

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 $10 \times 10 \text{ cm}^2$ 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 mm^2 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 “dosimetrics” 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 radyoterapiadaki 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 sınırlanmış, kullanımını kısıtlamıştır (van Dijk vd., 2022). MC doz hesaplama hızını artırmak 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 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.