



Contents lists available at *Dergipark*

Journal of Scientific Reports-C

journal homepage: <https://dergipark.org.tr/en/pub/jsrc>



E-ISSN: 2717-8633

Sayı(Number) 7, Ağustos(August) 2024

ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

Geliş Tarihi (Receive Date): 07.06.2023

Kabul Tarihi (Accepted Date): 20.02.2024

Akciğer kanseri tanısı için derin öğrenme modellerinin karşılaştırılması ve uygulanması

Ekrem Gökberk Koç^{a,*}, Durmuş Özdemir^b

^a Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID: 0009-0000-3589-2692

^b Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya ORCID: 0000-0002-9543-4076

Öz

Akciğer kanseri, dünya genelinde yaygın bir sağlık sorunu haline gelmiştir. Erken teşhis ve doğru tedavi, hastalığın seyrini önemli ölçüde etkileyebilmektedir. Bu çalışmada, akciğer tomografisi (CT) görüntülerini kullanarak akciğer kanserinin erken teşhisini yapabilmek amaçlanmıştır. Bu teşhisi yapabilmek için derin öğrenme modellerinin karşılaştırılması ve uygulanması üzerine odaklanılmıştır. CNN, DenseNet ve ResNet gibi üç popüler derin öğrenme modeli kullanılarak, akciğer kanseri tanısı için performansları değerlendirilmiştir. Ayrıca eğitim verileri için 1440 akciğer tomografisi görüntüsü, test verileri için 174 akciğer tomografisi görüntüsü ve doğrulama verileri için 36 adet akciğer tomografisi görüntüsü kullanılmıştır. Sonuçlar değerlendirildiğinde en başarılı modelin ResNet (%96.55), bir sonraki başarılı modelin CNN (%89.08) ve son olarak DenseNet modelinin (%88.51) başarısı olduğu gözlenmiştir.

© 2023 DPU All rights reserved.

Anahtar Kelimeler: Derin Öğrenme, Akciğer Kanseri, Erken Teşhis, Performans Değerlendirmesi

Comparison and application of deep learning models for diagnosis of lung cancer

Abstract

Lung cancer is a widespread health issue globally. Early detection and proper treatment can greatly impact the progression of the disease. This study aimed to identify lung cancer at an early stage using lung tomography (CT) images. The focus was on comparing and applying deep learning models for this diagnosis. The performance of three popular deep learning models - CNN, DenseNet, and ResNet - was evaluated for lung cancer diagnosis. The training data consisted of 1440 lung tomography images, while 174 images were used for testing and 36 for validation. Upon evaluation, it was observed that the most successful model was ResNet (96.55%), followed by CNN (89.08%), and finally the DenseNet model (88.51%).


© 2023 DPU All rights reserved.

Keywords: Deep Learning, Lung Cancer, Early Diagnosis, Performance Evaluation

* Corresponding author. Tel.: +90 530 246 96 48
E-mail address: ekrem.koc@ogr.dpu.edu.tr

1. Giriş

Tüm kanser türleri arasında en yaygın tür olan akciğer kanseri tüm dünyada kanser türleri arasında, erkeklerde en sık ölüme neden olan birinci, kadınlarda ise ikinci kanser türüdür ve tüm dünyada her yıl yaklaşık 1,6 milyon can kaybına neden olmaktadır [1]. Erken teşhis ve doğru tedavi, hastalığın seyrini önemli ölçüde etkileyebilmekte ve hastaların yaşam sürelerini artırabilmektedir. Bu nedenle, akciğer kanserinin erken teşhisi büyük bir öneme sahiptir. Geleneksel olarak, akciğer kanseri tanısı için radyologlar tarafından yapılan görüntüleme yöntemleri kullanılmaktadır. Bunlar arasında en sık kullanılanı akciğer tomografisi (CT) görüntülemesidir. Ancak, akciğer CT görüntülerinin incelenmesi zaman alıcı ve subjektif bir süreç olabilir. Bu nedenle, otomatik ve objektif bir tanı yönteminin geliştirilmesi büyük bir gereksinim haline gelmiştir [2]. Şekil-1'de örnek olarak akciğer kanseri hastasına ait bir CT görüntüsü sunulmuştur.



Şekil 1. Akciğer kanseri hastası CT görüntüsü [3]

Derin öğrenme, son yıllarda tıbbi görüntü analizinde büyük bir ilgi odağı haline gelmiştir. Derin öğrenme modelleri, büyük veri setleri üzerinde eğitilerek karmaşık yapıları algılayabilen ve yüksek doğrulukla sınıflandırma yapabilen yapay sinir ağlarıdır. Bu nedenle, akciğer kanseri tanısı için derin öğrenme modellerinin kullanımı, otomatik ve hassas bir tanı yöntemi sağlayabilir [4]. Derin öğrenme, yapay sinir ağları ile oluşturulan ve karmaşık veri yapılarını analiz etmek ve öğrenmek amacıyla kullanılan bir makine öğrenme yöntemidir. Bu yöntem, bilgisayar sistemlerinin veriye dayalı kararlar alabilmesinde rol oynar. Aynı zamanda birçok uygulama alanında büyük başarılar elde ettiği görülmüştür. Özellikle görüntü işleme, doğal dil işleme, ses tanıma ve otonom sürüş gibi alanlarda derin öğrenme modelleri büyük ilgi görmektedir [5]. Derin öğrenme modelleri, çoğunlukla çok katmanlı sinir ağları olarak tasarlanır ve büyük miktarda veriyle beslenerek öğrenme yeteneklerini geliştirirler. Bu modeller, veri setlerindeki karmaşık desenleri algılayabilir ve bu desenlere dayalı olarak tahminlerde bulunabilir. Özellikle görüntü işleme alanında, derin öğrenme modelleri, piksellerin düşük seviyeli özelliklerinden yüksek seviyeli özelliklere kadar aşamalı olarak öğrenme yeteneğine sahiptir. Bu sayede nesne tanıma, yüz tanıma, nesne tespiti gibi görevlerde oldukça etkili sonuçlar elde edilebilir [6]. Derin öğrenme, akciğer kanseri teşhisi gibi sağlık alanındaki hastalık teşhislerinde de büyük başarıya sahiptir. Akciğer tomografisi (CT) gibi görüntüleme yöntemleri kullanılarak elde edilen veriler, derin öğrenme modelleri tarafından analiz edilebilir ve akciğer kanserinin erken teşhisinde

önemli bir rol oynayabilir. Derin öğrenme modelleri, pulmoner nodüllerin tespiti ve sınıflandırılması gibi görevleri gerçekleştirebilir ve radyologlara hızlı ve doğru sonuçlar sunabilir. Ayrıca, derin öğrenme modelleri, akciğer kanserine ilişkin genetik verilerin analizinde de kullanılabilir ve kişiye özgü tedavi yöntemlerinin belirlenmesinde yardımcı olabilir [7].

Derin öğrenme, büyük veri setleriyle beslenerek öğrenme yeteneklerini sürekli olarak geliştirme potansiyeline sahiptir. Ayrıca, derin öğrenme modelleri, transfer öğrenme ve hızlı öğrenme gibi tekniklerle farklı veri setleri ve uygulama alanlarına da genişletilebilir. Ancak, derin öğrenme modellerinin karmaşıklığı ve hesleme gücü gereksinimi, eğitim sürecinde yüksek kaynak ve hesaplama gücü gerektirebilir. Sonuç olarak, derin öğrenme, akciğer kanseri teşhisi gibi ciddi sağlık sorunlarına çözüm olabilecek etkili bir araçtır. Görüntü işleme, genetik veri analizi gibi alanlarda derin öğrenme modellerinin kullanılması, akciğer kanseri tanısı ve tedavisinde önemli bir ilerleme sağlayabilir. Ancak, daha fazla araştırma ve geliştirme gerekmektedir ve derin öğrenme modellerinin klinik uygulamalara entegrasyonu için daha fazla çalışma yapılmalıdır [8].

Literatür incelendiğinde, Ayrık Dalgacık Dönüşümü (ADD) yaklaşımı ile 6053 akciğer tomografi veri seti kullanarak, VGG-16, Inception v4, MobileNet v3 ve AlexNet yöntemi ile görüntülerde kanser hastalığı tespiti yapılmıştır. En başarılı performansı AlexNet'in %99,86 ile sağladığı görülmüştür [9]. U-Net mimarisi kullanılarak yapılan piksel temelli görüntü segmentasyon modelinin avantajını sunan bir başka çalışmada, eğitim görüntüsü az olsa dahi klasik modellerden daha başarılı sonuç verdiği vurgulanmaktadır. 138 sol ve sağ akciğer bölgesinin GXI görüntülerini içeren veri setinde bulunan görüntüler %80 eğitim, %10 doğrulama ve %10 test olarak rastgele bölünmüştür. Modelin performansı Dice katsayısı ölçülerek 0,9763 Dice değeri elde edilmiştir [10].

Liu ve Lee, 37 hastanın biyopsi görüntülerini kullanarak kanserli ve kanser olmayan hastaları belirlemek için birden fazla derin öğrenme modelini kullanmışlardır. Çalışmada geleneksel derin öğrenme modellerinden CNN mimarisi tabanlı; AlexNet, VGG, ResNet ve SqueezeNet modelleri ince ayar yapılarak uyarlanmıştır. Derin öğrenme modelinin AUC' si daha makuldür (0,8808–0,9121). Yani genellikle modeli sıfırdan eğitmek daha iyi bir sonuç vermektedir. Fakat ResNet50 modeli için durum farklıdır, bu durumda önceden eğitilmiş modele ince ayar yapmak daha sağlıklı sonuç vermektedir [11].

Literatür incelendiğinde bir başka çalışmada InceptionV3 temel alınarak geliştirilen ISANET adlı sınıflandırma modeli kullanılmıştır. Model, kanal dikkati ve mekansal dikkat mekanizmalarını içererek patolojik bölgelere odaklanmayı amaçlamaktadır. ISANET'in geleneksel modellere (AlexNet, VGG16, InceptionV3, MobilenetV2 ve ResNet18) göre üstün doğruluk elde ettiğini göstermektedir. Bu deneylerin sonuçları, ISANET'in akciğer kanserini sınıflandırmada etkili bir model olduğunu doğrulamaktadır, %95,24 ve %98,14 başarı oranı elde edilmiştir [12].


Bu araştırmanın amacı, bu derin öğrenme modellerinin akciğer kanseri tanısı için performanslarını karşılaştırmak ve değerlendirmektir. Bu çalışma, akciğer kanseri tanısında derin öğrenme modellerinin etkili bir şekilde kullanılabilmesini ve potansiyel olarak mevcut yöntemleri tamamlayabileceğini göstermektedir. Derin öğrenme tekniklerinin kullanımıyla, akciğer kanseri tanısında erken teşhisin mümkün olabileceği ve hastaların tedavi sürecinde avantaj sağlanabileceği düşünülmektedir. Bu çalışmada, akciğer kanseri tanısı için derin öğrenme modellerinin karşılaştırılması ve uygulanması üzerine odaklanılmıştır. CNN, DenseNet ve ResNet gibi üç popüler derin öğrenme modeli kullanılarak, akciğer CT görüntülerinden elde edilen veriler üzerinde eğitim ve test işlemleri gerçekleştirilmiştir. Eğitim veri seti olarak 1440 akciğer CT görüntüsü kullanılırken, test veri setinde 174 görüntü ve doğrulama veri setinde 36 görüntü bulunmaktadır.

2. Materyal ve Yöntem

2.1. Veri seti

Araştırmada yer alan veri setine dair bilgiler şu şekildedir: Veri setinde akciğer CT görüntüleri bulunmaktadır bu görüntülerin etiketleri kanserli ve sağlıklı şeklinde etiketlenmiştir. Kanserli olarak etiketlenen 876 görüntü, sağlıklı olarak etiketlenen 564 adet görüntü vardır [13]. Toplamda 1440 adet eğitim verisi (876 kanserli 564 sağlıklı), 174

adet test verisi (120 kanserli 54 sağlıklı) ve 36 adet doğrulama verisi (23 kanserli 13 sağlıklı) olmak üzere ayrılmıştır [14]. Şekil 2' de temsili olarak sağlıklı ve kanserli akciğer CT görüntüleri paylaşılmıştır.



Şekil 2. Sağlıklı ve Kanserli akciğer CT görüntüleri [3]

2.2. Kullanılan modeller

2.2.1. Resnet50 modeli

ResNet50, Residual Neural Network (ResNet) ailesine ait bir derin öğrenme modelidir. İsmi, 50 adet katman içermesinden kaynaklanmaktadır. Bu model, özellikle görüntü sınıflandırma ve nesne tanıma gibi görevler için kullanılmaktadır. ResNet50'nin katmanları ve özellikleri şu şekildedir [15]. Giriş katmanında ilk katman, görüntülerin girişini alır ve boyutunu belirler. Genellikle RGB renk kanallarını temsil etmek için 3 kanala sahip olur. Bu katman, görüntülerin doğrudan alınmasından sorumludur ve verileri ağına geri kalanına iletmek için herhangi bir işlem yapmaz. Giriş katmanı, görüntü verilerinin doğru boyut ve formatlara sahip olduğundan emin olmak için önemlidir. Örneğin, piksel değerlerini normalize etmek gibi ön işleme adımları da bu katmanda gerçekleştirilebilir. Giriş katmanı, ağına temelini oluşturan ve verilerin ağına uygun bir şekilde aktarılmasını sağlayan önemli bir bileşendir. ResNet50 modeli, giriş katmanının yanı sıra birçok derinlikte konvolüsyonel ve toplama (addition) katmanlarından oluşur. Bu yapı, modelin daha derin ağlarda da başarılı olabilmesini sağlayan kendine has bir özelliktir. ResNet50'nin geri kalan katmanları, bu derin ağ yapısını oluşturmak, görüntülerin özelliklerini öğrenmek ve önemli desenleri yakalamak için optimize edilmiştir. Evrişim katmanında ardışık olarak yer alan katmanlarda, görüntüler üzerinde özellik haritaları oluşturulur. Bu katmanlar, farklı boyutlarda filtreleri kullanarak görüntünün farklı özelliklerini algılar. ResNet50'de 16 adet evrişim katmanı bulunur. Evrişim katmanlarının ardından havuzlama (pooling) katmanları gelir. Bu katmanlar, özellik haritalarını küçültür ve özelliklerin ölçeklenebilirliğini artırır. Çoğunlukla maksimum veya ortalama havuzlama kullanılır. Ardından özellik haritaları tam bağlantılı (fully connected) katmanlara verilir. Bu katmanlar, çıktıları düzleştirir ve sınıflandırma veya tanıma için kullanılacak özellik vektörünü oluşturur. Son katman olan çıkış katmanına gelindiğinde, sınıflandırma veya tanıma amacıyla kullanılan nöronları içerir. Akciğer kanseri tanısında, bu katman, kanserli veya kansersiz olarak sınıflandırma yapmak için kullanılır [16]. ResNet50 modelinin akciğer kanseri tanısıyla bağlantısı, derin öğrenme modelinin akciğer CT görüntülerinde kanserli bölgeleri doğru bir şekilde tanımlama ve sınıflandırma yeteneğiyle ilgilidir. ResNet50'nin evrişim ve havuzlama katmanları, akciğer CT görüntülerinin önemli özelliklerini algılar ve kanserli bölgeleri tespit eder. Tam bağlantılı katmanları, bu özellik vektörlerini kullanarak kanserli veya kansersiz sınıflandırmasını gerçekleştirir. ResNet50, yüksek doğruluk oranları ve genelleme yeteneğiyle akciğer kanseri tanısında etkili bir araç olabilir. Model, görüntülerdeki kanserli bölgeleri hassas bir şekilde tespit ederek erken teşhisin sağlanmasına katkıda bulunabilir. Ayrıca, derin ağ yapısı sayesinde geniş bir veri setiyle eğitilmiş olan

ResNet50, daha az veriyle çalışırken yüksek performans sergileyebilir ve klinik uygulamalarda radyologlara ciddi bir destek sunabilir.

2.2.2. Cnn modeli

CNN (Convolutional Neural Network) modeli, akciğer kanseri tanısı için kullanılan ve görüntü işleme görevlerinde başarıyla kullanılan bir derin öğrenme modelidir. Modelin katmanları şu şekildedir. Evrişim katmanı (Conv2D) ile modelin girişine (150, 150, 3) boyutunda olan ve RGB renk kanallarını içeren görüntüler verilir. Bu katmanda 32 adet 3x3 boyutunda filtre kullanılır ve aktivasyon fonksiyonu olarak ReLU (Rectified Linear Unit) kullanılır. Evrişim katmanı, görüntüler üzerinde farklı özellikleri vurgulayan özellik haritalarını oluşturur. Havuzlama katmanı (MaxPooling2D) ile evrişim katmanından elde edilen özellik haritaları üzerinde boyut küçültme işlemleri yapılır. Bu katmanda 2x2 boyutunda bir havuzlama filtresi kullanılır ve maksimum değeri olarak özellik haritalarının boyutunu küçültür. İkinci evrişim katmanı ile önceki evrişim katmanının çıktısına 64 adet 3x3 boyutunda filtre uygulanır ardından tekrar ReLU aktivasyon fonksiyonu kullanılır. Bu katmanda da farklı özelliklerin vurgulanması sağlanır. İkinci havuzlama katmanı ile ikinci evrişim katmanının çıktısına aynı şekilde 2x2 boyutunda bir havuzlama filtresi uygulanır ve özellik haritalarının boyutu daha da küçültülür. Üçüncü evrişim katmanı ile önceki katmanlardaki işlemler tekrarlanır. Bu sefer 128 adet 3x3 boyutunda filtre kullanılır ve ReLU aktivasyon fonksiyonu uygulanır. Üçüncü havuzlama katmanına gelindiğinde üçüncü evrişim katmanının çıktısına yine 2x2 boyutunda bir havuzlama filtresi uygulanır ve boyut küçültme işlemi yapılır. Dördüncü evrişim katmanında önceki adımlarda olduğu gibi 128 adet 3x3 boyutunda filtre kullanılır ve ReLU aktivasyon fonksiyonu uygulanır. Dördüncü havuzlama katmanı ile dördüncü evrişim katmanının çıktısına 2x2 boyutunda bir havuzlama filtresi uygulanır ve boyut küçültme işlemi yapılır. Düzleştirme katmanı (Flatten) ile havuzlama katmanlarının çıktılarını düzleştirilir ve tek boyutlu bir vektör elde edilir. Bu vektör, sonraki tam bağlantılı katmanlara giriş olarak kullanılır. Tam bağlantılı katman (Dense) ile de 512 nöron içeren bir tam bağlantılı katmandır. ReLU aktivasyon fonksiyonu kullanılır ve özelliklerin daha spesifik kombinasyonlarını öğrenmeye yardımcı olur. Çıkış katmanı (Dense) ile son olarak, tek bir nöron içeren bir çıkış katmanı yer alır. Bu katmanda sigmoid aktivasyon fonksiyonu kullanılır ve kanserli veya kansersiz sınıfını tahmin etmek için kullanılır. CNN modeli, akciğer CT görüntülerindeki kanserli bölgelerin tespiti ve sınıflandırılması için kullanılır. Evrişim katmanları, görüntüler üzerindeki özellikleri vurgulayarak kanserli bölgeleri belirler. Havuzlama katmanları ise boyut küçültme işlemi yaparak özelliklerin ölçeklenebilirliğini artırır. Tam bağlantılı katmanlar, özellik vektörünü oluşturarak sınıflandırma yapar. Çıkış katmanı ise kanserli veya kansersiz sınıfını tahmin eder. Bu şekilde, CNN modeli akciğer kanseri tanısında etkili bir şekilde kullanılabilir ve hastaların erken teşhis ve tedaviye yönlendirilmesine yardımcı olabilir [17] [18].

2.2.3. Densenet modeli

DenseNet, yoğun bağlantılı bloklar ve geçiş blokları adı verilen iki temel yapıyı içeren bir derin öğrenme modelidir. Modelin katmanları şu şekildedir. Giriş katmanında, modelin giriş verilerini alan ve işlemeye başlamak için ilk adımı atan bir katmandır. Giriş Katmanı, genellikle görüntüler için RGB (3 kanal) veya siyah-beyaz (1 kanal) gibi belirli bir giriş boyutuyla tanımlanır. Bu katman, ağa giriş verilerini aktarırken aynı zamanda boyut ve format ayarlamaları yapabilir. Örneğin, RGB görüntülerde her bir kanalı ayrı ayrı temsil edebilir ve siyah-beyaz görüntülerde yalnızca tek bir kanalı kullanabilir. Giriş Katmanı aynı zamanda giriş verilerini normalize etmek veya ön işleme adımlarını uygulamak için kullanılabilir.

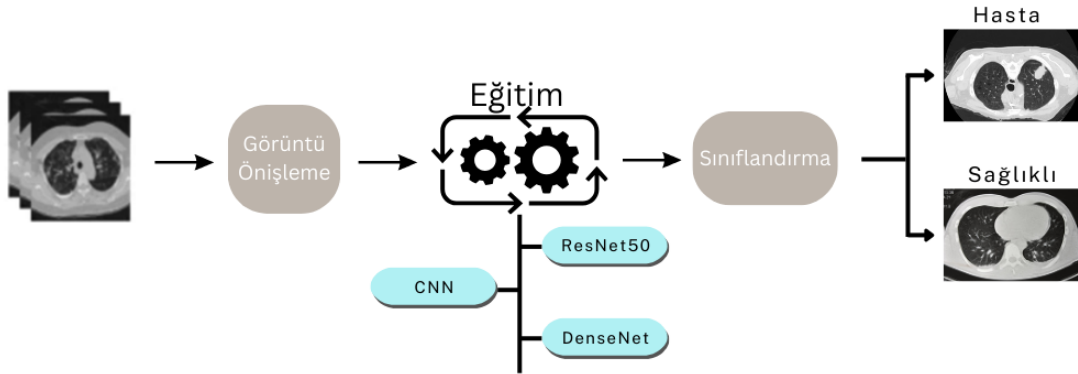
Giriş Katmanı, modelin temelini oluşturan ilk katmandır ve verilerin ağ içindeki diğer katmanlara doğru iletilmesini sağlar. Bu katman, veri akışının başlangıcını belirler ve diğer katmanların üzerinde çalışacağı uygun bir giriş formatı sağlar. Giriş Katmanı, modelin performansını etkileyen önemli bir bileşen olarak görülür ve giriş verilerinin doğru şekilde işlenmesi ve aktarılması için dikkatli bir şekilde tasarlanır. Ardından başlangıç konvolüsyon katmanı ile giriş verileri, konvolüsyon işlemi kullanılarak işlenir. Bu katmanda filtrelerle konvolüsyon yapılır ve aktivasyon fonksiyonu (genellikle ReLU) uygulanır. Bu adım, özellik çıkarımının başlamasını sağlar.

Yoğun bloklara gelindiğinde Yoğun bloklar, ardışık katmanların yoğun bağlantılarla birleştirdiği bloklardır. Her katman, önceki tüm katmanların çıktısına sahip olur. Bu bağlantılar, bilgi akışını kolaylaştırır ve gradient kaybını azaltır. Yoğun bloklar, bir dizi yoğun katmandan oluşur. Her katmanda, giriş ek olarak birer konvolüsyon, toplama işlemi ve aktivasyon fonksiyonu uygulanır. Hemen sonra geçiş bloklarına geçilir, yoğun bloklar arasında yer alır ve boyut küçültme işlemi yapar. Bu katmanlar, özellik haritalarının boyutunu azaltarak derinliği kontrol eder. Tipik olarak, havuzlama (pooling) veya konvolüsyon (convolution) işlemleri ile boyut küçültme sağlanır. Global average pooling ile yoğun blokların ardından, özellik haritaları global ortalama havuzlama işlemine tabi tutulur. Bu işlem, her özellik haritasının ortalamasını alır ve vektörleştirir. Bu sayede, boyut azaltma ve özelliklerin özeti elde edilir. Son olarak tam bağlantılı katmanlarıyla vektörleştirilmiş özellikler, tam bağlantılı (fully connected) katmanlara aktarılır. Bu katmanlar, sınıflandırma işlemi için kullanılır. Genellikle ReLU aktivasyon fonksiyonu ve çıkış sınıf sayısına uygun bir aktivasyon fonksiyonu (genellikle softmax) kullanılır. DenseNet modeli, akciğer kanseri tanısı için kullanıldığında, yoğun bloklar kanserli bölgelerin tespit edilmesi ve özelliklerinin vurgulanması için kullanılır. Geçiş blokları ise boyut küçültme işlemiyle ölçeklenebilirliği artırır. Bu sayede, model akciğer CT görüntülerinde kanserli bölgeleri tespit etmek ve sınıflandırmak için kullanılabilir [19] [20].

3. Önerilen model ve Bilgiler

Akciğer kanseri tanısı için derin öğrenme modelleri son derece etkili ve güçlü araçlar olarak kabul edilmektedir. Bu çalışmada, akciğer kanseri tanısı için üç farklı derin öğrenme modeli kullanılmıştır.

Şekil 3, incelendiğinde 1440 adet eğitim verisi (876 kanserli, 564 sağlıklı), 174 adet test verisi (120 kanserli, 54 sağlıklı) ve 36 adet doğrulama verisi (23 kanserli, 13 sağlıklı) olmak üzere ayrılmıştır. Görüntüler 224x224 boyutuna yeniden boyutlandırılmış ve piksel değerleri 0-1 aralığına ölçeklendirilmiştir. Bu ölçeklendirme işlemi, görüntülerin işlenmesini kolaylaştırmak için yapılmıştır. Veri seti sınırlı sayıda görüntü içerdiği için veri artırma teknikleri kullanılmıştır. Görüntüler yatay olarak çevrilmiş, 0.2 oranında kaydırılmış ve 0.2 oranında yakınlaştırılmıştır. Bu işlemler, veri setinin çeşitliliğini artırarak modelin genelleme yeteneğini geliştirmeyi hedeflemiştir. Şekil 3'te kullandığımız modellerin süreci sunulmuştur.



Şekil 3. Çalışmada önerdiğimiz modelin çalışma yapısı

CNN, DenseNet ve ResNet50 modeli, giriş katmanı, konvolüsyon katmanları, havuzlama katmanları, tam bağlantılı katmanlar gibi temel yapıları içerir. Bu modeller, akciğer tomografisi (CT) görüntülerinden özellik çıkarımı yaparak kanserli bölgeleri tespit etmeyi amaçlar. DenseNet modeli ise yoğun bağlantılı bloklar ve geçiş blokları kullanır. Yoğun bloklar, bilgi akışını artırır ve gradient kaybını azaltırken, geçiş blokları da boyut küçültme işlemiyle ölçeklenebilirliği artırır. Son olarak, ResNet modeli, derin ağlarda ortaya çıkan gradient kaybı sorununu çözmek için rezidüel bağlantıları kullanır. Bu sayede, daha derin ağların eğitimi daha kolay hale gelir. Her bir

modelin performansı değerlendirildiğinde, ResNet modelinin en yüksek başarıya (%96.55) ulaştığı görülmüştür. CNN modeli %89.08, DenseNet modeli ise %88.51 başarı elde etmiştir. Bu sonuçlar, derin öğrenme modellerinin akciğer kanseri tanısında önemli bir rol oynayabileceğini ve erken teşhis için değerli bir araç olabileceğini göstermektedir.

4. Performans metrikleri

Metriklerin sonuçlarını karşılaştırarak algoritmanın performansını değerlendirdik. Metrikler, Python Scikit-learn paketi kullanılarak hesaplandı. Duyarlılık, özgüllük, kesinlik, F1 puanı ve alıcı çalışma karakteristik eğrisinin altındaki alan (AUROC) olmak üzere beş metrik kullanıldı ve duyarlılık, özgüllük, doğruluk ve F1 puanı şu şekilde hesaplandı:

$$Sensitivity = \frac{TP}{TP+FN} \quad (1)$$

$$Specificity = \frac{TN}{TN+FP} \quad (2)$$

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (3)$$

$$F1score = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}} \quad (4)$$

Burada TP, doğru kanserli sayısı; TN, doğru sağlıklı sayısı; FP, yanlış pozitif kanserli sayısı; FN, yanlış sağlıklı sayısı; kesinlik (precision) = $TP / (TP + FP)$ ve hatırlama (recall) = duyarlılık olarak hesaplanmıştır.

Table 1. Elde edilen bulgular

Modeller	Görüntü boyutu	Duyarlılık	Özgüllük	Kesinlik	AUROC	F1 puanı
DenseNet	150 × 150	0.80	0.90	0.80	0.88	0.76
ResNet50	224 × 224	0.84	0.95	0.90	0.96	0.84
CNN	150 × 150	0.71	0.77	0.64	0.89	0.70

En başarılı modelin ResNet50 olduğu (%96.55), CNN modelinin ikinci sırada geldiği (%89.08) ve DenseNet modelinin üçüncü sırada olduğu (%88.51) görülmüştür. Veri setinin büyüklüğüne ve kalitesine göre özellikle F1 puanı ve diğer metrikler etkilenmektedir.

5. Sonuçlar ve tartışma

Bu çalışmanın sonuçları, akciğer kanseri tanısında derin öğrenme modellerinin etkili bir şekilde kullanılabilmesini göstermektedir. Her bir modelin performansı detaylıca incelenmiştir. ResNet modelinin performansı akciğer kanseri tanısında %96.55 doğruluk elde ederek yüksek bir performans sergilemiştir. Ayrıca, modelin hassasiyeti, özgüllüğü ve F1 skoru diğer modellere göre daha yüksek bulunmuştur. ResNet modelinin başarısı, literatürdeki benzer çalışmalarla tutarlıdır ancak en yüksek başarı oranına sahip değildir [21]. CNN modeli ise %89.08 doğruluk oranı ile ikinci sırada yer almıştır. Bu model, daha hızlı eğitim süreleri ve düşük hesaplama gücü gereksinimi gibi avantajlar sunmaktadır. CNN tabanlı modellerin geniş uygulama alanları ve etkileyici sonuçları, önceki literatürde de sıkça vurgulanmıştır [22]. DenseNet modeline gelince, %88.51 doğruluk oranı ile üçüncü sırada yer almıştır. Bu modelin, daha karmaşık yapıları anlamak ve öğrenmek için etkili olabileceği

gözlemlenmiştir ayrıca DenseNet'in, benzer çalışmalarda da kullanılarak başarı elde ettiği literatürde belirtilmiştir [23]. Bu çalışmanın sonuçları, akciğer kanseri tanısı alanında derin öğrenme modellerinin potansiyelini vurgulamakta olup, önceki araştırmalarla uyumludur. Bu sonuçlar, akciğer kanseri tanısı alanında derin öğrenme modellerinin gelecekteki klinik uygulamalar ve araştırmalar için önemli bir temel oluşturabileceğini göstermektedir. Ancak, daha büyük ve çeşitli veri setlerinin kullanıldığı gelecekteki çalışmaların, bu modellerin genelleştirilebilirliği ve klinik uygulamalardaki etkinliği üzerinde daha fazla bilgi sağlayabileceği unutulmamalıdır.

Teşekkür

Araştırma süresince sürekli destek ve geri bildirimleri için Doç. Dr. Durmuş Özdemir'e minnettarım. Ayrıca Kütahya Dumlupınar Üniversitesi Bilgisayar Mühendisliği bölümüne teşekkürlerimi sunarım.

Kaynaklar

- [1] I. Tunalı, R. J. Gillies, ve M. B. Schabath, "Application of radiomics and AI for lung cancer precision medicine," *Cold Spring Harbor Perspectives in Medicine*, vol. 11, no. 8, Jan. 2021, doi: 10.1101/cshperspect.a039537.
- [2] F. Binczyk, W. Prazuch, P. Bozek, ve J. Polanska, "Radiomics and artificial intelligence in lung cancer screening," *Translational Lung Cancer Research*, vol. 10, no. 2, pp. 1186-1199, Feb. 2021, doi: 10.21037/tlcr-20-708.
- [3] P. Batirel, «drhasanbatirel,» 2019. [Online]. Available: <https://www.drhasanbatirel.com/erken-evre-akciger-kanserinde-cerrahi/>.
- [4] Y. Xu vd. "Deep learning predicts lung cancer treatment response from serial medical imaging," *Clinical Cancer Research*, vol. 25, no. 11, pp. 3266-3275, 2019, doi: 10.1158/1078-0432.CCR-18-2495.
- [5] Y. LeCun, Y. Bengio, ve G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015, doi: 10.1038/nature14539.
- [6] P. P. Shinde ve S. Shah, "A review of machine learning and deep learning applications," in *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, IEEE, pp. 1-6, Aug. 2018, doi: 10.1109/ICCUBEA.2018.8697857
- [7] F. Binczyk, W. Prazuch, P. Bozek, ve J. Polanska, "Radiomics and artificial intelligence in lung cancer screening," *Translational Lung Cancer Research*, vol. 10, no. 2, pp. 1186, Feb. 2021, doi: 10.21037/tlcr-20-708.
- [8] J. Chamberlin vd. "Automated detection of lung nodules and coronary artery calcium using artificial intelligence on low-dose CT scans for lung cancer screening: accuracy and prognostic value," *BMC Medicine*, vol. 19, no. 1, pp. 1-14, Mar. 2021, doi: 10.1186/s12916-021-01928-3.
- [9] M. A. CİFCİ, "Derin Öğrenme Metodu ve Ayırık Dalgacık Dönüşümü Kullanarak BT Görüntülerinden Akciğer Kanseri Teşhisi," *Mühendislik Bilimleri ve Araştırmaları Dergisi*, vol. 4, no. 2, pp. 141-154, 2022, doi: 10.46387/bjesr.1114243.
- [10] N. KARACA ve A. KARACI, "DERİN ÖĞRENME VE GÖRÜNTÜ İŞLEME YÖNTEMLERİNİ KULLANARAK GÖĞÜS X-IŞINI GÖRÜNTÜLERİNDEN AKCİĞER BÖLGESİNİ TESPİT ETME," *International Journal of 3D Printing Technologies and Digital Industry*, vol. 6, no. 3, pp. 459-468, 2022, doi: 10.46519/ij3dptdi.1140171.
- [11] L. Liu ve C. Li, "Comparative study of deep learning models on the images of biopsy specimens for diagnosis of lung cancer treatment," *Journal of Radiation Research and Applied Sciences*, vol. 16, no. 2, pp. 100555, Jun. 2023, doi: 10.1016/j.jrras.2023.100555.
- [12] Z. Xu, H. Ren, W. Zhou, ve Z. Liu, "ISANET: Non-small cell lung cancer classification and detection based on CNN and attention mechanism," *Biomedical Signal Processing and Control*, vol. 77, pp. 103773, 2022, doi: 10.1016/j.bspc.2022.103773.
- [13] H. F. Al-Yasriy, «kaggle,» 2020. [Online]. Available: <https://www.kaggle.com/datasets/hamdallak/the-iqothnccd-lung-cancer-dataset>.
- [14] A. Mahimkar, «kaggle,» 2021. [Online]. Available: <https://www.kaggle.com/datasets/adityamahimkar/iqothnccd-lung-cancer-dataset>.
- [15] K. He, X. Zhang, S. Ren, ve J. Sun, "Identity mappings in deep residual networks," in *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14*, ss. 630-645, Springer International Publishing, Sep. 2016, doi: 10.1007/978-3-319-46493-0_38.
- [16] «TensorFlow ResNet50 documentation,» [Online]. Available: https://www.tensorflow.org/api_docs/python/tf/keras/applications/ResNet50.
- [17] W. Alakwaa, M. Nassef, ve A. Badr, "Lung cancer detection and classification with 3D convolutional neural network (3D-CNN)," *International Journal of Advanced Computer Science and Applications*, vol. 8, no. 8, 2017, doi: 10.14569/IJACSA.2017.080853.

- [18] C. J. Lin, S. Y. Jeng, ve M. K. Chen, "Using 2D CNN with Taguchi parametric optimization for lung cancer recognition from CT images," *Applied Sciences*, vol. 10, no. 7, pp. 2591, 2020, doi: 10.3390/app10072591.
- [19] G. Huang, Z. Liu, L. Van Der Maaten, ve K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 4700-4708, 2017, doi: 10.1109/CVPR.2017.243.
- [20] K. Team, «DenseNet,» [Online]. Available: <https://keras.io/api/applications/densenet/>.
- [21] M. Šarić, M. Russo, M. Stella, ve M. Sikora, "CNN-based method for lung cancer detection in whole slide histopathology images," in *2019 4th International Conference on Smart and Sustainable Technologies (SpliTech)*, pp. 1-4, IEEE, Jun. 2019, doi: 10.23919/SpliTech.2019.8783041.
- [22] N. Faruqui, M. A. Yousuf, M. Whaiduzzaman, A. K. M. Azad, A. Barros, ve M. A. Moni, "LungNet: A hybrid deep-CNN model for lung cancer diagnosis using CT and wearable sensor-based medical IoT data," *Computers in Biology and Medicine*, vol. 139, pp. 104961, Dec. 2021, doi: 10.1016/j.combiomed.2021.104961.
- [23] Z. Tao, H. Bingqiang, L. Huiling, Y. Zaoli, ve S. Hongbin, "NSCR-based DenseNet for lung tumor recognition using chest CT image," *BioMed Research International*, vol. 2020, Dec. 2020, doi: 10.1155/2020/6636321.