

## Yeni bir Evrişimsel Sinir Ağı Modeli Kullanarak Bilgisayarlı Tomografi Görüntülerinden Akciğer Kanseri Tespiti

Asiye Merve Nur ERDOĞAN<sup>1</sup>, Tülin ÖZTÜRK<sup>2</sup>, Muhammed TALO<sup>3\*</sup>

<sup>1</sup> Yazılım Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

<sup>2</sup> Radyoloji, Medical Park Hastanesi, Elazığ, Türkiye

<sup>3</sup> Yazılım Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

<sup>1</sup> asiymervenurerdogan@gmail.com, <sup>2</sup> tulin58@hotmail.com, <sup>3\*</sup> mtalo@firat.edu.tr

(Geliş/Received: 25/06/2022;

Kabul/Accepted: 31/08/2022)

**Öz:** Akciğer kanseri, ülkemizde ve dünyada yaygın bir şekilde görülen kanser tipidir ve kansere bağlı ölümlerde ilk sırada yer almaktadır. Akciğer kanserinin erken teşhisi, hastalık seyri hakkında daha bilinçli ilerlemeyi sağlar ve hastanın sağ kalım durumu açısından hayati bir önem taşımaktadır. Son zamanlarda teknolojinin gelişmesiyle birlikte yapay zekâ ve derin öğrenme tabanlı sistemler; Bilgisayarlı Tomografi (BT), Manyetik Rezonans (MR) vb. tıbbi görüntüleme sistemlerinden elde edilmiş verileri kullanarak hastalık teşhisinde hekimlere önemli destek sağlamaktadır. Bu çalışmada akciğer kanserinin BT görüntüleri kullanarak yeni bir Evrişimli Sinir Ağı (ESA) modeli önerilmiştir. Önerilen ESA modelinin sınıflandırma sonuçları, literatürde bulunan diğer ön eğitilmiş derin öğrenme modellerine göre daha başarılı olduğu için tercih ettiğimiz ResNeXt derin öğrenme modelinin sonuçları ile karşılaştırılmıştır. Modellerin eğitimi ve test aşamaları için açık erişimli akciğer BT görüntülerinin bulunduğu bir veri seti kullanılmıştır. Çalışma sonucunda, önerilen ESA modelinin %99 doğruluk oranı ile ResNeXt mimarisine göre daha yüksek performans sergilediği gözlemlenmiştir. Ayrıca mevcut çalışmadaki görüntülerde herhangi bir özellik çıkarımı yöntemi kullanılmadan görüntüler ham hali ile sınıflandırılmıştır. Ve önerilen ESA modelinin, literatürde yapılan benzer çalışmalarda kullanılan yöntemlere göre daha az katman sayısının olmasının yanında sınıflandırma başarısının da daha yüksek olduğu gözlemlenmiştir.

**Anahtar kelimeler:** Derin Öğrenme, Evrişimli Sinir Ağı, ResNeXt, Akciğer Kanseri, Akciğer BT Görüntüleri.

## Lung Cancer Detection from Computed Tomography Images Using a Novel Convolutional Neural Network Model

**Abstract:** Lung cancer is a common health problem in our country and in the world, and it ranks first in cancer-related deaths. Early diagnosis of lung cancer is of vital importance in terms of more informed progress about the course of the disease and survival of the patient. Recently, with the development of technology, artificial intelligence and deep learning-based systems; by using data obtained from medical imaging systems such as Computed Tomography (CT), Magnetic Resonance (MR), it provides some convenience to experts to diagnose the disease. In this study, a new Convolutional Neural Network (CNN) model is proposed to classify cancerous and normal lung CT images. The classification results of the proposed ESA model and the ResNeXt deep learning model, which is more successful than other pre-trained deep learning models in the literature, were compared. As a result of the study, it has been observed that the proposed ESA model performs better than the ResNeXt architecture, with an accuracy of 99%. In addition, the images in the current study were classified in their raw form without using any feature extraction method. And it has been observed that the proposed ESA model has a lower number of layers compared to the methods used in similar studies in the literature, as well as a higher classification success.

**Key words:** Deep learning, Convolutional neural network, ResNeXt, Lung cancer, Lung CT image.

### 1. Giriş

Akciğer kanseri günümüzde tüm dünyada kanser ölümlerinin önde gelen nedeni olup tüm kanser ölümlerinin yaklaşık %20'sini oluşturmaktadır [1]. Sigara kullanımı akciğer kanseri için büyük risk faktörüdür. Ayrıca asbest maruziyeti, koah, difüz akciğer fibrozisi diğer risk faktörlerindedir [2]. Akciğer kanserli hastalar, vakaların %50 sine kadar asemptomatik olabilir. Öksürük ve nefes darlığı, akciğer kanseri olanlarda yaygın olan, oldukça spesifik olmayan semptomlardır.

Akciğer kanseri en kötü huylu ve en ölümcül kanserlerden biridir. Erken tespit edilip aktif olarak tedavi edilebilirse, hastanın hayatta kalma oranını etkili bir şekilde artırabilir. Bu nedenle akciğer kanserinin erken teşhisi

\* Sorumlu yazar: [mtalo@firat.edu.tr](mailto:mtalo@firat.edu.tr). Yazarların ORCID Numarası: <sup>1</sup> 0000-0001-9061-7001, <sup>2</sup> 0000-0001-8942-5264, <sup>3</sup> 0000-0002-1595-5681

çok önemlidir. Erken evre akciğer kanseri radyolojik görüntülemelerle özellikle Toraks BT ile tespit edilebilir. Ancak bu her zaman kolay değildir. Günümüzde derin öğrenme tabanlı yapay zekâ, tıpta çeşitli branşlarda kullanıma girmeye başlamıştır. Literatürde malign ve benign pulmoner nodüllerin ayırıcı tanısında sağladığı katkılar bildirilmiştir [3]. Ancak daha fazla uygulama için sağlıklı klinik verilere ve bu verilerin doğrulanmasına ihtiyaç vardır. Derin öğrenme destekli sistemlerin kullanımı akciğer kanserinin erken tanı ve tedavisine ulaşmak için önemli bir adımdır. Bu sistemler hekimlere hastalığın erken teşhisi ve kanserli bölgelerdeki diğer anormalliklerin ayırt edilmesi gibi konularda yardımcı rol alma potansiyeli taşımaktadır.

Son birkaç yılda teknolojinin gelişimi ve medikal görüntüleme yöntemlerinin yaygın kullanımı sayesinde tıbbi görüntü verisi artmıştır. Bu durum, derin öğrenme tabanlı sistemlerin yüksek performansta çalışabilmesine olanak sağlamıştır. Literatürde akciğer kanserinin tespitinde derin öğrenme kullanan birçok önemli çalışma bulunmaktadır. Akciğer kanserinin BT görüntüleri üzerinden iyi huylu ve kötü huylu nodüllerini sınıflandırmak için Joshua ve diğerleri [4], 3B AlexNet mimarisini kullanarak %97,17'lik başarı elde etmişlerdir. An ve diğerleri [5] yapmış oldukları çalışmada tasarlanmış oldukları iki boyutlu Evrişimli Sinir Ağı (2B-ESA) ile akciğer BT görüntülerini sınıflandırmayı hedeflemişlerdir. Yazarlar modelin ilk aşamasında giriş BT görüntülerini iyileştirmek için bir ESA yapısı kullanmışlardır. İlk ESA'nın çıktısı GoogleNet' in [6] basitleştirilmiş bir versiyonu olan başka bir ESA ile birleştirilerek görüntülerin daha iyi tanınması sağlanmıştır. Çalışmanın sonucunda iki aşamalı ESA yapısından %89,6'lık doğruluk oranı elde etmişlerdir.

Devi ve diğerleri [7] ise akciğer BT görüntülerinden kanser tespiti için üç akışlı bir derin ağ modeli önermişlerdir. Önerilen modelde, özellik çıkarımı için manuel ve otomatik özellik çıkarımı bir arada kullanılmıştır. Otomatik özellik çıkarımı ve sınıflandırma işlemi atık derin sinir ağı ile özel derin sinir ağı kullanılarak yapılmıştır. Manuel özellik çıkarımı ise makine öğrenmesi algoritmalarından destek vektör makineleri (DVM) ile yapılmıştır. Bu yöntem ile girdi görüntülerindeki tüm özellikleri yakalamayı hedeflemişlerdir. Çalışmada LIDC/IDRI veri setini kullanarak %98,2'lik bir doğruluk elde etmişlerdir.

Bu çalışmada, akciğer BT görüntülerinden akciğer kanseri ve sağlıklı olmak üzere görüntülerin, sınıflandırılması için yeni bir ESA modeli önerilmiştir. Önerilen ESA modeli ile karşılaştırılması için literatürde var olan diğer ön eğitilmiş derin öğrenme mimarilerine kıyasla görüntü sınıflandırmada daha başarılı olan ResNeXt mimarisi seçilmiştir. ResNeXt mimarisi Facebook Yapay Zekâ Araştırması ekibi (Facebook AI Research - FAIR) tarafından tasarlanmış ve geliştirilmiştir. ResNeXt katılmış olduğu Büyük Ölçekli Görsel Tanıma Yarışmasında (ILSVRC2016) görüntülerin sınıflandırılması sonucunda elde etmiş olduğu düşük hata oranı ile yarışmaya katılan diğer mimarilerden daha başarılı olmuştur [8]. Yapmış olduğumuz deneysel çalışmalar sonucunda önerilen ESA modelinin %99 oranında ResNeXt mimarisine göre daha yüksek bir başarı sağladığı gözlemlenmiştir.

Yapılan bu çalışmada ki veri setine ait görüntüler, model eğitimine verilmeden önce hiçbir görüntü ön işleme adımı uygulanmadan ham hali ile kullanılmıştır. Hem yüksek doğruluk oranı hem de daha az katmana sahip yeni bir model sunulması açısından makale çalışması önemli katkılar sağlamaktadır.

Çalışmada kullanılan veri seti ve yöntem hakkında detaylar ikinci bölümdeki materyal ve metot kısmında verilmiştir. Yapılan çalışmanın başarımlarını değerlendirmesi ve sonuçların karşılaştırılması ise üçüncü bölümde yer alan deneysel sonuçlar ve tartışmalar kısmında detaylı bir şekilde ele alınmıştır.

## 2. Materyal ve Metot


Derin öğrenme son zamanlarda sağlık alanında ve diğer güncel problemlerin çözümünde sıklıkla karşımıza çıkmaktadır. Derin öğrenmenin önemli bir mimarisi olan ESA'lar; görüntü işleme, görüntü analizi ve sınıflandırılması gibi birçok işlemin gerçekleştirilmesinde kullanılmaktadır. ESA'lar çok sayıda gizli katman içerdiği için görüntülerdeki özelliklerin ayırt edilmesinde kolaylık sağlar. ESA temel olarak; evrişim katmanı, havuzlama katmanı ve tam bağlı katman olmak üzere üç ana yapıyı içerir.

Evrişim katmanı ham bir şekilde ele alınan görüntü verilerinin özellik çıkarımının yapıldığı katmandır. Görüntülerin piksel değerleri bir matris olarak tutulur. Filtreler sayesinde görüntü matrisi taranır istenilen ayırt edici özelliklerin çıkarımı yapılarak görüntünün yeni özellik matrisi elde edilmiş olur. Evrişim katmanından sonra gelen havuzlama katmanında ise elde edilen özellik matrisinin boyutu düşürülür. Bu sayede görüntüleri işlemek için yapılması gereken hesaplama maliyeti azalmış olur ve seçilen gereksiz özellikler yok sayılarak daha önemli özellikler çıkarılmasına olanak sağlanır. Havuzlama sonrası elde edilmiş özellik matrisinin tam bağlı katmanda kullanılabilmesi için tek boyutlu bir diziyeye dönüştürülür. Tam bağlı katmandaki her bir nöron, bu katmandan önce gelen havuzlama ve evrişim katmanlarındaki tüm girişlere bağlı olarak bir çıkış üretir. Böylelikle görüntülerin sınıflandırma ve tanıma işlemleri gerçekleştirilerek ESA yapısı tamamlanmış olur.

Bu çalışmada akciğer kanserinin tespit edilmesi için temel ESA yapısı baz alınarak yeni bir ESA modeli önerilmiştir. Önerilen ESA modeli ve ImageNet [9] veri seti üzerinde önceden eğitilmiş olan ResNeXt [10] mimarisi, aynı veri seti üzerinde uygulanarak karşılaştırılmıştır.

## 2.1. Kullanılan veri seti

Akciğer kanserinin tespiti için yapılan bu çalışmada, Kaggle platformunda açık erişimli popüler akciğer BT tarama görüntülerinden oluşan bir veri seti kullanılmıştır [11]. Veri seti içerisinde üç farklı akciğer kanseri ve normal etiketli olmak üzere dört ayrı sınıftan oluşan görüntüler bulunmaktadır. Bu çalışma için akciğer kanseri ve normal olarak iki sınıf kullanılmıştır. Veri setinde 465 tane akciğer kanseri BT taraması görüntüsü ve 215 normal akciğer BT tarama görüntüsü olmak üzere toplam 680 eğitim verisi bulunmaktadır. Bu veriler haricinde veri setinde eğitim verilerinden bağımsız normal ve akciğer kanseri sınıflarına ait 315 adet test görüntüsü bulunmaktadır. Eğitim öncesinde görüntüler üzerinde herhangi bir ön işlem adımı gerçekleştirilmemiş olup, görüntüler ham hali ile model eğitimine dâhil edilmiştir. Bu veri setine ait normal ve kanser etiketli akciğer BT tarama görüntülerinden örnek bir kesit Şekil 1’de verilmiştir.




Şekil 1. Normal ve kanser sınıflarına ait akciğer BT görüntü örnekleri.

## 2.2. Önerilen ESA modeli

Önerilen modelde temel ESA modelindeki evrişim, havuzlama, düzleştirme ve bırakma katmanlarının yanı sıra ResNet mimarisinin temelini oluşturan artık blokların yer almaktadır. Şekil 2’de görüldüğü üzere önerilen modelde Evrişim Blok (EB), Maksimum Havuzlama Katmanı (MaksH), Evrişim ve Artık Blok (EAB), Bırakma Katmanı (Dropout), Düzleştirme Katmanı ardışıl olarak eklenerek yeni bir ESA modeli oluşturulmuştur. Önerilen ESA modelinde toplam sekiz tane evrişim katmanı yer almaktadır. Her EB katmanının içerisinde, iki boyutlu evrişim katmanı, girdi parametrelerini standart hale getirmek için toplu normalleştirme ve çıktıları normalize etmek için ReLU aktivasyon fonksiyonları bulunmaktadır. EAB katmanı ise içerisinde bir adet EB ve bir adet artık blok içerecek şekilde oluşturulmuştur. Artık bloklar, bir katmandan elde edilen çıktıyı alıp başka bir katmana ekleyerek doğrusallığı ortadan kaldırır ve bu sayede model derinleştikçe oluşacak olan problemlerin önüne geçilmiş olur [12]. Maksimum havuzlama katmanında ise 2x2 boyutunda filtre kullanılarak görüntüler üzerinde en önemli değerler alınıp girdi boyutu küçültülmüştür. Yapılan çalışmada kullanılan veri sayısının az olmasından dolayı modelin ezber yapmasının önüne geçerek bazı nöronları unutmak adına model yapısında bir adet bırakma katmanı kullanılmıştır. Bırakma katmanında unutmama oranı %25 olarak belirlenmiştir. Model, Şekil 2’de girdi olarak aldığı akciğer BT görüntülerini Kanser ve Normal olmak üzere ikili sınıf şeklinde sınıflandırmıştır. Eğitilen

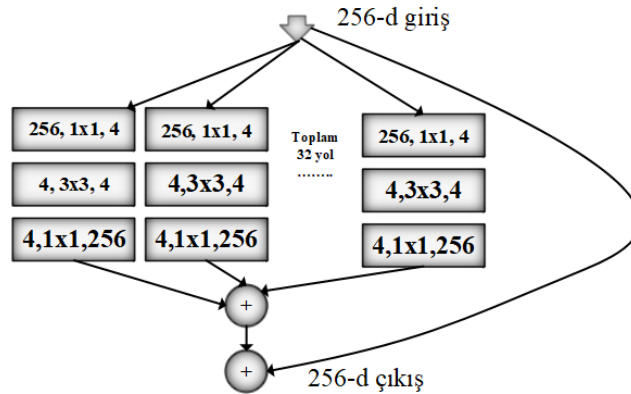
ESA modeli 147500 parametreden oluşmaktadır. Eğitim esnasında kayıp fonksiyonu olarak çapraz entropi kayıp fonksiyonu, optimizasyon algoritması olarak Adam ve öğrenme katsayısı olarak  $1e-3$  seçilerek modelin hiperparametreleri belirlenmiştir.



Şekil 2. Önerilen ESA modelinin yapısına ait bir blok gösterim.

### 2.3. ResNeXt mimarisi


ResNeXt mimarisi temelde ResNet mimarisine benzeyen ImageNet veri seti üzerinde derin öğrenme ile eğitilmiş görüntü verilerini sınıflandıran bir mimaridir [13]. ResNeXt 2016 yılında katıldığı yarışmada (ILSVRC2016) ImageNet veri setindeki görüntüleri sınıflandırmada yarışmadaki diğer mimarilerden daha düşük hata oranı ile daha yüksek başarı elde etmiştir. Yapısal olarak Inception modellerinde kullanılan “böl-dönüştür-birleştir” yöntemini kullanmıştır. Yani ResNet mimarisindeki kullanılan tek bir artık blok yerine bir hücre içerisinde dallanmış derin artık ağ yapısını kullanmaktadır. ResNeXt mimarisi yapısında  $1 \times 1, 3 \times 3, 1 \times 1$ ’lik evrişim katmanlarını her bir hücre satırına eşit bir şekilde uygulayarak, görüntü üzerinde filtreleme işlemini yapmıştır. Girdi parametrelerinin boyutunu küçültmek için global ortalama havuzlama katmanı, aktivasyon fonksiyonu olarak ReLU kullanılmıştır. ResNeXt mimarisi ile eğitilen model toplam 12,3 milyon parametreden oluşmaktadır. Mimarinin hiperparametreleri olarak, çapraz entropi kayıp fonksiyonu ve adam optimizasyon fonksiyonu kullanılmıştır. ResNeXt mimarisinin eğitiminde öğrenme katsayısı  $1e-3$  olarak seçildi. ResNeXt mimarisini yapısı Şekil 3 ‘de gösterilmiştir.



Şekil 3. ResNeXt mimarisinin yapısı [8].

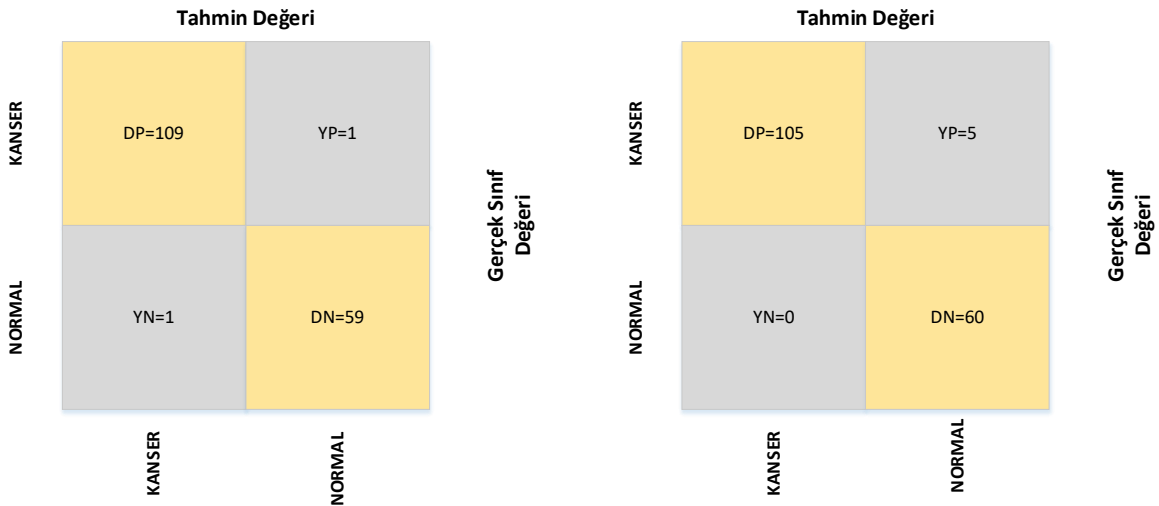
### 3. Deneysel Sonuçlar ve Tartışma

Çalışmada kullanılan akciğer BT görüntü veri seti, önerilen ESA modeli için %75:%25 oranında eğitim ve doğrulama olarak ikiye ayrılmıştır. Model eğitimi, eğitim ve doğrulama verileri üzerinde yapılarak, veri setine ait olan bağımsız test verileri üzerinde performans değerlendirmesi yapılmıştır. Modelin eğitim tur sayısı 30 olarak belirlenmiştir. Önerilen ESA modeli ve ResNeXt mimarisi için yapılan eğitimlerde tur sayısına göre elde edilen kayıp değerleri, eğitim ve test verilerine göre kayıp grafiği Şekil 4’de verilmiştir. Önerilen ESA modelinde eğitim verilerindeki kayıp değeri, 30 eğitim tur sayısı sonunda 4,31’den 0,1’e ve test verilerindeki kayıp değeri 4,7’den 0,1’e düşmüştür. ResNeXt mimarisinin eğitim verilerindeki kaybı, son eğitim tur sayısında 0,09 ve test verilerindeki kaybı 0,07 olarak elde edilmiştir. Elde edilen grafiklerde de görüldüğü gibi eğitim için kullanılan veri sayısı az olmasına rağmen, eğitim ve test verilerindeki kayıp değeri birbirine paralel miktarda azaldığı için modellerde aşırı öğrenme olmadığı gözlemlenmiştir.



**Şekil 4.** Eğitilen modellerin eğitim (train) ve test (validation) verilerine göre kayıp grafikleri; (a.) Önerilen ESA modelinin kayıp grafiği, (b.) ResNeXt mimarisinin kayıp grafiği.

Çalışmada test verileri üzerinde ResNeXt modeli için elde edilen doğruluk oranı % 97 iken, önerilen ESA modeli için doğruluk oranı %99 olarak gözlemlenmiştir. Elde edilen modellerin, performans karşılaştırmaları Şekil 5’de verilen karmaşıklık matrisleri üzerinden detaylı olarak sunulmuştur.




**Şekil 5.** Test verileri üzerinde elde edilen karmaşıklık matrisleri, a) Önerilen ESA modeli ve b) ResNeXt.

Karmaşıklık matrisi incelendiğinde, test aşamasında önerilen ESA modeli 110 adet kanser etiketli sınıf için bir tanesini yanlış (yanlış pozitif, YP) ve 109 tanesini doğru (doğru pozitif, DP) sınıflandırmıştır. Normal sınıf için


60 adet görüntü içerisinde bir adet yanlış (yanlış negatif, YN) ve 59 adet doğru (doğru negatif, DN) sınıflandırma yapmıştır. Toplamda 170 adet test görüntüsünde iki adet yanlış sınıf tahmininde bulunmuştur. ResNeXt mimarisi ise 110 adet akciğer kanseri BT görüntüsünde beş tane yanlış (yanlış pozitif, YP) ve 105 adet doğru (doğru pozitif, DP) sınıflandırma yapmıştır. Normal sınıfa ait 60 adet görüntüde tamamını doğru (doğru negatif, DN) tahmin etmiş ve hiç yanlış (yanlış negatif, YN) tahminde bulunmamıştır. Eğitilen modellerin, karmaşıklık matrislerinde belirtilen yanlış sınıflandırmalara ait görüntüler ve tahmin oranları Şekil 6 ve Şekil 7 'de verilmiştir.

Tahmini Sınıf/Gerçek Sınıf/Kayıp Değeri/Olasılık

NORMAL/KANSER/3.46/0.83



KANSER/NORMAL/1.56/0.49



Şekil 6. Önerilen ESA modelinin test aşamasında yanlış sınıflandırmış olduğu BT görüntüleri.

Tahmini Sınıf/Gerçek Sınıf/Kayıp Değeri/Olasılık

NORMAL/KANSER/3.27/0.96



NORMAL/KANSER/2.42/0.91



NORMAL/KANSER/1.60/0.80



NORMAL/KANSER/1.19/0.80



NORMAL/KANSER/1.00/0.63



Şekil 7. ResNeXt mimarisinin test aşamasında yanlış sınıflandırmış olduğu BT görüntüleri.

Şekil 6 ve Şekil 7 incelendiğinde, önerilen ESA modeli test aşamasında akciğer kanserli olguyu hatalı bir şekilde normal olarak sınıflandırmıştır. Bu olguda akciğer kitlesi büyük boyutlu olup mediastinal vasküler yapılarla ara planları silinmiş ve mediastinal yağ doku planlarına invaze görünümündedir. Muhtemelen bu nedenle

akciğer kitlesinin mediastinal normal anatomik yapılardan ayrımını yapamamıştır. Yine önerilen ESA modeli test aşamasında akciğer kanseri olmayan olguları yanlış olarak akciğer kanseri olarak sınıflandırmıştır. Bu olgularda akciğer parankiminde lineer uzanımlı içerisinde mukus tıkaçı bulunan bronşektazik değişiklikler ve enfeksiyöz süreçler mevcuttur. Model benign olan bu bulguları akciğer kanseri olarak sınıflandırmıştır. Bu nedenle modelin mediastinal alanlara uzanım gösteren kanser hastaları ve akciğerin benign hastalıkları ile ayırıcı tanı yapması açısından desteklenmesi gerekmektedir. Yanlış sınıflandırma yapıldığı düşünülen bir olguda da model doğru sınıflandırma yapmış olup bu görüntünün yanlış etiketlendiği tespit edilmiştir ve olguda kanser olmadığı uzman doktor ile doğrulanmıştır. Modelin akciğer kanseri ve normal akciğer radyolojik bulgularını ayırmadaki başarısı ile akciğerdeki kitleyi tespit etme oranı oldukça yüksektir. Model klinisyen ve radyoloji doktorlarına hastalığın erken tanı ve doğruluk oranında artma ve hata oranında azalma sağlayacak potansiyele sahiptir. Bu hastaların yaşam sürelerinin uzaması, kaliteli yaşam sürme şansının artması ve artmış tedavi oranları açısından oldukça önemli bir kazanımdır.

Çalışmamızın sonuçları klinik açıdan ele alındığında, derin öğrenme metodumuz en çok akciğer kanseri ve normal akciğeri ayırmada hastanelerde, radyoloji merkezlerinde ve tıp alanlarında kullanılabilir. Normal akciğer ve akciğer kanseri olan hastaların tespitine dair elde edilen kıymetli ve doğruluk oranı yüksek veriler doktorlara bir rapor olarak verilerek hastalığın ayırıcı tanısında yardımcı olacaktır. Yeterli sayıda uzman kişinin bulunmadığı durumlarda, artan iş yüküne bağlı olarak sağlık hizmetleri konusunda meydana gelen hatalar, aksaklıklar en aza indirilebilir.

#### 4. Sonuç

Yapılan bu çalışmada kanserli ve normal akciğer BT görüntülerinin ayrımı için yeni bir ESA modeli tasarlanmıştır. Çalışmada açık erişimli bir veri seti üzerinde önerilen ESA modeli ve önceden eğitilmiş olan hazır popüler derin öğrenme mimarilerinden biri olan ResNeXt mimarisi kullanılmıştır. Eğitilen modellerin test görüntüleri üzerinde karmaşıklık matrisleri oluşturulmuştur. Karmaşıklık matrislerinden elde edilen değerlerle hesaplanan performans metriklerine göre sonuçlar karşılaştırılmıştır. Elde edilen sonuçlara göre önerilen ESA modeli, %99 doğruluk oranı ile ResNeXt mimarisine göre akciğer BT görüntüleri üzerinde sınıflandırma yapmada daha başarılı sonuçlar elde etmiştir. Yapılan mevcut çalışmanın en büyük dezavantajı kullanılan veri kümesinin boyut bakımından nispeten küçük olmasıdır diyebiliriz. Veri sayısı açısından daha büyük klinik veriler ile çalıştırılırsa, modelin doğruluğu daha yüksek karar verebileceği düşünülmektedir. Buna bağlı olarak geliştirilen sonraki aşamalarda yapılacak olan çalışmalarda eğitim için veri sayısı fazla olan daha geniş akciğer kanseri veri seti kullanılabilir ve önerilen ESA modeli ile eğitimleri tekrar gerçekleştirilebilir. Bu doğrultuda elde edilen deneysel sonuçlar, mevcut çalışmada elde edilen sonuçlarla karşılaştırılabilir.

#### Kaynaklar

- [1] Rosado-de-Christenson, M. L., Templeton, P. A., & Moran, C. A. (1994). Bronchogenic carcinoma: radiologic-pathologic correlation. *Radiographics*, 14(2), 429-446.
- [2] Khuder, S. A. (2001). Effect of cigarette smoking on major histological types of lung cancer: a meta-analysis. *Lung cancer*, 31(2-3), 139-148.
- [3] Sathyakumar, K., Munoz, M., Singh, J., Hussain, N., & Babu, B. A. (2020). Automated lung cancer detection using artificial intelligence (AI) deep convolutional neural networks: A narrative literature review. *Cureus*, 12(8).
- [4] Joshua, E. S., Bhattacharyya, D., Chakkravarthy, M., & Byun, Y. C. (2021). 3D CNN with visual insights for early detection of lung cancer using gradient-weighted class activation. *Journal of Healthcare Engineering*, 2021.doi: 10.1155/2021/6695518
- [5] An, Y., Hu, T., Wang, J., Lyu, J., Banerjee, S., & Ling, S. H. (2019, July). Lung Nodule Classification using A Novel Two-stage Convolutional Neural Networks Structure'. In 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 6259-6262). IEEE. doi: 10.1109/EMBC.2019.8857744.
- [6] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).
- [7] Devi, T. A. M., & Jose, V. M. (2021). Three Stream Network Model for Lung Cancer Classification in the CT Images. *Open Computer Science*, 11(1), 251-261.doi: 10.1515/comp-2020-0145
- [8] <https://image-net.org/challenges/LSVRC/2016/results#loc>, Son Erişim Tarihi: 09.08.2022
- [9] <https://image-net.org/download.php>, Son Erişim Tarihi: 22.04.2022
- [10] Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2017). Aggregated residual transformations for deep neural networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1492-1500). doi: 10.48550/arXiv.1611.05431

- [11] “Chest CT-Scan images Dataset | Kaggle” Online: <https://www.kaggle.com/datasets/mohamedhanyyy/chest-ctscan-images>, Son Eriřim Tarihi: 30.03.2022
- [12] <https://towardsdatascience.com/resnets-residual-blocks-deep-residual-learning-a231a0ee73d2F>, Son Eriřim Tarihi: 21.04.2022
- [13] <https://www.jeremyjordan.me/convnet-architectures/#resnext>, Son Eriřim Tarihi: 22.04.2022