



## Derin Öğrenme Metodu ve Ayrık Dalgacık Dönüşümü Kullanarak BT Görüntülerinden Akciğer Kanseri Teşhisi

### Discrete Wavelet Transform and Deep Learning Model for Diagnosis of Lung Cancer from CT Images

<sup>1</sup>Mehmet Akif ÇİFÇİ

<sup>1</sup>Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bandırma/Balıkesir, Türkiye

[mcifci@bandirma.edu.tr](mailto:mcifci@bandirma.edu.tr)

[Araştırma Makalesi/Research Article](#)

#### ARTICLE INFO

Article history

Received : 9 May 2022

Accepted : 6 July 2022

Keywords:

Computed Tomography, Deep Learning, VGG, CNN, Lung Cancer

#### ABSTRACT

Recently, researchers have placed the greatest emphasis on using Deep Learning (DL) approaches for early cancer detection. In this study, A Computed Tomography (CT) scan was used to find the position of the tumor and identify the level of cancer in the body. The 6053 lung tomography dataset was processed using the Discrete Wavelet Transform (DWT) technique in conjunction with the DL approach (data source, age group, geographical region, and sensitive data were excluded). The diagnosis and prognosis of a cancer type at an early stage have become necessary in cancer research since they simplify the following clinical care of patients. Targeted was the significance of categorizing cancer patients as benign or malignant. Using computed tomography (CT) images and image preparation procedures, DWT is used to extract features. The gathered data served as input data for processing by the created architectures. Utilizing DWT, ResNet152V2, MobileNet, VGG-16, and Inception v4 have been optimized for early lung cancer detection. Comparative findings revealed that the ResNet152V2 model presented by DWT had 91.89 percent sensitivity, 94.16 percent specificity, and 97.5 percent accuracy.

© 2022 Bandırma Onyediy Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

#### MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 9 Mayıs 2022

Kabul : 6 Temmuz 2022

Anahtar Kelimeler:

Bilgisayarlı Tomografi, Derin Öğrenme, VGG, CNN, Akciğer Kanseri


#### ÖZET

Derin Öğrenmenin (DÖ) teknikleriyle erken kanser tanısı son dönemlerde araştırmacılar arasında en çok üzerinde durulan konu olmuştur. Bu çalışmada Ayrık Dalgacık Dönüşümü (ADD) yaklaşımı ile DÖ tekniği birleştirilerek, 6053 akciğer tomografi veri seti (veri kaynağı, yaş grubu, coğrafi bölge vb. kısa bilgi) üzerinde işlem yapılmıştır. Hastanın kanser olup olmadığı, kanser olduğu takdirde ise bunun iyi huylu (benign) ya da kötü huylu (malign) olduğuna karar verilmesine çalışılmaktadır. Bilgisayarlı Tomografi (BT), görüntülerde öncelikle görüntü işleme aşamalarının yanı sıra ADD ile öznelik çıkarımı yapıp elde edilen veriler DÖ 'ya girdi verisi olarak kullanılır. ResNet152V2, MobileNet, VGG-16 ve Inception v4, BT görüntülerine uygulandıktan sonra akciğer kanseri erken tanısı için ADD kullanılarak optimize edilmiştir. Karşılaştırmalı sonuçlar, ADD ile önerilen ResNet152V2 modelinin %91,89 duyarlılık, %94,16 özgüllük ve %97,52 doğrulukta sonuç verdiği belirlenmiştir.

© 2022 Bandırma Onyediy Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

## 1. GİRİŞ

Akciğer kanseri, dünya çapında en ölümcül kanser türü olarak kabul edilmektedir. Bu nedenle birçok ülke akciğer kanserinin erken teşhisi için stratejiler geliştirmektedir. Düşük doz Bilgisayarlı Tomografi (BT) kullanan yüksek riskli deneklerin üç yıllık tarama sonucunda, ölüm oranlarının önemli ölçüde azaldığı görülmektedir [1]. Birçok tıbbi görüntüleme tekniği; anjiyografi, ultrasonografi, nükleer görüntüleme ve manyetik rezonans görüntüleme (MRI) gibi tıbbi tanı yöntemleriyle elde edilen görüntüleri iyileştiren kontrast maddeleri içermektedir [2]. Elde edilen bu BT görüntüleri uzman radyologlarca işaretlenmiş ve teyit edilmiştir. Nodülleri tespit etmek uzmanlar için bile çok zor olduğundan, analiz edilecek BT taramalarının sayısı ile radyologların üzerindeki yük büyük ölçüde artmaktadır [3,4]. Önleyici/erken tespit tedbirlerinin sayısında beklenen artışla birlikte bilim insanları; doktorların işini hafifletmeye, öznellik faktörünü azaltarak teşhisin kesinliğini artırmaya, analizi hızlandırmaya ve tıbbi maliyetleri düşürmeye yardımcı olan bilgisayarlı çözümler üzerinde çalışmaktadırlar [5, 6]. BT taraması ile erken tanı, akciğer kanseri ölümlerini azaltabilir ancak bu taramaların maliyeti yüksektir. Bunun yanı sıra, düşük ve orta gelirli ülkeler için durum daha risklidir ve hekimlerin fikir ayrılıklarından dolayı vakalar yanlış teşhisle sonuçlanabilmektedir [6]. MRI sonuçları, morfoloji ve güçlendirme kinetiğinin bir kombinasyonu kullanılarak BIRADS sınıflandırmasına benzer bir modelde puanlanmaktadır [7]. Başka bir çalışma ise kurumsal inceleme kurulu onayının ardından Akdeniz Üniversitesi Radyoloji Anabilim Dalı'nda gerçekleştirilmiştir. Toplamda, 15 lezyonu olan 12 hasta, radyolojik sonuçlara göre çalışmaya dâhil edilmiştir [1, 7]. Genel olarak, yeniden oluşturulmuş görüntülerdeki gürültüyü azaltmak için üç boyutlu filtreleme yöntemleri önerilmektedir. Filtreleme; görüntü yumuşatma, keskinleştirme, kenar algılama, iyileştirme gerçekleştiren bir görüntü işleme prosedürüdür [8]. Malignite nodülleri saptamak için belirli özelliklerin tanınması ve ölçülmesi gerekmektedir. Tespit edilen özelliklere ve bunların kombinasyonuna dayanarak kanser olasılığı değerlendirilebilmektedir [9]. Bununla birlikte, nodül varlığı ile pozitif kanser teşhisi kolayca ilişkilendirilemediğinden, bu teşhis deneyimli bir tıp doktoru için bile kolay değildir. Yaygın bilgisayar destekli tanı yaklaşımları; diğerleri arasında hacim, şekil, incelik, sağlamlık, spekülasyon ve küresellik gibi kanser şüphesiyle ilgili daha önce çalışılmış özellikleri kullanmaktadır [10]. Nodülü iyi huylu veya kötü huylu olarak sınıflandırmak için bu özellikleri ve “Destek Vektör Makinesi” gibi Makine Öğrenimi (MÖ) tekniklerini kullanılmaktadır. Birçok çalışmada MÖ ile tahmin edilen akciğer kanserinin, çoğu araştırmada yanlış pozitif oranı yüksek çıkmıştır. Bunun asıl nedeni ilgi alanlarının el ile bulunmasıdır. Son teknolojik sonuçlar, bu yaklaşımları farklı BT taramaları ve farklı tarama parametreleri arasındaki değişkenliğe karşı savunmasız hâle getirir. Bilgisayar Destekli Tanı (BDT) sistemlerinde derin öğrenme kullanmanın avantajı, algoritmanın/ağın eğitim sırasında en göze çarpan özellikleri öğrenerek uçtan uca algılama gerçekleştirebilmesidir. Bu, değişen parametrelerle çeşitli BT taramalarında nodüllerin özelliklerini yakaladığı için ağın varyasyonlara karşı dayanıklı olmasını sağlar. Değişkenlik açısından zengin bir eğitim setine sahip olarak sistem, doğası gereği malignite nodüllerden değişmez özellikleri öğrenebilir ve daha iyi performanslar sağlar. Hiçbir özellik tasarlanmadığı için ağ, sağlanan temel gerçeği kullanarak özellikleri ve kanser arasındaki ilişkiyi kendi kendine öğrenebilir. Ağ eğitildikten sonra, sistem tarafından daha önce hiç görülmemiş yeni vakalarda öğrenmesini genelleştirebilmesi ve malignite nodülleri tespit/teşhis etmesi beklenmektedir. Bu çalışmada, akciğer kanseri tespiti için yeni derin öğrenme tekniklerinin bir incelemesi sunulmaktadır. Önerilen çalışmaların çoğu, derin Evrişimli Sinir Ağlarına (ESA) dayanmaktadır. ESA, eğitim sırasında bir dizi mevcut veriden evrişim parametrelerini öğrenmek için tasarlanmış bir sinir ağı sınıfıdır. Genel olarak evrişim katmanları; filtreler havuzlama katmanları gibi farklı katmanlardan oluşur. Şekil 1’de a. akciğer kanseri nodülü görüntüsü, b. gri tonlamalı yapı, c. ise gri tonlamalı nodül görüntüsü gösterilmektedir.



Şekil 1. a) akciğer kanseri nodülü görüntüsü, b) gri tonlamalı yapı, c) ise gri tonlamalı nodül görüntüsü.

Akciğer kanserinin nedenleri ve belirlenmesi: Akciğer kanserinin tespiti genel olarak zordur çünkü uzmanlar enfekte olmuş bölgeyi ilerleyen aşamaya geçinceye kadar bulamazlar. Kanser saptandıktan sonra hastanın hayatta kalma şansı akciğer kanseri için %54 civarındadır [13]. Çalışmanın katkısı iki yönlüdür. İlk olarak, DÖ yöntemlerinin akciğer kanseri sınıflandırması için küçük veri kümeleri üzerinde mevcut çalışmalardan daha iyi

performans gösterebileceği ilk kez ortaya konmuştur. İkinci olarak, akciğer kanseri sınıflandırması için diğer yöntemlerden daha iyi performans gösteren ve ayrıca performans iyileştirmesinin istatistiksel olarak anlamlı olduğunu gösteren ADD ile ResNet152V2 ağı mimarisi önerilmektedir.

Bu makalenin ikinci bölümünde, benzer araştırmalardan örnekler verilerek bu yayın ile bulguların karşılaştırılmasına yer verilecektir. Bölüm 3'te akciğer kanserinin tespit edilmesinde göz önünde bulundurulmuş yöntemler değerlendirilecektir. Bölüm 4'te, önerilen modelle ilgili uygulama üzerinde durulacaktır. Bu bölümü tartışma ve deneysel bulgular izleyecektir. Bölüm 5'te spesifik sonuçlar ortaya konacaktır. Şekil 1'de akciğer kanseri nodülü görüntüsü gösterilmektedir.

## 2. LİTERATÜR TARAMASI

Literatürde yer alan pek çok araştırma ve metodolojiler çerçevesinde değerlendirildiğinde, kanser hastalığına ilişkin araştırmalarda yaygın olarak karşılaşılan "yanlış sonuçlar" dikkat çekmektedir. Bu nedenle, teknolojik imkânlar sayesinde daha hızlı ve daha doğru sonuçlara ulaşmayı kolaylaştıran ve insan kaynaklı hataların en aza indirgenmesine katkı sağlayan teknolojik yöntemlerin geliştirilmesi oldukça önemlidir. Çalışmanın bu bölümünde, söz konusu önemden hareketle akciğer kanserini tanımlama yöntem ve prosedürleri, DÖ algoritmaları ile ilişkili çeşitli görüşler ve BT görüntülerinin işleme evreleri ele alınmaktadır.

Akciğer nodüllerinin tespit edilebilmesi amacıyla otomatik veya yarı otomatik sistemlerin geliştirilmesine yönelik olarak literatüre katkı sağlayan çok sayıda araştırma yapılmış olmakla birlikte hâlen de yapılmaya devam etmektedir. Bunun yanı sıra, yapılan çalışmalar sayesinde akciğer kanserinin tespit edilmesine yönelik olarak pek çok farklı algoritma geliştirilmiştir. Söz konusu algoritmalarından bazılarına aşağıda değinilmiştir:

DÖ tekniği kullanılarak akciğer nodülünün sınıflandırılabilmesi için BT görüntü verilerini şekil ve doku açısından ele alan bir algoritmayı öneren bazı çalışmalar bulunmaktadır [14]. Önerilen bu algoritmada, nodüllerin heterojenliğini betimlemek için bir "Fourier-Şekil Tanımlayıcı" ile bir "Gri Seviye Eş Oluşum Matrisleri" tabanlı yüzey tanımlayıcıdan ve düğümlerin özelliklerini eğitmek için Evrişimli Sinir Ağlarından (ESA) yararlanılmıştır. Diğer bir çalışma ise geleneksel BDT teknikleri üzerine odaklanmış olan ve manuel olarak tasarlanan sistem, akciğer kanseri erken teşhisi için ideal görünmemektedir [15]. Bazı bilim insanları tarafından akciğer kanserinin tanısı için sınıflandırıcı olarak Destek Vektör Makinelerinden (DVM) yararlanılarak çalışmalarda epidemiyoloji materyal, klinik semptomlar ve miRNA (mikroRNA) biyobelirteçlerin esas alınmasıyla bir DVM modeli geliştirilmiştir [16].

Son yıllarda, örüntü tanıma ve görüntü işleme tekniklerinde hızlı ilerleme kaydedilmiştir. Akciğer kanseri tespit sınıflandırması hakkında yapılan çalışmalar her geçen gün artmaktadır. İnce kesitli BT görüntülerinin doku analizi temelinde çeşitli obstrüktif akciğer hastalıklarını ayırt etmek için literatürde bazı yöntemler bulunmaktadır [12]. Chen vd., [16] BT ile saptanan ve değerlendirilen Soliter Pulmoner Nodüllerin doku özelliklerini sunmuşlardır. Çalışmada toplamda 67 öznelik çıkarılmış ve 300 genetik nesilden sonra yaklaşık 25 öznelik seçilmiştir. Bera vd., [17] sınıflandırıcı olarak Destek Vektör Makinelerinden (DVM) yararlanmışlardır. Çalışmalarında mikroRNA biyobelirteçleri, klinik semptomlar ve epidemiyoloji materyali temel alınarak akciğer kanseri tanısı için bir DVM modeli oluşturmuşlardır. Önerilen model ile %90,1'lik bir doğruluk oranına ulaşmış oldukları anlaşılmaktadır. Sharma vd., [18] lineer bir yöntem üzerine odaklanmışlardır. Düzenleme parametresinin geleneksel çapraz doğrulama algoritmasının hesaplandığı "doğrusal ayırıcı analiz" tekniğinden yararlanmışlardır. Hastalığın gereksinim tahmini için tıbbi verileri araştırmaya uygun özellik kümesine ihtiyaç duyulmuştur. Optimum özellik seçimini elde etmek için birçok evrimsel algoritma uygulanmıştır. Kuruvilla vd. [19] tarafından BT görüntüleri için Yapay Sinir Ağları (YSA) temelli bir kanser sınıflandırması geliştirilmiştir. Sınıflandırma modeli için kullanılan istatistik kısmi olarak başarı sağlamıştır. Aleesa vd., [20] akciğer kanserini teşhisi için Taksonomik Farklılık İndeksleri ve DVM tekniğinden yararlanmaktadırlar. Elde ettikleri başarı oranı %98,11 olarak açıklanmıştır. Aggarwal, Furquan ve Kalra [21] normal akciğer anatomi yapısını sınıflandıran bir model önermişlerdir. BT görüntü özelliklerini geometrik, istatistiksel ve gri seviye karakteristikleri kullanarak çıkarmışlardır. Sonuç olarak doğruluk başarı oranı %84 ve duyarlılık ise %97,14 olarak ölçülmüştür. Song vd. [22], DNN'nin dalgacık dönüşümü ve temel bileşen analizi ile birleştirildiği beyin tümörü sınıflandırması için DNN sınıflandırıcısı ile çalışmıştır. Buna göre benzer pikseller küme olarak oluşturulmakta ve etkilenen bölgede oluşan kümeden yararlanılmaktadır.

Sonuç olarak %84,6 doğruluk, %82,5 duyarlılık ve %86,7 özgüllük bildirmişlerdir. Hosny, vd., [33] derin öğrenme tekniği olan Otomatik Kodlayıcı kullanarak %75,01 doğruluk oranına sahip bir yöntem sunmuştur. Dey vd., [34] ise derin inanç ağını kullanarak %73,40 hassasiyet oranına ve %82,20'lik özel orana ulaşmıştır. Li vd., [35] LIDC veri tabanında akciğer kanserini çok ölçekli, iki katmanlı ESA üzerine çalışmıştır. Elde edilen doğruluk oranı %86,84 olarak kaydedilmiştir.

Çalışmanın bu bölümünde değinilen araştırmalar, öne çıkan bir model, genomik ve klinik gibi karışık bilgi kombinasyonlarını içermektedir. Değinilen bu araştırmalarda görülen tipik bir eksiklik olarak modellerin önceden oluşturulmasına yönelik bir dış onay mekanizması ya da testin olmayışı söylenebilir. Dolayısıyla, söz konusu eksiklikten hareketle ve DÖ stratejilerinin kullanılmasıyla hastalığın zayıflaması, tekrarlaması ve hastanın hayatta kalması hususlarında yapılan tahminlerin kesinlik yüzdelerinin artırılabilmesi mümkündür. Aynı şekilde, son zamanlarda DÖ stratejileri esas alınarak gerçekleştirilen tümör araştırmalarında %15-20 oranları arasında bir artış görülmüştür. Son zamanlarda akciğer kanseri teşhisinde BDT yerini daha gelişmiş DÖ tekniklerine bırakmıştır

### 3. VERİ VE YÖNTEM


#### 3.1. Yöntem ve Teknikler

İnsan vücudunda akciğer kanseri gibi insanın akciğer sistemine saldırabilecek birçok hastalık vardır. Bu hastalıkları teşhis etmek amacıyla, kritik ve önemli bir rol oynadıkları için BT veya X-ray gibi görüntüleme cihazlarına ihtiyaç duyulmaktadır [36]. Bilgisayar teknolojileri, DÖ tabanlı sistemler gibi hastalık tanılarına yardımcı olacak araçlar sunmaktadır. Bu çalışmada, akciğer kanseri erken tanısı için çok sınıflı bir derin öğrenme modeli geliştirilmiştir [37]. Çalışmadaki amaç, dört farklı model kullanarak göğüs hastalıkları sınıflandırması için bir derin öğrenme modeli önermektir [38]. Bu çalışma, akciğer kanseri hastalıklarının tespiti için tek bir DÖ modelini tanıtmaya yönelik ilk yaklaşım olarak kabul edilebilir. Geliştirilen mimari, Şekil 2'de gösterilmektedir. Şekilden açıkça görüldüğü gibi, model üç ana aşamadan oluşmaktadır: veri ön işleme, özellik çıkarımı için DÖ modelleri ve sınıflandırma. Önerilen model, girdi olarak BT'den alınan göğüs görüntülerini kullanmaktadır. Nihai çıktı, girdi görüntüsünün 3 sınıftan birine sınıflandırılmasıdır: normal, pnömoni ve akciğer kanseri.

Mimaride ilk aşama, yeniden boyutlandırma, görüntü büyütme ve veri gibi görüntü ön işlemeyi gerçekleştirmek ve rastgele iki gruba ayırmaktır: Veri setinin yaklaşık %70'i eğitim için, geri kalan %30 doğrulama için kullanılmıştır. Veri seti görüntüleri, görüntülerin çeşitliliğini sağlamak için rastgele iki bölüme (eğitim ve doğrulama) ayrılmaktadır. Görüntünün piksel değerini [0,1] aralığına yeniden ölçeklendirmek için görüntüyü bir dizi piksele dönüştürdükten sonra veri normalleştirme de kullanılmaktadır. İkinci ve üçüncü aşamalar ise farklı türde DÖ yaklaşımları kullanılarak sırasıyla özellik çıkarma ve görüntü sınıflandırma olarak sıralanabilir. Önerilen model için giriş görüntüleri  $224 \times 224 \times 3$  olarak yeniden boyutlandırılmıştır. Sistem için verimli ve güvenilir doğruluk üretmek amacıyla eğitim görüntülerinin sayısını artırmak için görüntü büyütme yöntemleri kullanılmaktadır.

Bu mimari, ReLU etkinleştirme işlevselliğini kullanan bir evrişim katmanı içermektedir. Evrişimden sonra maksimum havuzlama gerçekleştirilmektedir. Softmax katmanı, bu mimaride tamamen bağlı birkaç sinir ağı katmanıyla sınıflandırılmak için kullanılmaktadır.

Boyut indirgemenin amacı sınıflandırma yönteminde hesaplama süresini ve maliyetini düşürmektir. Boyut indirgeme için Doğrusal Ayırım Analizinden faydalanılmaktadır [39]. Sınıflandırma için kullanılan maksimum özellikler, hesaplama süresini ve depolama belleğini artırmaktadır. Sınıflandırma aşamasında BT akciğer görüntüleri, özelliklere göre normal, iyi huylu ve kötü huylu olarak sınıflandırılmaktadır. Genel olarak, sınıflandırma sorununun eğitim ve test olmak üzere iki aşaması bulunmaktadır; sınıflandırıcı, eğitim verilerinin seçilen özellikleri ile eğitilmektedir. Diğer yandan test aşamasında, sınıflandırma prosedürünün sonuçları, görüntülerin akciğer kanseri bölgelerini mi yoksa kanser dışı bölgeleri mi içerdiğini göstermektedir. Mevcut çalışma mimarisi Şekil 2'de görülmektedir.



Şekil 2. Derin öğrenme mimarisi.


DÖ mimarisi içerisinde dalgacık katsayıları ESA'ya girdi olarak kullanılmıştır [40]. Görüntülerde şüphelenilen lezyonlar için İlgi Alanı (region of interest) sağlanmamıştır. Yani önerilen ağ için girdiler, tüm görüntünün dalgacık katsayılarıdır. Tekrar eğitimden sonra BT görüntüleri; önerilen ağ kullanılarak normal, iyi, kötü diye üç kategoriye ayrılmıştır.



### Görüntü Veri Seti

Bu çalışmada kullanılan veri kümeleri, herhangi bir MÖ veya derin öğrenme yaklaşımının önemli bir parçasıdır. Uzmanlarca onaylanmış veriler; algoritmaların geliştirilmesine, eğitilmesine ve iyileştirilmesine yardımcı olur. Tıbbi görüntüleme uygulamalarında, mevcut veriler, herhangi bir geliştirmede faydalı olması için uzmanlar tarafından doğrulanmalı ve etiketlenmelidir. Bu bölüm, akciğer kanseri tespiti için Derin Öğrenme ile ilgili son çalışmalarda kullanılan veri kümelerini sunmaktadır.


Akciğer Görüntü Veri Tabanı Konsorsiyumu (LIDC-IDRI): Veri seti yedi akademik merkez ve sekiz tıbbi görüntüleme merkezinin iş birliğiyle toplanan 1018 vakadan oluşmaktadır. Her vaka, BT taramasının açıklamalarını içeren bir XML dosyası içerir. Bu açıklamalar dört deneyimli uzman tarafından 2 aşamalı bir süreçte gerçekleştirilir. İlk aşamada, her radyolog bulguları bağımsız olarak üç kategoriye ayırır. Daha sonra ikinci aşamada her radyolog kendi sınıflandırmasını ve diğer radyologlar tarafından anonim olarak yapılan sınıflandırmaları gözden geçirir. Böylece her nodül, dört radyolog tarafından bağımsız olarak gözden geçirilir. Veri seti, toplam 244.527 görüntü ile 1010 hastadan alınan 1018 BT taramasından oluşmaktadır. Bu veri seti ile tanı iki düzeyde yapılabilir. Hasta düzeyinde tanı ve nodül düzeyinde tanı. BT tarama DICOM görüntüleri, genişliğin 65 ile 764 dilim arasında değiştiği 512 x 512 x 3 genişlik çözünürlüğüne sahiptir. Bu veri seti için ortalama dilim genişliği sayısı 240'tır.



Şekil 3. Farklı lezyon örnekleri. a) üst sıra kötü huylu, b) alt sıra iyi huylu lezyonlar.


BT görüntülerindeki zayıflıkları, kör bölgeleri düzeltmek için Gauss filtreleri kullanılmaktadır. Yani BT görüntülerinin tüm gürültüsünü azaltmak amacıyla her BT görüntüsünde Gauss bulanıklığı uygulanır (bkz. Şekil 5). Bu işlemi yaptıktan sonra, BT görüntüleri aynı özelliğe sahip olmaktadır. Şekil 5'te BT görüntülerine Gauss bulanıklığı uygulaması gösterilmektedir.

Negatif görüntü: BT görüntüleri gri skala değerindeki görüntülerdir. 3 boyutlu görüntüler makine gücü düşük olduğundan gri tonlamalı görüntüye çevrilmektedir. Böylece her pikselin 8 bit (0- 255) aralığına inmektedir. Herhangi bir zamanda gri görüntülerde görüntülenebilecek maksimum renk sayısı 256 aralığındadır. Akciğer BT görüntüleri karakteristik olarak net değildir. Bu nedenle görüntü işlemede daha iyi performans elde etmek için gri tonlamalı görüntüyü negatif görüntüye çevirmek gerekir. Şekil 4'te BT görüntüsünün negatifi gösterilmektedir.



Şekil 4. BT görüntüsünün negatifi.

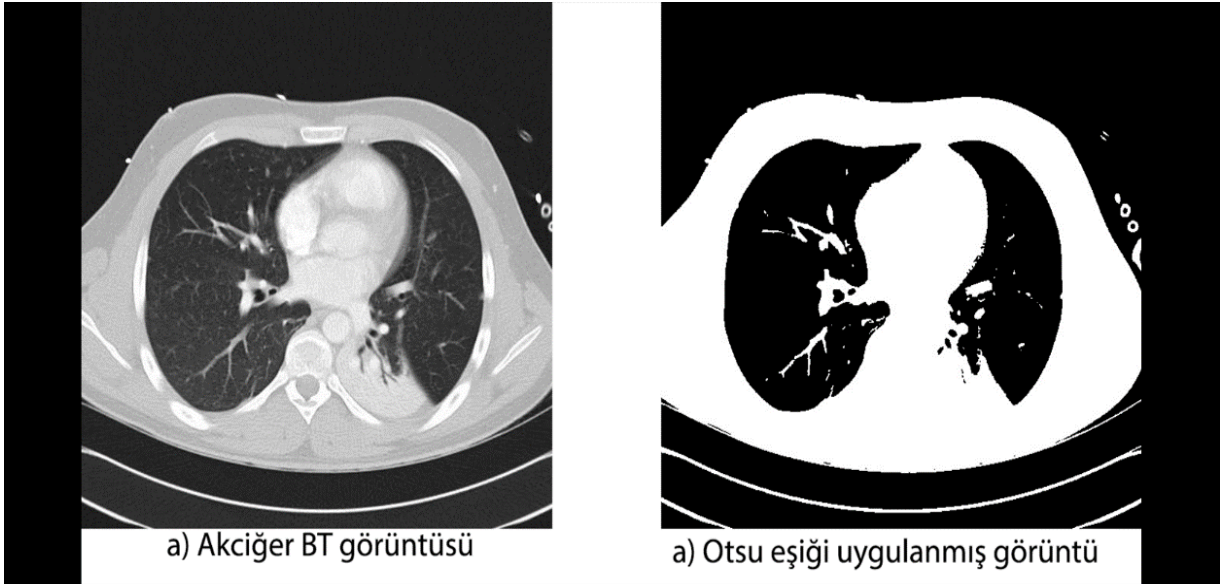
Bulanıklaştırma (Blurring) filtresi; BT görüntülerini etkilediğinde, görüntüdeki küçük bileşenlerin görselleştirilmesini ve görünürliğini azaltmaktadır. Bu nedenle, görüntünün bozulmamış şeklini bozuk sürümünden geri kazanmak ve görüntüye daha keskin bir görünüm vermek için Gauss bulanıklığı analizi uygulamak gerekmektedir [42].



Şekil 5. BT görüntülerine Gauss bulanıklığı uygulaması.

$$a_{\omega}^2(t) = q_1(t)a_1^2(t) + q_2(t)a_2^2(t) \quad (1)$$

Denklemden (1) görüldüğü üzere  $P(i)$ , her piksel değerinin olasılığıdır. Eşik, görüntüleri bir görüntünün daha basit bir formuna ve akciğer nodülünün algılanmasına dönüştürür. Şekil 6'da BT görüntüsüne uygulanan Otsu eşiği gösterilmektedir.




Şekil 6. a) akciğer BT görüntüsü, b) Otsu eşiği uygulanmış BT görüntüsü.

Görüntünün Bölünmesi: İnsan akciğeri simetrikdir. Başlangıç noktasının merkezi seçilir ve bu nokta yardımıyla sağ ve sol akciğer görüntüsü bölünür. Görüntü o noktada kırılır ve sol ve sağ görüntüyü iki belirli görüntüye dönüştürür. Daha iyi sonuç elde etmek için akciğer BT görüntüleri ikiye bölünmüştür. Şekil 7'de BT görüntüsünün bölünmesi gösterilmektedir.




Şekil 7. Akciğer BT Görüntüsünün bölünmesi.

Görüntünün Çevrilmesi: BT görüntüleri bölündükten sonra görüntü daha iyi anlamak adına sağ ve sol olarak çevrilmektedir. Burada x sütun sayısını ve y satır sayısını temsil eder. Şekil 8’de BT görüntüsünün çevrilmesi gösterilmektedir.



Şekil 8. Görüntünün çevrilmesi.

Histogram Özellikleri: Histogram özelliklerinde görüntü, piksel cinsinden gösterilmektedir. Histogram, görüntüdeki her güç değerindeki piksel sayısını göstermektedir. Görüntü histogramının güç değerlerine dönüştürülmesi yaklaşık olarak önceden belirlenmiş bir histogramla eşleştirilerek yapılmaktadır. Şekil 9’da Histogram ve önışlem uygulanmış görüntü verilmektedir.



Şekil 9. Histogram ve önışlem uygulanmış görüntüler.


Giriş görüntüsünden, toplam gri seviye aralığı histogram yöntemiyle değerlendirilmektedir. Burada, 0 ile 255 arasında değişen 256 gri seviye bulunmaktadır.

### 3.2. Dalgacık Dönüşümü ile Öznitelik Çıkarma

BT görüntülerine sadece Dalgacık Dönüşümü (DD) uygulandığı zaman, genelde boyut düşürme (down sampling) gerçekleşir. Sonuç olarak çözünürlük seviyesi 1 artmakta ve dört bileşenin her birinin örnek boyutu 1/4 olmaktadır. Bu sorunla başa çıkmak için bu çalışmada Ayrık Dalgacık Dönüşümü (ADD) kullanılmaktadır. DD’nin aksine ADD, boyut düşürme işlemlerini içermez ve dolayısıyla düşük frekans katsayıları ve yüksek frekans katsayıları her seviyede başlangıç sinyali ile aynı uzunluğa sahip olmaktadır. Geleneksel bir ADD’nin temel algoritması; görüntünün her noktasında dönüşüm uygulamaması, detaylı katsayıları saklaması ve yaklaşım katsayılarını bir sonraki seviye için kullanması şeklinde açıklanabilir. Katsayıların dizin boyutları seviyeden seviyeye azalmaz. Bu dönüşümün amacı, durağan olmayan sinyali küçük, durağan zaman dilimlerine bölmek ve bu zaman dilimlerindeki frekansları belirlemek için bahsedilen aralıkların ADD analizini yapmaktır. ADD dönüşümü, zaman-frekans eksenlerine bölünerek kullanılmıştır. Daha sonra güç spektral yoğunluğu alınır ve bu yöntem ses verilerinin enerjisinin frekansa göre nasıl dağıldığını açıklar. Son olarak dalgacık dönüşümü uygulanmaktadır. Bu teknik, görüntülerin merkezini bulmak için kullanılır. Burada normalize edilmiş çapraz korelasyon uygulanır. Denklemi şöyledir:

$$e = \frac{1}{p \cdot q} \sum_{i=1}^p \sum_{j=1}^q |x(i, j)| \quad (2)$$

Burada kaynak görüntü 'i' iken şablon görüntü 'j'dir. Denklem (2) burada 'p', 'q', şablon görüntüsünün sayısını/satırını ve sütun sayısını temsil eder. Şablon eşleşmesinin en iyi eşleşmesi seçilir ve bu eşleme en iyi eşleştiği noktayı verir. Bu seçilen nokta ilgi kaynağıdır. Her görüntü bu noktayı alır ve piksel değeri yüksek olan kenarlık bu pikselin düşük değerine çevrilmektedir. Şekil 10'da öznelik çıkarımı uygulanmış görüntü gösterilmektedir.



Şekil 10. Öznelik çıkarımı.

Öznelik çıkarma tekniğinde asıl amaç, görüntüyü kompakt ve benzersiz tek değer veya matris vektörü biçimine sokmaktır. Öznelik çıkarma, görüntü işlemede, sınıflandırma için hangi görüntünün kullanılabileceğine bağlı olarak boyutsal küçülmeyi hesaplar. Giriş verilerinin, temsili özelliklerinin azaltılmasını içerir. Öznelik çıkarma işlemi ADD yöntemi ile gerçekleştirilmektedir.

## 4. ÖNERİLEN DERİN ÖĞRENME MİMARİSİ

### 4.1. Performans parametreleri

Performans farklı parametreler ile ölçülmektedir. Her derin sinir ağı için doğruluk, özgüllük ve hassaslık hesaplanır. Bu bir ikili sınıflandırma görevidir. Böylelikle sonuç dört şekilde oluşturulabilir. Bunlar:

Doğru Pozitif (DP): BT görüntüsünde akciğer nodülü bulunur ve nodül ile BT görüntüsü olarak sınıflandırılır [43]

Yanlış Pozitif (YP): BT görüntüsünde akciğer nodülü yoktur ve nodül ile BT görüntüsü olarak sınıflandırılır [44].

Doğru Negatif (DN): BT görüntüsünde akciğer nodülü yoktur ve nodül olmadan BT görüntüsü olarak sınıflandırılır [45].

Yanlış Negatif (YN): BT görüntüsünde akciğer nodülü bulunur ve nodülsüz BT görüntüsü olarak sınıflandırılır [46].

### 4.2. Uygulanan Modeller

ESA, BT görüntülerine bir dizi öğrenilebilir filtre uygular. ESA'da evrişim katmanı, filtre boyutu, uygulanan filtre sayısı ve iş parçacıkları ile tanımlanabilir. Evrişimli bir katmanın giriş ve çıkışı, BT görüntülerinden başlayarak üç boyutlu bir yapıya (genişlik, yükseklik, kanal sayısı) sahiptir. Evrişim katmanlarını derlerken, çıktının genişliği ve yüksekliği en yüksek havuzlama işlemi kullanılarak ve derinlik ise az veya çok filtreler kullanılarak elde edilebilir.

Bilgisayar konfigürasyonu düşük olduğundan MobileNet V3'ten yararlanılmıştır. MacOS 10.15.3; işlemci, 2.2 GHz, Intel Core i7; ekran kartı, Intel HD Graphics 4000 ile programlama olarak Python dilinden yararlanılmıştır.

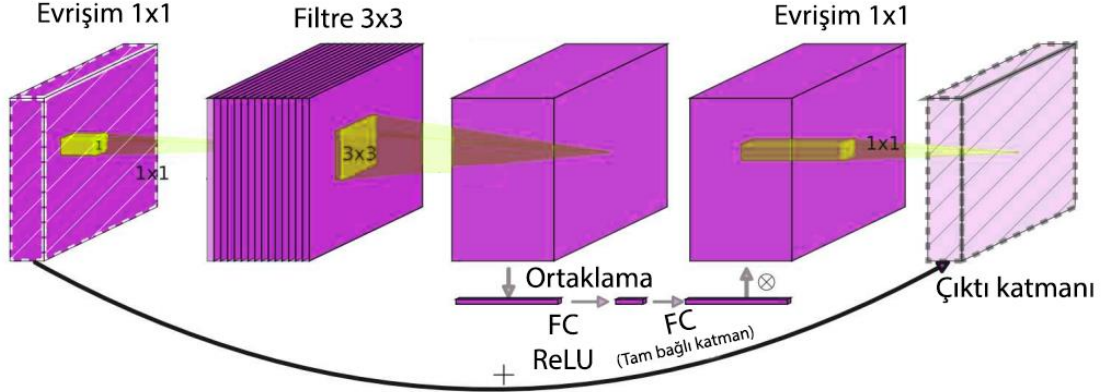
### 4.3. MobileNet V3

MobileNet etkili bir ESA ağıdır. Düşük konfigürasyonlu cihazlar için çok uygun olan MobileNet V3, platforma duyarlı ağ mimarisi araması ve NetAdapt algoritması [19] aracılığıyla tasarlanmıştır. Bölütme ve sınıflandırma görevleri için en gelişmiş sonuçları elde etmektedir. Bu modelin, farklı kaynak platformlarını karşılamak için MobileNet V3 geliştirilmiştir. MobileNet V3, ImageNet veri setinde %20 daha az gecikme ile MobileNet V2'den %3,2 daha başarılı sonuçlar sağlamaktadır [20].



MobileNet V3, MobileNet V2'den ters çevrilmiş darboğaz (bottleneck) Squeeze and Excitation bloklarının bir kombinasyonunu kullanmaktadır [21]. Bu darboğazlar  $1 \times 1$  genişleme evrişim katmanı,  $3 \times 3$  derinlemesine evrişim katmanı ve ardından  $1 \times 1$  projeksiyon katmanından oluşmaktadır.

H-swish doğrusal olmama işlevi, gömülü ortamlarda hesaplama açısından maliyetli olan swish'in sert bir karşılığı olarak kullanılmaktadır. Buna ek olarak, MobileNet V2'de bulunan önceki ters çevrilmiş kalıntı yapısındaki maliyetli katmanlar bu sürümde kullanılmak üzere yeniden tasarlanmıştır. Son aşamadan  $1 \times 1$  genişleme katmanı, havuzlama katmanının ötesine kaydırılmıştır. Bu,  $1 \times 1$  katmanının gecikme ve hesaplama süresini  $7 \times 7$  azaltmak yerine  $1 \times 1$  özellik haritası üzerinde çalışmasına izin vermektedir. Varsayılan olarak 32 filtre olan diğer MobileNet modellerine kıyasla, ilk aşamadaki filtre sayısı  $3 \times 3$  evrişim için 16'ya düşürülmüştür.



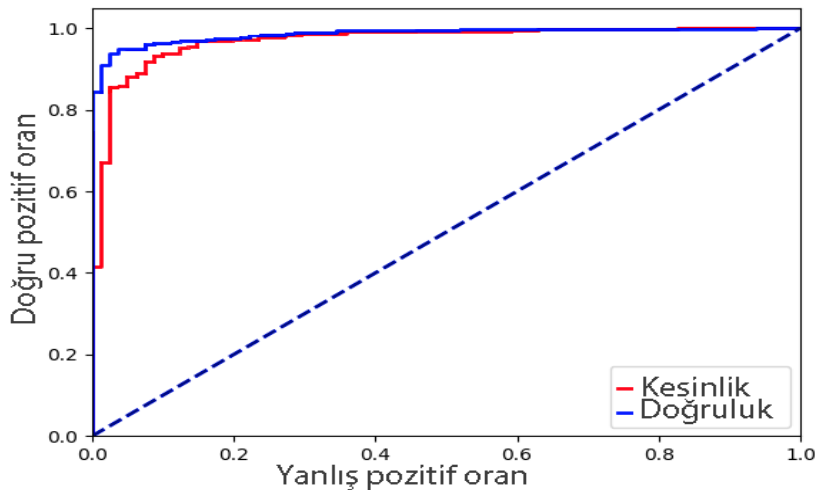
Şekil 11. MobileNet v3 uygulama şeması.

MobileNet V3, NetAdapt algoritması ile tamamlanan ve daha sonra yeni mimari avantajlar ile geliştirilen donanıma duyarlı ağ mimarisi araması kombinasyonu içermektedir

Mobil cihazlar için çok uygun olan hafif bir model olan MobileNet V3, platform farkında ağ mimarisi araması ve NetAdapt algoritması aracılığıyla tasarlanmıştır. Segmentasyon ve sınıflandırma görevleri için çok iyi sonuçlar elde etmektedir. MobileNet v3, ImageNet veri setinde %20 daha az gecikme ile MobileNet modelinin diğer versiyonlarından daha iyi sonuçlar vermektedir. MobileNet V3, eğitilmiş 16 ImageNet sınıflandırma modeli kontrol noktası oluşturulur. Giriş BT görüntüsü 6053 boyutlu bir vektör olarak alınır. Her görüntü, darboğaz (bottleneck) değeri için hesaplanır. Bu darboğazlar;  $1 \times 1$  genişleme evrişim katmanı,  $3 \times 3$  derinlemesine evrişim katmanı ve ardından  $1 \times 1$  projeksiyon katmanından oluşmaktadır. MobileNet V3'ün tam yapısı Şekil 11'de gösterilmektedir. Şekilde görüldüğü üzere son aşamadan  $1 \times 1$  genişleme katmanı, havuz katmanının ötesine kaydırılmıştır.

$$y_i^{(k)} = \alpha^{(k)} x_i^{(k)} + \beta^{(k)} \quad (3)$$

Denklemden (3) görüldüğü üzere hesaplama maliyetini azaltmak için, her  $k$  kanalı için  $\alpha$ , ağırlıkları paylaşılacak ve tekli evrişim işlemlerine yardımcı olacaktır. Ağırlık niceleme için kullanılan ölçek bütünsel olarak ağırlık dağılımının aralığına bağlıdır. TensorFlow uygulamasında, ölçek hesaplamak için minimum ve maksimum ağırlık değerleri tüm kanallardan aynı oranlarda alınmaktadır. Şekil 12'de MobileNet V3 modelinin doğruluk ve kesinlik seviyeleri gösterilmektedir.



Şekil 12. Model eğitiminde doğruluk seviyesi.


### 4.3.1. Inception-v4

Bilgisayar görüşünde, Inception etkili bir derin sinir ağı mimarisidir [7]. Başlangıç algoritması, yerleşik veya mobil bilgi işlem aygıtları için çok daha iyi performans göstermektedir. Derin ESA'da doğruluğu artırmanın yolu, her bir düzeydeki ortalama boyutlarda çalışma düzeyi ve birim sayısını artırmaktır. Başlangıçta  $1 \times 1$ ,  $3 \times 3$ ,  $5 \times 5$  evrişim filtresi ve  $3 \times 3$  maksimum ortaklama filtresi kullanılır. Evrişim katmanında maksimum ortaklama işlemi çok etkilidir. Başlangıç, optimum seyrek mimari ve diğer mimariden  $3 \sim 10 \times$  daha hızlıdır.

### 4.3.2. VGG-16

Bu modelde ise veri eğitimi için VGG-16 kullanılmıştır. VGG Net 16 mimarisini kullanan eğitilmiş model Şekil 13'te gösterilmektedir. Evrişim 1 giriş katmanı,  $224 \times 224$  kırmızı yeşil mavi (RGB) standart bir görüntü boyutudur. Filtrelerin  $3 \times 3$  boyutunda tam bir küçük alım alanıyla uygulandığı en doğru sonuçları bulmak için giriş 16 katmanın tümüne verilir [27]. Bazı düzenlerde, giriş istasyonlarının düz modifikasyonu olarak görülen  $1 \times 1$  evrişim filtreleri de kullanılır. Evrişim çizgisi 1 piksel olarak değiştirilmiştir. Evrişim katmanı girişinin uzamsal dolgusu, uzamsal çözünürlüğün evrişimden sonra depolanacağı şekildedir. Doldurma (padding),  $3 \times 3$  evrişim katmanları için 1 pikseldir. Koleksiyon, evrişim katmanlarından birini takip eden maksimum havuzlama lensleriyle gerçekleştirilmektedir. Maksimum havuzlama,  $2 \times 2$  piksel evrişim katmanıyla yapılır.

Tam bağlı 3 katmanın tümü, çeşitli yapılarla farklı derinliklere sahip evrişim katmanı ile devam edecektir. İlk iki katman 4096 kanala sahiptir ve üçüncü katman, kategori başına bir kanal oluşturarak 1000 kanalda ILSVRC sınıflandırmasına bağlanır. Softmax katmanı, tutma katmanıdır ve tamamen entegre katmanların konfigürasyonu, tüm ağırlarda benzerdir. Tüm gizli katmanlar, RELU (doğrultulmuş lineer birim/rectified linear unit) tarafından temsil edilen doğrusal olmayan erişime uyarlanır.




Şekil 13. Uygulanan VGG-16 Mimarisi [36].

Şekil 13'te görüldüğü gibi VGG-16 basit bir ağ modelidir, önceki modellerden en önemli farkı ikili veya üçlü evrişim katmanlarını birleştirme katmanlarının takip etmesidir. Girdiler tam bağlı katmanda  $7 \times 7 \times 512 = 4096$  nöronlu bir öznitelik vektörüne dönüştürülür. 1000 sınıfı esnek softmax performansı, tüm bağlantı katmanı çıkışında hesaplanır. Bu modelde yaklaşık 138 milyon parametrenin hesabı yapılmaktadır.

### 4.3.3. ResNet152V2 Mimarisi

ResNet152V2, Şekil 6'da gösterildiği gibi özellik çıkarma modeli olarak kullanılmaktadır. Model, geleneksel bir ESA'dan daha hızlı kabul edilebilir doğruluk elde etmeye yardımcı olabilecek, önceden eğitilmiş bir model olduğu için başlangıç ağırlıklarına sahiptir. Model mimarisi, ResNet152V2 modelini takip eden bir yeniden şekillendirme katmanı, düzleştirilmiş bir katman, 128 nöronlu yoğun bir katman, bir bırakma katmanı ve son olarak, görüntüyü karşılık gelen katmana ince ayar uygulamak için Softmax etkinleştirme işlevine sahip yoğun bir katmandan oluşmaktadır. Mimari Şekil 14'te detaylandırılmıştır. ResNet152V2'nin tüm parametreleri, iki tür parametreden oluşan 71.177.348'dir: Sırasıyla 71.033.604 ve 143.744 olan eğitilebilir parametreler ile eğitilemez parametreler olarak kabul edilmektedir.

Şekil 14'te görüldüğü gibi ilk adımda ResNet152V2, önce eğitilmiş ağın birinci kısmı dışa aktarılmıştır. İkinci adımda elde edilen öznitelik kısmı yeni tasarlanmış bir ikinci yarı kısmına (eğitilmemiş FC katmanları) bağlanır; önerilen ağın temel mimarisi bu şekilde oluşmaktadır [11]. Öğrenme ünitelerinin rastgele deaktif hâle gelmesi için tam bağlantılı katmanlarda %50 çıkarma uygulanmıştır. Böylece Softmax ile her eğitim yinelemesinin ardından ağırlıklar değişmektedir, bu da genelleme performansının artmasıyla sonuçlanır. Buna ek olarak, aşırı uymaya engel olmak ve genelleme performansını iyileştirmek için L2-norm düzenlemesi benimsenmiştir. Üçüncü adımda, 3 bileşen görüntüsünün dalgacık katsayıları yeni inşa edilmiş ağın üç girdi kanalına verilir; bunun ardından yeniden eğitim için geri yayılım gerçekleşir [48].



Şekil 14. ResNet152V2 önerilen model mimarisi [40].

#### 4.3.4. Tartışma ve Elde Edilen Sonuçlar

Bu çalışmada 4 klasik ESA modeli ve ADD yöntemi kullanılarak akciğer kanserinin erken teşhisi yapılmıştır. Önerilen bu metodoloji, büyük bir BT akciğer görüntüsü veri setinde uygulanmaktadır ve sistemlerin performansı, evrensel metriklerle karşılaştırma için alt bölümde sunulmaktadır. Tablo 1, önerilen yöntem için akciğer kanseri görüntü sınıflandırma oranlarının doğruluk düzeyini göstermektedir. Bu testte, ADD tabanlı ResNet152V2 modeli, BT görüntüsü için mevcut sınıflandırıcılar ile karşılaştırılmış ve önerilen algoritmanın daha iyi sınıflandırma sonucu sağladığı tespit edilmiştir. Tablo 1'de gösterildiği gibi, pozitif prediktif (öngörü) değer, testin pozitif değerinin o toplumda gerçekten hasta olma olasılığıdır. Tabloda Gerçek Pozitifliğin pozitif test toplamına oranıdır. Negatif prediktif değer, tarama testi negatif olan deneklerin aslında hastalığa sahip olmama olasılığı diğer modellere göre daha iyi sonuçlar göstermektedir. Bu, önerilen çalışmanın ADD ve ESA sınıflandırmasının yeterliliğini artırmak ve BT akciğer kanseri veri kümelerini gruplamak için doku ve renk özelliklerini dikkate almanın sonucudur. Dalgacık katsayıları, normal vakalar da dâhil olmak üzere akciğer BT görüntülerinden kanseri sınıflandırmak için girdi olarak kullanılmış ve elde edilen sonuçlar, önerilen yöntemin etkinliğini ve verimliliğini doğrulamak için birinci adımla karşılaştırılmıştır. Toplam doğruluk, diğer iki yöntemle elde edilenden daha yüksektir. Bu, önerilen yöntemin üstünlüğünü kanıtlamaktadır. Tablo 1, gerçekleştirilen deneylerin sonuçlarını göstermektedir.

Tablo 1. Yapılan deneyler sonucunda elde edilen model performansı.

BT veriseti	Nodül Tespiti	Model	Doğruluk	Hassaslık	Özgüllük	Pozitif tahmin değerler	Negatif tahmin değerler
		ResNet152V2 modeli	97,52	91,89	94,16	96,45	95,34
		MobileNet V3 modeli	96,45	93,85	90,40	89,50	60,20
		VGG-16 modeli	97,52	88,45	84,56	89,65	56,45
		Inception v4 modeli	94,11	90,45	72,22	73,12	83,34

#### 4.3.5. Mevcut çalışmalar ile karşılaştırma

Akciğer kanserinin erken teşhisine yönelik literatürde elde edilen çalışmanın sonuçları Tablo 2'de karşılaştırmalı olarak verilmiştir. Tablo 2'de görüldüğü gibi önerilen modelde, ADD yardımıyla elde edilen özelliklerin sınıflandırılması sonucunda daha iyi bir duyarlılık, özgüllük ve doğruluğa ulaşılmıştır.

**Tablo 2.** Önerilen modelin mevcut çalışmalar ile karşılaştırılması.

Mevcut çalışmalar	Doğruluk	Hassaslık	Özgüllük
Suren vd., [49]	92,24	93,65	91,23
Taruna vd., [50]	97,12	97,14	96,33
Hiram Madero vd., [51]	89,52	90,90	88,15
Hiram Madero vd., [52]	95,66	96,15	97,32
Hong Shao vd., [53]	90,35	89,47	90,52
Silva vd., [54]	94,78	94,66	95,14
Costa vd., [55]	91,81	93,42	91,21
Önerilen model	97.52	91.89	94.16

## 5. GENEL SONUÇ VE ÖNERİLER

Akciğer kanserinin otonom olarak tanımlanması ve tedavi edilmesi için son yıllarda birkaç Derin Öğrenme temelli araştırma yapılmıştır. Bu çalışmalar, yüksek doğruluk oranlarına sahip otomatik tanımlama ve yönetim sistemleri kullanarak halk sağlığı kurumları ve hastaneler üzerindeki yükü hafifletmektedir. Önceki sınıflandırma algoritmalarıyla karşılaştırıldığında, bu çalışmada oluşturulan ayrık dalgacık dönüşümüne sahip ResNet152V2 modeli, akciğer BT görüntüleri örneğinde daha iyi performans göstermiştir. Otomatik akciğer kanseri sınıflandırma yöntemi, manuel etiketleme süresini kısaltabilir ve insan hatalarını ortadan kaldırabilir. Önerilen teknik, deneysel verilere göre akciğer resimlerini %97,52 doğruluk, %91,89 duyarlılık ve %94,16 özgüllük ile kategorize etmede etkilidir. Teknik, akciğer kanseri için otomatik teşhis hedefini %97'nin üzerinde doğrulukla gerçekleştirmiştir.

Sonraki araştırmalarda sınıflandırma doğruluğunu artırmak için alternatif dalgacık tabanlı fonksiyonların sınıflandırma üzerindeki etkisinin araştırılması ve yeni bir mimari oluşturulması amaçlanmaktadır. Önerilen yaklaşımın, çeşitli hastalık sınıflandırmalarında ve görüntüleme yöntemlerinde kullanımı için yeterince güvenilir olması beklenmektedir.

### Yazar Katkıları

Yazar 1 kavram ve fikri ortaya atmıştır. Ayrıca denetleme ve danışmanlık görevi de Yazar 1 tarafından yürütmüştür. Yazar 1 literatür taraması ve formatı düzenlemiştir. Yazar 1 analiz ve metotları geliştirmiştir. Bütün süreçler Yazar 1 tarafından gerçekleştirilmiştir.

### Çıkar Çatışması

Yazarlar arasında çıkar çatışması bulunmamaktadır.

## KAYNAKÇA

- [1] M. Atasever, "Sağlık İşletmelerinde Tıbbi Laboratuvar Hizmet Alımları Yönetimi", 2017.
- [2] Y. A. Üncü, "Segmentation of Major Vessel in X-Ray Angiographic Images with Image Processing Technique", Eskişehir Technical University Journal of Science and Technology A-Applied Sciences and Engineering, vol. 22, no. 2, pp. 209-214, 2021.
- [3] H. Balsak, "Yoğun bakım hemşirelerine verilen radyasyon güvenliği programının değerlendirilmesi", 2019.
- [4] D. Moitra, and R. K. Mandal, "Automated AJCC staging of non-small cell lung cancer (NSCLC) using deep convolutional neural network (CNN) and recurrent neural network (RNN)", Health information science and systems, vol. 7, no. 1, pp. 1-12, 2019.
- [5] K. Munir et al., "Cancer diagnosis using deep learning: a bibliographic review", Cancers, vol. 11, no. 9, pp. 1235, 2019.
- [6] G. Sevim et al., "Image reconstruction for diffuse optical tomography using bi-conjugate gradient and transpose-free quasi minimal residual algorithms and comparison of them", International Journal of Imaging Systems and Technology, vol. 31, no. 4, pp. 1894-1905, 2021.
- [7] Y. A. Üncü et al., "Differentiation of tumoral and non-tumoral breast lesions using back reflection diffuse optical tomography: A pilot clinical study", International Journal of Imaging Systems and Technology, vol. 31, no. 4, pp. 2023-2031, 2021.
- [8] Y. A. Üncü, G. Sevim, and M. Canpolat, "Approaches to preclinical studies with heterogeneous breast phantom using reconstruction and three-dimensional image processing algorithms for diffuse optical imaging", International Journal of Imaging Systems and Technology, vol. 32, no. 1, pp. 343-353, 2022.
- [9] E. Warner et al., "Comparison of breast magnetic resonance imaging, mammography, and ultrasound for surveillance of women at high risk for hereditary breast cancer", Journal of Clinical Oncology, vol. 19, no. 15, pp. 3524-3531, 2001.
- [10] H. Park, and C. Monahan, "Genetic deep learning for lung cancer screening", arXiv preprint arXiv:1907.11849, 2019.
- [11] L. Ebner et al., "Lung nodule detection by microdose CT versus chest radiography (standard and dual-energy subtracted)", American Journal of Roentgenology, vol. 204, no. 4 pp. 727-735, 2015.



- [12] D. Ardila, A. P. Kiraly, S. Bharadwaj, B. Choi, J. J. Reicher, L. Peng, and S. Shetty, "End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography", *Nature medicine*, vol. 25, no. 6, pp. 954-961, 2019.
- [13] S. S. Singh et al., "Genotype driven therapy for non-small cell lung cancer: Resistance, pan inhibitors and immunotherapy", *Current Medicinal Chemistry*, vol. 27 no. 32, pp. 5274-5316, 2020.
- [14] F. Silva et al., "Pre-training autoencoder for lung nodule malignancy assessment using ct images", *Applied Sciences*, vol. 10, no. 21, p. 7837, 2020.
- [15] S. Lakshmananprabu et al., "Optimal deep learning model for classification of lung cancer on CT images", *Future Generation Computer Systems*, vol. 92, pp. 374-382, 2019.
- [16] S. Chen et al., "Texture analysis of baseline multiphasic hepatic computed tomography images for the prognosis of single hepatocellular carcinoma after hepatectomy: a retrospective pilot study", *European journal of radiology*, vol. 90, pp. 198-204, 2017.
- [17] H. Bera et al., "Carboxymethyl fenugreek galactomannan-g-poly (N-isopropylacrylamide-co-N, N'-methylene-bis-acrylamide)-clay based pH/temperature-responsive nanocomposites as drug-carriers", *Materials Science and Engineering: C*, vol. 110, p. 110628, 2020.
- [18] A. Sharma, and R. Rani, "An optimized framework for cancer classification using deep learning and genetic algorithm", *Journal of medical imaging and health informatics*, vol. 7, no. 8, pp. 1851-1856, 2017.
- [19] J. Kuruvilla, and K. Gunavathi, "Lung cancer classification using neural networks for CT images", *Computer methods and programs in biomedicine*, vol. 113, no. 1, pp. 202-209, 2014.
- [20] A. Aleesa et al., "Review of intrusion detection systems based on deep learning techniques: coherent taxonomy, challenges, motivations, recommendations, substantial analysis and future directions", *Neural Computing and Applications*, vol. 32, no. 14, pp. 9827-9858, 2020.
- [21] T. Aggarwal, A. Furqan, and K. Kalra, "Feature extraction and LDA based classification of lung nodules in chest CT scan images", In 2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI), IEEE, 2015.
- [22] Q, Song, et al., "Using deep learning for classification of lung nodules on computed tomography images", *Journal of healthcare engineering*, 2017.
- [23] P. M. Shakeel, M. A. Burhanuddin, and M. I. Desa, "Lung cancer detection from CT image using improved profuse clustering and deep learning instantaneously trained neural networks", *Measurement*, vol. 145, pp. 702-712, 2019.
- [24] R. Roslidar et al., "A review on recent progress in thermal imaging and deep learning approaches for breast cancer detection", *IEEE Access*, vol. 8, pp. 116176-116194, 2020.
- [25] Y. Zhong et al., "Deep learning for prediction of N2 metastasis and survival for clinical stage I non-small cell lung cancer", *Radiology*, vol. 302, no. 1), pp. 200-211, 2022
- [26] D. Riquelme, and M. A. Akhloufi, "Deep learning for lung cancer nodules detection and classification in CT scans", *AI*, vol. 1, no. 1, pp. 28-67, 2020.
- [27] S. Bhatia, Y. Sinha, and L. Goel, "Lung cancer detection: a deep learning approach", In *Soft Computing for Problem Solving*, Springer, pp. 699-705, 2019.
- [28] T. Pandiangan, I. Bali, and A. Silalahi, "Early lung cancer detection using artificial neural network", *Atom Indonesia*, vol. 45, no. 1, pp. 9-15, 2019.
- [29] F. Ciompi, F., "Towards automatic pulmonary nodule management in lung cancer screening with deep learning", *Scientific reports*, vol. 7, no. 1, pp. 1-11, 2017.
- [30] A. Halder, D. Dey, and A. K. Sadhu, "Lung nodule detection from feature engineering to deep learning in thoracic CT images: a comprehensive review", *Journal of Digital Imaging*, vol. 33, no. 3, pp. 655-677, 2020.
- [31] Z. Li et al., "Deep learning methods for lung cancer segmentation in whole-slide histopathology images—the acdc@ lunghp challenge 2019", *IEEE Journal of Biomedical and Health Informatics*, vol. 25, no. 2, pp. 429-440, 2020.
- [32] Q, Wang et al., "Prediction of gene mutation in lung cancer based on deep learning and histomorphology analysis", *Sheng wu yi xue gong cheng xue za zhi= Journal of biomedical engineering= Shengwu yixue gongchengxue zazhi*, vol. 37, no. 1, pp. 10-18, 2020.
- [33] A. Hosny et al., "Deep learning for lung cancer prognostication: a retrospective multi-cohort radiomics study", *PLoS medicine*, vol. 15, no. 11, p. e1002711, 2018.
- [34] R. Dey, Z. Lu, and Y. Hong, "Diagnostic classification of lung nodules using 3D neural networks", In 2018 IEEE 15th international symposium on biomedical imaging (ISBI), 2018.
- [35] K. Li et al., "Towards cross-modality medical image segmentation with online mutual knowledge distillation", In *Proceedings of the AAAI conference on artificial intelligence*, 2020.
- [36] S. Li, et al., "Predicting lung nodule malignancies by combining deep convolutional neural network and handcrafted features", *Physics in Medicine and Biology*, vol. 64, no. 17, p. 175012, 2019.
- [37] H. Polat, and H. Danaei Mehr, "Classification of pulmonary CT images by using hybrid 3D-deep convolutional neural network architecture", *Applied Sciences*, vol. 9, no. 5, p. 940, 2019.
- [38] N. Coudray, P. S. Ocampo, T. Sakellaropoulos, N. Narula, M. Snuderl, D. Fenyö, and A. Tsirigos, "Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning", *Nature medicine*, vol. 24, no. 10, pp. 1559-1567, 2018.

- [39] A. M. Mesleh, "Lung Cancer Detection Using Multi-Layer Neural Networks with Independent Component Analysis: A Comparative Study of Training Algorithms", *Jordan Journal of Biological Sciences*, vol. 10, no. 4, 2017.
- [40] A. Asuntha, and A. Srinivasan, "Deep learning for lung Cancer detection and classification", *Multimedia Tools and Applications*, vol. 79, no. 11, pp. 7731-7762, 2020.
- [41] D. Aberle et al., "National Lung Screening Trial Research T. Reduced lung-cancer mortality with low-dose computed tomographic screening" *N Engl J Med*, vol. 365, no. 5, pp. 395-409, 2011.
- [42] A. M. Santos et al., "Automatic detection of small lung nodules in 3D CT data using Gaussian mixture models", *Tsallis entropy and SVM. Engineering applications of artificial intelligence*, vol. 36, pp. 27-39, 2014.
- [43] F. Sahito, P. Zhiwen, J. Ahmed, and R. A. Memon, "Wavelet-integrated deep networks for single image super-resolution", *Electron.*, vol. 8, no. 5, pp. 1-16, 2019.
- [44] K. H. B. T. Sarode, and S. Natu, "Performance Comparison Of Hybrid Wavelet Transforms Formed Using Dct, Walsh, Haar and DKT in Watermarking", *Int. J. Comput. Sci. Inf. Technol.*, vol. 7, no. 1, pp. 41-58, 2015.
- [45] R. V. M. Da Nóbrega, S. A. Peixoto, S. P. P. Da Silva, and P. P. R. Filho, "Lung Nodule Classification via Deep Transfer Learning in CT Lung Images", In *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, 2018.
- [46] J. W. Lee, H. W. Lee, J. H. Lee, I. T. Kang, and G. K. Lee, "A study on lung nodule detection using neural networks", In *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, vol. 2, pp. 1150-1153, 1999.
- [47] S. Srinivas and R. V. Babu, "Learning the Architecture of Deep Neural Networks", *arXiv Prepr.*, no. Section 2, pp. 1-13, 2015.
- [48] J. Günther, P. M. Pilarski, G. Helfrich, H. Shen, and K. Diepold, "Intelligent laser welding through representation, prediction, and control learning: An architecture with deep neural networks and reinforcement learning", *Mechatronics*, vol. 34, pp. 1-11, 2016.
- [49] S. Makaju, A. A. Prasad, S. Elchouemi, "Lung Cancer detection using CTscan images", *Elsevier, Procedia Computer Science*, vol. 125, pp. 107-114, 2018.
- [50] T. Aggarwal, A. Furqan, K. Kalra, "Feature extraction and LDA based classification of lung nodules in chest CT scan images", *IEEE, International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pp. 1189-1193, 2015.
- [51] H. M. Orozco, O. O. V. Villegas, V. G. C. Sánchez, H. de Jesús Ochoa Domínguez, M. de Jesús Nandayapa Alfaro, "Automated system for lung nodules classification based on wavelet feature descriptor and support vector machine", *Biomed Eng* vol. 14, no. 9, pp. 1-20, 2015.
- [52] H. M. Orozco, O. O. V. Villegas, L. O. Maynez, V. G. C. Sanchez, H. de Jesus Ochoa Dominguez, "Lung Nodule CLASSIFICATION in Frequency Domain Using Support Vector Machine", *IEEE, In international conference on information science, signal processing and their application*, 2012.
- [53] H. Shao, L. Cao, Y. Liu, "A detection approach for solitary pulmonary nodules based on CT images", *IEEE, 2nd international conference on computer science and network technology*, 2012.
- [54] G. L. F. Da Silva, O. P. da Silva Neto, A. C. Silva, A. C. de Paiva Marcelo Gattass, "Lung nodules diagnosis based on evolutionary convolutional neural network", *Springer, Multimed Tools Appl*, vol. 76, no. 18, pp. 19039-19055, 2017.
- [55] R. W. de Sousa Costa, G. L. F. da Silva, A. O. de Carvalho Filho, A. C. Silva, A. C. de Paiva Marcelo Gattass, "Classification of malignant and benign lung nodules using taxonomic diversity index and phylogenetic distance", *Springer, Med Biol Eng Comput*, vol. 56, no. 11, pp. 2125-2136, 2018.