
39. Sibille L, Seifert R, Avramovic N, et al. ^{18}F-FDG PET/CT uptake classification in lymphoma and lung cancer by using deep convolutional neural networks. Radiology. 2020;294:445-452.
40. Bonardel G, Dupont A, Decazes P, et al. Clinical and phantom validation of a deep learning based denoising algorithm for F-18-FDG PET images from lower detection counting in comparison with the standard acquisition. EJNMMI Phys. 2022;9:36.
41. Dewaraja YK, Frey EC, Sgouros G, et al. MIRD pamphlet No. 23: quantitative SPECT for patient-specific 3-dimensional dosimetry in internal radionuclide therapy. J Nucl Med. 2012;53:1310-1325.
42. Boellaard R, Delgado-Bolton R, Oyen WJ, et al.; European Association of Nuclear Medicine (EANM). FDG PET/CT: EANM procedure guidelines for tumour imaging: version 2.0. Eur J Nucl Med Mol Imaging. 2015;42:328-354.
43. Kaalep A, Sera T, Oyen W, et al. EANM/EARL FDG-PET/CT accreditation - summary results from the first 200 accredited imaging systems. Eur J Nucl Med Mol Imaging. 2018;45:412-422.
44. Türkiye Cumhuriyeti. 6698 sayılı Kişisel Verilerin Korunması Kanunu. Resmî Gazete. 2016;(29677). Available from: https://www.resmigazete.gov.tr/eskiler/2016/04/20160407-8.pdf
45. European Parliament, Council of the European Union. Regulation (EU) 2024/1689 of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). Official Journal of the European Union. 2024;L 2024/1689. Available from: https://eur-lex.europa.eu/eli/reg/2024/1689/oj/eng
46. Mongan J, Moy L, Kahn CE Jr. Checklist for artificial intelligence in medical imaging (CLAIM): a guide for authors and reviewers. Radiol Artif Intell. 2020;2:e200029.
47. Ma J, He Y, Li F, Han L, You C, Wang B. Segment anything in medical images. Nat Commun. 2024;15:654.
48. Singhal K, Azizi S, Tu T, et al. Large language models encode clinical knowledge. Nature. 2023;620:172-180. Erratum in: Nature. 2023;620:E19.
49. Adams LC, Truhn D, Busch F, et al. Leveraging GPT-4 for post hoc transformation of free-text radiology reports into structured reporting: a multilingual feasibility study. Radiology. 2023;307:e230725.
50. Rieke N, Hancox J, Li W, et al. The future of digital health with federated learning. NPJ Digit Med. 2020;3:119.