



## Performance of Deep Residual Networks in Lung Cancer Classification: An Analysis on Histopathological Images

Merve Yağmurcu<sup>1,a,\*</sup>, Sultan Uzun<sup>1,b</sup>, Özlem Polat<sup>2,c</sup>

<sup>1</sup> Graduate School of Natural and Applied Sciences, Sivas Cumhuriyet University, Sivas, Turkey

<sup>2</sup> Department of Mechatronics Engineering, Faculty of Technology, Sivas Cumhuriyet University, Sivas, Turkey

\*Corresponding author

### Research Article

#### History

Received: 25/11/2024

Accepted: 18/12/2024

#### Copyright



This work is licensed under  
Creative Commons Attribution 4.0  
International License

### ABSTRACT

Lung cancer is one of the most commonly seen and deadly types of cancer worldwide. Early diagnosis of this disease is crucial for prolonging life and improving treatment success. This study focuses on classifying lung cancer from histopathological images and investigates the performance of residual-based models (ResNet18, ResNet34, ResNet50, ResNet50V2, ResNet101, ResNet101V2, ResNet152, ResNet152V2) in classification. The LC25000 dataset, containing three classes—adenocarcinoma, benign, and squamous cell carcinoma—with 5000 images per class, was used. Among the tested models, ResNet18 achieved the highest classification performance with an accuracy of 99.90%. The results demonstrate that ResNet-based models perform excellently in accurately classifying complex histopathological images and highlight the potential of deep learning methods as a practical solution for lung cancer diagnosis.

**Keywords:** Lung Cancer, Histopathological Images, Classification, ResNet

## Derin Rezidüel Ağların Akciğer Kanseri Sınıflandırmadaki Başarımı: Histopatolojik Görüntüler Üzerinde İnceleme

### Araştırma Makalesi

#### Süreç

Geliş: 25/11/2024

Kabul: 18/12/2024

### ÖZ

Akciğer kanseri, dünya genelinde yaygın olarak görülen ve yüksek ölüm oranına sahip kanser türlerinden biridir. Bu hastalığın erken teşhisi, yaşam süresini uzatmak ve tedavi başarısını artırmak açısından hayati önem taşımaktadır. Bu çalışmada, histopatolojik görüntülerden akciğer kanserinin sınıflandırılmasına odaklanılmış ve rezidüel tabanlı modellerin (ResNet18, ResNet34, ResNet50, ResNet50V2, ResNet101, ResNet101V2, ResNet152, ResNet152V2) sınıflandırma üzerindeki başarımı incelenmiştir. Veri seti olarak adenokarsinom, iyi huylu ve skuamöz hücreli karsinom olmak üzere üç sınıfa ayrılan ve her sınıfta 5000 görüntünün olduğu LC25000 veri seti kullanılmıştır. Test edilen modeller arasında ResNet18 %99,90 doğruluk oranı ile en yüksek sınıflandırma performansı göstermiştir. Elde edilen sonuçlar, ResNet tabanlı modellerin karmaşık histopatolojik görüntüleri doğru bir şekilde sınıflandırmada üstün performans sergilediğini ve akciğer kanseri teşhisinde derin öğrenme yöntemlerinin pratik bir çözüm sunabileceğini göstermektedir.

**Anahtar Kelimeler:** Akciğer Kanseri, Histopatolojik Görüntüler, Sınıflama, ResNet

<sup>a</sup> ygmrc.merve@gmail.com

<sup>b</sup> 0009-0000-5749-4337

<sup>c</sup> sultanuzun78@gmail.com

<sup>d</sup> 0000-0002-9383-5108

<sup>e</sup> ozlem.polat@cumhuriyet.edu.tr

<sup>f</sup> 0000-0002-9395-4465

## Giriş

Kanser dünyada insan yaşamını ciddi şekilde tehdit eden ve önemli zararlara yol açan en tehlikeli hastalıkların başında yer almaktadır (Sung ve ark., 2021). Kanser türlerinden biri olan akciğer kanseri, akciğer hücrelerinin kontrolsüz büyümesi ve değişime uğramasıyla oluşur. Akciğer kanserinin dünya genelinde görülme sıklığı, toksik maddelere maruz kalma, solunan zararlı maddeler ve yaşlanan nüfus gibi çeşitli faktörlere bağlı olarak artış göstermiştir. Akciğer kanserlerinin en sık görülen alt tipleri arasında adenokarsinom ve skuamöz hücreli karsinom bulunmaktadır. Küçük hücreli ve büyük hücreli karsinomlar ise diğer histolojik alt türlerdir. Bununla birlikte, küçük ve büyük hücreli karsinomlar genellikle hızlı bir şekilde yayılma eğilimindedir ve akciğerin herhangi bir bölümünde oluşabilir, bu da tedavi sürecini zorlaştırır (Callaghan ve ark., 2013). Skuamöz hücreli karsinom, anormal akciğer hücrelerinin kontrolsüz büyümesi sonucu ortaya çıkar ve bu süreçte bir tümör gelişir. Kanser hücreleri, akciğer çevresindeki lenf düğümleri, karaciğer, adrenal bezler, kemikler ve beyin gibi organlara yayılabilir. Skuamöz hücreli karsinom genellikle akciğerlerin merkezinde ortaya çıkar ve hızlı bir şekilde tespit edilip kontrol altına alınmadığı durumlarda vücudun diğer bölgelerine yayılabilir (Hamed ve ark., 2023a).

Akciğer kanseri, dünya çapında en yüksek ölüm oranlarına sahip büyük kanser türlerinden biridir (Sung ve ark., 2021). Bu ciddi durumla mücadele, şüpheli akciğer nodüllerinin erken teşhisine dayanır. Kanser türünü belirlemek için histopatolojik teşhis büyük önem taşır. Akciğer kanseri histopatolojisi görüntülerinin analizi, hastalığın evresi, moleküler profili ve doku türüne bağlı olarak tedaviye yön vermesi açısından kritik bir gerekliliktir (Masud ve ark., 2021).

Son yıllarda, makine öğrenimi ve derin öğrenme tekniklerinin kanser teşhisine yardımcı olarak kullanılmasıyla önemli gelişmeler kaydedilmiştir. Bu yöntemler, patoloğların iş yükünü azaltmak ve akciğer kanseri tespit sürecini hızlandırmak için kullanılmaktadır. Bu teknolojilerin temel amacı, bilgisayarların görsel bilgiyi insanlar gibi algılamasını, sınıflandırmasını ve analiz etmesini sağlamaktır. Erken teşhis, tedavi yanıtını hızlandırarak hayatta kalma oranını artırmakta ve hayat kurtarıcı olabilmektedir (Hamed ve ark., 2023b). Derin öğrenme yöntemlerinden biri olan Konvülsiyonel Sinir Ağları (CNN-Convolutional Neural Network) (LeCun ve ark., 1998), görüntü analizi ve özellik çıkarımı konularında yüksek verimlilikle kullanılmaktadır. CNN'ler, özellikle biyolojik alanlarda yüksek doğruluk oranları sunarak kanser teşhisinde etkili bir araç haline gelmiştir.

Literatürde akciğer kanserinin histopatolojik görüntülerden sınıflandırılması ile ilgili birçok çalışma mevcuttur. Şeker ve ark. (2024) ön işleme yaptıkları görüntüleri sınıflama amacıyla CNN, EfficientNetB7 ve Vision Transformer (ViT) modellerini kullanmışlardır. En yüksek sınıflandırma başarımını %98,40 ile ViT modelinden elde etmişlerdir. Uçar (2021) çalışmasında öncelikle veri setini DenseNet201, MobileNetV2, VGG16, NASNetLarge, Xception, InceptionV3, VGG19,

EfficientNetB7 ve ResNet152 gibi önceden eğitilmiş derin öğrenme mimarilerini kullanarak sınıflamıştır. Bunlardan en iyi sonucu veren üç mimariden (VGG16+MobileNetV2+Xception) çıkarılan öznelikleri birleştirmiş ve Adaboost, Çok Katmanlı Algılayıcı (MLP-Multi Layer Perceptron), Destek Vektör Makineleri (SVM-Support Vector Machine) ve Rastgele Orman (RF-Random Forest) olmak üzere dört farklı sınıflayıcı ile sınıflamıştır. Bu sınıflayıcılardan da ortalama %97,22 başarımler elde etmiştir. Hatuwal ve Thapa (2020) CNN kullanarak %96,11 eğitim doğruluğu ve %97,2 test doğruluğu elde etmişlerdir.

Sumon ve ark. (2024) görüntülerden özellik çıkarma amacıyla DenseNet121'i kullanmışlardır ve sınıflama amacıyla farklı makine öğrenme tekniklerini denemişlerdir. Yaptıkları testlerde en yüksek başarımları %96,6 ile SVM ile ulaşılmıştır. Hamed ve ark. (2023a) toplam parametre sayısı düşük yeni bir CNN modeli ile geliştirilmiş Light Gradient Boosting Model (LightGBM) sınıflandırıcısını birleştiren yenilikçi bir yöntem sunmuşlardır. Çalışmada, görüntüler ön işleme tabii tutulduktan sonra, önerilen CNN ile özellik çıkarımı yapmışlardır. Sınıflama amacıyla çoklu iş parçacığına sahip LightGBM modeli uygulanmıştır ve %99,6 sınıflama başarımları elde edilmiştir. Katar ve ark. (2024) önerdikleri modelde EfficientNetB0, yerel ikili desen (LBP-Local Binary Pattern) ve ViT kodlayıcı kullanılarak sırasıyla elde edilen derin, dokusal ve bağlamsal özellikleri işlemişlerdir. Bu yöntemde, her bir özellik matrisi ayrı ayrı düzleştirilmiş ve ardından kapsamlı bir özellik vektörü oluşturmak üzere birleştirilmiştir. Bu özellik vektörü, dört farklı makine öğrenmesi algoritmasına giriş olarak verilmiştir. Bu algoritmalar, SVM, Lojistik Regresyon (LR), LightGBM ve Extreme Gradient Boosting (XGBoost)) algoritmalarıdır. Test amacıyla 13 farklı senaryo oluşturulmuş ve en iyi başarımları %99,87 ile EfficientNetB0 + LBP + ViT Kodlayıcı + SVM kombinasyonu ile elde edilmiştir.

Noaman ve ark. (2024) DenseNet201 modelinin renk histogramı teknikleri ile birleşimi sayesinde sınıflandırma doğruluğunu artırmak için yeni bir hibrit özellik seti ortaya koymuşlardır. Yöntem olarak sekiz farklı makine öğrenmesi yöntemi kullanmışlardır: K-En Yakın Komşu (KNN), SVM, LightGBM, CatBoost, XGBoost, Karar Ağaçları (DT-Decision Tree), RF ve Multinomial Naive Bayes (MultiNB). Yapılan testlerde en iyi başarımları KNN ile elde etmişlerdir. Singh ve Singh (2023) yaptıkları araştırmada üç farklı yaklaşımdan RF, SVM ve LR modellerini kullanarak bir topluluk sınıflandırıcı önermişlerdir. Her sınıflandırıcıdan elde edilen tahminler, topluluk sınıflandırıcısını oluşturmak için çoğunluk oylama yöntemi kullanılarak birleştirilmiştir. Akciğere ve kolona ilişkin histopatolojik görüntülerinden derin özellikler, VGG16 ve LBP olmak üzere iki farklı yöntemle çıkarılmıştır. Yapılan testlerde %99 başarımları elde edilmiştir.

Gautam ve ark. (2024) akciğer kanserinin sınıflandırılmasında transfer öğrenme modellerinden faydalanmışlardır. LC25000 veri setinden akciğer kanseri ile ilgili olan 15000 görüntü üzerinde çalışmışlardır. Önce

üç farklı model olan InceptionResNetV1, EfficientNetB7 ve DenseNet121 transfer öğrenme modellerini kullanarak özellik çıkarımı yapmışlardır. Sonrasında Temel Bileşen Analizi (PCA-Principal Component Analysis) ile öznelik seçimi yapmışlar ve her üç modelden elde ettikleri özellikleri birleştirmişlerdir. Sonrasında klasik makine öğrenmesi modellerinden olan SVM ile sınıflama yapmışlardır. Sonuç olarak %99,43 başarımla elde etmişlerdir. Uddin (2024), akciğer kanserinin tespiti ile ilgili yaptığı çalışmada hem histopatolojik görüntüleri hem de bilgisayarlı tomografi (BT) görüntülerini kullanmışlardır. Transfer öğrenme modellerinden DenseNet modelini dikkat tabanlı mekanizmalar ile birleştirip (ATT-DenseNet) sınıflama yapmışlardır. Yaptıkları testler sonucunda histopatolojik görüntüler ve BT görüntüleri üzerinde sırasıyla %95,4 ve %94 sınıflandırma başarımla elde etmişlerdir.

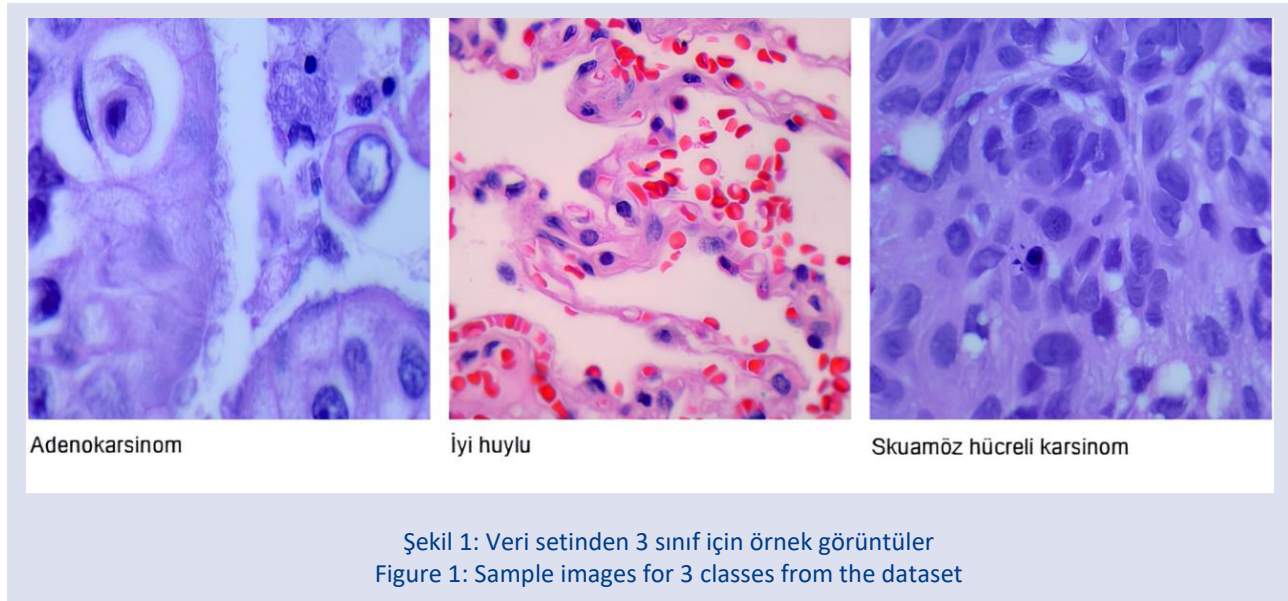
Ramesh ve ark. (2023), dört katmanlı bir CNN kullanarak sınıflama yapmışlardır. Veri seti olarak LC15000'i kullanmışlardır. Veri seti üzerinde çeşitli ön işleme ve veri çoğaltma işlemleri uygulamışlardır. Veri setini eğitim, test ve validasyon olmak üzere sırasıyla %80, %15 ve %5 oranında üç parçaya ayırmışlardır. Test kümesi üzerinde elde ettiği sonuçlarda %89,6 doğruluk değeri elde etmişlerdir. Singh ve ark. (2023) tarafından yapılan çalışmada topluluk öğrenmesi kullanılmıştır. Yöntem olarak transfer öğrenme modellerinden EfficientNetB3, ResNet50, VGG16 ve InceptionNetV2 modelleri tercih edilmiştir. Topluluk modeli VotingClassifier kullanılarak yumuşak oylama modunda oluşturulmuştur. Ön işleme uygulanan veri %80 ve %20 oranında eğitim ve test kümesine bölünmüştür. Yapılan testler sonucunda %99,33 başarımla elde edilmiştir.

Bu çalışmada rezidüel tabanlı derin transfer öğrenme ağlarından ResNet modellerinin akciğer kanserinin histopatolojik görüntülerden tespit edilmesi ve sınıflandırılmasındaki başarımla incelenmiştir. Elde edilen sonuçlar, ResNet tabanlı modellerin görüntü sınıflandırmada önemli ölçüde başarılı olduğunu göstermiştir.

## MATERYAL ve METOT

### Veri Seti

Bu çalışmada, Barkowski ve ekibi tarafından sunulan [LCW25000] akciğer ve kolon kanseri histopatolojik veri seti kullanılmıştır (Borkowski ve ark., 2019). Toplamda çoğaltılarak elde edilen 25000 renkli görüntü içeren bu veri seti, özellikle akciğer kanseri teşhisi ve sınıflandırmasına yönelik kapsamlı bir kaynak sunmaktadır. Veri setindeki akciğer ve kolon kanseri görüntüleri, beş farklı kategoriye ayrılmış olup, bunlardan akciğer ile ilgili olan, adenokarsinom, skuamöz hücreli karsinom, ve iyi huylu olmak üzere her biri 5000'er görüntü içeren üç sınıf analiz edilmiştir. Çalışmada kullanılan açık erişimli Kaggle veri seti (<https://www.kaggle.com/datasets/rm1000/lung-cancer-histopathological-images/data>), akciğer kanseri tanısına yönelik model geliştirme ve değerlendirme süreçlerinde önemli bir katkı sunmuştur. Toplamda 15000 görüntü, 768×768 çözünürlükteki orijinal boyutlarından 224×224 piksel çözünürlüğüne yeniden boyutlandırılarak işlenmiştir. Şekil 1'de sınıflara ait örnek görüntüler yer almaktadır.



## Rezidüel Tabanlı Modeller

Çalışmada, akciğer kanseri teşhisinde histopatolojik görüntülerden otomatik sınıflandırma yapılması hedeflenmiştir. Bu amaç doğrultusunda, derin öğrenme yöntemlerinden biri olan ResNet modelleri tercih edilmiştir. ResNet, 2015 yılında Kaiming He ve ekibi tarafından geliştirilmiş olup, derin sinir ağlarının eğitiminde gradyan sönümlenmesi sorununu çözmek için tasarlanmıştır (He ve ark., 2016a). Modellerin, katmanlar arasına eklenen artık bağlantılar sayesinde bilgi kaybını minimize ederek verimli öğrenmeyi sağlaması, tercih edilmesinin temel nedenlerinden biridir. Ayrıca, transfer öğrenme yaklaşımı ile büyük veri setlerinde önceden eğitilmiş ağırlıkların kullanılması, daha küçük ve farklı veri setlerinde yüksek performans göstermelerini sağlamaktadır (Talukder ve ark., 2024).

Farklı derinliklere sahip sekiz ResNet modeli (ResNet18, ResNet34, ResNet50, ResNet50V2, ResNet101, ResNet101V2, ResNet152 ve ResNet152V2) incelenmiş ve sınıflandırma performansları detaylı şekilde karşılaştırılmıştır. Veri setindeki görüntüler, %80 eğitim ve %20 test olacak şekilde ayrılmış ve tüm modeller aynı veri setleri ile eğitilip test edilmiştir. Model performansları, Kaggle Notebook ortamında GPU T4 x2 kullanılarak adil koşullarda değerlendirilmiştir. Elde edilen sonuçlar, model


derinliğinin sınıflandırma doğruluğu üzerindeki etkisini anlamak için kapsamlı bir analiz sunmaktadır.

### ResNet18

ResNet'in temel modellerinden biri olup, toplamda 18 katmandan oluşur. Bu model, basit bir mimariye sahip olmasına rağmen, artık bağlantılar sayesinde önceki katmanlardan gelen bilgileri sonraki katmanlara doğrudan ileterek gradyan kaybını azaltır ve verimli bir öğrenme sağlar (Ma ve ark., 2021). Düşük donanım gereksinimi ve hızlı işlem süreleriyle öne çıkan ResNet18, küçük ölçekli veri setleri için ideal bir modeldir. Doğruluk ve hız arasında dengeli bir performans sunduğu için, sınıflandırma ve transfer öğrenimi gibi temel derin öğrenme görevlerinde yaygın olarak tercih edilmektedir. Modelin açıklayıcı mimarisi Şekil 2'de sunulmuştur.

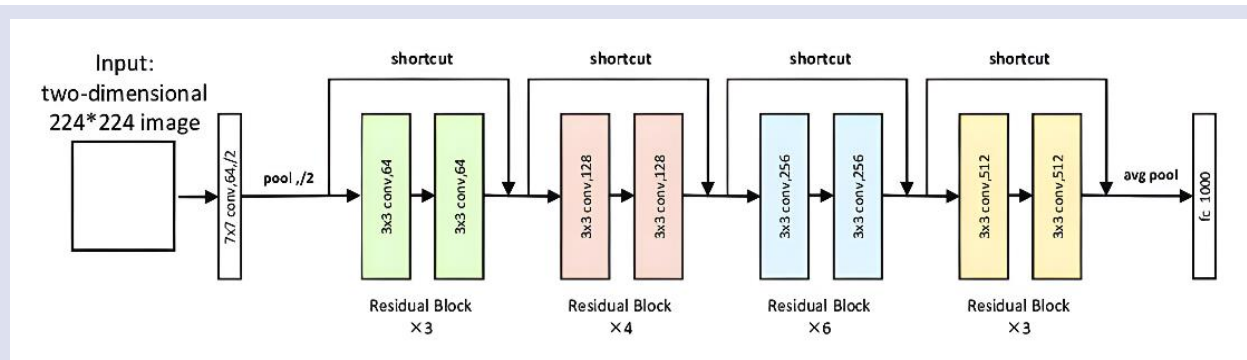
### ResNet34

ResNet18'in daha derin bir versiyonu olarak tasarlanmış, toplamda 34 katmandan oluşan bir derin öğrenme modelidir (He ve ark., 2016a). Artık bağlantılar sayesinde derin ağların etkili bir şekilde eğitim almasını sağlar. Fazla katmanlar, modelin karmaşık ve detaylı özellikleri öğrenmesini sağlar. Hesaplama maliyetleri açısından ResNet34, daha derin bir yapıya sahip olmasına rağmen makul bir seviyede kalarak doğruluk ve işlem süresi arasında dengeli bir performans sunar. ResNet34 modeline ilişkin mimari Şekil 3'te gösterilmektedir.



Şekil 2: ResNet18 modelinin mimari yapısı (Nergiz, 2023)

Figure 2: Architectural structure of the ResNet18 model (Nergiz, 2023)



Şekil 3: ResNet34 modelinin mimari yapısı (Zhang ve ark., 2023)

Figure 3: Architectural structure of the ResNet34 model (Zhang et al., 2023)

### ResNet50

Toplamda 50 katmandan oluşan ve derin öğrenme alanında geniş bir kullanım alanına sahip, güçlü bir modeldir (He ve ark., 2016a). Bu bloklar, giriş verisini önce düşük boyuta indirir. İşlemleri bu boyutta yapar ve ardından boyutu eski haline getirir. Bu yapı, modelin derinliğini artırırken parametre sayısını ve hesaplama yükünü optimize eder. Transfer öğrenimi, özellik çıkarımı ve sınıflandırma gibi görevlerde yaygın olarak kullanılan bu model, derinliği sayesinde daha yüksek doğruluk oranları sunar. Ancak, ResNet18 ve ResNet34 gibi daha basit modellere kıyasla daha yüksek işlem gücü ve bellek kapasitesi gerektirir, bu da onu güçlü donanım ortamları için daha uygun hale getirir. Modele ilişkin mimari Şekil 4'te sunulmuştur.


### ResNet50V2

ResNet50'nin geliştirilmiş bir versiyonu olarak tasarlanmış ve eğitim sürecindeki performansı artırmak için optimize edilmiştir. Bu model, gradyan akışını


iyileştirmeyi hedefler. Bu sayede daha verimli bir öğrenme süreci sağlar. ResNet50'ye kıyasla, ağ mimarisinde yapılan düzenlemeler, modelin eğitim sırasında oluşabilecek hataları azaltır ve daha derin katmanlarda öğrenmeyi kolaylaştırır (He ve ark., 2016b). Ayrıca, normalizasyondaki değişiklikler ve ağırlık optimizasyonları, eğitimi hızlandırır ve etkili hale getirir. ResNet50V2 modelinin mimarisi Şekil 5'te gösterilmektedir.

### ResNet101


Toplamda 101 katmandan oluşan ve derin öğrenme alanında büyük veri setleri üzerinde yüksek doğruluk oranları elde etmek için tasarlanan modeldir (He ve ark., 2016a). Derin yapısı, ince detayları öğrenmesine olanak tanır. ResNet101, blokları kullanarak hesaplama maliyetlerini optimize etse de artan derinlik nedeniyle diğer ResNet modellerine kıyasla daha fazla işlem gücü ve bellek gereksinimi duyar. Modelin açıklayıcı mimarisi Şekil 6'da sunulmuştur.



Şekil 4: ResNet50 modelinin mimari yapısı (Islam ve Tasnim, 2020)  
Figure 4: Architectural structure of the ResNet50 model (Islam and Tasnim, 2020)



Şekil 5: ResNet50V2 modelinin mimari yapısı (Patel ve Khan, 2023)  
Figure 5: Architectural structure of the ResNet50V2 model (Patel and Khan, 2023)



Şekil 6: ResNet101 modelinin mimari yapısı (Kalshetty ve Parveen, 2023)  
Figure 6: Architectural structure of the ResNet101 model (Kalshetty and Parveen, 2023)

### ResNet101V2

ResNet101'in daha optimize edilmiş bir versiyonu olarak geliştirilmiş ve derin öğrenme modellerinde eğitim sürecini daha verimli hale getirmek için tasarlanmıştır. Model, gradyan akışını iyileştiren yapısal değişikliklerle, özellikle derin katmanlarda öğrenme sürecini daha stabil ve etkili bir hale getirir (He ve ark., 2016b). Normalizasyon sırasındaki düzenlemeler ve ağ içindeki bağlantıların optimize edilmesi, modelin daha hızlı eğitim almasını sağlar. Bu iyileştirmeler, derinliği ve hassas öğrenme kapasitesi sayesinde, tıbbi görüntüleme, nesne tanıma ve geniş ölçekli sınıflandırma görevleri gibi doğruluğun kritik olduğu uygulamalarda sıklıkla kullanılmaktadır. Modele ilişkin mimari Şekil 7'de sunulmuştur.


### ResNet152

ResNet ailesinin en derin mimarilerinden biri olan, 152 katmanlı bu model özellikleri ve desenleri hassas bir şekilde öğrenme kapasitesine sahiptir (He ve ark., 2016a). Artan


katman sayısı, daha detaylı ve güvenilir sonuçlar sunarken, aynı zamanda yüksek işlem gücü ve bellek ihtiyaç duyar. Bu nedenle, genellikle güçlü hesaplama altyapısına sahip projelerde etkili bir çözüm olarak tercih edilir. Modelin açıklayıcı mimarisi Şekil 8'de sunulmuştur.

### ResNet152V2


Derin öğrenme alanında eğitim süreçlerini optimize etmek amacıyla geliştirilmiş bir modeldir. Bu sürüm, gradyan akışını iyileştiren mimari değişiklikler ile donatılmıştır; böylece derin katmanlarda karşılaşılan öğrenme zorlukları minimize edilir ve eğitim süreci hızlandırılır (He ve ark., 2016b). Ağırlıkların başlangıç değerleri ve normalizasyon süreçlerindeki iyileştirmeler, modelin performansını ResNet152'ye göre daha etkili hale getirir. Yüksek hesaplama gereksinimlerine rağmen optimize edilmiş yapısı ve detaylı öğrenme kapasitesi ile derin öğrenme problemleri için güvenilir bir çözüm sunmaktadır. Modelin açıklayıcı mimarisi Şekil 9'da sunulmuştur.



Şekil 7: ResNet101V2 modelinin mimari yapısı (Shabrina ve ark., 2023)  
Figure 7: Architectural structure of the ResNet101V2 model (Shabrina et al., 2023)



Şekil 8: ResNet152 modelinin mimari yapısı (Nguyen ve ark., 2018)  
Figure 8: Architectural structure of the ResNet152 model (Nguyen et al., 2018)



Şekil 9: ResNet152V2 modelinin mimari yapısı (Yang ve Lima, 2021)  
Figure 9: Architectural structure of the ResNet152V2 model (Yang and Lima, 2021)

## Deneysel Sonuçlar

### Performans Değerlendirme Metrikleri

Sınıflandırma metrikleri, sağlık, finans, doğal dil işleme ve görüntü işleme gibi çeşitli alanlarda geniş bir uygulama alanına sahiptir (Toğaçar ve ark., 2021). Model performansını değerlendirmek için en temel metriklerden biri doğruluktur ve bu, modelin genel tahmin performansını ölçmek için kullanılır (1). Ancak veri setindeki sınıflar arasında dengesizlik olduğunda doğruluk tek başına yeterli bir gösterge olmayabilir. Bu tür durumlarda, daha hassas ve odaklı metriklerin kullanılması gerekir. Metriklerde örneğin, doğru pozitif (DP) değerler, modelin gerçek pozitif tahminlerini doğru bir şekilde belirleme kapasitesini ifade ederken; doğru negatif (DN) değerler, modelin gerçek negatifleri tanımlama başarısını gösterir. Yanlış pozitif (YP) değerler, modelin pozitif olarak tahmin ettiği ancak gerçekte negatif olan durumları ifade ederken; yanlış negatif (YN) değerler, pozitif olarak sınıflandırılması gereken ancak negatif olarak tahmin edilen örnekleri tanımlar. Bu dört temel bileşen, modelin performansını kapsamlı bir şekilde analiz etmek için çeşitli metriklerin temelini oluşturur.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \quad (1)$$

Metriklerden biri olan kesinlik (2), doğru pozitif tahminlerin toplam pozitif tahminlere oranını ölçerken; duyarlılık (3), gerçek pozitiflerin ne kadarının doğru tahmin edildiğini değerlendirir. Bu iki metriği dengelemek ve genel bir performans değerlendirmesi sağlamak için F1 skoru (4) kullanılır.

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (2)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3)$$

$$F1 \text{ Skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

### Test Sonuçları

Çalışmada, modelin performansını artırmak ve aşırı öğrenmeyi önlemek amacıyla veri ön işleme teknikleri kullanılmıştır. Veri ön işleme kapsamında, görüntülere rastgele yatay çevirme, rastgele döndürme ve rastgele yakınlaştırma gibi işlemler uygulanmıştır. Ayrıca tüm görüntüler 0-1 aralığında normalize edilmiştir. Bu işlemler, modelin farklı görüntü varyasyonlarını öğrenmesini sağlayarak daha genel ve başarılı bir sınıflandırma performansı elde etmeyi hedeflemiştir. Hiperparametre değerleri Çizelge 1'de gösterilmiştir.

Veri seti, %80 eğitim ve %20 test olmak üzere ikiye ayrılmıştır. Çizelge 1'de belirtilen hiperparametre değerleri kullanılarak, ResNet tabanlı modeller bu veri setiyle eğitilmiştir. Modellerin test sonuçları ise Çizelge 2'de sunulmaktadır.

Sonuçlardan anlaşıldığı üzere akciğer kanserinin histopatolojik görüntüler kullanılarak sınıflandırılmasında en iyi performansı %99,90 doğruluk ile ResNet18 modeli göstermiştir. Bu modeli %99,87 ve %99,80 doğruluk oranları ile sırasıyla ResNet101 ve ResNet152 modelleri takip etmektedir. Sonuçlara bakıldığında tüm ResNet modellerinin akciğer kanserini yüksek doğrulukla sınıflandırdığı görülmektedir. En iyi performansa sahip ResNet18 modelinin testine ilişkin karışıklık matrisi Şekil 10'da gösterilmektedir.

Çizelge 1: Hiperparametre Değerleri

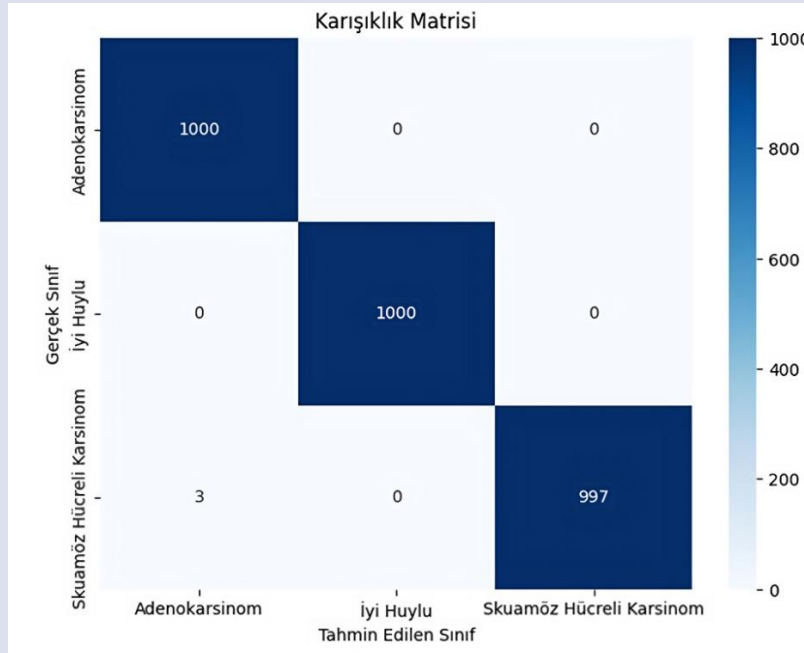
Table 1: Hyperparameter Values

Hiperparametre	Epok Sayısı	Öğrenme Oranı	Aktivasyon Fonksiyonu	Dropout	Batch Size
Değer	25	0,001	Adam	0,2	32

Çizelge 2: ResNet Model Performansları

Table 2: Performances of ResNet Models

	Doğruluk	Duyarlılık	Kesinlik	F1 Skor
ResNet18	0,9990	0,9990	0,9990	0,9990
ResNet34	0,9893	0,9893	0,9897	0,9893
ResNet50	0,9717	0,9717	0,9739	0,9716
ResNet50V2	0,9747	0,9747	0,9747	0,9747
ResNet101	0,9987	0,9987	0,9987	0,9987
ResNet101V2	0,9757	0,9757	0,9757	0,9757
RasNet152	0,9980	0,9980	0,9980	0,9980
ResNet152V2	0,9717	0,9717	0,9717	0,9717



Şekil 10: Karışıklık matrisi  
Figure 10: Confusion matrix

Şekilden görüldüğü üzere adenokarsinom ve iyi huylu sınıfları %100 doğrulukla sınıflandırılmıştır. Skuamöz hücreli karsinom sınıfında ise 1000 örnekten sadece 3 tanesi yanlış sınıflandırılmıştır. Bu sınıfa ilişkin başarımlar ise %99,7'dir. Sonuç olarak tüm sınıflar yüksek doğrulukla sınıflandırılmışlardır.

## Sonuçlar

Akciğer kanseri, dünya genelinde yüksek ölüm oranlarına sahip kanser türlerinden biri olarak halk sağlığı açısından tehdit oluşturmaktadır. Bu hastalığın erken teşhisi, hastaların yaşam süresini ve yaşam kalitesini önemli ölçüde artırabilir. Ancak geleneksel tanı yöntemleri zaman alıcı olduğundan yenilikçi yaklaşımlara ihtiyaç duyulmaktadır. Yapay zeka, özellikle derin öğrenme tabanlı modellerle, akciğer kanseri gibi hastalıkların teşhisinde büyük bir potansiyel sunmaktadır.

Rezidüel ağlar, kaybolan gradyan problemini çözme yetenekleri ve tıbbi görüntülerdeki karmaşık desenleri iyi bir şekilde öğrenebilme kapasiteleri nedeniyle kullanılır. Çalışmamızda, akciğer kanseri histopatolojik görüntülerinin sınıflandırılmasında farklı rezidüel ağ tabanlı modeller (ResNet18, ResNet34, ResNet50, ResNet50V2, ResNet101, ResNet101V2, ResNet152, ResNet152V2) kullanılmıştır. Farklı ResNet modelleri değerlendirilmiş ve tüm modellerin %95'in üzerinde sınıflandırma doğruluğu elde ettiği görülmüştür.

Modeller arasında en yüksek performansı, %99,90 doğruluk oranıyla ResNet18 modeli göstermiştir. ResNet18'in üstün başarısı, daha basit bir mimariye ve diğer modellere kıyasla düşük hesaplama maliyetine sahip olmasıyla öne çıkmaktadır. Bu özellikler, ResNet18'i yalnızca yüksek doğruluk oranı sunan bir model değil, aynı

zamanda verimlilik açısından da öne çıkan bir seçenek haline getirmektedir. Bu nedenle, ResNet18, sınırlı donanım kapasitesine sahip sistemlerde ve hızlı sonuç gerektiren uygulamalarda kullanım için özellikle iyi bir alternatif olarak değerlendirilmektedir. Elde edilen sonuçlar, ResNet tabanlı modellerin yalnızca tıbbi görüntüleme alanında değil, biyomedikal analiz, genetik araştırmalar, uzaktan algılama, endüstriyel kalite kontrol ve tarım gibi farklı alanlarda da uygulanabileceğini göstermektedir.

Bu çalışmada, ResNet tabanlı modellerin tıbbi tanı süreçlerinde yüksek doğruluk ve hassasiyet sağlayarak insan sağlığına önemli katkılar sunabileceğini gösterilmiştir. Gelecekteki çalışmalarda, hiperparametre optimizasyon algoritmalarının uygulanmasıyla bu modellerin performans ve verimliliğinin daha da artırılması hedeflenmektedir.

## Kaynaklar

- Borkowski, A. A., Bui, M. M., Thomas, L. B., Wilson, C. P., DeLand, L. A., & Mastorides, S. M. (2019). Lung and colon cancer histopathological image dataset (lc25000). arXiv preprint arXiv:1912.12142.
- Callaghan, R. C., Allebeck, P., & Sidorchuk, A. (2013). Marijuana use and risk of lung cancer: a 40-year cohort study. *Cancer Causes & Control*, 24, 1811-1820.
- Gautam, N., Ghosh, S., & Sarkar, R. (2024). Cnn models aided with a metaclassifier for lung Carcinoma classification using histopathological images. *Multimedia Tools and Applications*, 1-25.
- Hamed, E. A. R., Salem, M. A. M., Badr, N. L., & Tolba, M. F. (2023a). An efficient combination of convolutional neural network and LightGBM algorithm for lung cancer histopathology classification. *Diagnostics*, 13(15), 2469.



- Hamed, E. A. R., Salem, M. A. M., Badr, N. L., & Tolba, M. F. (2023b, March). Lung Cancer Classification Model Using Convolution Neural Network. In *The International Conference on Artificial Intelligence and Computer Vision* (pp. 16-26). Cham: Springer Nature Switzerland.
- Hatuwal, B. K., & Thapa, H. C. (2020). Lung cancer detection using convolutional neural network on histopathological images. *Int. J. Comput. Trends Technol*, 68(10), 21-24.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016a). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016b). Identity mappings in deep residual networks. In *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14* (pp. 630-645). Springer International Publishing.
- Islam, M., & Tasnim, N. (2020). Human gender classification using transfer learning via Pareto Frontier CNN networks. *Inventions* 5, 16.
- Kalshetty, R., & Parveen, A. (2023). Abnormal event detection model using an improved ResNet101 in context aware surveillance system. *Cognitive Computation and Systems*, 5(2), 153-167.
- Katar, O., Yildirim, O., Tan, R. S., & Acharya, U. R. (2024). A Novel Hybrid Model for Automatic Non-Small Cell Lung Cancer Classification Using Histopathological Images. *Diagnostics*, 14(22), 2497.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Ma, S., Huang, T., Sun, X., & Wei, Y. (2021, May). Driver Drowsiness Detection Based On ResNet-18 And Transfer Learning. In *2021 33rd Chinese Control and Decision Conference (CCDC)* (pp. 2390-2394). IEEE.
- Masud, M., Sikder, N., Nahid, A. A., Bairagi, A. K., & AlZain, M. A. (2021). A machine learning approach to diagnosing lung and colon cancer using a deep learning-based classification framework. *Sensors*, 21(3), 748.
- Nergiz, M. (2023). Federe Öğrenmede Birleştirme Algoritmalarının Model Performansına Etkisi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 14(1), 65-73.
- Nguyen, L. D., Lin, D., Lin, Z., & Cao, J. (2018, May). Deep CNNs for microscopic image classification by exploiting transfer learning and feature concatenation. In *2018 IEEE international symposium on circuits and systems (ISCAS)* (pp. 1-5). IEEE.
- Noaman, N. F., Kanber, B. M., Smadi, A. A., Jiao, L., & Alsmadi, M. K. (2024). Advancing Oncology Diagnostics: AI-Enabled Early Detection of Lung Cancer through Hybrid Histological Image Analysis. *IEEE Access*.
- Patel, S., & Khan, N. R. (2023). A Weighted-Average-Ensembling Based Hybrid CNN Model for Improved Covid-19 Detection.
- Ramesh, M., Maheswaran, S., Theivanayaki, S., Kodeeswari, K., Krishnasamy, L., & Sriram, N. (2023, July). Efficient Lung Cancer Classification on Multi level Convolution Neural Network using Histopathological Images. In *2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1-7). IEEE.
- Shabrina, N. H., Lika, R. A., & Indarti, S. (2023). Deep learning models for automatic identification of plant-parasitic nematode. *Artificial Intelligence in Agriculture*, 7, 1-12.
- Singh, O., & Singh, K. K. (2023). An approach to classify lung and colon cancer of histopathology images using deep feature extraction and an ensemble method. *International journal of information technology*, 15(8), 4149-4160.
- Singh, O., Singh, K. K., Das, S., Akbari, A. S., & Abd Manap, N. (2023, October). Classification of lung cancer from histopathology Images using a Deep Ensemble Classifier. In *2023 IEEE International Conference on Imaging Systems and Techniques (IST)* (pp. 1-6). IEEE.
- Sumon, R. I., Mazumdar, M. A. I., Uddin, S. M. I., & Kim, H. C. (2024, July). Exploring Deep Learning and Machine Learning Techniques for Histopathological Image Classification in Lung Cancer Diagnosis. In *2024 International Conference on Electrical, Computer and Energy Technologies (ICECET)* (pp. 1-6). IEEE.
- Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., & Bray, F. (2021). Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: a cancer journal for clinicians*, 71(3), 209-249.
- Şeker, D., Kartal, M. S., Yıldız, A., & Öksüz, İ. (2024). Akciğer Kanseri Tespitinde Dönüşüm ve Evrişim Tabanlı Modeller ile Açıklanabilir Yapay Zeka Uygulaması. *EMO Bilimsel Dergi*, 14(2), 59-69.
- Talukder, M. A., Layek, M. A., Kazi, M., Uddin, M. A., & Aryal, S. (2024). Empowering covid-19 detection: Optimizing performance through fine-tuned efficientnet deep learning architecture. *Computers in Biology and Medicine*, 168, 107789.
- Toğaçar, M., Eşidir, K. A., & Ergen, B. (2021). Yapay Zekâ Tabanlı Doğal Dil İşleme Yaklaşımını Kullanarak İnternet Ortamında Yayınlanmış Sahte Haberlerin Tespiti. *Journal of Intelligent Systems: Theory and Applications*, 5(1), 1-8.
- Uçar, E. (2021). Akciğer Histopatoloji Görüntülerinden Çıkarılan Derin Özellikleri Kullanan Makine Öğrenmesi Sınıflandırıcıları ile Akciğer Kanseri Tespiti. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 10(4), 1552-1562.
- Uddin, J. (2024). Attention-Based DenseNet for Lung Cancer Classification Using CT Scan and Histopathological Images.
- Yang, L., & Lima, D. (2021). Covid-19 Recognition by Chest CT and Deep Learning. *EAI Endorsed Transactions on e-Learning*, 7(23), e3-e3. *Designs*, 8(2), 27.
- Zhang, Z., Wang, S., Li, Z., Gao, F., & Wang, H. (2023). A Multi-Dimensional Covert Transaction Recognition Scheme for Blockchain. *Mathematics*.