

---

*Araştırma Makalesi / Research Article*

---

## **Akciğer Histopatoloji Görüntülerinden Çıkarılan Derin Özellikleri Kullanan Makine Öğrenmesi Sınıflandırıcıları ile Akciğer Kanseri Tespiti**

Emine UÇAR\*

*İskenderun Teknik Üniversitesi, İşletme ve Yönetim Bilimleri Fakültesi, Yönetim Bilişim Sistemleri Bölümü,  
Hatay*

(ORCID: [0000-0002-6838-3015](https://orcid.org/0000-0002-6838-3015))

---

### **Öz**

Kanser dünyada ve ülkemizde gözlenme sıklığı giderek artan sağlık sorunlarının başında gelmekte ve her yıl milyonlarca insan kanser nedeniyle hayatını kaybetmektedir. Histopatolojik tanı, kanser türünün teşhisinde ve tedavi stratejisinin belirlenmesinde önemli bir rol oynamaktadır. Bu çalışmada akciğer histopatoloji görüntüleri kullanılarak derin öğrenme yöntemlerine dayalı bir otomatik model geliştirilmesi amaçlanmıştır. Geliştirilen modelde öncelikle DenseNet201, MobileNetV2, VGG16, NASNetLarge, Xception, InceptionV3, VGG19, EfficientNetB7 ve ResNet152 gibi önceden eğitilmiş derin öğrenme mimarileri kullanılarak özellik çıkarımı gerçekleştirilmiş ve daha sonra Adaboost, Çok katmanlı algılayıcı, Rastgele orman ve Destek vektör makinesi gibi makine öğrenmesi yöntemleri ile sınıflandırılmıştır. Ardından sınıflandırıcılardan elde edilen değerlendirme sonuçlarına göre en iyi performansa sahip ilk üç derin öznelik birleştirilerek makine öğrenmesi sınıflandırıcılarına girdi olarak kullanılmıştır. Deneysel sonuçlar en iyi özneliklerin birlikte kullanılmasının sınıflandırma başarısına olumlu yönde katkı sağladığını göstermiştir. Test veri setinden elde edilen sonuçlar, önerilen hibrit yaklaşımın %97.22 ortalama sınıflandırma başarısı ile akciğer histopatoloji görüntülerinden adenokarsinom, skuamöz hücreli karsinom ve normal dokuların otomatik sınıflandırmasında etkili olduğunu göstermiştir.

**Anahtar kelimeler:** Akciğer kanseri tespiti, Sınıflandırma, Derin öğrenme, Makine öğrenmesi.

---

## **Lung Cancer Detection with Machine Learning Classifiers using Deep Features Extracted from Lung Histopathology Images**

---

### **Abstract**

Cancer is one of the health problems with an increasing incidence in the world and in our country, and millions of people die every year due to cancer. Histopathological diagnosis plays an important role in diagnosing the type of cancer and determining the treatment strategy. In this study, it is aimed to develop an automatic model based on deep learning methods using lung histopathology images. In the developed model, firstly feature extraction was performed using pre-trained deep learning architectures such as DenseNet201, MobileNetV2, VGG16, NASNetLarge, Xception, InceptionV3, VGG19, EfficientNetB7 and ResNet152, and then classified with machine learning methods such as Adaboost, Multi-layer perceptron, Random forest and Support vector machines. Afterwards, according to the evaluation results obtained from the classifiers, the first three deep features with the best performance were combined and used as input to the machine learning classifiers. Experimental results showed that using the best features together contributes positively to the classification success. Results from the test dataset showed that the proposed hybrid approach was effective in automatic classification of adenocarcinoma, squamous cell carcinoma and benign tissues from lung histopathology images, with an average classification accuracy of 97.22%.

**Keywords:** Lung cancer detection, Classification, Deep learning, Machine learning.

---

---

\*Sorumlu yazar: [emine.ucar@iste.edu.tr](mailto:emine.ucar@iste.edu.tr)

Geliş Tarihi: 16.08.2021, Kabul Tarihi: 18.11.2021

## 1. Giriş

Akciğer kanseri, hem ülkemizde hem de dünyada en çok ölüme neden olan hastalıklar arasında ilk sıralarda yer almaktadır. Kanser nedeni ile gerçekleşen ölümlere bakıldığında; akciğer kanseri erkeklerde birinci sırada yer alırken kadınlarda ise meme kanserinden sonra 2. sırada yer almaktadır [1]. Dünyada ölüm oranı yüksek olan akciğer kanserlerinin yaklaşık %80'i küçük hücreli dışı akciğer kanseri (KHDAK)'dir. KHDAK'ler, adenokarsinom, skuamöz (yassı) hücreli kanser, büyük hücreli kanser ve karma tip olmak üzere dört alt tipe sahiptir. Adenokarsinomlar ve skuamöz karsinomlar tüm KHDAK'lerin yaklaşık %50'sini temsil eder [2, 3]. Akciğer kanserinin henüz tam olarak bir tedavisi bulunmadığından hastalığın erken aşamada teşhis edilmesi tedavi açısından oldukça büyük önem arz etmektedir.

Derin öğrenme yöntemlerinin kullanım alanları son yıllarda sağlık sektöründe oldukça artmıştır. Özellikle tıbbi görüntü işleme alanında oldukça iyi sonuçlar vermektedir [4]. Histopatolojik görüntü, kanser tanısının altın standardı olarak görülmektedir ve derin öğrenme histopatolojik görüntü analizi zorlukları için de umut verici çözümler sunmaktadır [5]. Bu çalışmada akciğer histopatoloji görüntülerinden adenokarsinom, skuamöz hücreli karsinom ve normal dokuların sınıflandırılması için önceden eğitilmiş derin öğrenme yöntemleri ve klasik makine öğrenmesi yöntemleri birlikte kullanılarak hibrit bir yaklaşım sunulmuştur. Önerilen yaklaşımda öncelikle derin özellikleri çıkarmak için birçok önceden eğitilmiş konvolüsyonel sinir ağı modeli kullanılmış ardından makine öğrenmesi yöntemleri ile sınıflandırma işlemi gerçekleştirilmiştir. Özetle önerilen yaklaşımın katkıları şunlardır:

- Akciğer histopatoloji görüntülerinden tümör tipinin etkili bir şekilde sınıflandırılması için derin özellik çıkarmaya dayalı otomatik bir model tasarlanmıştır.
- Çıkarılan derin özelliklerden en iyi performansa sahip ilk üç derin özellik makine öğrenmesi teknikleri ile sınıflandırılmış ve yüksek bir doğruluk performansı elde edilmiştir.

Bu çalışmanın geri kalanı şu şekilde düzenlenmiştir. Bölüm 2'de mevcut alanda daha önce gerçekleştirilen çalışmalardan bahsedilmiştir. Bölüm 3'te çalışmada kullanılan veri seti ve önerilen derin öğrenme modelinin detayları sunulmuştur. Deneysel analizler ve elde edilen sonuçlar Bölüm 4'te paylaşılmıştır. Bölüm 5'te çalışmada elde edilen sonuçların literatürde daha önce gerçekleştirilen çalışmalarla kıyaslandığı bir tartışma bölümü sunulmuştur. Son olarak çalışma Bölüm 6'da sonuçlandırılmıştır.

## 2. Literatür Taraması

Literatürde akciğer kanserinin tespiti için önerilen çeşitli çalışmalar bulunmaktadır [6]. Bazı araştırmacılar geleneksel makine öğrenmesi yöntemlerini kullanarak akciğer kanserini tespit etmeye ve sınıflandırmaya çalışmışlardır. Dandil ve diğerleri akciğer kanseri teşhisi için yapay sinir ağları yöntemiyle iyi huylu ve kötü huylu nodülleri sınıflandırdıkları çalışmalarında modelin %90.63 doğruluk elde ettiğini bildirmişlerdir [7]. Chauhan ve Jaiswal temel bileşenler analizi ve lineer diskriminant analizi yöntemlerini kullanarak akciğer kanserini tespit etmeye çalışmışlar ve önerilen modelin %97.97 gibi yüksek bir doğruluk elde ettiğini bildirmişlerdir [8]. Faisal ve diğerleri akciğer kanseri tanısı için halka açık bir veri seti üzerinde destek vektör makinesi (DVM), çok katmanlı algılayıcı, Naive Bayes, karar ağacı, Rastgele Orman (RO) ve gradient boosting gibi birçok yöntem kullanmıştır. Gradient boosting algoritmasının %90 kesinlik sağlayarak en iyi sonucu verdiğini bildirmişlerdir [9]. Nasser ve Abu-Naser akciğer kanserini teşhis etmek için yapay sinir ağlarını (YSA) kullanmışlardır. Hastalara ait cinsiyet, yaş gibi değişkenlerin yanı sıra akciğer kanserinin tespitinde kullanılan bazı semptomları da YSA için girdi değişkenleri olarak kullandıkları çalışmalarında modelin %96.67 doğruluğa eriştiğini bildirmişlerdir [10]. Thallam ve diğerleri çalışmalarında akciğer kanserini erken bir aşamada tespit edebilmek için DVM, k en yakın komşu, RO, YSA ve hibrit bir model kullanarak modellerin doğruluk performanslarını karşılaştırmışlardır [11].

Bazı araştırmacılar ise akciğer kanseri tespiti için derin öğrenme yöntemlerini kullanmıştır. Shen ve diğerleri akciğer nodüllerini sınıflandırmak için çok ölçekli konvolüsyonel sinir ağlarını için

kullandıkları çalışmada %86.84 başarı elde ettiklerini bildirmişlerdir [12]. Rao ve diğerleri akciğer görüntülerinde görülen tümörleri iyi huylu ve kötü huylu olarak sınıflandırdıkları çalışmada konvolüsyonel sinir ağlarına dayalı yeni bir model önermişlerdir ve önerilen modelin hem geleneksel sinir ağlarından hem de görüntü sınıflandırma amaçları için oluşturulmuş mevcut CNN'lerden daha iyi performans gösterdiğini bildirmişlerdir [13]. Alakwaa ve diğerleri akciğer kanseri tespiti için sırasıyla segmentasyon, nodül tespiti ve sınıflandırma süreçlerini içeren bir model önermişlerdir. Sınıflandırma aşamasında kullanılan 3D konvolüsyonel sinir ağı modeli test veri seti üzerinde %86.6'lık bir doğruluk elde etmiştir [14]. Bir başka çalışmada Song ve diğerleri akciğerde bulunan nodülleri iyi huylu ve kötü huylu olarak tespit edebilmek için konvolüsyonel sinir ağı, derin sinir ağı ve yığın oto kodlayıcı sinir ağı olmak üzere üç farklı derin sinir ağı tasarlamışlardır. Tasarlanan modellerin performansını test ettiklerinde en başarılı modelin %84.15 doğruluk ile konvolüsyonel sinir ağı olduğunu bildirmişlerdir [15]. Shakeel ve diğerleri akciğer kanseri tespiti probleminin çözümü için öncelikle görüntü iyileştirme ardından derin öğrenme modelleri kullanarak sınıflandırma içeren bir yaklaşım önermişlerdir. Önerilen modelin %98.42 doğruluğa eriştiğini bildirmişlerdir [16]. Abbas ve diğerleri akciğer histopatolojik görüntülerinden adenokarsinom, skuamöz hücreli karsinom ve normal dokuların tespiti için öncelikle yatay-dikey döndürme, yakınlaştırma ve aydınlatma yöntemlerini kullanarak veri artırımı gerçekleştirmiş daha sonra altı farklı derin öğrenme mimarisinden yararlanarak görüntüleri sınıflandırmıştır. Önerilen yöntemlerin %97 üzerinde doğruluk oranına ulaştığını bildirmişlerdir [17]. Masud ve diğerleri akciğer ve kolon kanseri teşhisi için histopatolojik görüntüleri analiz ederek sınıflandıran derin öğrenme temelli yeni bir yaklaşım önermişlerdir. Deneysel çalışmalar sonucunda önerilen yaklaşımın en yüksek %96.33 sınıflandırma doğruluğuna ulaştığını bildirmişlerdir [18]. Garg ve Garg histopatolojik görüntülerden akciğer ve kolon kanseri tanısı için öncelikle çeşitli veri artırım teknikleri aracılığıyla yeni veriler üretmiş daha sonra VGG16, NASNetMobile, InceptionV3, InceptionResNetV2, ResNet50, Xception, MobileNet, ve DenseNet169 gibi önceden eğitilmiş konvolüsyonel sinir ağı modellerini kullanarak sınıflandırma yapmışlardır. Sınıflandırmada kullanılan modellerin %96 ila %100 arasında doğruluk değeri elde ettiklerini bildirmişlerdir [19]. Bir başka çalışmada Hatuwal ve Thapa akciğer kanseri sınıflandırma görevi için histopatolojik görüntülerde öncelikle yatay-dikey döndürme ve yakınlaştırma yöntemlerini kullanarak veri artırımı gerçekleştirmiştir. Daha sonra konvolüsyonel sinir ağı modelini kullanarak sınıflandırdıkları çalışmada %97.2 doğruluk değeri elde ettiklerini bildirmişlerdir [20].

Son yıllarda akciğer kanseri tanısında derin öğrenme mimarilerinin kullanımında bir artış olduğu ancak yeni modeller ve deneysel çalışmalarla ilgili literatürde hala bazı boşluklar olduğu gözlemlenmiştir. Bu nedenle bu çalışmada önerilen derin özellik çıkarmaya dayalı hibrit yaklaşımın yüksek doğruluk oranı ile mevcut literatüre geçerli bir katkı sağlayacağı düşünülmektedir.

### 3. Materyal ve Metot

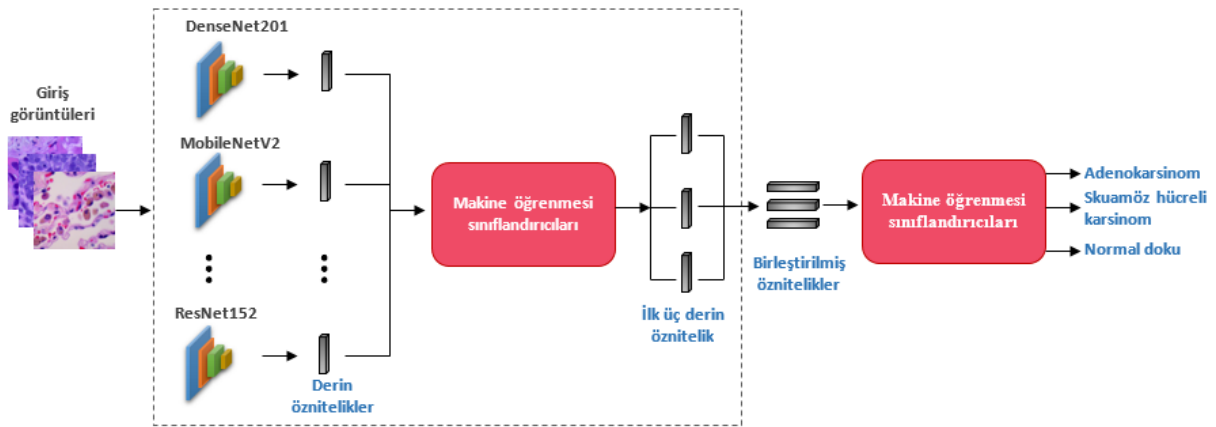
#### 3.1. Veri Seti

Bu çalışmada Borkowski ve diğerleri tarafından oluşturulan akciğer ve kolon kanseri histopatolojik görüntü veri seti (LC25000) kullanılmıştır [21]. Veri seti içerisinde 25000 adet görüntü bulunmaktadır ancak bu çalışmada akciğer kanseri teşhisi amaçlandığından sadece akciğer histopatolojik görüntülerinden adenokarsinom, skuamöz hücreli karsinom ve normal dokuların her birine ait 5000 görüntü dahil edilmiştir. Toplamda 15000 görüntüden oluşan veri seti 768×768 çözünürlüğe sahip jpeg formatındadır. Şekil 1'de her bir sınıfa ait örnek görüntüler sunulmaktadır.



### 3.2. Önerilen Yöntem

Akciğer histopatoloji görüntülerinden adenokarsinom, skuamöz hücreli karsinom ve normal dokuların tespiti için geliştirilen yöntemde öncelikle görüntüler çalışmada kullanılan önceden eğitilmiş konvolüsyonel sinir ağı modellerinin giriş boyutlarına uygun olarak yeniden boyutlandırılmıştır. İkinci aşamada DenseNet201, MobileNetV2, VGG16, NASNetLarge, Xception, InceptionV3, VGG19, EfficientNetB7 ve ResNet152 mimarileri kullanılarak öznetelikler çıkarılmış ve Adaboost, Çok katmanlı algılayıcı, Rastgele orman ve Destek vektör makinesi gibi makine öğrenmesi yöntemleri ile sınıflandırılmıştır. Ardından sınıflandırıcılardan elde edilen değerlendirme sonuçlarına göre en iyi performansa sahip ilk üç derin öznetelik topluluk modülünde birleştirilmiş ve nihai çıktıyı tahmin etmek için makine öğrenmesi sınıflandırıcılarına girdi olarak kullanılmıştır. Çalışmada önerilen yöntemin mimarisi Şekil 2’de gösterilmektedir.



### 3.3. Önceden Eğitilmiş Konvolüsyonel Sinir Ağı Modelleri ile Özellik Çıkarımı

Derin öğrenme, özellik çıkarma ve dönüştürme için derin konvolüsyonel sinir ağları kullanan makine öğrenmesi yaklaşımıdır. Konvolüsyonel sinir ağları, günümüzde sınıflandırma ve nesne tanıma problemlerinin çözümünde oldukça başarılı sonuçlar elde etmektedir. Konvolüsyonel sinir ağları özellikle büyük veri setlerinde daha iyi performansa sahiptir. Transfer öğrenmede genellikle büyük veri kümeleri üzerinde önceden eğitilmiş model farklı bir görev için özellik çıkarıcı olarak kullanılabilir [22]. Transfer öğrenimi sayesinde derin öğrenme modellerini sıfırdan eğitmek için normalde gerekli olan uzun eğitim süresi azaltılır ve aynı zamanda eğitim modeli için büyük bir veri kümesine sahip olma gereksinimi ortadan kalkar [23, 24].

Bu çalışmada transfer öğrenme yaklaşımı kullanılarak derin öğrenme tabanlı bir özellik çıkarıcı olarak önceden eğitilmiş konvolüsyonel sinir ağı modelleri kullanılmıştır. Özellik çıkarma aşamasında DenseNet201, MobileNetV2, VGG16, NASNetLarge, Xception, InceptionV3, VGG19, EfficientNetB7 ve ResNet152 derin öğrenme mimarilerinden yararlanılmıştır.

### 3.4. Makine Öğrenmesi Sınıflandırıcıları

Önceden eğitilmiş konvolüsyonel sinir ağı modellerinden çıkarılan derin özellikler daha sonra çıkışı tahmin etmek için, Adaboost, Çok katmanlı algılayıcı, Rastgele orman ve Destek vektör makinesi gibi geleneksel makine öğrenmesi sınıflandırıcılarının girdisi olarak kullanılmıştır.

Adaboost topluluk sınıflandırıcı yöntemi ilk olarak Freund ve Schapire tarafından önerilmiştir. Bu yöntem zayıf sınıflandırıcıları bir araya getirerek güçlü bir sınıflandırıcı oluşturur. Her bir iterasyonda temel öğrenici adı verilen bir öğrenme algoritması çağırılarak sınıflandırıcı oluşturulur. Ardından bu sınıflandırıcıya ağırlık katsayısı atanır. Son sınıflandırma kararı ise zayıf sınıflandırıcıların ağırlık katsayılarına bağlı olarak ağırlıklı oylama sonucunda elde edilir [25].

Çok katmanlı algılayıcı yapay sinir ağı algoritmaları arasında en çok tercih edilen yöntemler arasında olup çeşitli hastalıkların teşhisinde yaygın olarak kullanılmaktadır. Genellikle çalışmalarda giriş katmanı, gizli katman ve çıkış katmanından oluşan üç katmanlı yapı kullanılmaktadır. Bu yapıda katmanları birbirine bağlayan ağ ağırlıkları, hata geri yayılım öğrenme yöntemi kullanılarak güncellenir. Daha sonra hesaplanan ağ çıkışı ile gerçek çıkış arasındaki ortalama kare hatası elde edilir ve bu hata değeri ağ ağırlıklarını güncellemek için kullanılır. Bu rutin ortalama kare hatası belirli bir eşik değerine düşürülene kadar tekrarlanır [26].

Rastgele orman, ilk olarak 1996 yılında Breiman tarafından ortaya atılmış olup karar ağaçlarının birleşiminden oluşan bir algoritmadır. Bu yöntemde kullanılan her bir ağaç veri setindeki özelliklere göre dallanmaktadır ve her bir ağaç giriş vektörünü sınıflandırmak için birim oyu verir. Rastgele orman algoritmasında aşırı öğrenme sorununu aşmak için öznelik setinden rassal olarak birçok alt set seçilir. Seçilen alt setlerin ürettiği sonuçlar arasında en fazla birim oyunu alan değer, Rastgele orman algoritmasının sonucunu oluşturur [27].

Destek vektör makineleri ilk olarak Vapnik tarafından geliştirilmiş ve bugünkü standart halini Cortes ve Vapnik'in birlikte geliştirmesiyle almıştır [28]. DVM, sınıflandırma problemlerinin çözümü için ilk olarak verileri lineer olarak ayrılabilirliği yüksek bir boyuta aktarmaktadır. Sonrasında da bunlar arasındaki maksimum sınırın bulunmasını sağlamaktadır. DVM, birçok sınıflandırma probleminin çözümünde başarıyla uygulanmış ve yüksek genelleme performansı ile ön plana çıkmış bir makine öğrenmesi algoritmasıdır.

### 3.5. Performans Ölçütleri

Bu çalışmada önerilen yaklaşımın sınıflandırma başarısının ölçümü için karmaşıklık matrisi kullanılmış ve doğruluk, duyarlılık, kesinlik, özgüllük ve  $F_1$  ölçütü olmak üzere toplamda 5 farklı performans ölçütü kullanılmıştır. Doğruluk; doğru olarak sınıflandırılan örnek sayısının toplam örnek sayısına oranı olarak hesaplanmaktadır. Duyarlılık; gerçek pozitif değerler içinde doğru sınıflandırılmış örnek sayısının, tüm gerçek pozitif örnek sayısına oranı olarak hesaplanmaktadır. Kesinlik; doğru tahmin edilen pozitif örnek sayısının toplam pozitif örnek sayısına oranı olarak hesaplanmaktadır. Özgüllük; gerçek negatif değerler içinde doğru sınıflandırılmış örnek sayısının, tüm gerçek negatif örnek sayısına oranı olarak hesaplanmaktadır.  $F_1$  ölçütü kesinlik ve duyarlılık değerlerinin harmonik ortalamasını ifade etmektedir. Ölçütlere ait formüller aşağıdaki eşitliklerde verilmiştir.

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

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (2)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (3)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (4)$$

$$F_1 \text{ ölçütü} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

#### 4. Deneysel Analizler ve Sonuçlar

Bu çalışmada deneysel çalışmalar Google Colaboratory ortamında Python programlama dili ve Keras Kütüphanesi kullanılarak gerçekleştirilmiştir. Eğitim ve test verileri belirlenirken k katlı çapraz doğrulama tekniği kullanılmış ve k sayısı 5 olarak belirlenmiştir. Çalışmada kullanılan veri seti her bir katta %80 eğitim ve %20 test olarak bölünmüştür. Ayrıca çok katmanlı algılayıcı sınıflandırıcısında eğitim veri setinin %10'u doğrulama için kullanılmıştır.

Çalışmada özellik çıkarımı için DenseNet201, MobileNetV2, VGG16, NASNetLarge, Xception, InceptionV3, VGG19, EfficientNetB7 ve ResNet152 olmak üzere 9 farklı ön-eğitilmiş ağ kullanılmıştır. Özellik çıkarımı aşamasında öncelikle giriş görüntüleri her bir ön-eğitilmiş ağ mimarisine uygun olarak yeniden boyutlandırılmıştır. Giriş görüntü boyutları DenseNet201, MobileNetV2, VGG16, VGG19 ve ResNet152 modelleri için 224×224; Xception ve InceptionV3 modelleri için 299×299; NASNetLarge modeli için 331×331; EfficientNetB7 modeli için ise 600×600 olarak ayarlanmıştır.

Derin özellikler çıkarıldıktan sonra sınıflandırıcılara giriş olarak verilmeden önce Z-skor normalizasyon tekniği kullanılarak normalize edilmiştir. Sınıflandırma aşamasında çok katmanlı algılayıcı sınıflandırıcısında 2 adet gizli katman kullanılmıştır. Gizli katman nöron sayıları sırasıyla 1024 ve 512'dir. Aktivasyon fonksiyonu olarak ReLU (Rectified Linear Unit) seçilmiştir. Aşırı öğrenmeyi engellemek için son gizli katman ile çıkış katmanı arasında bir bırakma(dropout) katmanı eklenmiştir. Bırakma katmanı değeri 0.2, batch size 32 ve öğrenme oranı 0.0001 olarak ayarlanmıştır. Optimizasyon için Adam optimizasyon algoritması ve kayıp fonksiyon için ise kategorik çapraz entropi kullanılmıştır. Çok katmanlı algılayıcı modelin eğitim aşamasında erken durdurma tekniği kullanılmış ve eğer doğrulama kaybı 50 devir boyunca düşmüyorsa eğitim otomatik durdurulmuştur. Adaboost yönteminde temel sınıflandırıcı olarak karar ağacı seçilmiş ve tahmin edici(estimator) değeri 300 olarak uygulanmıştır. Rastgele orman yönteminde tahmin edici(estimator) değeri 1000 olarak uygulanmıştır. Son olarak destek vektör makineleri yönteminde lineer çekirdek fonksiyonu kullanılmıştır.

Bu çalışmada akciğer histopatoloji görüntülerinden tümör tipinin etkili bir şekilde sınıflandırılması için ilk olarak 9 farklı ön-eğitilmiş ağ aracılığıyla öz nitelikler çıkarılmış ve bu öz nitelikler kullanılarak Adaboost, Çok katmanlı algılayıcı, Rastgele orman ve Destek vektör makinesi gibi geleneksel makine öğrenmesi yöntemleri ile sınıflandırma yapılmıştır. Ayrıca bu aşamada sınıflandırıcılardan elde edilen ortalama başarılar da hesaplanmıştır. İlk aşamaya ait analiz sonuçları Tablo 1'de gösterilmiştir. Tablo 1'den görülebileceği üzere en yüksek ortalama sınıflandırma başarısı 0.96223 ile VGG16 modelinden çıkarılan öz-nitelikler ile elde edilirken en düşük ortalama sınıflandırma başarısı 0.80428 ile ResNet152 modelinden çıkarılan öz-nitelikler ile elde edilmiştir.

**Tablo 1.** Ön-eğitilmiş ağ öz nitelikleri ile makine öğrenmesi sınıflandırıcı doğrulukları

Derin öz-nitelik çıkarılan ağ	Sınıflandırıcı doğrulukları				Ortalama Başarı
	Adaboost	Çok katmanlı Algılayıcı	Rastgele Orman	Destek Vektör Makinesi	
VGG16	0.90520	0.98647	0.97333	0.98393	0.96223
MobileNetV2	0.86807	0.98980	0.97360	0.98213	0.95340
Xception	0.87040	0.98340	0.97067	0.98000	0.95112
VGG19	0.87333	0.98267	0.95867	0.97793	0.94815
NASNetLarge	0.83973	0.97973	0.97180	0.98420	0.94387
DenseNet201	0.83907	0.97793	0.97587	0.97400	0.94172
InceptionV3	0.84140	0.97413	0.96707	0.96920	0.93795
EfficientNetB7	0.75547	0.88300	0.83427	0.90600	0.84468
ResNet152	0.74347	0.85120	0.76387	0.85860	0.80428

İkinci aşamada en iyi ortalama başarı performansına sahip üç modele ait öz nitelikler seçilerek bu öz-niteliklerin ikili ve üçlü kombinasyonları ile sınıflandırma gerçekleştirilmiş ve öz-nitelik

seçiminin sınıflandırma başarısına etkisi araştırılmıştır (Tablo 2). Tablo 1’den görülebileceği üzere en iyi ortalama sınıflandırma başarıları sırasıyla VGG16, MobileNetV2 ve Xception modellerinden çıkarılan öz-nitelikler kullanılarak elde edilmiştir. Tablo 2’den görülebileceği üzere öz-niteliklerin birlikte kullanılması sınıflandırma başarısını olumlu yönde etkilemiş ve en yüksek ortalama sınıflandırma başarısı 0.97217 olarak elde edilmiştir.

**Tablo 2.** Öz-niteliklerin birleşimi ile elde edilen makine öğrenmesi sınıflandırıcı doğrulukları

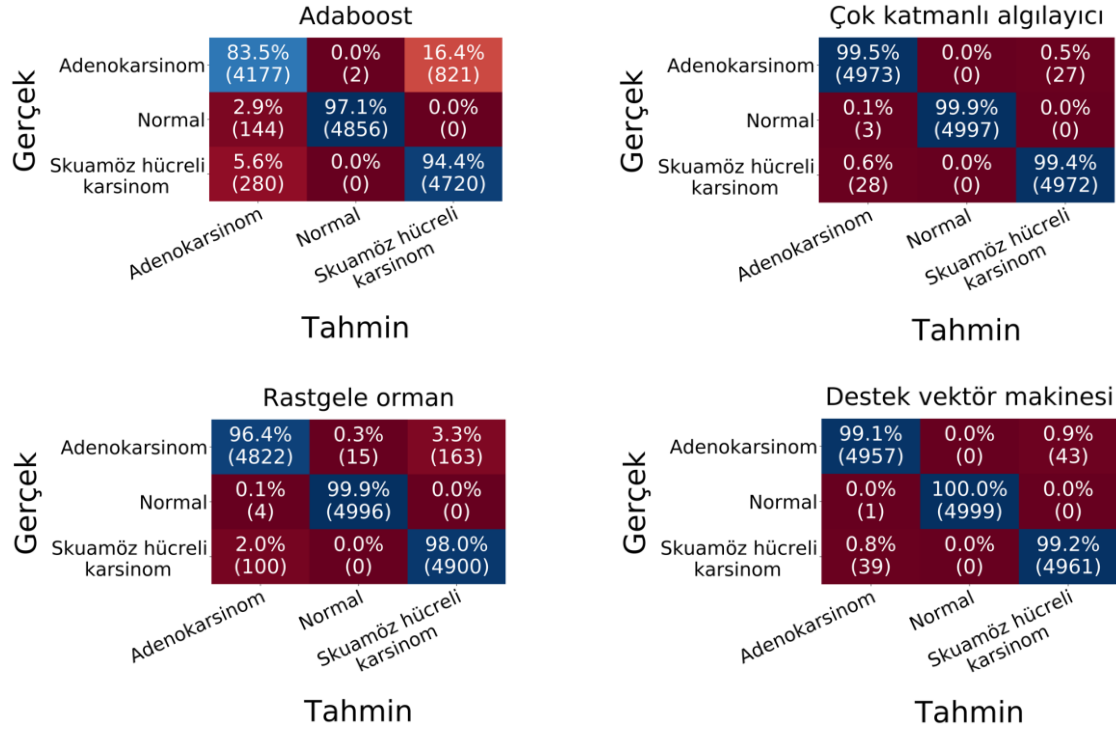
Derin öz-nitelik çıkarılan ağ	Sınıflandırıcı doğrulukları				Ortalama Başarı
	Adaboost	Çok katmanlı Algılayıcı	Rastgele Orman	Destek Vektör Makinesi	
VGG16 + Xception	0.92433	0.99487	0.97920	0.98867	0.97177
VGG16 + MobileNetV2	0.90213	0.99413	0.98113	0.99020	0.96690
Xception + MobileNetV2	0.88287	0.99393	0.97767	0.99100	0.96137
<b>VGG16 + MobileNetV2 + Xception</b>	<b>0.91687</b>	<b>0.99613</b>	<b>0.98120</b>	<b>0.99447</b>	<b>0.97217</b>

En yüksek ortalama sınıflandırma başarısına sahip öz-niteliklerin birlikte kullanıldığı durum için her bir modelin test veri setinde elde etmiş olduğu doğruluk, duyarlılık, özgüllük, kesinlik, ve F<sub>1</sub> ölçütü değerleri Tablo 3’te sunulmuştur.

**Tablo 3.** Öz-niteliklerin birleşimi sonucunda sınıflandırıcılara ait sonuçlar

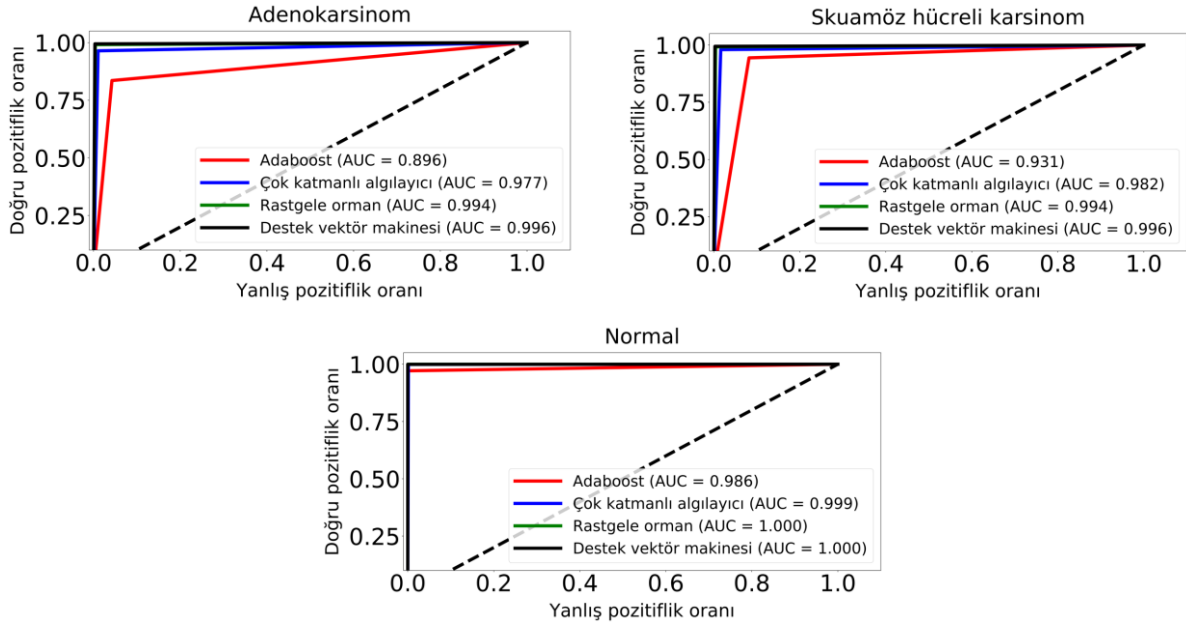
Model	Sınıflandırıcı	Kat	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F <sub>1</sub> ölçütü
<b>VGG16+ MobileNetV2+ Xception</b>	Adaboost	1	0.94133	0.91200	0.95100	0.93020	0.91200
		2	0.94422	0.91633	0.97400	0.95883	0.91633
		3	0.95000	0.92500	0.97350	0.96007	0.92500
		4	0.94556	0.91833	0.97967	0.96647	0.91833
		5	0.94178	0.91267	0.95750	0.93808	0.91267
	Çok katmanlı algılayıcı	1	0.99822	0.99733	0.99833	0.99767	0.99733
		2	0.99622	0.99433	0.99617	0.99467	0.99433
		3	0.99844	0.99767	0.99700	0.99600	0.99767
		4	0.99800	0.99700	0.99750	0.99667	0.99700
		5	0.99622	0.99433	0.99650	0.99533	0.99433
	Rastgele orman	1	0.98711	0.98067	0.98933	0.98556	0.98067
		2	0.99022	0.98533	0.99100	0.98763	0.98533
		3	0.98511	0.97767	0.98500	0.97958	0.97767
		4	0.98844	0.98267	0.99217	0.98889	0.98267
		5	0.98644	0.97967	0.98933	0.98487	0.97967
	Destek vektör makinesi	1	0.99644	0.99467	0.99500	0.99335	0.99467
		2	0.99600	0.99400	0.99650	0.99532	0.99400
		3	0.99733	0.99600	0.99650	0.99534	0.99600
		4	0.99644	0.99467	0.99683	0.99566	0.99467
		5	0.99533	0.99300	0.99550	0.99399	0.99300

Çalışmada makine öğrenmesi sınıflandırıcı performanslarını değerlendirmek amacıyla en yüksek ortalama sınıflandırma başarısına sahip öz-niteliklerin birlikte kullanıldığı duruma ait karmaşıklık matrisleri (confusion matrix) elde edilmiştir. Her bir sınıflandırıcıya ait karmaşıklık matrisleri Şekil 3’te sunulmuştur. Şekil 3’ten görülebileceği üzere normal dokuların sınıflandırılmasında en iyi performansı sağlayan sınıflandırıcı destek vektör makinesi olurken adenokarsinom ve skuamöz hücreli karsinom dokuların sınıflandırılmasında en iyi performansı sağlayan sınıflandırıcı çok katmanlı algılayıcı olmuştur. Adaboost yöntemi ise en düşük performansı sergileyen sınıflandırıcı olmuştur.



Şekil 3. Sınıflandırıcılara ait karmaşıklık matrisleri

Bu çalışmada makine öğrenmesi sınıflandırıcı performansları ayrıca AUC – ROC (Area Under The Curve - Receiver Operating Characteristics) eğrileri ile de değerlendirilmiştir. Her bir durumda sınıflandırıcılara ait ROC eğrileri ve AUC değerleri Şekil 4’te verilmiştir.



Şekil 4. Sınıflandırıcılara ait ROC eğrisi ve AUC değerleri

## 5. Tartışma

Tablo 4’te akciğer kanseri teşhisi için geliştirilen modeller ve literatürde kullanılan veri setleri üzerindeki performansları sunulmuştur. Tablo 4’ten görüleceği üzere araştırmacılar akciğer kanseri tanısında hem geleneksel makine öğrenmesi yöntemlerini hem de derin öğrenme yöntemlerini kullanmışlardır. Geleneksel makine öğrenmesi yöntemleri ile en yüksek başarı %97.97 ile Chauhan ve Jaiswal tarafından gerçekleştirilen çalışmada elde edilirken, derin öğrenme yöntemleri ile en yüksek



başarı %100 ile Garg ve Garg [19] tarafından gerçekleştirilen çalışmada kullanılan önceden eğitilmiş derin öğrenme modelleri ile elde edilmiştir. Bu çalışmada önerilen yaklaşım ise literatürde aynı veri setini kullanan modellerle karşılaştırıldığında; modelin sınıflandırma başarısının %97.22 doğruluk değeri ile üst noktalara yakın olduğu görülmektedir. Öte yandan diğer birçok çalışmada [17, 19, 20] sınıflandırma işlemi orijinal veri seti üzerinde değil veri artırımı yapılmış bir veri setinde gerçekleştirilmiştir. Çalışmada önerilen model orijinal veri setini kullanan Masud ve diğ., [18] tarafından önerilen model ile karşılaştırıldığında bu çalışmada önerilen yaklaşımın daha yüksek doğruluk değeri elde ettiği görülmektedir.

**Tablo 4.** Literatürde önerilen yaklaşımların sonuçlarının karşılaştırılması

Yazar	Yöntem	Veri Seti	Performans
Dandıl ve diğ. [7]	Yapay sinir ağları	Özel veri seti (128)	Doğruluk: %90.63
Chauhan ve Jaiswal [8]	Temel bileşenler analizi ve lineer diskriminant analizi	Özel veri seti (120)	Doğruluk: %97.97
Shen ve diğ. [12]	Çok ölçekli konvolüsyonel sinir ağları	LIDC-IDRI (1375)	Doğruluk: %86.84
Rao ve diğ. [13]	Konvolüsyonel sinir ağları	LIDC-IDRI (1000)	Doğruluk: %76
Alakwaa ve diğ. [14]	3D konvolüsyonel sinir ağı modeli	Kaggle veri seti (1397)	Doğruluk: %86.60
Song ve diğ. [15]	Konvolüsyonel sinir ağları	LIDC-IDRI (5024)	Doğruluk: %84.15
Shakeel ve diğ. [16]	Önceden eğitilmiş derin öğrenme modeli	LIDC-IDRI (5043)	Doğruluk: %98.42
Abbas ve diğ. [17]	ResNet-101	LC25000(15000)	Doğruluk: %99.80
Masud ve diğ. [18]	Konvolüsyonel sinir ağları	LC25000(25000)	Doğruluk: %96.33
Garg ve Garg [19]	InceptionV3, InceptionResNetV2, Xception, MobileNet, DenseNet169	LC25000(15000)	Doğruluk: %100
Hatuwal ve Thapa [20]	Konvolüsyonel sinir ağları	LC25000(15000)	Doğruluk: %97.20
<b>Bu çalışmada önerilen yaklaşım</b>	<b>VGG16+ MobileNetV2 + Xception</b>	<b>LC25000(15000)</b>	<b>Doğruluk: %97.22</b>

## 6. Sonuç

Bu çalışmada önceden eğitilmiş derin öğrenme yöntemleri ve klasik makine öğrenmesi yöntemleri birlikte kullanılarak akciğer histopatoloji görüntülerinden adenokarsinom, skuamöz hücreli karsinom ve normal dokuların sınıflandırılması gerçekleştirilmiştir. 9 farklı önceden eğitilmiş derin öğrenme mimarisi kullanılarak çıkarılan özellikler 4 farklı makine öğrenmesi yöntemi ile sınıflandırılmıştır. Deneysel sonuçlar çalışmada önerilen hibrit modelin %97.22 ortalama sınıflandırma başarısı ile akciğer kanserinin erken teşhisi için faydalı olduğunu göstermektedir.

## Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

## Kaynaklar

- [1] Torre L.A., Siegel R.L., Jemal A. 2019. Lung cancer statistics. Lung Cancer and Personalized Medicine, 1–19.
- [2] Rosamaria P., Daniela P., Rosanna L., Michele M., Annamaria C., Pamela P., Antonietta B.M., Alfredo Z.F., Gabriella D.B., Antonia Z., others 2019. KRAS-driven lung adenocarcinoma and B cell infiltration: novel insights for immunotherapy. Cancers. 11 (8): 1145.

- [3] Gan Z., Zou Q., Lin Y., Huang X., Huang Z., Chen Z., Xu Z., Lv Y. 2019. Construction and validation of a seven-microRNA signature as a prognostic tool for lung squamous cell carcinoma. *Cancer Management and Research*, 11: 5701.
- [4] Ranschaert E.R., Morozov S., Algra P.R. (ed) 2019. *Artificial Intelligence in Medical Imaging: Opportunities, Applications and Risks*. Springer
- [5] Janowczyk A., Madabhushi A. 2016. Deep learning for digital pathology image analysis: a comprehensive tutorial with selected use cases. *Journal of Pathology Informatics*, 7.
- [6] Abdullah D.M., Ahmed N.S. 2021. A review of most recent lung cancer detection techniques using machine learning. *International Journal of Science and Business*, 5 (3): 159–173.
- [7] Dandl E., Çakiroğlu M., Ekşi Z., Özkan M., Kurt Ö.K., Canan A. 2014. Artificial Neural Network-based Classification System for Lung Nodules on Computed Tomography Scans. 2014 6th International conference of soft computing and pattern recognition (SoCPaR). 382–386.
- [8] Chauhan D., Jaiswal V. 2016. An Efficient Data Mining Classification Approach for Detecting Lung Cancer Disease. 2016 International Conference on Communication and Electronics Systems (ICCES). 1–8.
- [9] Faisal M.I., Bashir S., Khan Z.S., Khan F.H. 2018. An Evaluation of Machine Learning Classifiers and Ensembles for Early Stage Prediction of Lung Cancer. 2018 3rd International Conference on Emerging Trends in Engineering, Sciences and Technology (ICEEST). 1–4.
- [10] Nasser I.M., Abu-Naser S.S. 2019. Lung cancer detection using artificial neural network. *International Journal of Engineering and Information Systems*, 3 (3): 17–23.
- [11] Thallam C., Peruboyina A., Raju S.S.T., Sampath N. 2020. Early Stage Lung Cancer Prediction Using Various Machine Learning Techniques. 2020 4th International Conference on Electronics, Communication and Aerospace Technology (ICECA). 1285–1292.
- [12] Shen W., Zhou M., Yang F., Yang C., Tian J. 2015. Multi-Scale Convolutional Neural Networks for Lung Nodule Classification. *International Conference on Information Processing in Medical Imaging*, 588–599.
- [13] Rao P., Pereira N.A., Srinivasan R. 2016. Convolutional Neural Networks for Lung Cancer Screening in Computed Tomography (CT) Scans. 2016 2nd International Conference on Contemporary Computing and Informatics (IC3I), 489–493.
- [14] Alakwaa W., Nassef M., Badr A. 2017. Lung cancer detection and classification with 3D convolutional neural network (3D-CNN). *Lung Cancer*. 8 (8): 409.
- [15] Song Q., Zhao L., Luo X., Dou X. 2017. Using deep learning for classification of lung nodules on computed tomography images. *Journal of Healthcare Engineering*, 8314740.
- [16] Shakeel P.M., Burhanuddin M.A., Desa M.I. 2019. Lung cancer detection from CT image using improved profuse clustering and deep learning instantaneously trained neural networks. *Measurement*, 145: 702–712.
- [17] Abbas M.A., Bukhari S.U.K., Syed A., Shah, S.S.H. 2020. The Histopathological Diagnosis of Adenocarcinoma & Squamous Cells Carcinoma of Lungs by Artificial intelligence: A comparative study of convolutional neural networks. medRxiv.
- [18] 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.
- [19] Garg S., Garg S. 2020. Prediction of Lung and Colon Cancer through Analysis of Histopathological Images by Utilizing Pre-trained CNN Models with Visualization of Class Activation and Saliency Maps. 2020 3rd Artificial Intelligence and Cloud Computing Conference, 38–45.
- [20] Hatuwal B.K., Thapa H.C. 2020. Lung cancer detection using convolutional neural network on histopathological images. *International Journal of Computer Trends and Technology*, 68 (10): 21–24.
- [21] 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 Prepr. arXiv1912.12142.
- [22] Christodoulidis S., Anthimopoulos M., Ebner L., Christe A., Mougiakakou S. 2016. Multisource transfer learning with convolutional neural networks for lung pattern analysis. *IEEE Journal of Biomedical and Health Informatics*, 21 (1): 76-84.

- [23] Tajbakhsh N., Shin J.Y., Gurudu S.R., Hurst R.T., Kendall C.B., Gotway M.B., Liang J. 2016. Convolutional neural networks for medical image analysis: full training or fine tuning? *IEEE Transactions on Medical Imaging*, 35 (5): 1299-1312.
- [24] Pan S.J., Yang Q. 2009. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22 (10): 1345-1359.
- [25] Freund Y., Schapire, R.E. 1997. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55 (1): 119-139.
- [26] Duda R.O., Hart P.E., others 2006. *Pattern Classification*. John Wiley & Sons.
- [27] Breiman L. 2001. Random forests. *Machine Learning*, 45: 5–32.
- [28] Cortes C., Vapnik V. 1995. Support-vector networks. *Machine Learning*, 20: 273–297.