

# Yapay zekâ radyoloğun yerini alır mı?

**Prof. Dr. Cengiz Erol**



1970 yılında Ankara, Ayaş'ta doğdu. Hacettepe Üniversitesi Tıp Fakültesinden mezun oldu (1994). Radyoloji uzmanlığını Hacettepe Üniversitesi Tıp Fakültesinde tamamladı (1999). 1999-2010 yılları arasında TDV 29 Mayıs Hastanesinde radyoloji uzmanı olarak çalıştı. 2010 yılında Selçuk Üniversitesi Tıp Fakültesi Radyoloji Ana Bilim Dalı'na ve 2012 yılında İstanbul Medipol Üniversitesi Radyoloji Ana Bilim Dalı'na yardımcı doçent olarak atandı. 2013 yılında doçent, 2018 yılında profesör olan Erol, halen İstanbul Medipol Üniversitesi Tıp Fakültesi Radyoloji Ana Bilim Dalı Başkanı olarak görev yapmaktadır.

**R**adyoloji bilimi, X ışınının, 1895 yılında Alman fizikçi Wilhelm Conrad Röntgen tarafından bulunması ile doğdu (1). Bu keşiften sadece 2 yıl sonra ülkemizdeki ilk röntgen cihazı kuruldu. Yirminci yüzyılın son çeyreğinde keşfedilen yeni teknolojiler, yeni tanısal cihazların ortaya çıkmasını sağladı. Günümüzde görüntüleme cihazları arasında; röntgen cihazları, bilgisayarlı tomografi (BT), pozitron emisyon tomografisi (PET), floroskopi ve anjiyografi cihazları, ultrason (US) ve manyetik rezonans (MR) cihazları eklendi. BT'nin klinik kullanıma girdiği 1970'lerde bir tek görüntüyü oluşturmak için dakikalarca beklemek gerekirken bugün birkaç saniyede yüksek çözünürlüklü binlerce görüntü elde edebiliyoruz.

Hayatın her alanına nüfuz etmekte olan yapay zekânın radyoloji iş akışına entegre edilmesi tetkik hızını ve kalitesini artırmaktadır. Görüntünün elde edilme ve takip eden ön işleme adımlarında hastanın aldığı X ışını miktarını düşürmek, tetkiki hızlandırmak ve görüntü artefaktlarını azaltarak görüntü kalitesini iyileştirmek mümkün olmaktadır. Ayrıca yapay zekânın rapordan önce radyolog için hazırlayacağı anormal bulgular ve olası ayırıcı tanıları tanı kalitesini de yükseltecektir. Bunlar verimlilikte artış da beraberinde getirir.

Radyoloji uzmanlık eğitimini alan doktorlar radyoloji görüntülerini görsel olarak değerlendirir ve anormal bulguları tespit ederek onları karakterize etmeye

çalışırlar. Bu şekilde bulgularını raporlayarak hastalıkların ayırıcı tanısını yapar, mümkünse hastalığın tanısını koyar ya da bilinen hastalıkların görüntüleri üzerinden takibini yaparlar. Radyoloğun başarısı, aldığı eğitime ve uzun yıllara dayanan deneyimine bağlıdır. Modern tıbbi yaklaşımda hastalıkların tanı ve tedavisinde görüntüleme cihazlarının ağırlığı ve önemi gün geçtikçe artarken daha hızlı ve daha kesin sonuca ulaşma beklentisi de beraberinde artmaktadır. Tüm dünyada radyoloji tetkik sayıları, mevcut radyologların sayısı ile karşılaştırıldığında orantısız bir şekilde artmaya devam ettiği görülmektedir. Türkiye, 1 milyon kişiye düşen MR cihazı sayısında 11,2 ile 35 OECD ülkesi arasında 26. sırada yer alırken bin kişiye düşen MR tetkik sayısında ise 186,4 ile birinci sırada yer almaktadır (2). Ülkemizde baktığımızda gelişmiş ülkelere farklı olarak mevcut talebe yetişmek için MR ve BT çekimlerinin 7 gün 24 saat aralıksız devam etmesi gerekmekte ve bu da radyologların iş yüklerinde dramatik bir artışa yol açmaktadır. Bazı durumlarda, ortalama bir radyoloğun bir iş gününde 50-100 civarında BT-MR raporu yapması gerekebilmektedir. Bu durumda binlerce görüntüyü görsel olarak işlemesi ve sonuca bağlaması gereken radyoloğun hata oranının artması kaçınılmazdır. Derin öğrenme modelleri günde 24 saat destekleyici görevler üstlenebilirse radyoloğun yoğunluğunu hafifletip hata oranının düşürülmesine katkıda bulunabilir.

Bir radyolog BT'de akciğer nodüllerini tespit ederken, sanal kolonoskopide kolon poliplerini bulmaya çalışırken ya da mamografide meme kanserini yakalamaya çalışırken radyolojik görüntü kümelerini görsel olarak tarar, anormal bir bulguyu önce görsel algılama becerisi ile tespit eder ve ardından bilişsel becerisi ile bu bulguları onaylar ya da reddeder. Akciğer nodülleri, kolon polipleri ve meme lezyonlarını tespit etmek için geliştirilmiş bilgisayar destekli otomatik tespit (BDOT) programları uzun bir süredir radyoloji pratiğinde kullanılmaktadır. Akciğer nodülleri özelinde konuşacak olursak bilgisayar raporundan önce BT görüntülerini tarar, tespit ettiği nodülleri listeler ve doğruluğunu onaylaması için radyoloğun onayına sunar. Otomatik tespit sistemlerinde yalancı pozitiflik oranlarının yüksek olması ve bazı çalışmalarda BDOT sistemlerinden gelen sonuçların radyologların performansı üzerinde istatistiksel bir önemi olmadığı gösterilmiş olması nedeniyle eski önemini yitirmiştir. Son yıllarda derin öğrenme algoritmalarının entegre edildiği BDOT programlarının geleneksel BDOT programlarına göre daha iyi performans gösterdiği ve radyologlarla karşılaştırıldığında benzer sonuçlara sahip olduğu görülmektedir (3).

Yapay zekânın radyolojide kullanılmaya başlandığı bir diğer alan; anormal dokuların karakterizasyonu, segmentasyonu ve tanısının konulmasıdır. Derin öğrenme, kendisine sunulan yeterli örnek veriyle, hastalıklı dokuları normal

dokulardan ayırarak tanımlayabilir ve böylece bir radyoloğun segmentasyon ihtiyacını ortadan kaldırabilir. Derin öğrenme aynı zamanda, radyologlar arası segmentasyon değişkenliklerini de önleyebilir (4).

Derin öğrenmenin şu anda radyolojik verileri kullanarak bazı hastalıkları teşhis edebildiğini biliyoruz. Örneğin akciğer grafisi dünyada en çok yapılan radyolojik tetkik olup derin öğrenme için çok büyük veri kümesine sahiptir. Derin öğrenme modellerinin akciğer grafisindeki pnömoni ve pnömotoraks gibi klinik olarak önemli durumları genç radyologlarla karşılaştırılabilir bir performans düzeyinde tespit edebildiğini görüyoruz (5). Yapay zekâ acil tedavi gerektiren hastalara karşı radyologları ve doktorları uyararak için kullanılabilen gibi görüntüleme bulgularını aciliyetine göre sıralayarak radyoloji iş akışını optimize edebilir. MR anjiyografide beyin anevrizmalarının saptanması, karaciğer kitlelerinin kategorize edilmesi, karaciğer fibrozisinin evrelendirilmesi, gliomların genomik durumunun belirlenmesi gibi pek çok alanda çalışmalar devam etmektedir (6). Görüntüleme dayalı histopatolojik bulguları tahmin etmek için eğitilmiş derin öğrenme modelleri, biyopsiden kaynaklanan komplikasyon riskini azaltmada yardımcı olabilir.

Hastalığın izlenmesi ve tedaviye yanıt değerlendirilmesi için takip tetkiklerinin öncekilerle karşılaştırılması ve değişikliklerin ölçülmesi gerekir. Örneğin tümör tedavisine yanıtın değerlendirilmesinde en sık kullanılan parametre boyut değişikliğidir. Ancak bazı durumlarda tümörün ilaç tutma düzeyi gibi başka parametreler de kullanılabilir. Bilgisayar destekli değişiklik analizi daha yeni bir yapay zekâ uygulaması olup henüz yaygın bir şekilde kullanılmamaktadır. Ancak bu tür zamansal sıralı veri formatlarının değerlendirilmesi için çok uygundur ve gelecekte geniş uygulama alanı bulması beklenmektedir.

Radyoloji raporlarının metinsel olarak oluşturulması rutin işlemlerde zahmetli ve zaman alıcı bir işidir. Yapay zekâ destekli otomatik rapor oluşturma araçları standardize edilmiş bir terminolojinin önünü açabilir ve böylece tüm taraflarca anlaşılabilir iyi bir rapor oluşturmak mümkün olabilir. Böyle bir rapor akciğer kanseri taramasında bir nodülün

boyutunu, yerleşimini, kanser olasılığını klinisyene yansıtabilir. Klinikten, patolojiden, biyokimyadan ve genetik testlerden benzer şekilde elde edilmiş veriler radyoloji verileriyle entegre edildiğinde tanı ve tedavide tekrarlanabilir, doğruluk düzeyi yüksek ve güvenli sonuçlara ulaşmak mümkün olacaktır.

Yapay zekâ öğrenilebilmek için veriye gereksinim duyar. Radyoloji görüntü verileri PACS (*Picture Archiving and Communication Systems*) adını verdiğimiz görüntü saklama ve iletişim sistemlerinde depolanmaktadır. Bugün Sağlık Bakanlığımızın hayata geçirdiği e-nabız sistemi sayesinde ülkemizde çekilen tüm tıbbi görüntüler ve raporlar merkezi arşivde depolanmaktadır. Böylece Türkiye'nin herhangi bir sağlık merkezinde çekilmiş radyolojik görüntüleri başka bir merkezdeki doktorun ulaşması mümkün olmakta ve belli bir oranda gereksiz tekrar çekimin önüne geçilebilmektedir (7). Gelecekte bu sistem üzerine entegre edilecek derin öğrenme destekli yapay zekâ uygulamaları sayesinde radyolojik görüntüleme protokolleri ve kontrast madde uygulamalarında standardizasyon sağlanabilir. Böylece sağlık kurumları arasındaki tetkik kalite farklılıklarını önlemek mümkün olacaktır. Ülkemizde bu alanda başlatılacak çalışmalar ve büyük veri ile beslenen derin öğrenme algoritmaları sayesinde radyoloji iş akışında performans ve etkinlik artışı sağlanarak zamanı ve emeği tüketen rutin görevler azaltılabilir. Derin öğrenme ve yapay zekâ, otomatik etiketleme algoritmalarının bulunmadığı nadir görülen hastalıkların tanınmasında sıkıntılar yaşamaktadır. E-nabız sayesinde az görülen hastalık verileri bu sistemde biriktirilerek derin öğrenmenin hizmetine verilebilir.

Sonuç olarak, yapay zekânın radyolojik görüntülemeye entegrasyonu artmaktadır. Derin öğrenme ve yapay zekâ, gelecekte radyoloji alanındaki vaatlerini gerçekleştirebilirse radyologların tanısal mükemmelliğe ulaşmalarına ve sağlık hizmetlerini geliştirmelerine yardımcı olacaktır. Deneyimli radyologlar tarafından etiketlenmiş görüntüler kullanılarak oluşturulan modeller eğitim sürecine entegre edildikçe mesleğe yeni başlayan radyologların eğitim süreci de bundan olumlu etkilenecektir. Henüz emekleme döneminde olan yapay zekânın yakın ve orta gelecekte

Derin öğrenme ve yapay zekâ, gelecekte radyoloji alanındaki vaatlerini gerçekleştirebilirse radyologların tanısal mükemmelliğe ulaşmalarına ve sağlık hizmetlerini geliştirmelerine yardımcı olacaktır. Deneyimli radyologlar tarafından etiketlenmiş görüntüler kullanılarak oluşturulan modeller eğitim sürecine entegre edildikçe mesleğe yeni başlayan radyologların eğitim süreci de bundan olumlu etkilenecektir.

radyologların yerini alması pek mümkün görünmüyor. Radyologların rolleri teknoloji geliştikçe genişleyecektir. Radyologlar sadece sonuçları denetlemekle kalmayacak gözden kaçmış bilgileri keşfetmeyi sürdüreceklerdir.

## Kaynaklar

1) Mould RF. *Invited Review: Röntgen and the Discovery of X-rays*, *Br J Radiol*. 1995 Nov;68(815):1145-76.

2) Sak H, Sağbaş İ. *Sağlık Harcamaları Kapsamında Tıbbi Görüntüleme Cihazlarının Bölgesel Dağılımının Analizi*, *Journal of Public Finance Studies* 2020; 63: 77-92.

3) Huang X, Shan J Vaidya V in 2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017) 379-383 (Mekbourne, Australia, 2017).

4) Hosny A, Parmar C, Quackenbush J, et al. *Artificial Intelligence in Radiology*, *Nat Rev Cancer*. 2018 Aug;18(8):500-510.

5) Rajpurkar P, Irvin J, Ball RL, et al. *Deep Learning for Chest Radiograph Diagnosis: A Retrospective Comparison of CheXNeXt to Practicing Radiologists*. *PLoS Med*. 2018;15(11): e1002686.

6) Yasaka K, Abe O. *Deep Learning and Artificial Intelligence in radiology: Current Applications and Future Directions*. *PLoS Med*. 2018 Nov 30;15(11):e1002707.

7) *Dijital Sağlık ve E-nabız Farkındalık Düzeyi Belirleme Çalışması*, Mehmet Yorulmaz, Şeyma Odacı, Merve Akkan, Selçuk Üniversitesi, Sosyal ve Teknik Araştırmalar Dergisi, Sayı: 16, 2018, ss. 1-11.