Mühendislik Mimarlık Fakültesi Dergisi
Journal of The Faculty of Engineering and Architecture of Gazi University
Elektronik / Online ISSN : 1304 - 4915
Basılı / Printed ISSN : 1300 - 1884

Lung cancer subtype classification from chest ct scans using vision transformers

Sinan Toklu[1], Abdullah Talha Kabakuş[2]*
[1]Department of Computer Engineering, Faculty of Technology, Gazi University, 06560, Ankara, Türkiye
[2]Department of Computer Engineering, Faculty of Engineering, Duzce University, 81620, Düzce, Türkiye

Highlights:

- Comprehensive preprocessing pipeline for class imbalance mitigation before stratified splitting
- Use of Vision Transformer (ViT-Large) to capture long-range dependencies in medical images
- State-of-the-art performance with 98.5% accuracy and 0.985 macro F1-score in four-class lung cancer subtype classification

Keywords:

- Lung cancer classification
- Deep learning
- Chest CT scans
- Vision transformer
- Medical image analysis

Article Info:

Research Article
Received: 26.10.2025
Accepted: 14.02.2026

DOI:

10.17341/gazimmfd.1811234

Correspondence:

Author: Abdullah Talha Kabakuş
e-mail: talhakabakus@duzce.edu.
phone: +90 380 542 1036 / 4749

Graphical/Tabular Abstract

The study proposes a transformer-based pipeline for lung cancer subtype classification from chest CT images. The workflow consists of (*i*) data acquisition (Chest CT-Scan Images Dataset), (*ii*) preprocessing (label normalization, resizing to 224×224, class balancing via oversampling, RandAugment), (*iii*) model training using a Vision Transformer (ViT-Large), and (iv) evaluation using accuracy and macro F1-score. The model captures long-range spatial dependencies and achieves high classification performance across four classes (adenocarcinoma, squamous cell carcinoma, large cell carcinoma, normal).

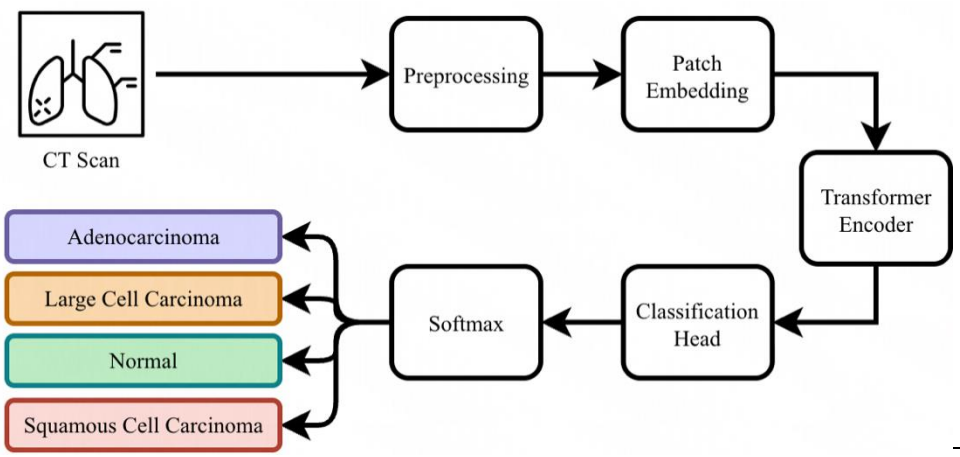


Figure A. Overview of the proposed lung cancer classification model

Purpose: This study aims to develop a robust and scalable artificial intelligence framework for the automatic classification of lung cancer subtypes from chest CT images.

Theory and Methods: A transformer-based deep learning approach is adopted, leveraging the ViT-Large architecture pre-trained on large-scale image datasets. A comprehensive preprocessing pipeline is applied, including label normalization, image resizing, class balancing through oversampling prior to stratified splitting, and data augmentation using RandAugment. The model is fine-tuned end-to-end using PyTorch and HuggingFace Transformers. Optimization techniques such as AdamW, cosine learning rate scheduling, mixed precision training, label smoothing, and early stopping are employed. Hyperparameters are optimized using an automated search strategy to enhance model stability and performance.

Results: The proposed model demonstrates strong classification performance, achieving an accuracy of 0.985 and a macro-averaged F1-score of 0.980 on the test set. Class-wise evaluation shows consistently high precision and recall across all categories, with near-perfect performance in the normal class. The confusion matrix indicates minimal misclassification, with only a few errors among visually similar cancer subtypes. Comparative analysis reveals that the proposed ViT-based approach outperforms several state-of-the-art convolutional neural network (CNN) architectures under the same experimental conditions.

Conclusion: The findings confirm that Vision Transformer-based models are highly effective for lung cancer subtype classification from chest CT images. The integration of a robust preprocessing pipeline with transformer architectures significantly enhances classification accuracy and generalization. This approach has strong potential for clinical decision support systems, enabling early and reliable diagnosis. Future work may focus on multi-modal integration, larger and more diverse datasets, and explainability techniques to further improve clinical applicability.

Mühendislik Mimarlık Fakültesi Dergisi
Journal of The Faculty of Engineering and Architecture of Gazi University
Elektronik / Online ISSN : 1304 - 4915
Basılı / Printed ISSN : 1300 - 1884

Görsel dönüştürücüler kullanılarak göğüs BT görüntülerinden akciğer kanseri alt tipi sınıflandırması

Sinan Toklu[1], Abdullah Talha Kabakuş[2]*
[1]Gazi Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, 06560, Ankara, Türkiye
[2]Düzce Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 81620, Düzce, Türkiye

Ö N E Ç I K A N L A R

- Sınıf dengesizliğini gidermek için geliştirilmiş, tabakalı bölümlemeden önce uygulanan kapsamlı bir ön işlem hattı
- Tıbbi görüntülerdeki uzun menzilli bağımlılıkları yakalamak için Görsel Dönüştürücü modelinin kullanılması
- Akciğer kanseri alt tipi sınıflandırmasında %98,5 doğruluk ve 0,985 makro F1-skoru ile en iyi sonuçların elde edilmesi

Makale Bilgileri
Araştırma Makalesi
Geliş: 26.10.2025
Kabul: 14.02.2026

DOI:
10.17341/gazimmfd.1811234

Anahtar Kelimeler:
Akciğer kanseri sınıflandırması, derin öğrenme, göğüs BT görüntüleri, görsel dönüştürücüler, tıbbi görüntü analizi

ÖZ

Akciğer kanseri, dünya genelinde önemli bir sağlık sorunu olmaya devam etmekte ve kanser kaynaklı ölümlerin başlıca nedenlerinden biri olarak öne çıkmaktadır; bu durum hasta sağkalım oranlarını artırmak için doğru ve erken tanı yaklaşımlarının geliştirilmesi gerekliliğini açıkça ortaya koymaktadır. Bu çalışmada göğüs BT (bilgisayarlı tomografi) görüntülerinden akciğer kanseri alt tiplerinin otomatik sınıflandırılması amacıyla dönüştürücü (transformer) tabanlı bir derin öğrenme modeli önerilmektedir. Model, dört tanısal kategori (adenokarsinom, skuamöz hücreli karsinom, büyük hücreli karsinom ve normal dokular) içeren halka açık Chest CT-Scan Images Dataset veriseti üzerinde eğitilip değerlendirilmiştir. Etiket normalizasyonu, görüntü yeniden boyutlandırma, veri dengelenmesi ve RandAugment yöntemiyle veri artırımı adımlarını içeren kapsamlı bir ön işleme hattı uygulanmıştır. Tıbbi görüntülerde uzun menzilli uzamsal bağımlılıkları yakalamadaki üstün kapasitesi nedeniyle Görsel Dönüştürücü (ViT-Large) mimarisi tercih edilmiştir. Deneysel sonuçlar modelin test kümesi üzerinde %98,5 doğruluk ve 0,980 makro ortalamalı F1-skoru elde ettiğini göstermektedir. Bu çalışmanın yeniliği klinik olarak anlamlı bir veri kümesinde ViT-Large omurgasıyla entegre edilen güçlü bir ön işleme stratejisinin ve jeton düzeyinde eğitim kararlılığını artırıcı yöntemlerin bir araya getirilmesiyle güncel en iyi (state-of-the-art) performansın elde edilmesinde yatmaktadır.

Lung cancer subtype classification from chest ct scans using vision transformers

H I G H L I G H T S

- Comprehensive preprocessing pipeline for class imbalance mitigation before stratified splitting
- Use of Vision Transformer to capture long-range dependencies in medical images
- State-of-the-art performance with 98.5% accuracy and 0.985 macro F1-score in lung cancer subtype classification

Article Info
Research Article
Received: 26.10.2025
Accepted: 14.02.2026

DOI:
10.17341/gazimmfd.1811234

Keywords:
Lung cancer classification, deep learning, chest CT scans, vision transformer, medical image analysis

ABSTRACT

Lung cancer is a major global health concern and remains a leading cause of cancer-related mortality, highlighting the urgent need for accurate and early diagnostic approaches to improve patient survival rates. In this study, we propose a transformer-based deep learning model for the automatic classification of lung cancer subtypes from chest CT images. The model is trained and evaluated on the publicly available Chest CT-Scan Images Dataset, which includes four diagnostic categories: adenocarcinoma, squamous cell carcinoma, large cell carcinoma, and normal tissues. A comprehensive preprocessing pipeline was employed, including label normalization, image resizing, data balancing, and augmentation using RandAugment. We adopted the Vision Transformer (ViT-Large) architecture due to its superior capacity for capturing long-range spatial dependencies in medical imaging. Experimental results demonstrate significant performance gains, with the model achieving 98.5% accuracy and a macro-averaged F1-score of 0.980 on the test set. The novelty of this study lies in the integration of a robust preprocessing strategy with a ViT-Large backbone and token-level training stability enhancements to achieve state-of-the-art performance on a clinically relevant dataset.

*Sorumlu Yazar / Yazarlar / *Corresponding Author / Authors: stoklu@gazi.edu.tr, *talhakabakus@duzce.edu.tr / Tel: +90 380 542 1036 / 4749

1. Giriş (Introduction)

Akciğer kanseri dünya genelinde en yaygın ve en ölümcül kanser türlerinden biri olmaya devam etmektedir. Her yıl yaklaşık 2 milyon yeni vaka ve 1,8 milyon ölümle sonuçlanmakta; bu da onu kanser kaynaklı ölümlerin birincil nedeni hâline getirmekte ve küresel sağlık üzerindeki derin etkisini ortaya koymaktadır [1, 2]. Birçok ülkede akciğer kanseri kanserden ölümlerin başlıca nedeni konumundadır ve yapılan projeksiyonlar 2025 ve sonrasında da bu konumunu koruyacağını öngörmektedir [3, 4]. Görülme sıklığı cinsiyete ve coğrafyaya göre farklılık göstermekte olup tarihsel olarak erkeklerde daha yüksek oranlara rastlanmakla birlikte bazı bölgelerde değişen sigara içme alışkanlıkları nedeniyle bu fark azalmaktadır [5, 6]. Akciğer kanserleri arasında (i) Küçük Hücreli Dışı Akciğer Kanseri (NSCLC) alt tiplerinden organların iç yüzeyini döşeyen salgı bezlerinin epitel dokusundan kaynaklanan bir kanser türü olan *Adenokarsinom,* (ii) *Büyük Hücreli Karsinom* ve (iii) genellikle derinin üst tabakalarında veya akciğer gibi organların iç astarındaki yassı hücrelerde gelişen bir kanser türü olan *Skuamöz Hücreli Karsinom* kesin tanı ve uygun tedavi yönetimi gerektiren başlıca klinik kategorileri oluşturmaktadır [7].

Yapay Zekâ (YZ) özellikle derin öğrenme yaklaşımları, tıbbi görüntü yorumlama alanında dönüm noktası niteliğinde bir gelişme olmuştur. YZ tabanlı yöntemler, vücudun iç yapısını kesitler halinde görüntülemek için X ışınlarını kullanan radyolojik inceleme yöntemi Bilgisayarlı Tomografi (BT) göğüs görüntülerinden akciğer kanserinin tespiti ve sınıflandırılmasında doğruluğu ve otomasyonu önemli ölçüde artırmıştır [8]. BT, vücudun kesitsel (dilim) görüntülerini oluşturmak için çoklu açılardan alınan X-ışını ölçümlerini kullanan bir tıbbi görüntüleme tekniğidir. Bu kesitler yüksek uzamsal çözünürlükte iç organların, kemiklerin ve yumuşak dokuların ayrıntılı 3B (3 Boyutlu) temsillerine dönüştürülebilir. Göğüs görüntülemede BT, akciğerlerin ve çevresindeki yapıların kapsamlı anatomik ayrıntılarını sunarak akciğer hastalıkların tanı ve takibinde kritik bir araç olarak kullanılmaktadır. BT, kemik, damar ve yumuşak doku anormalliklerinin tespitine olanak tanıyarak kapsamlı tanısal değerlendirmeyi destekler [9]. Yapay zekâdaki bu ilerlemeler, erken tanı, gelişmiş tedavi planlaması ve daha iyi tıbbi öngörü (prognostik) değerlendirmesine katkı sağlamaktadır. Son dönemlerde geliştirilen Görsel Dönüştürücü (Vision Transformer, ViT) mimarisi, dikkat (attention) mekanizmalarını kullanarak tıbbi görüntülerdeki küresel bağlamsal ilişkileri modelleyebilmekte ve özellikle heterojen görüntü verilerinde sınıflandırma performansını artırma potansiyeli taşımaktadır [8]. Klinik iş akışlarına YZ'nin entegrasyonu tanısal değişkenliği azaltarak radyologlara destek olmakta, görüntü yorumlamayı hızlandırmakta ve sınıf dengesizliği ile görüntü heterojenliği gibi zorlukların üstesinden gelmeye yardımcı olmaktadır.

Bu çalışmanın amacı BT görüntülerinden akciğer kanseri alt tiplerinin çok sınıflı sınıflandırılması için sağlam ve ölçeklenebilir bir yapay zekâ çerçevesi geliştirmektir. Özellikle dengeli bir NSCLC alt tipleri ve normal örneklerden oluşan veri kümesi üzerinde ince ayar (fine-tuning) yapılan ViT modellerinin temsil gücü araştırılmaktadır. Hedef, yüksek tanısal doğruluk ve heterojen klinik görüntülere genellenebilirlik elde ederek erken ve kesin akciğer kanseri tespitini kolaylaştırmaktır. Sınıf dengesizliği sorununu yenilikçi veri ön işleme ve artırma yöntemleriyle ele alarak bu çalışma otomatik akciğer patolojisi sınıflandırma alanına katkı sağlamayı amaçlamaktadır. Çalışmanın başlıca katkıları şu şekilde özetlenebilir:

- Klinik açıdan anlamlı dört akciğer durumunun - (i) *Adenokarsinom,* (ii) *Büyük Hücreli Karsinom,* (iii) *Skuamöz Hücreli Karsinom* ve (iv) *Normal* akciğer dokusu - sınıflandırması amacıyla *ImageNet* üzerinde önceden eğitilmiş bir Görsel Dönüştürücü (ViT-Large, Patch-16) modelinin geliştirilmesi ve ince ayarının gerçekleştirilmesi.
- Modelin sağlamlığını artırmak ve sınıf dengesizliğini gidermek amacıyla etiket normalizasyonu, tabakalı veri bölünmesinden önce dengeli örnekleme ve RandAugment tabanlı veri artırımı adımlarını içeren kapsamlı bir ön işleme hattının geliştirilmesi.
- Bağımsız bir test kümesi üzerinde %98,5 doğruluk ve 0,985 makro ortalamalı F1-skoru elde edilerek dönüştürücü tabanlı modellerin akciğer kanseri alt tiplerini yüksek doğrulukla ayırt etme potansiyelinin gösterilmesi.
- Modelin karar sınırları ve olası yanlış sınıflandırmalarına ilişkin içgörüler sunmak amacıyla karmaşıklık matrisi (confusion matrix) üzerinden görselleştirme ve sınıf bazlı performans metriklerinin ayrıntılı analizinin yapılması.
- Yüksek çözünürlüklü BT görüntü veri kümelerine uygun, verimli ve kararlı ince ayar süreci sağlamak için karma hassasiyetli (mixed precision) eğitim ve güncel optimizasyon tekniklerinin kullanılması.
- Önerilen modelin tıbbi görüntü analizindeki etkinliğinin güncel Evrişimsel Sinir Ağı (Convolutional Neural Network, CNN) mimarileri ile kapsamlı bir karşılaştırmalı analize tabi tutularak kanıtlanması.

Bu katkılar bir arada değerlendirildiğinde dönüştürücü tabanlı derin öğrenme yaklaşımlarının göğüs BT görüntülerinden akciğer kanseri tanısını geliştirme potansiyelini ortaya koymakta; klinik karar destek süreçlerini güçlendirerek doğru ve erken tarama yoluyla hasta sonuçlarını iyileştirme olasılığını göstermektedir. Makalenin geri kalanı şu şekilde yapılandırılmıştır: 2. Bölüm ilgili çalışmaları incelemektedir. 3. Bölüm çalışmada kullanılan materyal ve yöntemleri sunmaktadır. 4. Bölüm deneysel sonuçları ve bulguların tartışmasını içermektedir. Son olarak 5. Bölüm makaleyi sonuçlandırmakta ve gelecekteki araştırmalara yönelik önerilerde bulunmaktadır.

2. İlgili Çalışmalar (Related Works)

Akciğer kanseri sınıflandırması için *SE-ResNeXt-50* isimli bir CNN modeli uygulanmıştır. Önerilen yöntem, dinamik dört parçalı histogram eşitleme (QDHE) tabanlı bir ön işleme aşamasıyla birlikte veri artırımı, hiperparametre optimizasyonu ve gelişmiş öznitelik çıkarımı adımlarını içermektedir. Ayrıca, etkili bir ön işleme hattı tasarlamak amacıyla birden fazla görüntü artırma tekniği kullanılmıştır [10]. Başka bir çalışmada önerilen çerçeve üç aşamadan oluşmaktadır: veri kaynaklarından BT görüntülerinin toplanması, Adaptive Multiscale Extended Trans-Unet3+ yöntemiyle segmentasyon ve sınıflandırma. Segmentasyon başarımını artırmak için Modified Transfer Operator-Based Archimedes Optimization (MTO-AO) algoritması uygulanmış, ardından Inception, ResNet ve MobileNet mimarilerini entegre eden Advanced Extended Ensemble Convolutional Neural Network (ADECNN) ile sınıflandırma yapılmıştır [11]. Bu alandaki bir başka çalışmada akciğer tümörleri segmentlere ayrılmış ve doğruluğu artırmak amacıyla modelin ince ayarı gerçekleştirilmiştir. Segmentasyon sürecinde kodlayıcı–çözücü (encoder–decoder) mimarisi kullanılmış; ön ve son işleme aşamalarında evrişim (convolution) blokları uygulanmış, derin katmanlarda ise dönüştürücü (transformer) modülü entegre edilmiştir [12].

[13] numaralı çalışmada BT görüntülerini iyileştirmek amacıyla bir ön işleme tekniği uygulanmış ve ardından derin CNN öznitelik çıkarımı için kullanılmıştır. Geliştirilen yöntem ayrıca Raspberry Pi cihazı üzerinde de uygulanmıştır. Başka bir çalışmada klasik BT ve FDG PET/BT görüntüleri üzerinde derin öğrenme modelleri

kullanılarak bu modalitelerdeki performans değerlendirilmiştir. Bu amaçla ResNet-18 modeli tercih edilmiş ve *ImageNet* veri kümesinden aktarım öğrenmesi (transfer learning) uygulanmıştır [14]. Ayrı bir çalışmada 530 Küçük Hücreli Dışı Akciğer Kanseri (NSCLC) hastasından oluşan bir veri kümesi kullanılarak topluluk (ensemble) temelli bir derin öğrenme ağı geliştirilmiştir. Birden fazla 2B dilimden öznitelik çıkarımı farklı giriş yolları üzerinden gerçekleştirilmiş ve çeşitli boyutlarda evrişim çekirdekleri kullanılarak farklı özellikler yakalanmıştır. Bu çoklu dilim yaklaşımı farklı BT dilimlerinden gelen bilgilerin bütünleştirilmesini mümkün kılmıştır [15].

[16] numaralı çalışmada olasılık haritaları üretmek için 3B tam evrişimli ağ (Fully Connected Network, FCN) kullanan varyasyonel bir derin öğrenme yöntemi önerilmiştir. Bu sonuçlar, üyelik derecesi önceliğinden yararlanarak doğru segmentasyon sağlayan bulanık varyasyonel bir modelle bütünleştirilmiştir. Başka bir çalışmada iki derin öğrenme yaklaşımı tanıtılmıştır: birincisinde Değiştirilmiş AlexNet (MAN) X-ışını görüntülerinde hastalık sınıflandırması için uygulanmış, Destek Vektör Makineleri (Support Vector Machine, SVM) sınıflandırma için kullanılmış ve Softmax ile karşılaştırılmıştır. İkinci yaklaşımda ise MAN elle çıkarılmış ve öğrenilmiş öznitelikleri seri füzyon yoluyla birleştirmiş ve bu süreç Temel Bileşen Analizi (Principal Component Analysis, PCA) ile güçlendirilmiştir [17]. İlgili bir çalışmada sınıflandırma katmanı değiştirilmiş EfficientNetB1 tabanlı Lung-EffNet adlı yeni bir mimari önerilmiştir. Lung-EffNet, EfficientNetB0–B4 modelleriyle karşılaştırılmış ve sınıf dengesizliği sorunu bir arttırma (boosting) yöntemiyle ele alınmıştır [17]. Başka bir çalışmada ise pekiştirmeli öğrenme (reinforcement learning) ile entegre bir derin öğrenme çerçevesi geliştirilmiştir. Dengesizlik sorununu çözmek amacıyla elastik dönüşüm ve diğer veri artırma teknikleri uygulanmıştır. Beş önceden eğitilmiş CNN modeli birleştirilerek DEV-MV adlı bir topluluk modeli oluşturulmuş ve hiperparametreler ızgara arama (grid search) yöntemiyle optimize edilmiştir [18].

Bir diğer çalışmada her bir görüntüden üç farklı öznitelik kümesi çıkarılan Fuse-TSD adlı yeni bir yöntem önerilmiştir. Bir öznitelik kümesi için Derin Evrişimsel Sinir Ağı (DCNN) kullanılırken, doku ve şekil özelliklerini yakalamak için sırasıyla Gri Düzey Eş-Oluşum Matrisi (GLCM) ve Fourier analizi uygulanmıştır. Bu öznitelikler, Geri Yayılım Sinir Ağı (BPNN) ve AdaBoost tabanlı topluluk sınıflandırıcılarıyla işlenmiş ve çıktılar ağırlıklı olasılık toplamı yoluyla birleştirilmiştir [19]. Bir başka çalışmada derin sinir ağlarında (DNN) ince ayar yöntemi olarak Sınıf Varyans Analizi (CVA)'nın etkinliği değerlendirilmiş ve Softmax ile SVM sınıflandırıcılarıyla karşılaştırılmıştır. Çalışma, standart aktivasyon çıktıları yerine sınıf içi benzerliklerin kullanılmasının önemini vurgulamış ve bu süreci CVA aracılığıyla uygulamıştır [20]. [21] numaralı çalışmada yedi farklı veri kümesi kullanılarak, bilgisayar destekli tanı (CAD) sistemlerine yönelik CNN tabanlı yaklaşımlar incelenmiştir. Çalışma, nodül tespiti ve yanlış pozitif oranlarının azaltılmasına odaklanmış, farklı veri kümeleri, teknikler ve modeller arasındaki sonuçları karşılaştırmıştır. Bir başka çalışmada [22] BT görüntüleri üzerinde önceden eğitilmiş modeller kullanılmış; InceptionUNet modeli tümör tespitinde güçlü performans sergilemiştir. Ayrıca, kanserli bölgelerin belirlenmesinin ardından UNet, SegNet ve InceptionUNet modelleri segmentasyon için uygulanmıştır.

Bu alandaki bir çalışmada BT görüntülerine uygulanan çeşitli derin öğrenme modellerinden elde edilen sonuçlar sunulmuş ve Max-Min CNN adlı bir yöntem tanıtılmıştır. Bu yaklaşımdan yola çıkarak Max-Min CNN, iki Max-Min CNN'den oluşan Bilinear Max-Min CNN ve hibrit Max-Min ViT modelleri geliştirilmiştir. Ayrıca sınıflandırma performansını artırmak amacıyla CNN tabanlı bir CAD sistemi önerilmiştir. Bu yöntemin temel katkısı ReLU aktivasyonundan sonra bilgi kaybını önlemek için standart evrişim işleminin Max-Min evrişim ile değiştirilmesidir. Değerlendirme için *z-testi* kullanılmıştır [23]. Başka bir çalışmada kanserli ve kansersiz vakaların ayrımı ile kanser varlığında bunun iyi huylu (benign) ya da kötü huylu (malign) olup olmadığının belirlenmesi amaçlanmıştır. Başlangıçta Belirsizlik Ölçümü (Uncertainty Quantification – UQ) uygulanmamış, performans çeşitli derin öğrenme yöntemleriyle değerlendirilmiştir. Daha sonra UQ entegrasyonu yapılmış ve farklı derin öğrenme modelleriyle sonuçlar elde edilmiştir. Çalışma ayrıca dört katmanlı bir CNN önermiş ve UQ'nun sınıflandırmadaki rolünü incelemiştir [24]. Farklı bir çalışmada NoduleDiag adlı bir makine öğrenmesi modeli ve buna entegre bir akciğer nodülü segmentasyon modeli geliştirilmiştir. Bu iki modelin birlikte kullanılması, etkili bir bilgisayar destekli tanı (Computer Aided Diagnosis, CAD) çerçevesi oluşturmak üzere tasarlanmıştır. Çalışmada büyük bir halka açık veri kümesinden yararlanılmış ve erken tespit ile uygun tedavi planlaması için bir puanlama sistemi geliştirilmiştir [25]. İlgili çalışmaların nicel ve nitel karşılaştırması Tablo 1'de sunulmuştur.

3. Materyal ve Yöntem (Materıal and Method)

Bu bölüm BT görüntülerinden akciğer kanseri sınıflandırmasını otomatikleştirmek amacıyla tasarlanan derin öğrenme modelinde kullanılan yazılım yığını, veri kümesi, veri ön işleme yöntemleri, önerilen model mimarisi ve eğitim yapılandırmasını açıklamaktadır. Bu çalışmanın temel amacı dönüştürücü (transformer) tabanlı görsel modellerin - özellikle Görsel Dönüştürücülerin (ViT'lerin) - temsil gücünden yararlanarak heterojen akciğer patolojilerinin doğru, sağlam ve ölçeklenebilir bir şekilde sınıflandırılmasını sağlamaktır.

3.1. Yazılım Yığını (Software Stack)

Bu çalışmadaki tüm deneyler, derin öğrenme araştırmaları için GPU destekli bir ortam sağlayan *Kaggle* bulut platformu üzerinde gerçekleştirilmiştir. Uygulama, Python (v3.*11*) programlama dili kullanılarak yapılmış ve modelin oluşturulması, eğitimi ve değerlendirilmesi için PyTorch [29] derin öğrenme çerçevesinden yararlanılmıştır. *HuggingFace Transformers* [30] kütüphanesi, Görsel Dönüştürücülerin (ViT-Large) mimarisinin entegrasyonu ile önceden eğitilmiş modellerin yüklenmesi ve ince ayar işlemlerini kolaylaştırmak amacıyla kullanılmıştır.

Veri manipülasyonu ve ön işleme adımları için *NumPy* [31], *Pandas* [32] ve *Pillow* [33] kütüphaneleri kullanılırken; performans eğrileri ve karmaşıklık matrisleri gibi sonuçların görselleştirilmesi için *Matplotlib* [34] ve *Seaborn* [35] tercih edilmiştir. Yeniden üretilebilirlik ve verimli eğitim süreçlerini sağlamak amacıyla, performans metrikleri ve tabakalı (stratified) veri kümesi bölünmesi için ek araçlar olarak *scikit-learn* [36] kullanılmıştır.

3.2. Veriseti ve Ön İşleme (Dataset and Preprocessing)

3.2.1. Veriseti Tanımı (Dataset Description)

Bu çalışmada, *Chest CT Scan Images Dataset* adlı, *Kaggle*'da [37] halka açık olarak erişilebilen bir referans (benchmark) veri kümesi kullanılmıştır. Veri kümesi, göğüs BT görüntülerinden otomatik akciğer kanseri sınıflandırması amacıyla derlenmiş olup, her biri dört kategoriden birine etiketlenmiş 1.000 yüksek çözünürlüklü göğüs BT kesitinden oluşmaktadır: (i) *Normal*, (ii) *Adenokarsinom*, (iii) *Büyük Hücreli Karsinom* ve (iv) *Skuamöz Hücreli Karsinom*. Normal görüntüler, patolojik belirti göstermeyen sağlıklı akciğer taramalarını ifade ederken, Adenokarsinom NSCLC'nin en yaygın formu olup genellikle periferik akciğer dokularında ve sigara kullanmayanlarda görülür. *Büyük Hücreli Karsinom*, daha nadir ve agresif bir alt tip olup iyi farklılaşmamış büyük tümör hücreleri ile bilinir. *Skuamöz Hücreli Karsinom* ise merkezi hava yollarına yakın bölgelerde ortaya çıkar ve

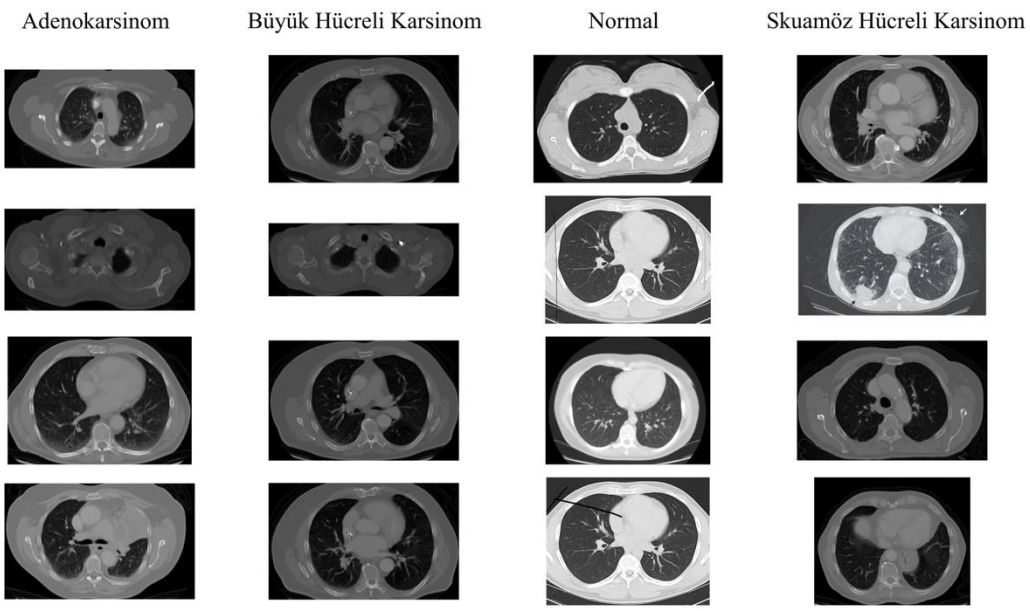
Tablo 1. ML ve DL tabanlı ilgili çalışmalara genel bakış (A comparison of the related work)

Çalışma	Veriseti	Yöntem	Görüntü Tipi	Raporlanan Sınıflandırma Başarısı
[10]	LUNA16 ve 888 BT taraması	SE bloklu SE-ResNeXt-50 CNN	BT	%99,15 doğruluk, %97,58 duyarlılık, %99,51 kesinlik, %99,80 özgüllük ve %98,54 F1-skoru
[11]	DSB3 ve göğüs BT taramaları	Archimedes Optimizasyon destekli genişletilmiş topluluk CNN (MTO-AO-ADECNN)	BT	%98,72 doğruluk, %97,45 duyarlılık, %98,91 kesinlik, %99,12 özgüllük, %98,03 F1-skoru ve %96,84 Dice benzerlik katsayısı
[12]	NSCLC-radyomik ve özel hastane veri kümesi	ViT ve CNN kombinasyonu	BT	%88,7 doğruluk, %90,2 duyarlılık, %87,4 özgüllük ve %92,5 Dice benzerlik katsayısı
[13]	UCI BT taramaları	ResNet-50 (Raspberry Pi uygulaması dahil)	BT	%72,41 doğruluk
[14]	Dahili BT ve FDG PET/BT	ResNet-18 ile aktarım öğrenmesi	BT, PET/BT	BT görüntülerinde %93,2 doğruluk, %91,5 duyarlılık ve %94,8 özgüllük; PET/BT ile entegre edildiğinde ise %95,6 doğruluk
[15]	VHS Medical Center ve TCIA NSCLC	Çok çekirdekli, çok ölçekli topluluk CNN	BT	%92,4 doğruluk, %89,7 duyarlılık, %93,2 kesinlik ve 0.95 AUC
[16]	PET/BT taramaları (Reveal HD, CTI)	3B Tam Evrişimli Ağ (3D FCN)	PET/BT	%89,2 Dice benzerlik katsayısı, %82,5 Jaccard indeksi
[26]	LIDC-IDRI BT ve Rajpur göğüs röntgenleri	Değiştirilmiş AlexNet (MAN), AlexNet, VGG16/19, ResNet50, MAN-SoftMax/SVM/KNN/RF	BT, Röntgen	BT görüntülerinde %96,4 doğruluk, %94,8 duyarlılık, %97,2 kesinlik ve %96,1 F1-skoru; röntgenlerde ise %95,2 doğruluk raporlandı
[17]	IQ-OTH/NCCD	EfficientNetB0–B4	BT	%98,1 doğruluk, %97,3 duyarlılık, %98,5 kesinlik, %99,0 özgüllük, %97,9 F1-skoru
[18]	IQ-OTH/NCCD	Topluluk (EfficientNetB7, DenseNet201, VGG16/19, MobileNet, DEV-MV)	BT	%97,8 doğruluk, %96,5 duyarlılık, %98,2 kesinlik, %98,9 özgüllük ve %97,6 F1-skoru
[27]	TCIA ve histopatolojik görüntüler	CNN, VGG16/19, InceptionV3, ResNet50	BT, Histopatoloji	%98,5 doğruluk, yüksek hassasiyet, duyarlılık, özgüllük ve F1-skoru
[19]	LIDC-IDRI	Fuse-TSD (DCNN+FSD+GLCM+AdaBoost BPNN)	BT	%86,8 doğruluk, %85,4 duyarlılık, %88,2 kesinlik ve 0.89 AUC
[20]	LIDC-IDRI ve SPIE-AAPM 2015	EfficientNet, Inception-V3, MobileNetV2, ResNet50, Xception, VGG16, SVM	BT	%94,6 doğruluk, %93,2 duyarlılık, %95,1 kesinlik, %96,3 özgüllük ve 0,97 AUC
[22]	Kaggle Akciğer Tümörü Segmentasyonu (S. Rasouli)	MobileNetV2, ResNet152V2, Xception, InceptionResNetV2, VGG19, InceptionV3, UNet, SegNet, InceptionUNetV2	BT	%98,57 doğruluk, 0.07 kayıp, %98,61 kesinlik, %98,58 duyarlılık, %98,58 F1-skoru, %99,39 ROC AUC ve %95,3 Jaccard indeksi
[23]	LUNA16, LIDC–IDRI (888 BT taraması)	Max-Min CNN, İkili Max-Min CNN, Hibrit Max-Min ViT, VGG16/19, ResNet50, DenseNet121, MobileNetV2	BT	%97,2 doğruluk, %96,1 duyarlılık, %97,8 kesinlik, %98,4 özgüllük ve %96,9 F1-skoru
[24]	Cancer Archive Center (KAM)	ResNet50, AlexNet, InceptionV3, VGG16, Önerilen 4K-ESA ile Bayesyen NN	BT	%96,8 doğruluk, %95,4 duyarlılık ve %97,2 özgüllük
[28]	TCIA	Radyomik + sınıflandırıcılar (Tree, SVM, KNN, Topluluk, iMRRN segmentasyon için)	BT, PET/BT	%92,7 doğruluk ve 0,97 AUC

sigara kullanımıyla güçlü şekilde ilişkilidir. Veri kümesi, eğitim (%70), doğrulama (%15) ve test (%15) olmak üzere üç alt kümeye tabakalı olarak ayrılmıştır; buna rağmen, *Büyük Hücreli Karsinom* ve *Normal* örnekler, *Adenokarsinom* ve *Skuamöz Hücreli Karsinom*'a kıyasla daha az temsil edilmektedir. Her alt küme, sınıfa özgü dizinler halinde düzenlenmiş olup görüntüler JPEG ve PNG formatlarında saklanmaktadır. Görüntü çözünürlükleri 172×110 ile 1200×874 piksel arasında değişmekte ve ortanca boyut yaklaşık 429×285 pikseldir, bu da klinik görüntüleme verilerindeki gerçek heterojenliği yansıtmaktadır. Bu veri kümesi, özellikle birden fazla NSCLC alt tipini içeren senaryolarda, akciğer kanseri sınıflandırması görevlerinde derin öğrenme modellerinin değerlendirilmesi için anlamlı bir temel sunar ve sınıflandırma performansı ile genelleme yeteneğinin değişken görüntü kalitesi ve sınıf dengesizliği koşullarında incelenmesine olanak tanır. Literatürde yaygın olarak kullanılan *LIDC-IDRI* gibi standart (benchmark) veri setleri genellikle radyologlar tarafından işaretlenmiş nodül tespiti ve malignite (kötü huyluluk) derecelendirmesine odaklanmaktadır. Ancak, klinik teşhis sürecinde kanserin alt tipinin belirlenmesi, tedavi protokolünün oluşturulması açısından kritik bir öneme sahiptir. Seçilen veri seti adenokarsinom, skuamöz hücreli karsinom ve büyük hücreli karsinom gibi spesifik alt tipleri içeren homojen yapısı sayesinde ViT modelinin karmaşık dokusal farkları öğrenme kapasitesini ölçmek için ideal bir zemin sunmaktadır. Veri setinin bu spesifik yapısı genel amaçlı nodül tespit setlerinden ayrılarak, çalışmamızın 'alt tip sınıflandırması' şeklindeki özgün hedefine doğrudan hizmet etmektedir. Çalışmamızda analiz edilen her akciğer durumu için temsil niteliğindeki örnekler Şekil 1'de gösterilmiş olup, bunlar arasında zararlı (malign) sınıflar (*Adenokarsinom*, *Büyük Hücreli Karsinom* ve *Skuamöz Hücreli Karsinom*) ile *Normal* kontroller yer almakta ve her kategori için rastgele seçilmiş dört görüntü sunulmaktadır.

3.2.2. Önişleme Boru Hattı (Preprocessing Pipeline)

Eğitim öncesinde tüm BT görüntüleri dönüştürücü tabanlı (transformer) mimarilerin giriş gereksinimleriyle uyumluluk ve modelin genelleme yeteneğini artırmak amacıyla standart bir ön işleme sürecinden geçirilmiştir. Ön işleme hattı, etiket normalizasyonu, görüntü yeniden boyutlandırma, sınıf dengelenmesi ve veri artırma gibi ardışık adımları içermektedir. İlk olarak ham görüntüler, veri kümesinin önceden tanımlanmış eğitim, doğrulama ve test klasörlerinden yüklenmiş ve tek bir havuzda birleştirilmiştir; bundan sonra yeni bir eğitim/doğrulama/test bölünmesi oluşturulmuştur. Bu aşamada histolojik alt tipleri gösteren dizin adları (ör. adenocarcinoma.left.lower.lobe-CTscan1.1) özel bir eşleme fonksiyonu kullanılarak dört ana tanısal kategoriye normalize edilmiştir.



Şekil 1. Dört farklı akciğer durumunu temsil eden göğüs BT tarama görüntüleri
(Representative chest CT scan images from four pulmonary conditions)

Özellikle *Adenokarsinom, Büyük Hücreli Karsinom* ve *Skuamöz Hücreli Karsinom* alt tiplerine ait tüm klasörler kendi ana etiketleri altında birleştirilmiştir. Bu adım, etiket tutarlılığını sağlamakta ve etiket seyrekliğini azaltmakta olup, etkili model eğitimi ve değerlendirmesi için kritik öneme sahiptir. Her görüntü, Görsel Dönüştürücü (ViT-Large) modeli için giriş boyutlarını standartlaştırmak amacıyla 224×224 piksel çözünürlüğe çift kübik (bicubic) interpolasyon ile yeniden boyutlandırılmış ve RGB formatına dönüştürülerek önceden *ImageNet* tabanlı modellerle uyumlu hâle getirilmiş ve bellek üzerinde *NumPy* dizileri olarak saklanmıştır. İlk görüntü yükleme işlemi sonrasında, sınıf dengesizliğini gidermek için rastgele aşırı örnekleme (oversampling) uygulanmıştır. Pek çok çalışmanın yalnızca eğitim setinde aşırı örnekleme uygulamasının aksine, bizim yöntemimiz sınıf dengelenmesini tabakalı bölünme öncesinde gerçekleştirmiştir. Tüm sınıflar, rastgele tekrar örnekleme ile çoğunluk sınıfının örnek sayısına yükseltilmiştir. Bu yaklaşım, tüm veri kümesinde sınıf dağılımını eşitleyerek, eğitim, doğrulama ve test alt kümelerinde tabakalı örnekleme ile dengeli sınıf dağılımının korunmasını sağlamıştır. Bu geleneksel uygulamalardan farklı bir yaklaşım olsa da özellikle *Büyük Hücreli Karsinom* gibi az temsil edilen kategoriler için doğrulama ve test setlerinde seyrekliği önlemek amacıyla gereklidir. Uygulanan veri dengelenmesi sonucunda örnek sayısı 1.000'den 1.352'ye yükselmiştir. Veri dengelenmesinin ardından, veri kümesi eğitim (%70, 946 örnek), doğrulama (%15, 203 örnek) ve test (%15, 203 örnek) alt kümelerine tabakalı bölünme ile ayrılmış, böylece tüm sınıfların alt kümelerde eşit temsil edilmesi sağlanmıştır. Sınıf etiketleri, eğitim ve değerlendirme süreci boyunca tutarlı bir etiket-indeks eşlemesi sağlamak için *LabelEncoder* ile tamsayı formatında kodlanmıştır. Eğitim seti için ayrıca, döngüsel rastgele veri artırma yöntemi olan *RandAugment* uygulanmış; bu yöntem, döndürme, ölçeklendirme, parlaklık ayarı ve öteleme gibi rastgele seçilen görüntü dönüşümlerini içererek gerçek dünya görüntüleme varyasyonlarını yansıtan çeşitlilik sağlayarak genelleme yeteneğini artırmıştır. Her eğitim görüntüsü ViT gövdesinin önceden eğitildiği *ImageNet-21k* veri kümesinin kanal bazlı ortalama ve standart sapma değerleri kullanılarak normalize edilmiş ve *PyTorch* tensörlerine dönüştürülmüştür. Doğrulama ve test setlerinde ise veri artırma kasıtlı olarak uygulanmamış, yalnızca yeniden boyutlandırma ve normalizasyon yapılmıştır; böylece performans metrikleri, modelin rastgele görüntü bozulmalarından etkilenmeden gerçek genelleme yeteneğini yansıtmıştır. Tüm ön işlenmiş veri kümeleri eğitim döngüsüne kolay entegrasyon ve eğitim/eğitim sırasında toplu örnekleme ile dönüşümlerin uygulanabilmesi için *HuggingFace Dataset* soyutlaması kullanılarak kapsüllenmiştir. Bu ön işleme hattı hem sayısal stabiliteyi hem de mimari uyumluluğu sağlarken sınıf dengesizliği, tutarsız etiketleme ve giriş çözünürlüğü değişkenliği gibi gerçek dünya zorluklarını da ele almaktadır. Sonuç olarak model klinik göğüs BT görüntülerinde akciğer kanseri alt tiplerinin doğru sınıflandırılması için optimize edilmiş, standart ve temsil edici bir veri kümesi üzerinde eğitilmiştir. Görsel Dönüştürücü modeli ile uyumluluk için BT görüntülerinin hazırlandığı genel ön işleme hattı Şekil 2'de gösterilmiştir.

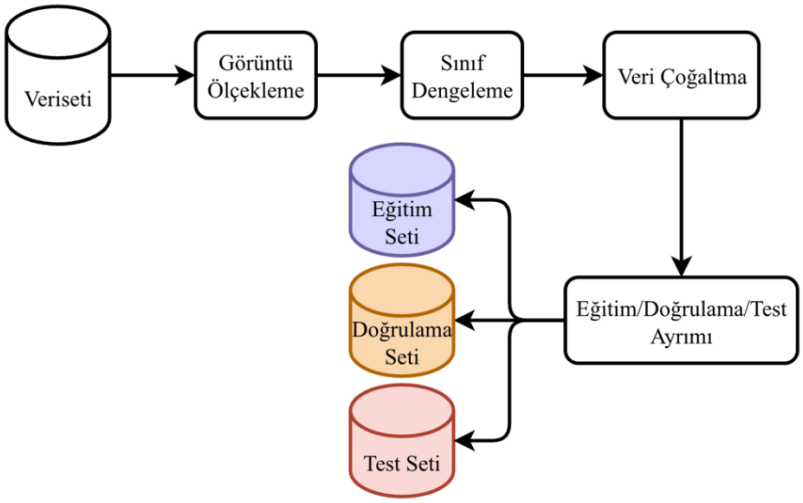
3.3. Model Ön İzlemesi (Model Overview)

Önerilen yaklaşımımızın temelini [38] tarafından geliştirilen ve *ImageNet-21k* veri kümesi üzerinde önceden eğitilmiş olan Görüntü Dönüştürücü (ViT-Large, Patch-16) adlı son teknoloji mimarisi oluşturmaktadır. Model, *Hugging Face Transformers* kütüphanesi kullanılarak uygulanmıştır; bu kütüphane önceden eğitilmiş ağırlıklara verimli erişim, yapılandırma yönetimi ve özel eğitim boru hatlarına kesintisiz entegrasyon imkânı sunmaktadır. Geleneksel CNN yaklaşımlarının aksine Görüntü Dönüştürücü her bir girdi görüntüsünü bir dizi çakışmayan yama (patch) dizisine böler (bu çalışmada 16×16 piksellik yamalar), bu yamaları düzleştirir ve bir doğrusal gömme katmanı (linear embedding layer) aracılığıyla gizli bir uzaya (latent space) yansıtır. Bu yama gömmeleri (patch embeddings) öğrenilebilir konumsal kodlamalar (positional encodings) ile zenginleştirilir ve Çok Başlı Öz Dikkat (Multi-head Self-Attention, MSA) ve Çok Katmanlı Algılayıcılar (Multi-Layer Perceptrons, MLPs) içeren standart bir dönüştürücü kodlayıcı (transformer encoder) üzerinden işlenir. Bu tasarım, ViT'nin uzun menzilli bağımlılıkları ve küresel bağlamsal ilişkileri modelleyebilmesini sağlar. Bu özellik göğüs BT görüntüleri gibi tıbbi görüntüleme alanlarında özellikle değerlidir; çünkü nodüller, opasiteler gibi yerel yapılar genellikle daha geniş anatomik bölgelerin bağlamında yorumlanmalıdır. Sınıflandırma görevimiz için, önceden eğitilmiş ViT-Large modelinin orijinal sınıflandırma başlığı veri kümesindeki dört akciğer kanseri sınıfına karşılık gelecek şekilde

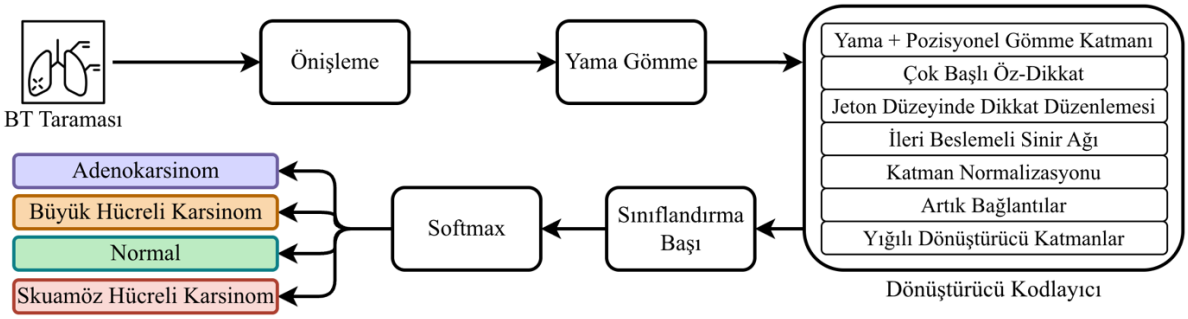
rastgele başlatılmış bir doğrusal katmanla değiştirilmiştir. Dönüştürücü kodlayıcının geri kalanı korunmuş ve göğüs BT taramalarında yer alan alana özgü örüntülere uyum sağlayacak şekilde uçtan uca (end-to-end) ince ayar uygulanmıştır. Önerilen akciğer kanseri sınıflandırma modelinin genel mimarisi, dönüştürücü tabanlı omurga yapısını ve yapılandırılmış bir ön işleme hattını birleştirmekte olup Şekil 3'te görselleştirilmiştir.

3.4. Eğitim Konfigürasyonu ve Optimizasyon
(Training Configuration and Optimization)

Eğitim yapılandırmasını daha da optimize etmek için, *Optuna* [39], modern bir hiperparametre optimizasyon çerçevesi, ViT modeli için en etkili hiperparametre ayarlarını otomatik olarak aramak amacıyla kullanılmıştır. Arama uzayı; öğrenme oranı ($1 \times e^{-6}$ ile $1 \times e^{-4}$ arasında log-uniform dağılım), ağırlık bozulması (0 ile 0,1 arasında uniform dağılım), etiket yumuşatma katsayısı (0 ile 0,2 arasında uniform dağılım) ve eğitim epok sayısı (10 ile 30 arasında) parametrelerini içermektedir. Her deneme, *Hugging Face Trainer API* kullanılarak gerçekleştirilmiş ve sınıf dengesizliğini gidermek amacıyla *RandomOverSampler* (*Aşırı Örneklemdirici*) ile dengelenmiş eğitim seti üzerinde bir ViT-Large modeli eğitilmiştir. Bu esnada literatürdeki veri sızıntısı (data leakage) riskleri göz önünde bulundurularak veri sızıntısını önlemek adına öncelikle orijinal veri seti içerisinden bağımsız bir test kümesi ayrılmıştır. Aşırı örnekleme ve *RandAugment* tabanlı veri artırımı işlemleri yalnızca eğitim kümesi üzerinde gerçekleştirilmiştir. Böylelikle test aşamasında kullanılan görüntülerin veya bu görüntülerin herhangi bir kopyasının/türevinin eğitim sürecine dahil edilmediği garanti altına alınmıştır. Bu yaklaşım hem modelin genelleyebilirliğini korumuş hem de elde edilen başarı oranlarının veri sızıntısından kaynaklanmadığını doğrulamıştır. Rastgele affine dönüşümler ve Gauss bulanıklığı gibi görüntü artırma teknikleri, genelleme yeteneğini artırmak için uygulanmıştır. Doğrulama doğruluğu (validation accuracy) optimizasyon amacı olarak belirlenmiş, erken durdurma (early stopping) mekanizması ise aşırı öğrenmeyi önlemek için devreye alınmıştır. 15 denemenin ardından, *Optuna* en uygun hiperparametre konfigürasyonunu belirlemiş ve bu yapılandırma son eğitim çalışmasında kullanılmıştır. Bu sayede doğrulama performansında iyileşme ve eğitim sürecinde daha yüksek kararlılık sağlanmıştır. Optimize edilen hiperparametreler, değer uzayları ve en iyi performansı veren değerleri Tablo 2'de sunulmuştur.



Şekil 2. Bu çalışmada kullanılan ön işleme hattının iş akışı diyagramı (Workflow diagram of the preprocessing pipeline employed in this study)



Şekil 3. Önerilen akciğer kanseri sınıflandırma modelinin ön izlemesi (Overview of the proposed lung cancer classification model)

Tablo 2. Optimize edilen hiperparametreler, değer uzayları ve elde edilen en iyi değerleri (Optimized hyperparameters, their value ranges, and the best obtained values)

Hiperparametre	Arama Uzayı	En İyi Performansı Veren Değer
Öğrenme oranı	$1 \times e^{-6}$ ile $1 \times e^{-6}$ (Log-uniform)	$1 \times e^{-5}$
Ağırlık bozulması	0 ile 0,1 (Uniform)	0,01
Etiket yumuşatma	0 ile 0,2 (Uniform)	0,1

Modelin ince ayarı *Hugging Face Trainer* [40] çerçevesi kullanılarak gerçekleştirilmiştir. Eğitim süreci maksimum 100 epok boyunca çalışacak şekilde yapılandırılmış, ancak doğrulama doğruluğu artmadığında beş ardışık epok sonrasında erken durdurma uygulanarak hem aşırı öğrenme hem de gereksiz hesaplama önlenmiştir. *AdamW* [41] optimizasyon algoritması, 5×10^{-6} temel öğrenme oranı, 0,05 ağırlık bozulması ve GPU bellek kısıtlamalarına uyum sağlamak için iki adımda gradyan birikimi (gradient accumulation) ile kullanılmıştır. Ayrıca, cosine öğrenme oranı zamanlayıcısı ve 0,1 ısınma (warm-up) oranı uygulanarak eğitim sürecinin başında kademeli yakınsama sağlanmıştır. Sayısal verimliliği ve hızını artırmak için karışık hassasiyetli eğitim (mixed precision, fp16), PyTorch'un Automatic Mixed Precision (AMP) özelliğiyle etkinleştirilmiştir. Eğitim sürecini düzenlemek için 0,1'lik bir etiket yumuşatma (label smoothing) katsayısı kullanılmıştır. Bu teknik, gerçek etiketin olasılık kütlesinin bir kısmını diğer sınıflara dağıtarak modelin aşırı güvenini azaltır ve özellikle etiket gürültüsü içeren verilerde genelleme performansını artırır. Her epok sonunda hesaplanan değerlendirme metrikleri arasında genel doğruluk (accuracy) ve makro ortalamalı F1-skoru (macro-averaged F1-score) bulunmaktadır; bu metrikler *Hugging Face Evaluate* [42] kütüphanesiyle uygulanmıştır. Son olarak, en yüksek doğrulama doğruluğu elde eden model kontrol noktası (checkpoint) korunmuş ve test seti üzerinde nihai çıkarım (inference) işlemlerinde kullanılmıştır.

3.5. Eğitim Konfigürasyonu ve Optimizasyon (Training Configuration and Optimization)

Eğitim süreci tamamlandıktan sonra en iyi model ayrılmış test seti üzerinde değerlendirilmiştir. Tahminler softmax ile normalleştirilmiş logitler üzerinde *argmax* işlemi uygulanarak elde edilmiştir. Modelin performansı her sınıf için kesinlik (precision), duyarlılık (recall) ve F1-skoru değerlerini içeren ayrıntılı bir sınıflandırma raporu ile değerlendirilmiştir. Ayrıca, sınıflar arası karışıklıkları analiz etmek amacıyla bir karışıklık matrisi (confusion matrix) oluşturulmuştur. Bu matrisin görselleştirilmesi, modelin karar sınırlarının yorumlanabilirliğini artırmak ve hataların nedenlerini incelemek için kullanılmıştır. Bu çalışma kapsamında geliştirilen boru hattı (pipeline), güncel model mimarisini, titiz ön işleme ve artırma stratejilerini ve sağlam eğitim prosedürlerini bütünleştirerek, tıbbi görüntü sınıflandırmasının zorluklarına özel olarak uyarlanmış kapsamlı bir çözüm sunmaktadır.

4. Sonuçlar ve Tartışmalar (Results and Discussions)

Bu bölüm göğüs BT taramalarından akciğer hastalıklarının çok sınıflı sınıflandırması için önerilen Görüntü Dönüştürücü tabanlı modelin eğitim dinamiklerini, nihai performans ölçümlerini ve tanısal değerlendirmesini sunmaktadır. Model, *Adenokarsinom, Büyük Hücreli Karsinom, Skuamöz Hücreli Karsinom* ve *Normal* olmak üzere dört sınıftan oluşan dengelenmiş bir veri kümesi üzerinde 25 epok boyunca eğitilmiştir. Eğitim süreci boyunca hem eğitim ve doğrulama kayıpları hem de sınıflandırma doğruluğu (accuracy) ve F1-skoru izlenerek, öğrenme istikrarı ve genelleme performansı değerlendirilmiştir.

4.1. Eğitim Dinamikleri (Training Dynamics)

Eğitim ve doğrulama kayıplarının evrimi Şekil 4'te gösterildiği üzere eğitim kaybında istikrarlı bir azalma eğilimi sergilemektedir. Başlangıçta modelin kayıp değerleri yüksek olup bu durum rastgele ağırlık başlatımıyla uyumludur. Ancak yaklaşık 10. epok civarında hem eğitim hem de doğrulama kayıplarında belirgin bir düşüş gözlemlenmiş; bu da modelin veriden anlamlı özellikleri başarıyla öğrendiğini göstermektedir. 15. epok sonrasında doğrulama kaybı kararlılığa ulaşmış ve daha fazla iyileşme sınırlı kalmıştır; bu durum modelin yakınsama (convergence) aşamasına eriştiğini göstermektedir.

4.2. Performans Metrikleri (Performance Metrics)

Bir derin öğrenme modelinin etkinliğinin değerlendirilmesi verileri doğru şekilde sınıflandırma yeteneğini doğrulamak açısından son derece önemlidir. Kapsamlı bir değerlendirme süreci, modelin olası sınırlılıklarını veya zayıf yönlerini ortaya çıkararak performansın hedefe yönelik iyileştirilmesine olanak tanır. Bu amaçla sınıflandırıcı performansını ölçmede yaygın olarak kullanılan değerlendirme metriklerinden yararlanılmıştır: Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall) ve F1-skoru (F1-score). Doğruluk (Eş. 1), doğru tahmin edilen örneklerin (hem doğru pozitif hem de doğru negatiflerin) toplam örnek sayısına oranını ifade eder. Kesinlik (Eş. 2), pozitif olarak tahmin edilen örnekler arasındaki gerçek pozitiflerin oranını ölçer ve pozitif sınıflandırmaların güvenilirliğini gösterir. Duyarlılık (Eş. 3), modelin gerçek pozitif örnekleri ne kadar iyi tespit ettiğini değerlendirir. F1-skoru (Eş. 4) ise kesinlik ve duyarlılığın harmonik ortalaması olup özellikle sınıf dengesizliği bulunan durumlarda daha dengeli bir performans göstergesi sunar. Bu eşitliklerde *TP* (True Positive), modelin doğru biçimde pozitif sınıfı tahmin ettiği; *TN* (True Negative), doğru biçimde negatif sınıfı tahmin ettiği; *FP* (False Positive), gerçekte negatif olmasına rağmen pozitif olarak tahmin ettiği; *FN* (False Negative) ise gerçekte pozitif olmasına karşın negatif olarak tahmin ettiği örnekleri ifade eder.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \tag{1}$$

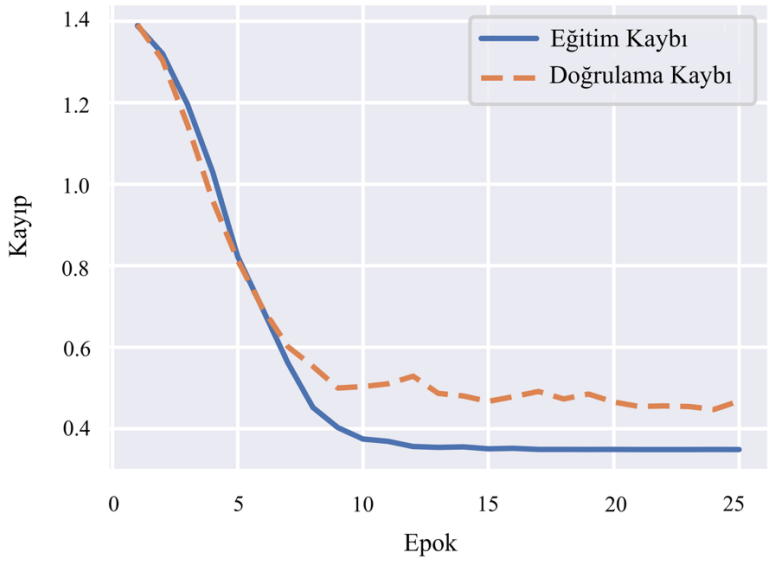
$$Kesinlik = \frac{TP}{TP + FN} \tag{2}$$

$$Duyarlılık = \frac{TP}{TP + FN} \tag{3}$$

$$F1 - skoru = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \tag{4}$$

Önerilen model, Tablo 3'te sunulduğu üzere güçlü bir genelleme yeteneği sergileyerek test verisinde %98,5 doğruluk ve 0,985 makro ortalama F1-skoru elde etmiştir. Bu performans düzeyi modelin yüksek görsel benzerliklere sahip çok sınıflı bir senaryoda dahi akciğer kanseri alt tiplerini ve sağlıklı örnekleri güvenilir biçimde ayırt edebildiğini göstermektedir. *Şekil 4'te* özetlenen eğitim sürecine ait doğruluk değerlerinin ilerleyişi modelin kararlı bir öğrenme davranışı sergilediğini doğrulamaktadır. Doğruluk oranı ilk epokta %24,1 iken 20. epokta %95,5'e ulaşmakta; bu noktadan sonra artış marjinal hâle gelmektedir. Bu hızlı öğrenme eğrisi dönüştürücü (transformer) tabanlı dikkat (attention) mekanizmaları ile yüksek çözünürlüklü BT görüntü girişlerinin sinerjik etkisini yansıtmaktadır. Model özellikle *Normal* sınıfında neredeyse mükemmel sınıflandırma başarısı (F1 = 0,990) elde etmiş; kanserli alt tiplerde de yüksek F1-skorları sağlamıştır. *Skuamöz Hücreli Karsinom* sınıfında gözlenen biraz daha düşük duyarlılık (Recall = 0,96), az sayıda örneğin yanlış sınıflandırıldığını göstermektedir; ancak bu durum genel doğruluğu anlamlı biçimde etkilememiştir.

Tablo 4'te bu çalışmada elde edilen sınıflandırma başarımının aynı veri kümesi üzerinde gerçekleştirilen çeşitli güncel yöntemlerle karşılaştırması sunulmaktadır. Önerilen yaklaşım 0,985 doğruluk ile tüm önceki çalışmalardan daha yüksek bir performans sergilemiş ve sınıflandırma için anlamlı özellikleri yakalamada üstün bir yetkinlik göstermiştir. [43] numaralı çalışmada %99,49 doğruluk bildirilmiş olsa da yazarların veri kümesinin tamamını kullanmamış olmaları nedeniyle bu çalışma karşılaştırma kapsamına alınmamıştır.



Şekil 4. 25 epok boyunca eğitim ve doğrulama kayıplarının değişimi (Evolution of training and validation loss over 25 epochs)

Tablo 3. Test kümesine ait sınıf bazlı performans ölçütleri (Class-based performance metrics for the test-set)

Sınıf	Kesinlik	Duyarlılık	F1-skoru	Destek
Adenokarsinom	0.962	0.980	0.971	51
Büyük Hücreli Karsinom	0.980	0.980	0.980	51
Normal	0.981	1.000	0.990	51
Skuamöz Hücreli Karsinom	1.000	0.960	0.980	50
Genel Doğruluk			0.980	203

Tablo 4. Bu çalışma ile aynı veri kümesini kullanan güncel yöntemlerle sınıflandırma doğruluklarının karşılaştırması (Comparison with state-of-the-art methods that utilized the same dataset as this study)

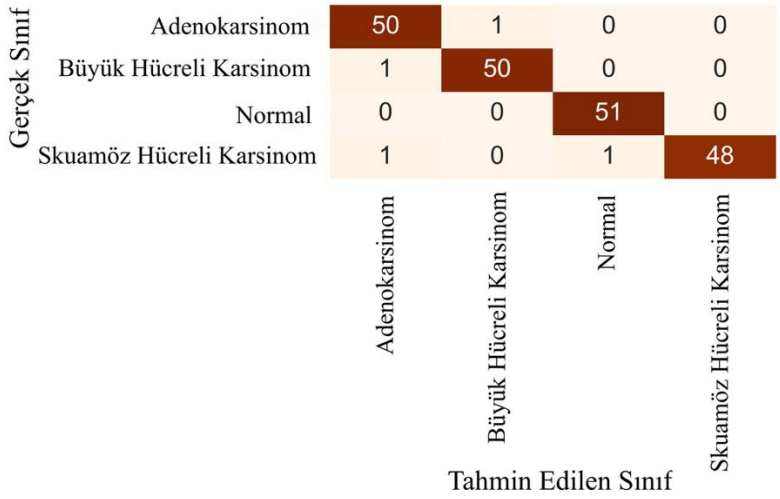
Çalışma	Sınıflandırma Doğruluğu	Çalışma	Sınıflandırma Doğruluğu
[44]	0.7222	[52]	0.9333
[45]	0.9786	[53]	0.9392
[46]	0.8600	[54]	0.9300
[47]	0.8214	[55]	0.9333
[48]	0.9600	[56]	0.8921
[49]	0.9200	[57]	0.9637
[50]	0.9500	[58]	0.9370
[51]	0.9778	[59]	0.9600
Bu çalışma	0.9850		

4.3. Karmaşıklık Matrisi Analizi (Confusion Matrix Analysis)

Sınıflandırma performansının daha derinlemesine incelenmesi, Şekil 5'te gösterilen karmaşıklık matrisi üzerinden yapılmıştır. Model, test örneklerinin neredeyse tamamını doğru biçimde sınıflandırmıştır; yalnızca üç yanlış sınıflandırma gözlemlenmiştir: Bir *Büyük Hücreli Karsinom* örneği *Adenokarsinom* olarak, bir *Adenokarsinom* örneği *Büyük Hücreli Karsinom* olarak, bir *Skuamöz Hücreli Karsinom* örneği ise *Normal* olarak tahmin edilmiştir. Bu yanlış sınıflandırmalar radyolojik olarak örtüşen görsel özelliklerden kaynaklanıyor olabilir; bu tür benzerlikler klinik uzmanlar için bile ayırt edilmesi güç durumlardır. Model, *Normal* sınıfında %100 (51/51) duyarlılık (recall) elde etmiş ve hiçbir örneği kaçırmamıştır. Karmaşıklık matrisi modelin sınıflar arası dengeli ve iyi kalibre edilmiş olduğunu; dolayısıyla herhangi bir tanı kategorisine sistematik bir önyargı göstermediğini doğrulamaktadır.

4.4. Genelleme ve Dayanıklılık (Generalization and Robustness)

Modelin performansı yaklaşık 20. epok civarında plato seviyesine ulaşmış olup eğitim ve doğrulama kayıpları arasındaki farkların ihmal edilebilir düzeyde kalması aşırı öğrenmenin minimum seviyede olduğunu göstermektedir. Bu durum birden fazla etkenin sinerjisine bağlanabilir: dönüştürücü (transformer) dikkat mekanizmasının ifade gücü, etkili etiket normalizasyonu ve *RandAugment* tabanlı güçlü veri artırma süreci. Katmanlı bölünmeden (stratified splitting) önce uygulanan aşırı örnekleme stratejisi tüm sınıflarda dengeli bir temsil sağlayarak genelleme kabiliyetini artırmıştır. İlginç bir şekilde 10. epok sonrasında doğrulama kaybında bazı dalgalanmalar gözlemlense de bu durum performans düşüşüne yol açmamıştır. Aksine model F1-skorunu korumuş veya iyileştirmiştir; bu da küçük doğrulama gürültülerine ve parti içi (inter-batch) değişkenliğe karşı dayanıklılığını (robustness) göstermektedir.



Şekil 5. Test kümesi üzerindeki model tahminlerini gösteren karmaşıklık matrisi
(Confusion matrix depicting the model's predictions on the test set)

4.5. Çalışma Süresi Analizi (Runtime Analysis)

Tüm deneyler, GPU hızlandırmalı hesaplama, önceden yüklenmiş Python veri bilimi paketleri ve yeniden üretilebilir (reproducible) bir hesaplama ortamı sunan *Kaggle*'ın bulut altyapısı üzerinde yürütülmüştür. Önerilen model, verimliliğini değerlendirmek amacıyla hem eğitim hem de çıkarım süreleri açısından ayrıca test edilmiştir. Deney ortamında, her biri 15 GB *GDDR6* belleğe ve *CUDA* 12.6 desteğine sahip iki *NVIDIA Tesla T4* GPU, 2.00 GHz hızında çalışan *Intel Xeon* CPU, 31 GB sistem belleği ve *Ubuntu 22.04 LTS* işletim sistemi kullanılmıştır. Bu donanım yapılandırması; *Hugging Face*, *PyTorch*, *TensorFlow*, *scikit-learn* ve *pandas* gibi önceden yüklenmiş Python veri bilimi paketleriyle birlikte, modelin eğitim ve çıkarım süreçlerinin verimli şekilde yürütülmesini sağlamıştır. Önerilen modelin eğitim süreci toplamda 2.663,11 saniye (yaklaşık 44 dakika 23 saniye) sürmüştür. Test aşamasında ise model 136 örnekten oluşan test kümesini 5,65 saniyede işlemiş ve ortalama örnek başına yaklaşık 41,5 milisaniye çıkarım süresi elde edilmiştir. Bu sonuçlar, modelin düşük gecikmeli (low-latency) işlem yapabilme yeteneğini vurgulamakta olup gerçek zamanlı tıbbi görüntüleme uygulamaları için potansiyel uygunluğunu göstermektedir.

4.6. Karşılaştırmalı Analiz (Comparative Analysis)

Önerilen Görüntü Dönüştürücü (ViT-Large) modelinin başarısını ve literatürdeki konumunu nesnel bir çerçevede değerlendirmek amacıyla tıbbi görüntü sınıflandırma çalışmalarında sıklıkla tercih edilen yedi farklı derin öğrenme mimarisi ile kapsamlı bir karşılaştırmalı analiz gerçekleştirilmiştir. Bu kapsamda *VGG19*, *ResNet50V2*, *Xception*, *InceptionV3*, *InceptionResNetV2* ile *EfficientNet* ailesinden *B0* ve *B7* modelleri önerilen model ile aynı veri kümesi ve ön işleme koşulları altında test edilmiştir. Karşılaştırma sürecinde CNN tabanlı bu modellerin *ImageNet* üzerinde önceden eğitilmiş ağırlıklarından yararlanılmış ve iki aşamalı eğitim (staged training) stratejisiyle ince ayar (fine-tuning) işlemleri gerçekleştirilmiştir. Bu stratejinin ilk aşamasında, önceden eğitilmiş temel modellerin tüm evrişimli katmanları dondurularak (frozen), sadece yeni eklenen sınıflandırma başlıklarının (top layers) tıbbi veri setine uyum sağlaması hedeflenmiştir. Bu sayede rastgele başlatılan üst katman ağırlıklarının, ImageNet'ten gelen hassas öznitelik bilgilerini bozması ("gradyan şoku") engellenmiştir. İkinci aşamada ise tüm mimarinin kilidi açılarak (unfrozen), çok düşük bir öğrenme oranıyla ($1 \times e^{-5}$) tüm katmanlar üzerinde hassas ağırlık güncellemeleri yapılmıştır. Yapılan deneyler sonucunda önerilen modelin tüm CNN tabanlı modelleri geride bırakarak en yüksek sınıflandırma doğruluğuna ulaştığı gözlemlenmiştir. Bunun sebebi, ViT mimarisinin öz-dikkat (self-attention) mekanizması sayesinde tıbbi görüntülerdeki karmaşık dokusal özellikleri ve pikseller arası uzun menzilli bağımlılıkları, yerel evrişim işlemlerine dayanan CNN mimarilerine göre daha efektif bir şekilde modelleyebilmesidir. Özellikle *EfficientNetB7* ve *InceptionResNetV2* gibi parametre sayısı bakımından derin olan modellerin dahi önerilen modelin performansının gerisinde kalması, önerilen yöntemin akciğer kanseri alt tiplerini ayırt etmedeki ayırt edici gücünü ve sağlamlığını (robustness) kanıtlamaktadır.

Tablo 5. Önerilen modelin literatürde yaygın kullanılan CNN mimarileriyle performans karşılaştırması
(Performance comparison of the proposed model with widely used CNN architectures in the literature)

Model	Test Doğruluğu
VGG19	0.8413
ResNet50V2	0.6984
Xception	0.7111
InceptionV3	0.6508
InceptionResNetV2	0.6127
EfficientNetB0	0.6698
EfficientNetB7	0.5968
Önerilen model	0.9850

5. Sonuçlar (Conclusions)

Bu çalışmada göğüs BT görüntülerinden akciğer kanseri alt tiplerinin sınıflandırılması için derin öğrenme temelli bir çerçeve sunulmuştur. Önerilen model dört klinik olarak anlamlı sınıf (*Adenokarsinom*, *Skuamöz Hücreli Karsinom*, *Büyük Hücreli Karsinom* ve *Normal* Akciğer Dokusu) arasında ayırt edici özellikleri etkili biçimde öğrenebilmek için Görsel Dönüştürücü (ViT-Large) mimarisinden yararlanmakta; buna ek olarak seçici jeton düzeyinde dikkat düzenlileştirmesi (selective token-level attention regularization) ve adaptör (adapter) katmanları ile güçlendirilmiştir. *Chest CT-Scan Dataset* isimli veriseti üzerinde gerçekleştirilen kapsamlı deneyler sonucunda önerilen yaklaşım %98,5 sınıflandırma doğruluğu elde ederek karmaşık akciğer kanseri paternlerini ayırt etmede sağlam ve güvenilir bir performans sergilemiştir. Tüm sınıflar için yüksek F1-

skorları ve dengeli bir karışıklık matrisi elde edilmesi modelin gerçek dünyadaki tanısal iş akışlarında potansiyel olarak kullanılabilirliğini doğrulamaktadır. Ayrıca, veri dengeleme tekniklerinin ve katman bazlı öğrenme oranı bozunmasının (layer-wise learning rate decay) entegrasyonu eğitim sürecinde genelleme ve kararlılığın artmasına katkı sağlamıştır. Bulgularımız özellikle dikkat mekanizmasına özgü düzenlileştirme stratejileriyle birleştirildiğinde dönüştürücü tabanlı mimarilerin tıbbi görüntü sınıflandırma görevlerindeki etkinliğini açıkça ortaya koymaktadır.

Mevcut sonuçlar umut verici olmakla birlikte gelecekteki araştırmalar için çeşitli geliştirme alanları bulunmaktadır. İlk olarak, veri kümesinin daha çeşitli vakaları ve çok merkezli görüntüleri içerecek şekilde genişletilmesi, modelin farklı popülasyonlar üzerindeki genellenebilirliğini artırabilir. İkinci olarak, klinik metaverilerin (hasta öyküsü, semptomlar veya genetik belirteçler gibi) görüntü verileriyle bütünleştirilmesi, sınıflandırma performansını daha da iyileştirebilecek çoklu-modalite (multi-modal) bir perspektif sağlayabilir. Ayrıca, Grad-CAM++ veya dikkat tabanlı önem haritaları (attention-based saliency maps) gibi açıklanabilirlik tekniklerinin uygulanması klinisyenlere görsel yorumlama kolaylığı sunarak model tahminlerine duyulan güveni artırabilir. Son olarak, önerilen sistemin klinik karar destek çerçevesine entegre edilmesi ve gerçek dünya sağlık ortamlarında ileriye dönük (prospektif) doğrulama çalışmalarının yapılması bu araştırmanın uygulamaya dönüşebilirliği açısından kritik bir adım olacaktır.

Kaynaklar (References)

1. Sharma R., Mapping of global, regional and national incidence, mortality and mortality-to-incidence ratio of lung cancer in 2020 and 2050, Int J Clin Oncol, 27 (4), 665-675, 2022.
2. Thandra K.C., Barsouk A., Saginala K., Aluru J.S., Barsouk A., Epidemiology of lung cancer, Contemp Oncol, 25 (1), 45-52, 2021.
3. Jung K.W. vd., Prediction of Cancer Incidence and Mortality in Korea, 2025, Cancer Res Treat, 57 (2), 331-338, 2025.
4. Luo G. vd., Projections of Lung Cancer Incidence by 2035 in 40 Countries Worldwide: Population-Based Study, JMIR Public Health Surveill, 9, e43651, 2023.
5. Siegel R.L., Kratzer T.B., Giaquinto A.N., Sung H., Jemal A., Cancer statistics, 2025, CA Cancer J Clin, 75 (1), 10-45, 2025.
6. Thandra K.C., Barsouk A., Saginala K., Aluru J.S., Barsouk A., Epidemiology of lung cancer, Contemp Oncol, 25 (1), 45, 2021.
7. Chen Q. vd., Evaluating the tumor response assessment of modified-RECIST 1.1 in advance non-small cell lung cancer: a post-hoc analysis of 1,147 patients from the EAST-LC trial, Transl Lung Cancer Res, 14 (5), 1688-1698, 2025.
8. Mandala A., Kurapati V.S.R., Musunuri S.R.K., Mutthina J.V.S.C., Sistla V.P.K., Kolli V.K.K., An Experimental Study on Prediction of Lung Cancer from CT Scan Images, Proceedings of the International Conference on Intelligent Systems and Computational Networks (ICISCN 2025), IEEE, 1-6, 2025.
9. Wan Y., Wang D., Li H., Xu Y., The imaging techniques and diagnostic performance of ultrasound, CT, and MRI in detecting liver steatosis and fat quantification: A systematic review, J Radiat Res Appl Sci, 16 (4), 100658, 2023.
10. Priya A., Shyamala Bharathi P., SE-ResNeXt-50-CNN: A deep learning model for lung cancer classification, Appl Soft Comput, 171, 112696, 2025.
11. Chowdary S., Purushotaman S.B., An Improved Archimedes Optimization-aided Multi-scale Deep Learning Segmentation with Dilated Ensemble CNN Classification for Detecting Lung Cancer Using CT Images, Network: Computation in Neural Systems, 2024.
12. Tyagi S., Talbar S.N., Predicting lung cancer treatment response from CT images using deep learning, Int J Imaging Syst Technol, 33 (5), 1577-1592, 2023.
13. Bherje A. vd., Design of Deep Learning-based Approach to Predict Lung Cancer on CT Scan Images, Proceedings of the 5th International Conference on Innovative Trends in Information Technology (ICITIIT 2024), IEEE, Kottayam, India, 1-5, 2024.
14. Park Y.J., Choi D., Choi J.Y., Hyun S.H., Performance Evaluation of a Deep Learning System for Differential Diagnosis of Lung Cancer with Conventional CT and FDG PET/CT Using Transfer Learning and Metadata, Clin Nucl Med, 46 (8), 635-640, 2021.
15. Kim G., Park Y.M., Yoon H.J., Choi J.H., A multi-kernel and multi-scale learning based deep ensemble model for predicting recurrence of non-small cell lung cancer, PeerJ Comput Sci, 9, e1311, 2023.
16. Li L., Zhao X., Lu W., Tan S., Deep learning for variational multimodality tumor segmentation in PET/CT, Neurocomputing, 392, 277-295, 2020.
17. Raza R. vd., Lung-EffNet: Lung cancer classification using EfficientNet from CT-scan images, Eng Appl Artif Intell, 126, 106902, 2023.
18. Jain R., Singh P., Kaur A., An ensemble reinforcement learning-assisted deep learning framework for enhanced lung cancer diagnosis, Swarm Evol Comput, 91, 101767, 2024.
19. Xie Y., Zhang J., Xia Y., Fulham M., Zhang Y., Fusing texture, shape and deep model-learned information at decision level for automated classification of lung nodules on chest CT, Information Fusion, 42, 102-110, 2018.
20. Ashames M.M.A. vd., Indifference subspace of deep features for lung nodule classification from CT images, Expert Syst Appl, 262, 125571, 2025.
21. Riquelme D., Akhloufi M.A., Deep Learning for Lung Cancer Nodules Detection and Classification in CT Scans, AI (Switzerland), 1 (1), 28-67, 2020.
22. Kalkan M., Guzel M.S., Ekinci F., Akcapinar Sezer E., Asuroglu T., Comparative Analysis of Deep Learning Methods on CT Images for Lung Cancer Specification, Cancers (Basel), 16, 3321, 2024.
23. Mastouri R., Khlifa N., Neji H., Hantous-Zannad S., Performance analysis of various deep learning models based on Max-Min CNN for lung nodule classification on CT images, Mach Vis Appl, 35 (83), 1-16, 2024.
24. Uzulmez S., Cifci M.A., Early diagnosis of lung cancer using deep learning and uncertainty measures, Journal of the Faculty of Engineering and Architecture of Gazi University, 39 (1), 385-400, 2024.
25. Alshayeji M.H., Abed S., Lung cancer classification and identification framework with automatic nodule segmentation screening using machine learning, Applied Intelligence, 53, 19724-19741, 2023.
26. Bhandary A. vd., Deep-learning framework to detect lung abnormality – A study with chest X-Ray and lung CT scan images, Pattern Recognit Lett, 129, 271-278, 2020.
27. Rajasekar V., Vaishnnave M.P., Premkumar S., Sarveshwaran V., Rangaraaj V., Lung cancer disease prediction with CT scan and histopathological images feature analysis using deep learning techniques, Results in Engineering, 18, 101111, 2023.
28. Dunn B., Pierobon M., Wei Q., Automated Classification of Lung Cancer Subtypes Using Deep Learning and CT-Scan Based Radiomic Analysis, Bioengineering, 10 (6), 690, 2023.
29. Paszke A. vd., PyTorch: An Imperative Style, High-Performance Deep Learning Library, Proceedings of the Thirty-third Conference on Neural Information Processing Systems (NIPS 2019), Vancouver, Canada, 8026-8037, 2019.
30. Wolf T., Debut L., Sanh V., Chaumond J. vd., Transformers: State-of-the-art Natural Language Processing, Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations, ACL, Online, 38-45, 2020.
31. Harris C.R. vd., Array Programming with NumPy, Nature, 585, 357-362, 2020.
32. The pandas development team, pandas: Python Data Analysis Library, https://pandas.pydata.org, Erişim tarihi: 07 Ocak 2024.
33. Clark A. ve Contributors, Pillow (Python Imaging Library Fork), https://python-pillow.github.io/, Erişim tarihi: 05 Ağustos 2025.
34. Hunter J.D., Matplotlib: A 2D Graphics Environment, Comput Sci Eng, 9 (3), 90-95, 2007.
35. Waskom M.L., seaborn: statistical data visualization, J Open Source Softw, 6 (60), 1-4, 2021.
36. Pedregosa F. vd., Scikit-learn: Machine Learning in Python, J Mach Learn Res, 12, 2825-2830, 2011.
37. Hany M., Chest CT-Scan images Dataset, Kaggle, https://www.kaggle.com/datasets/mohamedhanyyy/chest-ctscan-images/data, Erişim tarihi: 05 Ağustos 2025.

38. Dosovitskiy A. vd., An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale, Proceedings of the 9th International Conference on Learning Representations (ICLR 2021), Vienna, Austria, 2021.

39. Akiba T., Sano S., Yanase T., Ohta T., Koyama M., Optuna: A Next-generation Hyperparameter Optimization Framework, Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'19), Anchorage, USA, 2623-2631, 2019.

40. Hugging Face, Trainer, https://huggingface.co/docs/transformers/en/main_classes/trainer, Erişim tarihi: 05 Ağustos 2025.

41. Loshchilov I., Hutter F., Decoupled Weight Decay Regularization, Proceedings of the 7th International Conference on Learning Representations (ICLR 2019), New Orleans, USA, 1-19, 2019.

42. Hugging Face, Evaluate, https://huggingface.co/docs/evaluate/index, Erişim tarihi: 09 Nisan 2025.

43. Hossain M.S., Basak N., Mollah M.A., Nahiduzzaman M., Ahsan M., Haider J., Ensemble-based multiclass lung cancer classification using hybrid CNN-SVD feature extraction and selection method, PLoS One, 20 (3), e0318219, 2025.

44. Riadi A., Achmad A., Zainuddin Z., Performance Analysis of Optimizers on Convolutional Neural Network for Lung Cancer Classification Using CT Scan Images, Proceedings of the 3rd International Conference on Disruptive Technologies (ICDT 2025), Greater Noida, India, IEEE, 1467-1472, 2025.

45. Chandra Sekhar J., Buvaneswari B., Vimala Devi K., Ezhilarasi P., Muniyandy E., Asif Alisha S., Machine Learning based Early-detection of Lung Cancer Using CT Scan for the Early Identification and Classification, Journal of Electrical Systems, 20 (2s), 828-836, 2024.

46. Rani R., Gupta S., Enhanced Chest Cancer Classification using Convolutional Neural Networks on CT Scan Images for Improved Diagnostic Accuracy, Proceedings of the 5th International Conference on Smart Electronics and Communication (ICOSEC 2024), Trichy, India, IEEE, 1237-1241, 2024.

47. Bumpenje H., Rahmadwati, Abidin Z., Chest Cancer Classification from Chest CT-Scan Images using Deep Learning, Proceedings of the 2024 International Conference on Smart Computing, IoT and Machine Learning (SIML 2024), Surakarta, Indonesia, IEEE, 49-55, 2024.

48. Deepa P., Arulselvi M., Sundaram S.M., Classification of Lung Cancer in Segmented CT Images Using Pre-Trained Deep Learning Models, Int J Electr Electron Res, 12 (1), 154-159, 2024.

49. Mamun M., Mahmud M.I., Meherin M., Abdelgawad A., LCDctCNN: Lung Cancer Diagnosis of CT Scan Images Using CNN Based Model, Proceedings of the 10th International Conference on Signal Processing and Integrated Networks (SPIN 2023), Noida, India, IEEE, 205-212, 2023.

50. Lanjewar M.G., Panchbhai K.G., Charanarur P., Lung cancer detection from CT scans using modified DenseNet with feature selection methods and ML classifiers, Expert Syst Appl, 224, 119961, 2023.

51. Sandag G.A., Kabo D.T., Comparative Analysis of Lung Cancer Classification Models Using EfficientNet and ResNet on CT-Scan Lung Images, CogITo Smart Journal, 10 (1), 259-270, 2024.

52. Sari S., Soesanti I., Setiawan N.A., Best Performance Comparative Analysis of Architecture Deep Learning on CT Images for Lung Nodules Classification, Proceedings of the IEEE 5th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE 2021), Purwokerto, Indonesia, IEEE, 138-143, 2021.

53. Adnan Palash M.I., Yousuf M.A., A Federated Learning-based Model for the Detection of Lung Cancer from CT Scan Images, Proceedings of the 6th International Conference on Electrical Engineering and Information and Communication Technology (ICEEICT 2024), Dhaka, Bangladesh, IEEE, 741-745, 2024.

54. Rehman A., Kashif M., Abunadi I., Ayesha N., Lung Cancer Detection and Classification from Chest CT Scans Using Machine Learning Techniques, Proceedings of the 1st International Conference on Artificial Intelligence and Data Analytics (CAIDA 2021), Riyadh, Saudi Arabia, IEEE, 101-104, 2021.

55. Verma A., Upadhyay A.K., Singh A.K., Joshi G., EfficientNet-B3-Based Automated Lung Cancer Detection System for CT Scans, Proceedings of the 11th Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON 2024), Lucknow, India, IEEE, 1-6, 2024.

56. Ray A., Chakraborty N., ETL-LWNet: An Ensemble of Transfer Learning Based Light Weight Deep Learning Models for Identification of Lung Cancer Type in CT-Scan Images, Proceedings of the Third International Conference on Advanced Computing and Applications (ICACA 2024), Springer, Singapore, 575-585, 2024.

57. Macasoi E.-D., Neagoe V.-E., An Approach to Lung Cancer Detection and Classification from Chest CT-Scan Images Using Deep Convolutional Neural Networks and Decision Fusion as a Diagnostic Tool, Proceedings of the 17th International Conference on Electronics, Computers and Artificial Intelligence (ECAI 2025), Targoviste, Romania, IEEE, 1-6, 2025.

58. Akhand Z.-E.-N. vd., Lung Cancer Detection Using Ensemble Technique of CNN, Proceedings of the International Conference on Information and Communication Technology for Development (ICICTD 2022), Khulna, Bangladesh, Springer, Singapore, 497-507, 2022.

59. Goh Y.T., Chua H.N., Jasser M.B., Wong R.T.K., Issa B., Multi-Class Classification of Lung Cancer Using Streamlined Convolutional Neural Networks, Proceedings of the International Colloquium on Signal Processing and Its Applications (CSPA 2025), Pulau Pinang, Malaysia, IEEE, 301-306, 2025.