


İnterstisyel Akciğer Hastalığı, Kantitatif BT Analizi ve Yapay Zeka Uygulamaları, Radiomics

Interstitial Lung Disease, Quantitative CT Analysis and Artificial Intelligence Applications, Radiomics

Naciye Sinem Gezer 

ÖĞRENME HEDEFLERİ

- Tıbbi görüntü analizinde kullanılan kantitatif analiz yöntemlerinin (doku tabanlı analiz, kantitatif bilgisayarlı tomografi ve radiomics) öğrenilmesi
- İnterstisyel akciğer hastalıklarının görüntülenmesinde kullanılan yüksek çözünürlüklü akciğer bilgisayarlı tomografisinin analizinde yapay zekanın kullanım amaçlarının anlaşılması
- Bu alanda yapılmış çalışmaların yöntemlerinin anlaşılması ve geliştirilmiş makine öğrenmesi uygulamalardan alınan sonuçların öğrenilmesi
- Medikal görüntü işlemede yapay zekanın önündeki engellerin ve bu engellerin nasıl aşılabileceğinin anlaşılması

Gezer NS. Interstitial Lung Disease, Quantitative CT Analysis and Artificial Intelligence Applications, Radiomics. *Trd Sem 2024;12(1):162-176.*

ÖZ

Son on yılda başta derin öğrenme olmak üzere yapay zeka teknolojisindeki ilerlemeler, tıbbi görüntü analizinde yeni fırsatlar yaratmıştır. Bu alandaki çalışmaların sayısı gün geçtikçe artmakta ve yapay zekanın performansı iyileştirilmektedir. Yapılan çalışmalarda yeni görüntüleme biyobelirteçleri geliştirmek ve güvenilir görüntü analiz araçları oluşturmak amaçlanmıştır. Yüksek çözünürlüklü akciğer bilgisayarlı tomografi görüntülerinin yapay zekanın bir alt kümesi olan makine öğrenmesi yöntemi ile analizi sayesinde, interstisyel akciğer hastalıklarının erken ve doğru tanısının, şiddetinin belirlenmesinin ve prognozun öngörülmesinin mümkün olabileceği gösterilmiştir. Tüm bu umut verici gelişmelere rağmen aşılması gereken bazı zorluklar da vardır. En önemlilerinden biri, performansı yüksek modeller geliştirilmesi için büyük ve kaliteli veri kümelerine ihtiyaç olmasıdır. Bu nedenle ulusal veri havuzları oluşturulmasına ve uluslararası iş birliklerine ihtiyaç vardır. Elde olunan dijital görüntüleme verisinin en ideal şekilde toplanması, depolanması, paylaşımı ve yönetimi sağlanmalıdır. Ayrıca kişisel veri mahremiyeti ihlalinin önüne geçilmesine yönelik önlemler alınmalıdır.

Anahtar Kelimeler: Derin öğrenme, interstisyel akciğer hastalığı, makine öğrenmesi, radiomics, yapay zeka

Dokuz Eylül Üniversitesi Tıp Fakültesi, Radyoloji Anabilim Dalı, İzmir, Türkiye

✉ Naciye Sinem Gezer • drsinemgezer@gmail.com

Geliş Tarihi: 28.08.2023 • Kabul Tarihi: 18.03.2024



Copyright© 2024 Yazar. Türk Radyoloji Derneği adına Galenos Yayınevi tarafından yayımlanmıştır. Creative Commons Atıf-GayriTicari 4.0 Uluslararası (CC BY-NC 4.0) Uluslararası Lisansı ile lisanslanmış, açık erişimli bir makededir.

doi: 10.4274/trs.2024.23114

turkadyolojiseminerleri.org

ABSTRACT

In the last decade, advances in artificial intelligence technology, especially deep learning, have created new opportunities in medical image analysis. The number of studies in this field is increasing day by day and the performance of artificial intelligence is being improved. The aim of the studies is to develop new imaging biomarkers and to create reliable image analysis tools. It has been shown that early and accurate diagnosis of interstitial lung diseases, determination of severity and prediction of prognosis can be possible by the analysis of high-resolution chest computed tomography images with machine learning method, which is a subset of artificial intelligence. Despite all these promising developments, there are still some challenges to be overcome. One of the most important is the need for large and high-quality datasets to develop high-performance models. For this reason, there is a need for the creation of national data pools and international cooperation. Optimal collection, storage, sharing and management of the obtained digital imaging data should be ensured. In addition, measures should be taken to prevent personal data privacy violations.

Keywords: Deep learning, interstitial lung disease, machine learning, radiomics, artificial intelligence

GİRİŞ

Bilgi işlem gücündeki gelişmeler sayesinde son on yılda yapay zekanın tıbbi görüntüleme alanında kullanımına yönelik çalışmalar artmıştır. Elde edilen başarılı sonuçlar hem araştırmacıların hem potansiyel kullanıcıların hem de yatırımcıların büyük ilgisini çekmiştir.

Tıbbi görüntülerin işlenmesi ve analizinde yapay zekanın kullanım amacı, uzmanların görüntüleri daha iyi yorumlamasını ve daha doğru tanı koymasını sağlamak, klinik yararlanımı artırmak, yapılan işi zaman ve maliyet açısından daha ekonomik hale getirmektir. Genel kanı, yapay zekanın radyologların rakibi veya alternatif olmayıp aksine onların kullandığı yardımcı ve faydalı bir araç olacağı yönündedir.

İnterstisyel akciğer hastalıklarının (İAH) etkin yönetiminde, hastalığın erken ve doğru tanısı, şiddetinin belirlenmesi, prognozun öngörülmesi ve tedaviye yanıtın kesin doğrulukla belirlenmesi ile ilgili zorluklar yaşanmaktadır. Makine öğrenmesi, bu zorlukların aşılmasında alternatif çözüm yöntemleri sunmaktadır (Tablo 1). Tıbbi görüntü işleme ve analizi alanında, ağırlıklı olarak derin öğrenme yöntemi kullanılarak geliştirilmiş doku tabanlı analiz ve patern tanıma uygulamalarının yakın gelecekte hasta değerlendirmesinin rutin bir parçası olacağı öngörülmektedir [1].

Erken ve Doğru Tanı

Benzer semptomlara ve klinik özelliklere sahip olmasına rağmen İAH, patolojik olarak farklı özelliklere ve prognoza sahip heterojen bir hastalık grubudur [1]. İAH tanısının doğru konulması çok önemlidir çünkü hastalık seyri ve tedaviye yanıt tahmin etmeye yardımcı olur. Ancak hastalığın tanısında radyopatolojik paternlerin temel alındığı karmaşık bir klinik, radyolojik ve patolojik tanı süreci yaşanır.

Yüksek çözünürlüklü akciğer bilgisayarlı tomografisi (YÇBT), İAH şüphesi olan tüm hastalarda rutin olarak kullanılır ve hastalık morfolojisi ile hastalığın yaygınlığının invazif olmayan bir şekilde görüntülenmesini sağlar [2]. Bununla birlikte, YÇBT bulgularının görsel değerlendirmesinde gözlemci-içi ve gözlemciler-arası uyumun yüksek olmayışı, hastalığın tanısını zorlaştırır [2-5]. Bu zorluk sayısal, objektif ve tekrarlanabilir nitelikte olan kantitatif görüntüleme yöntemiyle aşılarak hastalığın erken ve doğru tanısı kolaylaştırılabilir [5, 6].

Ayrıca, İAH şüphesi olmayan ancak YÇBT’de raslantısal olarak saptanan subklinik interstisyel akciğer anormallikleri bulunan olguların bir kısmının ilerleyen yıllar içerisinde İAH geliştirdiği gözlemlenmiştir [7]. Bu grup olgular içerisinde hangisinin İAH geliştirdiğinin belirlenmesi klinik açıdan henüz mümkün değildir. Derin öğrenme tabanlı algoritmalar sayesinde interstisyel akciğer anormalliklerinin davranış paternini analiz etmenin ve hastalık

gelişimini öngörmenin mümkün olabileceği öne sürülmektedir [3, 5, 8].

Hastalığın Şiddetinin Belirlenmesi

Yüksek çözünürlüklü akciğer bilgisayarlı tomografisi ile İAH'nin görsel değerlendirmesi, kısa takip süreleri boyunca hastalık şiddetindeki değişikliklere karşı çok az duyarlılığa sahiptir [2]. Objektif ve tekrarlanabilir nitelikte bir bilgisayar tabanlı teknik olan kantitatif bilgisayarlı tomografi (QBT) hastalığın takibinde kullanılabilir güvenilir bir yöntemdir [4]. Yapılan çalışmalar BT atenüasyon değerlerinin istatistiksel analizi yapılarak hastalık şiddetinin ölçülebileceğini ortaya koymuştur [3, 5, 9, 10].

Computer-aided Lung Informatics for Pathology Evaluation and Rating (CALIPER), hacimsel histogram verisini ve morfolojik veriyi kullanarak YÇBT görüntülerindeki İAH bulgularını tam otomatik etiketleyen bir uygulamadır [11]. Mevcut olan buzlu cam miktarını, retiküler opasiteleri, bal peteği oluşumunu, damarla ilgili yapıları ve perivasküler fibrozu tanımlar ve bunların miktarını belirler. Ayrıca radyoloğa İAH'nin niceliğini belirlemede yardımcı olan grafiksel veriler sunar. Yakın zamanda yayınlanan bir çalışma, makine öğrenmesi kullanılarak belirlenen CALIPER skorlarının, idiyopatik pulmoner fibrozis (İPF) tanısı koymada ve İPF'nin zaman içerisindeki ilerleyişini göstermede kullanılabilirliği gösterilmiştir [12].

Tablo 1. İnterstiyel akciğer hastalıklarında kullanılmak üzere geliştirilmiş kantitatif bilgisayarlı tomografi ve derin öğrenme araçları

Kantitatif BT

| | |
|--|--|
| CALIPER | Hacimsel histogram verisini ve morfolojik veriyi kullanarak YÇBT görüntülerindeki İAH bulgularını tam otomatik etiketler (normal akciğer, buzlu cam, retiküler opasiteler, bal peteği oluşumu, vb.) ve bunların miktarını belirler |
| AMFM | Doku tabanlı analiz yöntemini kullanarak YÇBT görüntülerindeki İAH bulgularını tam otomatik etiketler (normal akciğer, buzlu cam, retiküler opasiteler, bal peteği oluşumu, nodül, vb.) ve bunların miktarını belirler |
| QLF | İAH yaygınlığını belirlemek için YÇBT görüntülerindeki fibrotik retiküler desen, bal peteği ve buzlu cam bulgularının miktarını ölçer. Hastalık progresyonuna ilişkin niceliksel değerlendirme yapar |
| Fonksiyonel solunumsal görüntüleme (<i>functional respiratory imaging</i>) | Düşük doz YÇBT görüntülerini bilgisayar tabanlı akış simülasyonlarıyla birleştirerek fonksiyonel görüntüleme yapar. Hava yolu hacmini, damar hacmini ve hava yolu direncini ölçer. Ek olarak, mortalitenin bir göstergesi olan traksiyon bronşektazisi miktarını ölçer |

Derin öğrenme

| | |
|--|---|
| SOFIA | YÇBT'de OİP benzeri özellikleri tanımlamak üzere geliştirilmiştir. "OİP olasılık" skoru verir. İPF şüphesi olan hastalarda hastalığın ilerlemesini ve mortaliteyi öngörebilir |
| Veriye dayalı doku analizi (<i>data-driven texture analysis</i>) | YÇBT görüntülerini fibrozis varlığına göre sınıflandırır ve fibrozisin miktarını ölçer. Hastaları fibrozis derecesine göre sınıflandırabilir |

BT, bilgisayarlı tomografi; CALIPER, *Computer-aided Lung Informatics for Pathology Evaluation and Rating*; AMFM, *Adaptive Multiple Features Method*; QLF, kantitatif akciğer fibrozis; SOFIA, *Systematic Objective Fibrotic Imaging Analysis Algorithm*; YÇBT, yüksek çözünürlüklü akciğer bilgisayarlı tomografi; İAH, interstiyel akciğer hastalığı; OİP, olağan interstiyel pnömoni; İPF, idiyopatik pulmoner fibrozis.

Prognozun Öngörülmesi

İnterstiyel akciğer hastalıklarının doğal seyri bireysel olup hastalar arasında oldukça değişkendir. Tanı anında elde olunan radyolojik ve klinik verilere dayanarak hastalığın seyrini önceden tahmin etmek henüz mümkün değildir [13].

İdiyopatik pulmoner fibrozis, prototipik progresif fibrotik akciğer hastalığı olmasına rağmen, İPF dışı progresif fibrotik akciğer hastalığının da tıpkı tedavi edilmemiş İPF'ye benzer bir hastalık seyri izleyebileceği ve bu hastaların anti-fibrotik ilaçlardan fayda gördüğü bilinmektedir [5, 14]. Bu durum, araştırmacıları temel radyolojik ve klinik verileri kullanarak progresif fibrotik akciğer hastalığının gelişimini güvenilir bir şekilde öngören biyobelirteçler bulmaya yöneltmiştir [3].

Klinik veya histopatolojik tanılarına bakılmaksızın bazı hastalar "ilerleyici pulmoner fibroz" olarak adlandırılan, geleneksel tedaviye rağmen ilerleyici hastalık davranışı gösterir [15]. Bu hasta grubunun belirlenmesi ve etkin tedavinin erken dönemde başlaması, hastalığın prognozu açısından büyük önem taşır. Ancak tanımlanmış modeller, özellikle tipik olağan interstiyel pnömoni (OİP) paterni görülmeyen olgularda, hastalığın seyrini öngörme ve tedaviye yanıt hakkında güvenilir bilgi verme konusunda yetersiz kalmaktadır [3]. Zorlu vital kapasite (FVC) değişikliği İPF'de ve İPF dışı ilerleyici İAH'de mortalitenin en iyi belirteci olarak kabul edilmekle birlikte doğruluk ve güvenilirlik düzeyi değişkendir [14, 16-18]. Tedaviye yanıtı değerlendirmek için daha hassas ve tekrarlanabilir biyobelirteçlere ihtiyaç vardır [5].

Tanısal bir derin öğrenme algoritması olan *Systematic Objective Fibrotic Imaging Analysis Algorithm* (SOFIA), büyük ulusal bir İPF çalışma grubunda prognozu belirlemede başarılı olmuştur [19]. Sonraki çalışmalarda prognoz belirlemeye yönelik algoritmaların radyolojik verilerle birlikte fizyolojik, proteomik ve genomik verileri kullanmasının başarımı artırdığı gösterilmiştir [3].

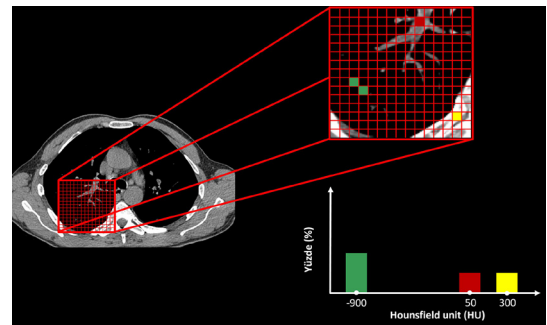
Bu makalede İAH'nin radyolojik tanısında ve yönetiminde karşılaşılan zorlukların aşıl-

masında makine öğreniminin sunduğu problem çözücü yöntemlerin ana hatları ile anlatılması amaçlanmıştır. Yapılmış çalışmalar ve geliştirilmiş uygulamaların büyük çoğunluğunda YÇBT görüntüleri kullanıldığı için makale YÇBT temel alınarak hazırlanmıştır.

KANTİTATİF BİLGİSAYARLI TOMOGRAFİ VE İNTERSTİYEL AKCİĞER HASTALIKLARI

Yüksek çözünürlüklü akciğer bilgisayarlı tomografisine dayalı kantitatif analizler, İAH'de gözlemciler arası değişkenlik oranlarının yüksek olması nedeniyle önem taşır. Öncü QBT çalışmalarında akciğer bölütlenmesine, görüntü ön işlemeye (örneğin; gürültünün azaltılması) ve farklı görüntülerin çakıştırılmasına yönelik algoritmalar geliştirilmiştir. İlerleyen yıllarda akciğer dansitometrisine yönelik histogram çalışmaları ön plana çıkmıştır (Resim 1) [1]. Bu çalışmalarda, akciğer parankimindeki değişimleri yansıtan eşik atenüasyon değerleri belirlenmiştir. Atenüasyon değerlerinin ortalama, medyan, çarpıklık ve basıklık gibi birinci dereceden BT piksel istatistikleri yapılmış, atenüasyon histogramı kullanılarak tüm akciğerdeki veya seçilen bir bölgedeki önemli değişimleri ortaya koymak mümkün olmuştur [11, 20, 21].

Normal akciğer dokusunun BT atenüasyon histogramı yaklaşık -800 Hounsfield unit skalası (HU) değerinde pik yapar ve sola çarpıktır. İAH'de gelişen fibrozise bağlı yumuşak doku



Resim 1. Histogram analizinin sematik gösterimi. X eksenindeki vöksel atenüasyonlarının Y ekseninde her bir atenüasyon değeri için frekansının gösterilmesidir. HU, Hounsfield unit skalası.

miktarındaki artış, ortalama akciğer yoğunluğunu artırır, histogram basıklığını ve eğriliğini azaltır (Resim 2a, b) [22]. Yapılan çalışmalarda, akciğerlerdeki yüksek atenüasyon alanlarının (-600 ile 250 HU) artışı, FVC ve egzersiz kapasitesinde azalma, hastalık progresyonu ve mortalite artışı ile ilişkili bulunmuştur [23]. Histogram eğrisinin çarpıklık ve basıklığının azalmasının akciğer fonksiyonundaki (FEV1, FVC ve TLC değerleri) değişim ile korale olduğu, İPF hastalarında artmış mortalite ve morbidite riskini gösterdiği ortaya konmuştur [7, 11, 24].

Ancak QBT ile elde edilen bu eşik ve ortalama atenüasyon verileri, karmaşık paternleri ve lokal parankim değişikliklerini ayırt etmede yetersiz kalır. Örneğin; OİP paterni olan İPF hastaları ile hipersensitivite pnömonisi ve sınıflandırılmayan idiyopatik interstisyel pnömoni hastalarının histogram analizinde basıklık, çarpıklık ve ortalama akciğer atenüasyonu açısın-

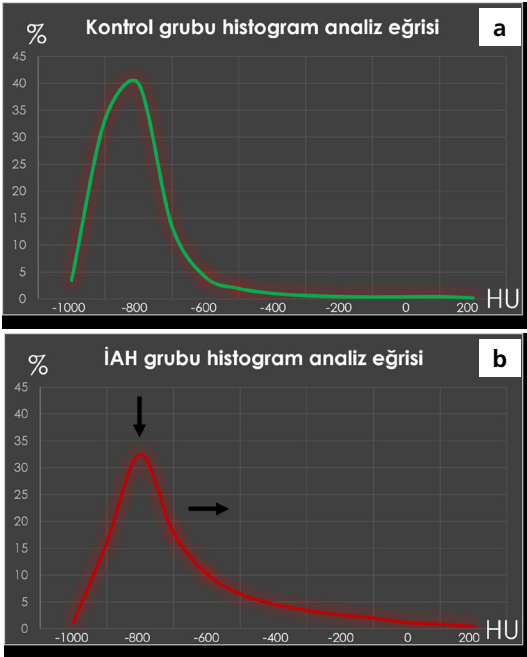
dan anlamlı fark tespit edilmemiştir [25, 26]. Uzaysal veri içermeksizin akciğerin bütününe kapsayan analizler, özellikle obstrüktif ve konstrüktif patolojileri birlikte barındıran olgularda kafa karıştırıcı olabilir [27, 28].

Doku tabanlı analiz yöntemi, ikinci derece istatistiksel parametreleri kullanarak piksellerin değerlerini ve bitişik pikseller arasındaki ilişkiyi belirleyen makine öğrenme yöntemidir. Bu yöntem, iki boyutlu veya hacimsel sınıflandırma algoritmaları kullanarak görüntü özelliklerini karakterize etmek, modellemek ve işlemek için kullanılır. Bu sayede İAH'de görülen retikülasyon, bal peteği ve traksiyon bronşektazisi gibi bulgular ayırt edilebilir [29]. Doku tabanlı analiz yöntemi kullanılarak elde edilen doku analiz skorlarının, solunum fonksiyonları ile güçlü korelasyon gösterdiği ve prognozu belirleyebildiği gösterilmiştir [30-32].

Uygulamadaki Zorluklar

Kantitatif bilgisayarlı tomografi ile yapılan akciğer analizlerinin en önemli kısıtlılıklarından biri, akciğer hacmi ve yoğunluğunun hastanın nefes tutma derinliği ile direkt ilişkili olmasıdır [1, 28]. Farklı hastalar arasında ve aynı hastanın farklı zamanlarda çekilmiş BT tetkikleri arasında inspiriyum derinliğinin değişkenliği QBT'nin duyarlılığı ve tekrarlanabilirliği açısından dezavantajdır. Yetersiz inspiriyuma bağlı atelektazi ve buzlu cam opasitelerinin görülmesi, hastalığın ilerlediği yanılığına neden olabilir [1]. Bazı çalışmalarda, vital kapasitenin %90'ının analiz için en uygun inspiriyum derinliği olduğu gösterilmiş olmakla birlikte çoğu merkezde spirometrik tetikleme ile çekim yapma imkânı bulunmamaktadır [33]. Kalp yetmezliği gibi eşlik eden hastalıkların veya kontrast madde gibi eksojen faktörlerin de akciğer atenüasyonu üzerine etkisi muhtemeldir, ancak bunların etkilerinin niceliksel analizi ile ilgili bilgiler yetersizdir [28].

Görsel değerlendirme için yeterli kalitede görüntü oluşturan çekim protokolleri ile elde olunan görüntülerin, QBT analizleri için uygun kalitede olmaması da önemli bir sorundur [34].



Resim 2. Normal akciğer dokusunun BT atenüasyon histogramı yaklaşık -800 HU değerinde pik yapar ve sola çarpıktır (a). İAH'de gelişen fibroze bağlı yumuşak doku miktarındaki artış, ortalama akciğer yoğunluğunu artırır, histogram basıklığını ve eğriliğini azaltır (b). BT, bilgisayarlı tomografi; HU, Hounsfield unit skalası; İAH, interstisyel akciğer hastalıkları.

Örneğin; düşük mAs ile çekim yapılması veya tüp akım modülasyon metodlarının farklı cihaz firmaları tarafından farklı şekillerde kullanılması gibi nedenlerle, voksel atenüasyon değerlerinin standardizasyonu sağlanamamaktadır [34]. Voksel atenüasyon değeri üzerine etkili diğer bir parametre olan rekonstrüksiyon kernelinin, orta keskinlikte olan nötral kernel seçilmesi de QBT analizleri için önemlidir [34]. Son yıllarda hasta dozunu azaltmaya yönelik yaygın olarak kullanılan bir rekonstrüksiyon metodu olan iteratif rekonstrüksiyon da yine voksel atenüasyon değerini değiştireceğinden, QBT için uygun değildir [34]. QBT için optimal akciğer çekim protokolleri belirlenmiş olsa da tüp akım modülasyonu ve iteratif rekonstrüksiyon gibi değişkenlerden etkilenmenin önüne geçilememiştir.

YAPAY ZEKA, MAKİNE ÖĞRENMESİ VE İNTERSTİSYEL AKCİĞER HASTALIKLARI

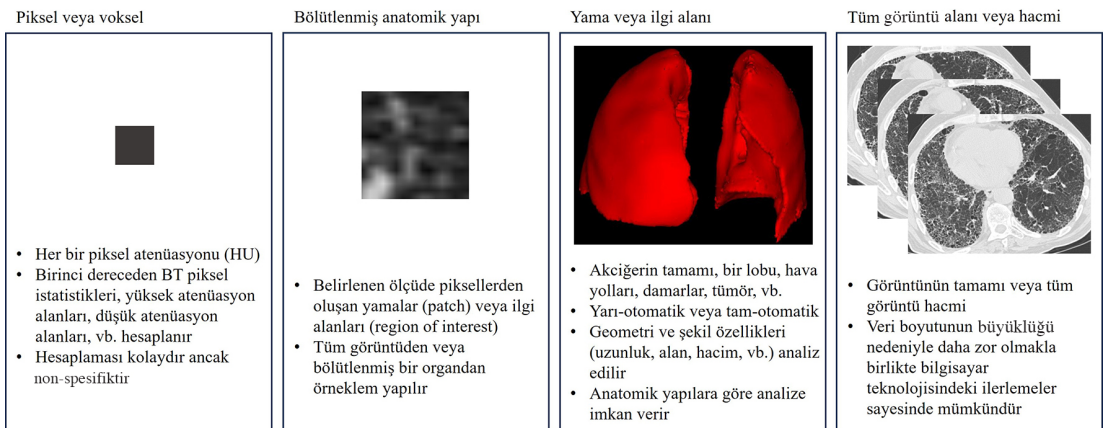
Yapay zeka, tipik olarak insan zekası gerektiren görevleri yerine getirebilen bilgisayar sistemleri için kullanılan genel bir terimdir [35]. Makine öğrenmesi, bilgisayarların belirli bir görevi yerine getirmek için örnek veri kümesinden kurallar çıkararak kendi kendilerine öğrenen sistemler oluşturmasına dayanan bir yapay zeka alt kümesidir [36]. Doğru ve klinik olarak yararlı modeller geliştirmek için, kod yazmak yerine örnek veri kümesine dayanarak kendi mantığını oluşturan algoritmalar geliştirilir.

Bir algoritma, kendisine sunulan eğitim veri kümesinde göze çarpan özellikleri karmaşık hesaplamalı istatistikler ve matematiksel optimizasyon yöntemleri aracılığıyla ayrıştırabilir. Eğitim setinde ayrıştırdığı bu özellikleri, bir başka veri setinde tahminlerde bulunmak ve sınıflandırma yapmak için kullanabilir.

Görüntüden özellik çıkarma, piksel ölçütünde, seçilmiş bir alanda veya bölütlenmiş bir organ düzeyinde yapılabileceği gibi görüntünün tamamını da kapsayabilir (Resim 3). Başlangıçta manuel olarak veya manuel düzeltme ile yarı otomatik olarak yapılan bölütlemeler, günümüzde makine öğrenmesi ve derin öğrenme sayesinde doğruluk, verimlilik ve tekrarlanabilirlik açısından büyük ilerleme kaydetmiştir [27].

Makine öğrenmesi türleri denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç gruba ayrılır. Denetimli öğrenmede makineye grupların sayısı ve türü de dahil olmak üzere önceden etiketlenmiş veriler verilir. Denetimsiz öğrenmede, makineye herhangi bir ön etiketleme yapılamamış veriler verilir ve nasıl gruplanacağını bağımsız olarak belirlemesi istenir. Pekiştirmeli öğrenmede ise makine genellikle deneme yanılma yoluyla en iyi eylemleri öğrenirler. İAH'de bu yöntemlerin herhangi biri veya birlikte kullanımı tercih edilebilir.

Araştırmacılar İAH'yi değerlendirmek amacıyla çeşitli makine öğrenimi yöntemleri uygulayarak, YÇBT'lerden çıkarılan görüntü özelliklerini analiz eden akciğer-doku tabanlı analiz yazılımları üzerinde çalışmaktadır.



Resim 3. Görüntü özelliği çıkarma ölçeği.

Adaptive Multiple Features Method (AMFM), doku tabanlı analiz yöntemini kullanarak YÇBT görüntülerini normal akciğer, amfizem ve İAH olarak sınıflandırmak üzere geliştirilmiş uygulamaların ilklerindedir [37-39]. Matematiksel olarak türetilmiş 26 görüntü özelliğini kullanarak BT bulgularını sınıflandırabilir (fibrozis, buzlu cam, bal peteği, retikülasyon, vb.). İPF hastalarında bu yöntem ile saptanan buzlu cam dansitesi ve retiküler patern hacminin, hastalık progresyonu ile ilişkili olduğu gösterilmiştir [30].

Computer-aided Lung Informatics for Pathology Evaluation and Rating, (CALIPER), önceden tespit edilmemiş biyobelirteçleri belirlemek için makine öğrenimini kullanan yazılımlara bir örnektir [40]. Bu yazılım tarafından hesaplanan pulmoner damar hacmi, pulmoner hipertansiyondan bağımsız olarak İAH spektrumunda akciğer fonksiyonundaki düşüşle ilişkili bulunmuştur. Bu alanda yapılan çalışmaların büyük çoğunluğunda YÇBT kullanılmış olmakla birlikte dual enerji BT [41], manyetik rezonans görüntüleme [42, 43] ve ultrasonografi [44] gibi farklı modalitelerin kullanıldığı araştırmalar da bulunmaktadır.

Derin Öğrenme ve İnterstisyel Akciğer Hastalıkları

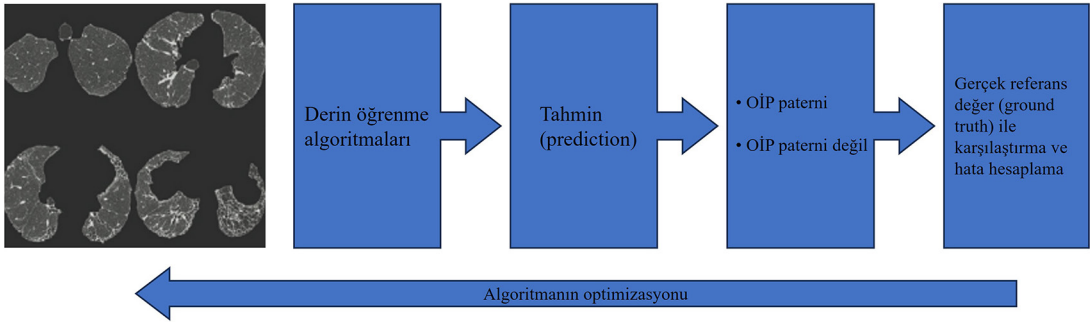
Derin öğrenme, ilk ortaya çıkışı itibari ile, özellikle görseller arasındaki örüntülerin tanınmasında, özniteliklerin çıkarımında ve sınıflandırılmasında kullanılmak üzere geliştirilmiş bir yaklaşımdır ve yapay zekanın bir alt dalıdır [45]. **Derin öğrenmenin geleneksel görüntü analizine göre avantajı, görsel olarak tespit edilemeyen değişkenler de dahil olmak üzere, klinik açıdan önemli görüntüleme değişkenlerini insan denetimi olmadan tanımlama potansiyeline sahip olmasıdır [46].**

Özellik vektörü tabanlı sınıflandırma (regresyon), görüntülerden türetilmiş olması gerekmeyen veriler dahil olmak üzere, farklı türlerdeki birden çok özelliğin bileşik özellik vektörlerinde birbirine bağlanabilmesine olanak verir. Bununla birlikte, pratikte özelliklerin seçimi tipik

olarak algoritma tasarımcısı tarafından önceden gerçekleştirilir ve muhtemelen yetersizdir. Derin öğrenme, büyük boyuttaki veri girişiyle bir veya daha fazla gizli katman içeren yapay sinir ağlarını kullanarak verideki ayırt edici özellikleri kendisi öğrenen makine öğrenme yöntemidir. Bu yöntem sayesinde, insan tarafından yapılan özellik seçme ve model tasarlama adımlarını ortadan kaldırarak otomatik bölütleme, yapılandırma (registration) ve patern sınıflama da dahil olmak üzere, geleneksel olarak zor olan bir dizi tıbbi görüntü işleminde büyük gelişme kaydedilmiştir [47].

İnterstisyel akciğer hastalıklarında ortaya çıkan YÇBT bulgularının saptanması ve hastaların sınıflandırılması da bir patern sınıflama problemidir. Derin öğrenme, özellikle yüksek boyutlu verilerdeki karmaşık paternleri keşfetmek ve bunları hastalık ilerlemesi veya ölüm oranı gibi basit ama nesnel sınıflandırmalarla eşleştirmek için uygun bir yöntemdir. Eğitimi güçlendirmek için yeterli görüntüleme verisi verildiğinde, nesnel sonuçlara (FVC düşüşü gibi) bağlı algoritmalar geliştirilebilir. Bu yaklaşımın iki faydası vardır. İlk olarak, veri etiketleri görüntülemenin kendisiyle ilgili subjektif ölçümlere (örneğin; radyolojik tanı) dayanmadığından, doğal önyargılar ve gözlemciyle ilgili değişkenlik algoritma eğitimine dahil edilmez. İkincisi, bu yaklaşım, görsel olarak değerlendirilemeyenler de dahil olmak üzere patern, dağılım ve diğer prediktif YÇBT özelliklerini kullanarak yeni hastalık fenotiplerinin tanımlanmasına izin verir.

Örneğin; İPF’de görülen tipik OİP paterni varlığını saptanmaya yönelik bir uygulama geliştirmek isteniyorsa, öncelikle YÇBT görüntülerinin OİP paterni varlığı veya yokluğu açısından sınıflandırılması ve algoritmanın iteratif olarak eğitilmesi gerekir (Resim 4). Her defasında algoritmanın çıktısı ile gerçek sonuç karşılaştırılır. Çıktı hatalı ise algoritma bu taramadaki hatasını hesaplar ve “geri yayılım (*backpropagation*)” adı verilen bir süreç aracılığıyla gelecekteki uyumsuzluğu en aza indirmek için dahili parametrelerini değiştirir. Bu eğitim süreci, eğitim veri setindeki tüm görüntüler için birçok kez tekrarlanır; her yineleme, algoritmik



Resim 4. YCBT görüntüsünün kategorize edilmesine yönelik derin öğrenme sürecinin basitleştirilmiş çizimi. YCBT, Yüksek çözünürlüklü akciğer bilgisayarlı tomografi; OİP, olağan interstisyel pnömoni.

tahminlerin giderek iyileştirmesiyle sonuçlanır. Büyüklük ve çeşitlilik açısından yeterli bir veri seti ile yeteri kadar eğitilen algoritma, daha önce hiç karşılaşmadığı doğrulama (validasyon) veri setinde test edildiğinde, OİP paterni varlığını doğru bir şekilde tahmin edebilir. Eğitim sırasında, her tanı kategorisinin en ayırt edici BT özellikleri otomatik olarak güçlendirilir ve öğrenilirken önemsiz özellikler bastırılır. Bu örnekte görüldüğü gibi algoritma, bal peteği bulgusunu OİP paternini belirleyen bir özellik olarak tanımak üzere açıkça programlanmamıştır. Ancak muhtemelen bu bulgu eğitim sırasında modelin paterni öğrenmesinde etkili olmuştur. Üstelik, algoritmanın OİP paternini belirlemede radyolog tarafından görülemeyen başka YCBT özelliklerini öğrenmesi de mümkündür.

İnterstisyel akciğer hastalıkları için derin öğrenme kullanılarak geliştirilmiş veri güdümlü doku analiz uygulamalarından biri olan SOFIA, BT görüntülerini kullanarak tanı kılavuzlarına göre akciğer fibrozisinin boyutunu saptamak ve ölçmek için geliştirilmiştir [19, 48]. Diğer bir uygulama olan “kantitatif akciğer fibrozis skoru” ise destek vektör makineleri sınıflandırma yöntemini (*support vector machine classifier*) kullanılarak tedaviye yanıtı tahmin etmek için geliştirilmiştir [49].

Radiomics

Radiomics, tıbbi görüntüyü oluşturan anatomik ve fonksiyonel verilerden, çıplak gözle ayırt edilemeyen niceliksel veriler elde edilebileceği ve bu verilerin dokunun biyolojik özel-

likleri hakkında bilgi içerdiği hipotezine dayanmaktadır. Bir özellik çıkarma ve analiz yöntemi olan radiomics, medikal görüntülerdeki kantitatif verileri, hastalıkların tanısı ve prognozuyla ilişkilendirmeye dayanır.

Tıbbi görüntüler standart protokol ile elde edildikten sonra, ilgilenilen anatomik bölge veya patolojik alan bölütlenir ve görüntü özellikleri çıkartılır. Bu özelliklere ek olarak sayısal değerler olarak kodlanmış klinik, demografik, genetik veya diğer omik özellikler de kullanılarak modelleme yapılır. Radiomic analizler ile hipotez üretmek veya tahmine dayalı modeller geliştirmek mümkün olmakla birlikte, çok sayıda karma özelliğin kullanılmasına bağlı zorluklarla karşılaşılır. Yüksek boyutlu verilerin analizi, çok fazla gözlem gerektirir ve potansiyel olarak gereksiz, yanıltıcı ve tutarsız özellikler arasından, en kıymetli olanlarının doğrulukla seçilmesini gerektirir.

Sonuçların Yorumlanması

Tıbbi görüntüleme makine öğrenimi, derin öğrenme ve radiomics kullanımının temel amacı, klinik sonuçlar ile henüz anlamlandırılmamış olan kantitatif radyolojik veriler arasındaki bağlantının kurulabilmesidir. Bu kullanım, daha önce insan gözü tarafından görselleştirilmemiş görüntüleme biyobelirteçlerinin tanımlanmasına olanak sağlar. Bununla birlikte uygulamaların güvenilirliği ve sonuçların anlamlandırılabilirliği için algoritmaların dahili işlemlerinin ve çıktılarının görsel temsillerinin de bulunmasına ihtiyaç duyulmaktadır. Görüntü

bölütlemesi veya belirginlik haritaları da dahil olmak üzere görselleştirilmiş veriler oluşturulması, radyologların hangi görüntü bölgelerinin veya özelliklerinin bir bilgisayar sistemini bir tahmine varmaya yönlendirdiğini anlamalarına yardımcı olur.

Doğrulama

Algoritmik görüntü analizlerinin uygun şekilde doğrulanması (validasyon), teknik performansın ve klinik önemin ortaya konması açısından önemlidir. Çalışmaların, yanlılığı en aza indirecek şekilde tasarlanması ve algoritmanın eğitim için kullanılan kohorttan bağımsız veri setleri ile validasyonu gerekir.

Model çıktısı, ilgilenilen probleme göre farklı şekillerde tasarlanabilir. Örneğin; bir hastanın İPF'ye sahip olup olmama olasılığı değerlendirilen olasılık skoru belirlenebilir. İlgili bir özelliğin işgal ettiği akciğer hacmi oranı şeklinde kantitatif bir çıktı ile İAH'den etkilenen akciğer parankim oranı verilebilir. Dahası, her bir bulgu (buzlu cam, retikülasyon, bal peteği, traksiyon bronşektazisi) ayrı ayrı analiz edilerek görsel haritalama yapılabilir. Hastanın önceden elde olunmuş ve güncel BT tetkikleri analiz edilerek prognoz tahmin edilebilir. İdeal olarak, model çıktısı aynı zamanda çıktıdaki güven ölçümlerini de içermelidir.

Performansın Artırılması

Yapay zeka algoritmalarının performansını artırmaya yönelik pek çok teknik vardır. Topluluk öğrenme yöntemi (*ensemble learning*), veri çoğaltma, kırpma (*cropping*), çok ölçekli (*multiscale*) görüntüler veya maksimum yoğunluk projeksiyon görüntüler kullanmak bunlardan bazılarıdır.

Tıbbi görüntüleme verilerine ek olarak güvenilir biyolojik biyobelirteçlerin eş zamanlı geliştirilmesi ve uygulamalara entegrasyonu ile yapay zeka performansını artırmak mümkündür. Örneğin; İPF tanısı koymak için bir algoritmanın performansını artırma amaçlı, YÇBT verilerine ek olarak hastanın yaşı, tütün kullanma

öyküsü ve solunum fonksiyon testi gibi veriler kullanılabilir.

Uygulamadaki Zorluklar

Günümüzde her biri yüzlerce gigabyte olarak depolanan metaveriler ve piksel değerlerinden oluşan tıbbi görüntüleme veri kümeleri oldukça büyük boyutludur. Bu veri kümelerinin içerdiği bilgiler klinik açıdan önemli olmakla birlikte, genellikle yapılandırılmamıştır. Önceden tanımlanmış bir şekilde organize edilmemiş veya etiketlenmemiş bu verileri analiz yapılmadan önce ön işleme ihtiyaç vardır.

Medikal görüntü işlemede yapay zekanın önündeki engellerden biri, güvenilir veri kümelerinin göreceli eksikliğidir. Başarılı sonuç veren bir yapay zeka modelinin geliştirilmesi için yeterli sayıda ve kalitede eğitim ve test verilerine ihtiyaç vardır. İAH'nin nadir görülen bir hastalık olduğu da göz önüne alındığında, hasta çeşitliliğinin artırılması ve özellikle belirli hastalık fenotipleri için verilerin zenginleştirilmesi, uygulamaların performansını artıracak ve rutin kullanıma adaptasyonu kolaylaştıracaktır. Bu amaçla hem ulusal veri havuzları oluşturulmasına hem de uluslararası iş birliklerine ihtiyaç vardır.

Şüphesiz elde olunan bu verilerle açık kaynak görüntüleme konsorsiyumu oluşturulması, yapay zeka araştırmacılarını iş birliğine teşvik etmek, uygulamaların performansını artırmak ve genelleştirmek açısından önemlidir. Ancak verilerin gerek ulusal gerekse uluslararası düzeyde toplanması, paylaşımı ve depolanması, hasta mahremiyetine dair yönergelere ve uluslararası veri gizliliği düzenlemelerine uyulmasını gerektirir. Bu konularda araştırmacıların ve kurumların bilgi düzeylerini artırmaları, yönergelerin uygulanmasında yaşanan sistemsel sorunları saptamaya ve çözmeye yönelik girişimlerde bulunmaları faydalı olacaktır.

Hem klinik hem de radyolojik veri toplamanın standartlaştırılması, makine öğrenimi algoritmalarını eğitmek için önemlidir. YÇBT tetkiklerinin, başlangıçta ve standart takip sürelerinde, bilgisayar tabanlı görüntü analizi için

en ideal şekilde standartlaştırılmış BT protokolleri kullanılarak çekilmesine ihtiyaç vardır.

Araştırmacılar, algoritmaların klinik pratiğe nasıl entegre edilebileceği konusunda çeşitli alternatifler sunmaktadır. Günümüzde web tabanlı uygulamalar, mevcut pacs sistemlerine entegre edilebilen uygulamalar veya başka bir pacs sistemine sahip iş istasyonunda çalışan uygulamalar mevcuttur. Her bir yöntemin kendine özgü avantajları ve dezavantajları bulunmaktadır. Bizim deneyimlerimiz, mevcut pacs sistemlerine entegre edilebilen uygulamaların, ek iş yükü oluşturmaması ve iş akışını yavaşlatmaması nedeniyle daha kullanışlı olduğu yönündedir.

SONUÇ

Yapılan çalışmalar ve elde edilen sonuçlar, makine öğrenmesinin İAH görüntülemesinde güçlü bir araç olduğunu göstermektedir. YÇBT görüntülerinin özellikle denetimsiz öğrenme ve derin öğrenme yöntemleri ile geliştirilmiş algoritmalar tarafından analizi sayesinde, hastalığın erken ve doğru tanısı, şiddetinin belirlenmesi ve prognozun öngörülmesi mümkündür. Günümüzde İAH'de kullanılmak üzere geliştirilmiş makine öğrenmesi uygulamalarının performansını iyileştirmeye yönelik çalışmalar artarak devam etmektedir. Ancak bu, pratik olarak sonu olmayan bir süreçtir. Mükemmel en yakın performansa ulaşmak ve klinik yararlanımı artırmak, ancak geliştirilmiş algoritmaların rutin iş akışına entegrasyonu ve gerçek hayatta test edilmesi ile mümkün olabilir.

Çıkar Çatışması

Yazar bu makale ile ilgili olarak herhangi bir çıkar çatışması bildirmemiştir.

Kaynaklar

- [1]. Chen A, Karwoski RA, Gierada DS, Bartholmai BJ, Koo CW. Quantitative CT analysis of diffuse lung disease. *Radiographics* 2020; 40: 28-43. [\[CrossRef\]](#)
- [2]. Walsh SLF, Wells AU, Desai SR, Poletti V, Piciucchi S, Dubini A, et al. Multicentre evaluation of multidisciplinary team meeting agreement on diagnosis in diffuse parenchymal lung disease: a case-cohort study. *Lancet Respir Med* 2016; 4: 557-65. [\[CrossRef\]](#)
- [3]. Dack E, Christe A, Fontanellaz M, Brigato L, Heverhagen JT, Peters AA, et al. Artificial Intelligence and interstitial lung disease: diagnosis and prognosis. *Invest Radiol* 2023; 58: 602-9. [\[CrossRef\]](#)
- [4]. Soffer S, Morgenthau AS, Shimon O, Barash Y, Konen E, Glicksberg BS, et al. Artificial intelligence for interstitial lung disease analysis on chest computed tomography: a systematic review. *Acad Radiol* 2022; 29 (Suppl 2): S226-35. [\[CrossRef\]](#)
- [5]. Felder FN, Walsh SLF. Exploring computer-based imaging analysis in interstitial lung disease: opportunities and challenges. *ERJ Open Res* 2023; 9: 00145-2023. [\[CrossRef\]](#)
- [6]. Milam ME, Koo CW. The current status and future of FDA-approved artificial intelligence tools in chest radiology in the United States. *Clin Radiol* 2023; 78: 115-22. [\[CrossRef\]](#)
- [7]. Putman RK, Hatabu H, Araki T, Gudmundsson G, Gao W, Nishino M, et al. Association between interstitial lung abnormalities and all-cause mortality. *JAMA* 2016; 315: 672-81. [\[CrossRef\]](#)
- [8]. Wells AU, Walsh SLF. Quantitative computed tomography and machine learning: recent data in fibrotic interstitial lung disease and potential role in pulmonary sarcoidosis. *Curr Opin Pulm Med* 2022; 28: 492-7. [\[CrossRef\]](#)
- [9]. Lederer DJ, Enright PL, Kawut SM, Hoffman EA, Hunninghake G, van Beek EJ, et al. Cigarette smoking is associated with subclinical parenchymal lung disease: the Multi-Ethnic Study of Atherosclerosis (MESA)-lung study. *Am J Respir Crit Care Med* 2009; 180: 407-14. [\[CrossRef\]](#)
- [10]. Ash SY, Harmouche R, Vallejo DL, Villalba JA, Ostridge K, Gunville R, et al. Densitometric and local histogram based analysis of computed tomography images in patients with idiopathic pulmonary fibrosis. *Respir Res* 2017; 18: 45. [\[CrossRef\]](#)
- [11]. Best AC, Lynch AM, Bozic CM, Miller D, Grunwald GK, Lynch DA. Quantitative CT indexes in idiopathic pulmonary fibrosis: relationship with physiologic impairment. *Radiology* 2003; 228: 407-14. [\[CrossRef\]](#)
- [12]. Jacob J, Bartholmai BJ, Rajagopalan S, van Moersel CHM, van Es HW, van Beek FT, et al. Predicting outcomes in idiopathic pulmonary fibrosis using automated computed tomographic analysis. *Am J Respir Crit Care Med* 2018; 198: 767-76. [\[CrossRef\]](#)
- [13]. Wells AU, Brown KK, Flaherty KR, Kolb M, Thannickal VJ; IPF Consensus Working Group. What's in a name? That which we call IPF, by any

- other name would act the same. *Eur Respir J* 2018; 51: 1800692. [\[CrossRef\]](#)
- [14]. Flaherty KR, Wells AU, Cottin V, Devaraj A, Walsh SLF, Inoue Y, et al. Nintedanib in progressive fibrosing interstitial lung diseases. *N Engl J Med* 2019; 381: 1718-27. [\[CrossRef\]](#)
- [15]. Raghu G, Remy-Jardin M, Richeldi L, Thomson CC, Inoue Y, Johkoh T, et al. Idiopathic pulmonary fibrosis (an update) and progressive pulmonary fibrosis in adults: an official ATS/ERS/JRS/ALAT clinical practice guideline. *Am J Respir Crit Care Med* 2022; 205: e18-47. [\[CrossRef\]](#)
- [16]. Noble PW, Albera C, Bradford WZ, Costabel U, Glassberg MK, Kardatzke D, et al. Pirfenidone in patients with idiopathic pulmonary fibrosis (CAPACITY): two randomised trials. *Lancet* 2011; 377: 1760-9. [\[CrossRef\]](#)
- [17]. Richeldi L, du Bois RM, Raghu G, Azuma A, Brown KK, Costabel U, et al. Efficacy and safety of nintedanib in idiopathic pulmonary fibrosis. *N Engl J Med* 2014; 370:2071-82. [\[CrossRef\]](#)
- [18]. King TE Jr, Bradford WZ, Castro-Bernardini S, Fagan EA, Glaspole I, Glassberg MK, et al. A phase 3 trial of pirfenidone in patients with idiopathic pulmonary fibrosis. *N Engl J Med* 2014; 370:2083-92. [\[CrossRef\]](#)
- [19]. Jo HE, Corte TJ, Calandriello L, Silva M, Sverzellati N, Chapman S, et al. Deep learning-based prediction of progressive fibrotic lung disease on baseline computed tomography in the Australian IPF Registry. *Am J Respir Crit Care Med* 2020; 201: 5994. [\[CrossRef\]](#)
- [20]. Best AC, Meng J, Lynch AM, Bozic CM, Miller D, Grunwald GK, et al. Idiopathic pulmonary fibrosis: physiologic tests, quantitative CT indexes, and CT visual scores as predictors of mortality. *Radiology* 2008; 246: 935-40. [\[CrossRef\]](#)
- [21]. Obert M, Kampschulte M, Limburg R, Barańczuk S, Krombach GA. Quantitative computed tomography applied to interstitial lung diseases. *Eur J Radiol* 2018; 100: 99-107. [\[CrossRef\]](#)
- [22]. Hartley PG, Galvin JR, Hunninghake GW, Merchant JA, Yagla SJ, Speakman SB, et al. High-resolution CT-derived measures of lung density are valid indexes of interstitial lung disease. *J Appl Physiol (1985)* 1994; 76: 271-7. [\[CrossRef\]](#)
- [23]. Podolanczuk AJ, Oelsner EC, Barr RG, Hoffman EA, Armstrong HF, Austin JH, et al. High attenuation areas on chest computed tomography in community-dwelling adults: the MESA study. *Eur Respir J* 2016; 48: 1442-52. [\[CrossRef\]](#)
- [24]. Hatabu H, Hunninghake GM, Richeldi L, Brown KK, Wells AU, Remy-Jardin M, et al. Interstitial lung abnormalities detected incidentally on CT: a position paper from the Fleischner Society. *Lancet Respir Med* 2020; 8: 726-37. [\[CrossRef\]](#)
- [25]. Sverzellati N, Zompatori M, De Luca G, Chetta A, Bnà C, Ormitti F, et al. Evaluation of quantitative CT indexes in idiopathic interstitial pneumonitis using a low-dose technique. *Eur J Radiol* 2005; 56: 370-5. [\[CrossRef\]](#)
- [26]. Sverzellati N, Calabrò E, Chetta A, Concari G, Larici AR, Mereu M, et al. Visual score and quantitative CT indices in pulmonary fibrosis: relationship with physiologic impairment. *Radiol Med* 2007; 112: 1160-72. [\[CrossRef\]](#)
- [27]. Barnes H, Humphries SM, George PM, Assayag D, Glaspole I, Mackintosh JA, et al. Machine learning in radiology: the new frontier in interstitial lung diseases. *Lancet Digit Health* 2023; 5: e41-50. [\[CrossRef\]](#)
- [28]. Weatherley ND, Eaden JA, Stewart NJ, Bartholmai BJ, Swift AJ, Bianchi SM, et al. Experimental and quantitative imaging techniques in interstitial lung disease. *Thorax* 2019; 74: 611-9. [\[CrossRef\]](#)
- [29]. Rosas IO, Yao J, Avila NA, Chow CK, Gahl WA, Gochuico BR. Automated quantification of high-resolution CT scan findings in individuals at risk for pulmonary fibrosis. *Chest* 2011; 140: 1590-7. [\[CrossRef\]](#)
- [30]. Salisbury ML, Lynch DA, van Beek EJ, Kazerooni EA, Guo J, Xia M, et al. Idiopathic pulmonary fibrosis: the association between the adaptive multiple features method and fibrosis outcomes. *Am J Respir Crit Care Med* 2017; 195: 921-9. [\[CrossRef\]](#)
- [31]. Jacob J, Bartholmai BJ, Rajagopalan S, Kokosi M, Nair A, Karwoski R, et al. Mortality prediction in idiopathic pulmonary fibrosis: evaluation of computer-based CT analysis with conventional severity measures. *Eur Respir J* 2017; 49: 1601011. [\[CrossRef\]](#)
- [32]. Jacob J, Bartholmai BJ, Rajagopalan S, Egashira R, Brun AL, Kokosi M, et al. Unclassifiable-interstitial lung disease: outcome prediction using CT and functional indices. *Respir Med* 2017; 130: 43-51. [\[CrossRef\]](#)
- [33]. Lamers RJ, Kemerink GJ, Drent M, van Engelshoven JM. Reproducibility of spirometrically controlled CT lung densitometry in a clinical setting. *Eur Respir J* 1998; 11: 942-5. [\[CrossRef\]](#)
- [34]. Newell JD Jr, Tschirren J, Peterson S, Beinlich M, Sieren J. Quantitative CT of interstitial lung disease. *Semin Roentgenol* 2019; 54: 73-9. [\[CrossRef\]](#)
- [35]. Ertel W. Introduction to artificial intelligence. 2nd ed. Cham, Switzerland: Springer; 2017. [\[CrossRef\]](#)
- [36]. Kubat M. Introduction To Machine Learning. Springer 2018. [\[CrossRef\]](#)
- [37]. Uppaluri R, Hoffman EA, Sonka M, Hunninghake GW, McLennan G. Interstitial lung disease: a quantitative study using the adaptive multiple feature method. *Am J Respir Crit Care Med* 1999; 159: 519-25. [\[CrossRef\]](#)

- [38]. Uppaluri R, Hoffman EA, Sonka M, Hartley PG, Hunninghake GW, McLennan G. Computer recognition of regional lung disease patterns. *Am J Respir Crit Care Med* 1999; 160: 648-54. [\[CrossRef\]](#)
- [39]. Uppaluri R, Mitsa T, Sonka M, Hoffman EA, McLennan G. Quantification of pulmonary emphysema from lung computed tomography images. *Am J Respir Crit Care Med* 1997; 156: 248-54. [\[CrossRef\]](#)
- [40]. Jacob J, Bartholmai BJ, Rajagopalan S, Kokosi M, Nair A, Karwoski R, et al. Automated quantitative computed tomography versus visual computed tomography scoring in idiopathic pulmonary fibrosis: validation against pulmonary function. *J Thorac Imaging* 2016; 31: 304-11. [\[CrossRef\]](#)
- [41]. Moon JW, Bae JP, Lee HY, Kim N, Chung MP, Park HY, et al. Perfusion- and pattern-based quantitative CT indexes using contrast-enhanced dual-energy computed tomography in diffuse interstitial lung disease: relationships with physiologic impairment and prediction of prognosis. *Eur Radiol* 2016; 26: 1368-77. [\[CrossRef\]](#)
- [42]. Bondesson D, Schneider MJ, Gaass T, Kühn B, Bauman G, Dietrich O, et al. Nonuniform fourier-decomposition MRI for ventilation- and perfusion-weighted imaging of the lung. *Magn Reson Med* 2019; 82: 1312-21. [\[CrossRef\]](#)
- [43]. Wang Z, Robertson SH, Wang J, He M, Virgincar RS, Schrank GM, et al. Quantitative analysis of hyperpolarized ¹²⁹Xe gas transfer MRI. *Med Phys* 2017; 44: 2415-28. [\[CrossRef\]](#)
- [44]. Depeursinge A, Chin AS, Leung AN, Terrone D, Bristow M, Rosen G, et al. Automated classification of usual interstitial pneumonia using regional volumetric texture analysis in high-resolution computed tomography. *Invest Radiol* 2015; 50: 261-7. [\[CrossRef\]](#)
- [45]. Gulli, A, Kapoor A, Pal S. Deep learning with Tensor Flow 2 and Keras. 2nd ed. Birmingham Mumbai: Pact publishing; 2019. [\[CrossRef\]](#)
- [46]. Walsh SLF, Humphries SM, Wells AU, Brown KK. Imaging research in fibrotic lung disease; applying deep learning to unsolved problems. *Lancet Respir Med* 2020; 8: 1144-53. [\[CrossRef\]](#)
- [47]. Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, Al-Shamma O, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data* 2021; 8: 53. [\[CrossRef\]](#)
- [48]. Humphries SM, Yagihashi K, Huckleberry J, Rho BH, Schroeder JD, Strand M, et al. Idiopathic pulmonary fibrosis: data-driven textural analysis of extent of fibrosis at baseline and 15-month follow-up. *Radiology* 2017; 285: 270-8. [\[CrossRef\]](#)
- [49]. Lancaster L, Goldin J, Trampisch M, Kim GH, Ilowite J, Homik L, et al. Effects of nintedanib on quantitative lung fibrosis score in idiopathic pulmonary fibrosis. *Open Respir Med J* 2020; 14: 22-31. [\[CrossRef\]](#)

Eđitici Noktalar

Sayfa 163

Tıbbi grntlerin iřlenmesi ve analizinde yapay zekanın kullanım amacı, uzmanların grntleri daha iyi yorumlamasını ve daha dođru tanı koymasını sađlamak, klinik yararlanımı artırmak, yapılan iři zaman ve maliyet aısından daha ekonomik hale getirmektir.

Sayfa 163

İnterstisyel akciđer hastalıklarının (İAH) etkin ynetiminde, hastalığın erken ve dođru tanısı, řiddetinin belirlenmesi, prognozun ngrlmesi ve tedaviye yanıtın kesin dođrulukla belirlenmesi ile ilgili zorluklar yařanmaktadır. Makine đrenmesi, bu zorlukların ařılmasında alternatif zm yntemleri sunmaktadır.

Sayfa 168

Derin đrenmenin geleneksel grnt analizine gre avantajı, grsel olarak tespit edilemeyen deđiřkenler de dahil olmak zere, klinik aıdan nemli grntleme deđiřkenlerini insan denetimi olmadan tanımlama potansiyeline sahip olmasıdır.

Sayfa 169

Radiomics, tıbbi grnty oluřturan anatomik ve fonksiyonel verilerden, ıplak gzle ayırt edilemeyen niceliksel veriler elde edilebileceđi ve bu verilerin dokunun biyolojik zellikleri hakkında bilgi ierdiđi hipotezine dayanmaktadır. Bir zellik ıkarma ve analiz yntemi olan radiomics, medikal grntlerdeki kantitatif verileri, hastalıkların tanısı ve prognozuyla iliřkilendirmeye dayanır.

Sayfa 170

Tıbbi grntleme verilerine ek olarak gvenilir biyolojik biyobelirtelerin eř zamanlı geliřtirilmesi ve uygulamalara entegrasyonu ile yapay zeka performansını artırmak mmkndr.

Sayfa 170

Medikal grnt iřlemede yapay zekanın nndeki engellerden biri, gvenilir veri kmelerinin greceli eksikliđidir.

Sayfa 170

Hem klinik hem de radyolojik veri toplamanın standartlařtırılması, makine đrenimi algoritmalarını eđitmek iin nemlidir.

Çalışma Soruları

1. Atenüasyon değerlerinin ortalama, medyan, çarpıklık ve basıklık gibi birinci dereceden BT piksel istatistiklerinin yapılmasına, atenüasyon histogramı oluşturulmasına, tüm akciğerdeki veya seçilen bir bölgedeki önemli atenüasyon değişimlerini ortaya koymaya yarayan radyolojik görüntü analiz yöntemi aşağıdakilerden hangisidir?
 - a. Kantitatif BT
 - b. Doku tabanlı analiz
 - c. Radiomics
 - d. Histogram yöntemi
 - e. Substraction
2. İkinci derece istatistiksel parametreleri kullanarak radyolojik görüntülerdeki piksellerin değerlerini ve bitişik pikseller arasındaki ilişkiyi belirleyen makine öğrenme yöntemi aşağıdakilerden hangisidir?
 - a. Kantitatif BT
 - b. Doku tabanlı analiz
 - c. Radiomics
 - d. Histogram yöntemi
 - e. Substraction
3. Tıbbi görüntüyü oluşturan anatomik ve fonksiyonel verilerden, çıplak gözle ayırt edilemeyen niceliksel veriler elde edilebileceği ve bu verilerin dokunun biyolojik özellikleri hakkında bilgi içerdiği hipotezine dayanan analiz yöntemi aşağıdakilerden hangisidir?
 - a. Kantitatif BT
 - b. Doku tabanlı analiz
 - c. Radiomics
 - d. Histogram yöntemi
 - e. Substraction
4. Aşağıdakilerden hangisi kantitatif BT'nin avantajlarından biri değildir?
 - a. Niceliksel analiz yapması
 - b. Tekrarlanabilir olması
 - c. Histogram çalışması yapmaya olanak sağlaması
 - d. Tüm akciğerdeki veya tercihe göre seçilen bir bölgedeki önemli atenüasyon değişimleri ortaya koyabilmesi
 - e. Kantitatif BT ile elde edilen eşik ve ortalama atenüasyon verileri sayesinde karmaşık paternleri ayırt edebilmesi

Çalışma Soruları

5. Tıbbi görüntülerin işlenmesi ve analizinde yapay zekânın kullanımı ile ilgili aşağıdakilerden hangi yanlıştır?
- Derin öğrenme, özellikle yüksek boyutlu verilerdeki karmaşık paternleri keşfetmek ve bunları hastalık ilerlemesi veya ölüm oranı gibi basit ama nesnel sınıflandırmalarla eşleştirmek için uygun bir yöntemdir.
 - Bir veri seti ile eğitilen algoritmanın, daha önce hiç karşılaşmadığı doğrulama veri setinde test edilmesine validasyon denir.
 - Topluluk öğrenme yöntemi (*ensemble learning*), veri çoğaltma, kırpma (*cropping*), çok ölçekli (*multiscale*) görüntüler veya MİP (*maximum intensity projection*) görüntüler kullanılarak yapay zeka algoritmalarının performansı artırılabilir.
 - Tıbbi görüntüleme verilerine ek olarak güvenilir biyolojik biyobelirteçlerin eş zamanlı geliştirilmesi ve uygulamalara entegrasyonu ile yapay zeka performansını artırmaz.
 - Hem klinik hem de radyolojik veri toplamanın standartlaştırılması, makine öğrenimi algoritmalarını eğitmek için önemlidir.