

Radyoterapi Tedavi Planlama Konturlamasında Yapay Zeka

Hikmettin Demir¹

Özet

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

1. GİRİŞ

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

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

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

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

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

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

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

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

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

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

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

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

2. Radyoterapi Tedavi Planlama Konturlamasında Yapay Zeka

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

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

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

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

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

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

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

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

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

3. YZ tabanlı oto-segmentasyonun klinik açıdan değerlendirilmesi

3.1. Klinik değişkenliklere bağlı zorluklar ve sınırlılıklar

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

3.2. Görüntü kalitesi ve edinim parametrelerindeki varyasyonlar

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

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

3.3. Kurumlara özgü klinik protokollerdeki ve hasta özelliklerindeki farklılıklar

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

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

3.4. Konturlama stilleri ve kılavuzlarındaki farklılıklar

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

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

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

3.5. Uygulama Aşamaları ve QA

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

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

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

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

4. Sonuç

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

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

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

Kaynaklar

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

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

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

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

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