

(Geliş Tarihi / Received Date: 13.12.2023, Kabul Tarihi / Accepted Date: 30.01.2024)

**(Araştırma Makalesi)****Derin Öğrenme Yöntemleri Kullanılarak Böbrek Hastalıklarının Tespiti ve Çoklu Sınıflandırma****Kenan GÜLLE<sup>1</sup>, Durmuş ÖZDEMİR<sup>2</sup>, Hasan TEMURTAŞ<sup>3</sup>**<sup>1</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No : <http://orcid.org/0000-0002-4650-1412><sup>2</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No : <http://orcid.org/0000-0002-9543-4076><sup>3</sup>Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No : <http://orcid.org/0000-0001-6738-3024>**Anahtar Kelimeler:**

Derin Öğrenme,  
Böbrek Hastalığı,  
Biyomedikal,  
Poly-CNN,  
Çoklu Sınıflandırma,  
VGG

**Özet:** Derin öğrenme, sağlık alanında hastalık ve anomalî tespiti gibi alanlarda son yıllarda başarılı sonuçlar elde etmiştir. Literatür incelendiğinde, böbrek hastalıklarının teşhisî, karmaşık, hata eğilimli ve zaman alıcı bir süreç olduğundan, bilgisayar destekli yazılımlara olan ihtiyaç kaçınılmazdır. Bu çalışmada, hastalara böbrek taşı, tümör ve kist teşhisî konmuş bilgisayarlı tomografi cihazı tarafından oluşturulan görüntüler kullanılmıştır. Veri setimizdeki görüntüler, erişime açık Kaggle platformundan elde edilmiştir. Veri seti, Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve çalışmada önerdiğimiz geliştirilmiş Poly-CNN derin öğrenme modeli kullanılarak sınıflandırma performansı ölçülmüştür. Daha istikrarlı öğrenme sağlamak için CNN yapısına ekstra havuzlama katmanı ve bağlantı katmanı eklenmiştir. Eklenen bu katmanlar aşırı öğrenmeye sebebiyet vermemesi için, eğitim sırasında rastgele nöronlar devre dışı bırakılmıştır. Çalışmada kullanılan derin öğrenme modellerinde, kullanılan parametreler, katman yapıları, doğruluk ve kayıp grafikleri detaylı bir şekilde incelenmiştir. Çalışmada Poly-CNN'in %99,94'lük yüksek bir doğruluk orâniyla öne çıktıgı görülmüştür. Bu sonuçlar, Poly-CNN modelinin, diğer kullanılan modellerde daha iyi bir performans sergileyerek, önerilen araştırma çerçevesinin etkinliğini belirgin bir şekilde ortaya koymaktadır.

**(Research Article)****Kidney Disease Detection and Multi-Classification Using Deep Learning Methods****Keywords:**

Deep Learning,  
Kidney Disease,  
biomedical,  
Poly-CNN,  
Multiple Classification,  
VGG

**Abstract:** Deep learning has achieved successful results in recent years in areas such as disease and anomaly detection in the field of healthcare. When the literature is examined, the need for computer-aided software is inevitable since the diagnosis of kidney diseases is a complex, error-prone and time-consuming process. In this study, images created by a computerized tomography device were used in which patients were diagnosed with kidney stones, tumors and cysts. The images in our dataset were obtained from the open-access Kaggle platform. Classification performance was measured using the dataset, Classic CNN, ANN, ALEXNET, VGG16, VGG19 networks and the developed Poly-CNN deep learning model we proposed in the study. Extra pooling layer and connection layer were added to the CNN structure to provide more stable learning. To prevent these added layers from causing excessive learning, random neurons were disabled during training. In the deep learning models used in the study, the parameters used, layer structures, accuracy and loss graphs were examined in detail. The study showed that Poly-CNN stands out with a high accuracy rate of 99.94%. These results clearly demonstrate the effectiveness of the proposed research framework, with the Poly-CNN model outperforming other used models.

\*Sorumlu Yazar: kenangulle@hotmail.com

## 1. GİRİŞ

Günümüzde, sağlık sektöründe derin öğrenme yöntemlerinin kullanımı, çeşitli hastalıkların erken teşhisini, sınıflandırılmasında ve uzman hekimlere yönelik öneri sistemi olarak kullanımı önemli bir potansiyele sahiptir [1], [2], [3]. Böbrek tümörleri dünya çapında erkek ve kadınlarda en sık görülen 10. tümördür [4]. Bu araştırmada, böbrek hastalıklarının tespiti ve çoklu sınıflandırılmasında derin öğrenme yöntemlerinin etkinliğinin ve veriminin belirlenmesi ve değerlendirilmesi amaçlanmaktadır. Derin öğrenme, geniş ve karmaşık veri setleri üzerinde otomatik öğrenme kapasitesi ile öne çıkan bir yapay zekâ dalıdır [5]. Hastalıklarının tespiti ve çoklu sınıflandırılmasında derin öğrenme yöntemlerinin etkinliğini değerlendirmeyi amaçlayan ve mühendislik pratığıne aktarılmış birçok bilimsel çalışma yapılmıştır [6]. Bunlardan bazıları birçok araştırmaciya referans olarak sunulmuştur [6-10].

Tüzün ve Özdemir [7], MRI görüntüleriyle beyin tümörü hastalığının erken tespiti için mevcut derin öğrenme modellerinin karşılaştırmalı analizini sunmayı amaçlamaktadır. GoogleNet, Mobilenetv2, InceptionV3 ve Efficientnet-b0 modelleri Matlab platformunda kodlanarak beyin tümörü tespiti ve sınıflandırılması için kullanıldı. Glioma, Meningioma ve Hipofiz beyin tümörleri üzerinde sınıflandırma yapıldı. Kaggle platformunda halka açık olarak paylaşılan dört farklı sınıfta 7022 beyin MRI görüntüsü içeriyor. Analiz sonuçlarına göre, Efficientnet-b0 (%99,54), InceptionV3 (%99,47), Mobilenetv2 (%98,93) ve GoogleNet (%98,25) sırasıyla başarı elde etmiştir.

Özdemir ve Arslan [8], Covid-19 hastalığının erken teşhisini tespit etmek amacıyla derin öğrenme modellerinin karşılaştırmalı analizini sunmaktadır. VGG-19, VGG-16 ve Inception V3 modelleri Covid-19 tespiti için değerlendirilmiştir. Kamuya açık olan Kaggle veri tabanından eğitim için 280 göğüs röntgeni görüntüsü ve test için 140 göğüs röntgeni görüntüsü kullanılmıştır. Analiz sonuçlarına göre, Inception V3 (%92) en başarılı model olmuştur.

Krizhevsky vd. [9], çalışmalarında DigiMammo (UCHCDM) veritabanında toplanan 96 meme kanseri görüntüsü üzerinde gerçekleştirilmiştir. Görüntüler 69'u kanserli, 27'si sağlıklı bireylerden oluşmaktadır. Meme kanseri taraması için önerilen bir bilgisayar destekli tespit (CAD) yöntemi tanıtılmıştır. Mamografik görüntüler incelenerek şüpheli kanserli bölgeler belirlenmiştir. Ardından görüntüler eğitilmiş bir CNN ile beslenerek yanlış pozitifler eleme işlemi gerçekleştirilmiştir. Önerilen CAD yönteminin başarı oranının %92,8 olduğu gözlemlenmiştir.

Rehman vd. [10], çalışmalarında beyin tümörünün doğru teşhisini için halka açık figshare ortamında bulunan 233 hastadan toplanan 3064 MRI kesitinde bulunmaktadır. Önerilen çerçeve kapsamında, AlexNet, GoogLeNet ve VGGNet olmak üzere üç evrişimli sinir ağı mimarisi kullanılarak menenjiyom, hipofiz ve glioma gibi beyin

tümörlerini sınıflandırmak için çalışma yürütülmüştür. Her çalışma, beyin tümörü veri kümesi olan Figshare'deki MRI dilimleri kullanılarak ince ayar ve dondurma gibi transfer öğrenme tekniklerini kullanmaktadır. Sonuçların genelleştirilmesi, veri kümesi örneklerinin artırılması ve aşırı uyum şansını azaltmak için MRI dilimlerine veri artırma teknikleri uygulanmıştır. Önerilen çalışmalarla, VGG16 mimarisi ile yapılan sınıflandırma tespit açısından en yüksek doğruluğu (98,69) ulaştığı gözlemlenmiştir.

Bingöl ve vd.[11], Derin öğrenme ve yapay zekanın tip alanındaki etkilerini değerlendirerek böbrek tümörü tespiti üzerindeki rolünü incelemiştir. Derin öğrenme modellerinin, özellikle radyolog yoğunluğu yüksek ortamlarda ve hızlı teşhis ihtiyacında, böbrek tümörü tespiti konusunda hızlı ve doğru sonuçlar sağlayabileceğini vurgulamaktadır. Çalışmada Kaggle platformundan elde ettikleri veri seti ile böbrek görüntülerini taş, kist ve tümör ve normal olarak sınıflandırma amacıyla, EfficientNetb0, InceptionV3, GoogleNet, DenseNet201, ShuffleNet ve CNN tabanlı bir hibrit model önerisinde bulunmuştur. Veri setindeki görüntülerin %80'ini eğitim %20'sini test için ayırmıştır. Karşılaştırma yaptıkları modellerin hepsinde 5 epoch değeri, learning rate 1.0004 ve 16 batch size değeri kullanılmıştır. Önerilen CNN tabanlı hibrit modelin %99,37 doğruluk değerine ulaşılmıştır.

**Tablo 1.** Böbrek tümörü sınıflandırması ile ilgili çalışmalar.

| Yıl  | Dataset              | Method              | Sonuç | Kaynak |
|------|----------------------|---------------------|-------|--------|
| 2021 | KiTS19               | InceptionV3,<br>ROC | %97.4 | [12]   |
| 2023 | CT Kidney<br>Dataset | Proposed CNN        | %99.5 | [13]   |
| 2022 | KiTS19               | DeepLabv3+ 2.5D     | %99.7 | [14]   |
| 2022 | 8400                 | 2D-CNN              | %97.0 | [15]   |
| 2023 | CT Kidney<br>Dataset | Hybrid CNN<br>Model | %99,3 | [11]   |
| 2022 | CT Kidney<br>Dataset | Swin Transformer    | %99,3 | [16]   |
| 2024 | CT Kidney<br>Dataset | Proposed Model      | %99,7 | [17]   |

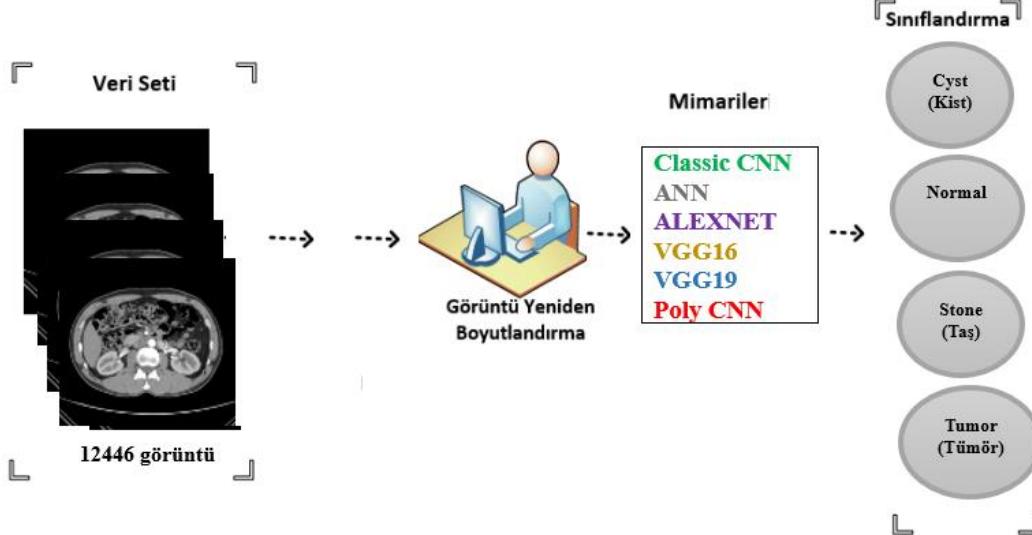
Literatürde de görüldüğü üzere farklı derin öğrenme mimarileri kullanılarak tip alanında covid-19, beyin tümörü ve böbrek tümörü ve meme kanseri tespiti için, etkili araç olabileceği göstermektedir [18]. Derin öğrenme özellikle radyolog yoğunluğu yüksek ortamlarda ve hızlı teşhis ihtiyacında, doğru ve hızlı sonuçlar sağlama potansiyeline sahip olmaktadır [19]. Bu çalışmalarдан elde edilen sonuçlar, derin öğrenme modellerinin tıbbi görüntüleme alanında çeşitli uygulamalarda etkili bir şekilde kullanılabileceğini ve hastalıkların erken tespisi konusunda önemli bir potansiyele sahip olduğunu ortaya koymaktadır. Tablo 1.'de böbrek tümörü sınıflandırması ile ilgili literatürde yapılan çalışmalar görülmektedir. Bu çalışmada da Kaggle platformundan elde edilen böbrek görüntülerini Classic CNN, ANN, ALEXNET, VGG16,

VGG19 ağları ve çalışmada önerdiğimiz geliştirilmiş Poly-CNN ağ gibi farklı derin öğrenme metotları kullanılarak analiz edilmesi amaçlanmıştır.

## 2. MATERİYAL VE METOT

Bu çalışma, Classic Convolutional Neural Network (Classic CNN), Artificial Neural Network (ANN), AlexNet, VGG16 ve VGG19 gibi önceden belirlenmiş derin öğrenme modellerini içeren bir dizi modeli ve

geliştirilmiş Poly-CNN modelini kapsamaktadır. Bu modeller, böbrek hastalıklarının farklı alt tiplerini tanımak ve çoklu sınıflandırma başarılı olmak amacıyla geniş bir görüntü veri seti üzerinde eğitilecek ve test edilecektir. Çalışmada geliştirilmiş uygulama ortamı Python programlama dilinin Jupyter Notebook açık kaynak kodlu programı tercih edilmiştir. Numpy, Matplotlib, Tensorflow, Keras gibi kütüphaneleri uygulamada kullanılmıştır. Çalışmanın akış modeli Şekil 1.'de gösterilmiştir.



Şekil 1. Çalışmanın genel yapısı

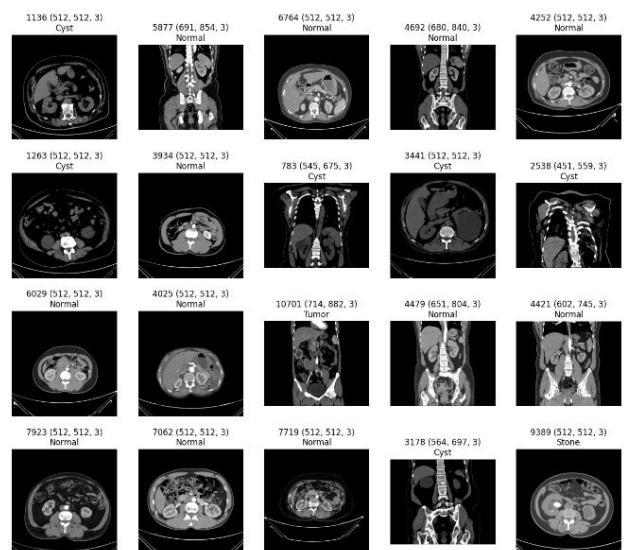
### 2.1. Veri Seti

Çalışmada böbrek hastalığının tespit edilmesi ve sınıflandırılması amacıyla kullanılan veri seti, Bangladeş'teki çeşitli hastanelerden PACS (Resim Arşivleme ve İletişim Sistemi) aracılığıyla toplanmıştır. Hastalara böbrek tümörü, kist, normal veya taş teşhisi konulmuş. Dicom görüntülerini kayıpsız JPG formatına dönüştürülmüş. Dönüşürme işleminden sonra, her bir görüntü doğruluğunu teyit etmek için bir radyolog ve bir tıbbi teknoloj tarafından tekrar kontrol edilmiştir [20]. Veri setinin sınıflara göre dağılımı ise 3709'u Cyst (kist), 5077'si Normal, 1377'si Stone (taş) ve 2283'ü Tumor (tümör) olmak üzere toplam 12446 Bilgisayarlı Tomografi (CT) görüntüsü içermektedir. Bu veri setinde kullanılan tüm görüntüler erişime açık Kaggle platformundan alınmıştır [20]. Veri setinden alınan örnek görüntüler Şekil 2'de gösterilmiştir. Çalışmada verilerin %70'ni eğitim, %15'ni test ve %15'ni doğrulama olarak ayrılmıştır.

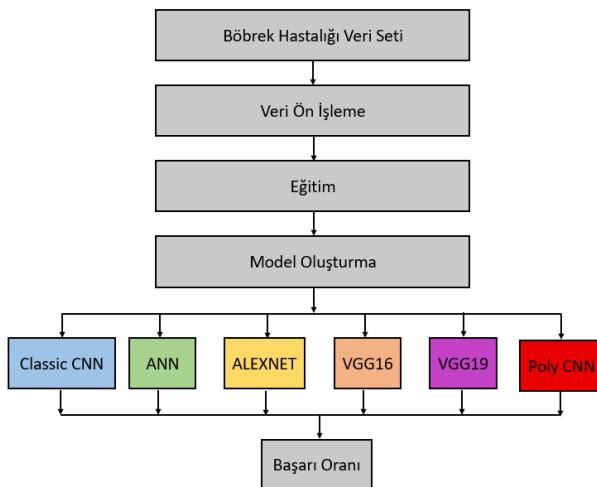
### 2.2. Classic CNN, ANN, ALEXNET, VGG16, VGG19 ve Poly-CNN ile Öğrenilen Modelleri ve Uygulama Perspektifleri

Veri seti içindeki bilgiler kategorik hale getirilmiş ve modellerin daha etkili bir şekilde işleyebilmesi için uygun boyutlara getirilmiştir. Veri setini zenginleştirmek amacıyla veri artırma teknikleri uygulanmıştır [21]. Bu kapsamında özellikle tabanlı normalizasyon işlemleri yanı sıra yatay ve dikey çevirmeler, 30 derecelik döndürme, ayrıca yatayda ve dikeyde %0,3 oranında genişletme gibi

çeşitli manipülasyonlar gerçekleştirileerek veri setindeki çeşitlilik artırılmıştır. Önerdiğimiz ağ yapısına göre oluşturulan modelin başlangıç değerleri ile modelin katmanları ve parametreleri belirlenmiştir. Farklı epoch değerleri ile oluşturulan model farklı iterasyonlarla eğitilmiş ve test verilerinin sınıflandırma sonuçları hesaplanmıştır. Çalışmada Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve geliştirilmiş Poly-CNN ağ kullanılmıştır. Çalışmaya ait genel akış diyagramı Şekil 3'te verilmiştir.



Şekil 2. Böbrek hastalığı için kullanılan görüntüler [20]



**Şekil 3.** Çalışmaya ait akış diyagramı

### 2.2.1. Classic CNN

Çalışmada derin öğrenme modellerinden biri olan Classic CNN (Evrişimsel Sinir Ağları), görsel veri analizi ve tanıma alanında kullanılmaktadır [22]. Bu modelde kullanılan parametre değerlerinde 15 epoch döngüsü için 200 batch size kullanılmıştır. Bu modelin girdisi  $32 \times 32 \times 1$  boyutundaki görüntülerdir. Classic CNN modelinde veri girişini Giriş Katmanı ile sağlayarak evrişim filtrelerini Evrişim Katmanları (Convolutional Layers) ile oluşturuldu. Evrişim sonuçlarında Relu Aktivasyon fonksiyonları uygulanarak evrişim sonuçlarının küçültüldüğü Havuzlama Katmanları (Pooling Layers) gösterildi. Havuzlama katmanlarının çıkışlarını düzleştirmek için Tam Bağlantılı Katman (Fully Connected Layer) kullanıldı. Sınıflandırmalar Çıkış Katmanı ile gösterildi. Her bir katmanın parametreleri (örneğin, filtre boyutları, adım büyüklükleri) ve aktivasyon fonksiyonları, böbrek veri setine göre oluşturuldu.

### 2.2.2. ANN

Yapay sinir ağları genellikle üç temel katmandan oluşan bir mimariye sahiptir: giriş katmanı, gizli katmanlar ve çıkış katmanıdır [23]. Bu modelin girdisi  $150 \times 150 \times 3$  boyutundaki görüntülerdir. Bu modelde kullanılan parametre değerlerinde 15 epoch döngüsü için 200 batch size, aktivasyon fonksiyonu olarak relu ve softmax kullanılmıştır. Aktivasyon fonksiyonu nöronun çıkış değerini hesaplamaktadır.

### 2.2.2. AlexNet

Böbrek hastalığı veri seti üzerinde kullanılan AlexNet mimarisinde, 5 evrişimli katman, 3 max-pooling katmanı, 3 normalizasyon katmanı, 2 tam bağlantılı katman ve 1 softmax katmanından oluşmaktadır. Evrişimli katmanlar, evrişimli filtreler ve doğrusal olmayan ReLU aktivasyon fonksiyonları ile tanımlanmaktadır. Maksimum havuzlama işlemi, havuzlama katmanları aracılığıyla gerçekleştirilmektedir [24]. Tam bağlantılı katmanların varlığı, giriş boyutunu sabit kılmaktadır. Modelin girdisi,  $227 \times 227 \times 3$  boyutundaki görüntülerden oluşmaktadır.

Cıkış katmanında kullanılan aktivasyon fonksiyonu Softmax'tır

### 2.2.3. VGG16

Çalışmanın bu aşamasında evrişimli sinir ağından (CNN) Görsel Geometri Grubu (VGG16) konseptindeki böbrek görüntüleri kullanıldı. VGG16 ağı çok küçük evrişimli filtrelerle oluşturulmuştur. Evrişimli katman ve üç tam bağlantılı katmandan oluşmakta olup ayrıca 16 katmani destekleyen bir evrişim sinir ağı (CNN) modelidir [25]. Bu modelin girdisi (None,512) boyutundaki görüntülerdir.

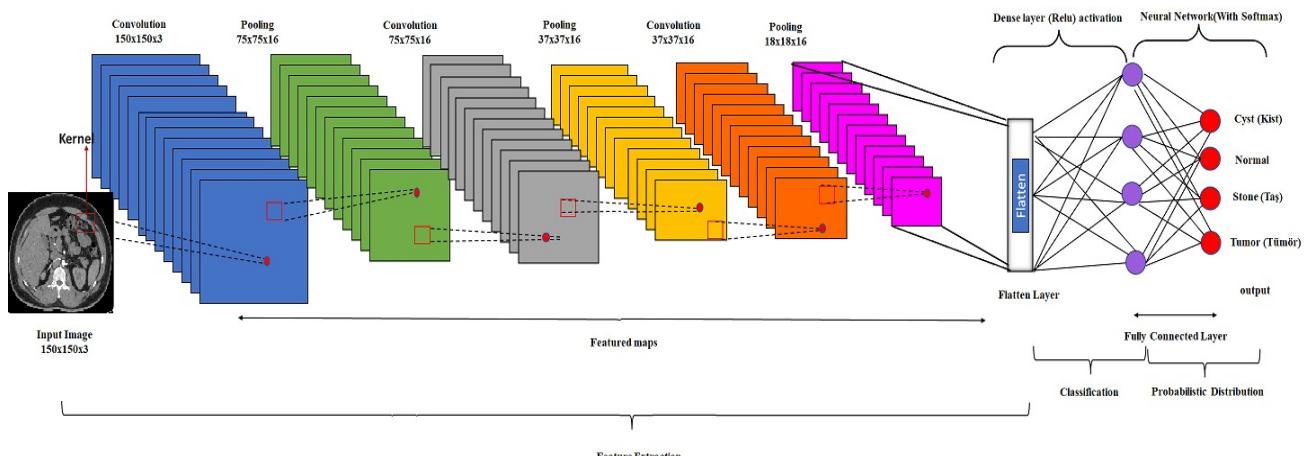
### 2.2.4. VGG19

VGG19, özellikle görüntü sınıflandırma görevleri için tasarlanmış bir derin öğrenme modelidir [26]. VGG19, toplamda 19 katmandan oluşan derin bir sinir ağı mimarisine sahiptir. Bu 19 katman, evrişimli (convolutional) ve tam bağlantılı (fully connected) katmanları içermektedir. Modelde genellikle ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmaktadır. ReLU, öğrenme sürecini hızlandıracak ve eğitimi daha etkili hale getirebilmektedir. Evrişimli katmanlar arasında maksimum havuzlama (max pooling) katmanları da bulunmaktadır. Havuzlama katmanları, özellik haritalarını öbeklemek ve boyutunu azaltmak için kullanılmaktadır.

### 2.2.5. Önerilen Poly-CNN Modeli

Bu çalışma, Poly-CNN mimarisinin temelinde yatan yapısal özelliklerini ve hiper parametreleri yeniden değerlendirerek, görüntü segmentasyonunda daha iyi performans sağlama hedeflemektedir. Elde edilen sonuçlar, geliştirilen modelin genel görüntü analizi uygulamalarında kullanılabilirliğini ve etkinliğini göstermeye yönelik önemli bir katkı sunmayı amaçlamaktadır. Convolutional Neural Network (CNN) tabanlı yenilikçi bir yaklaşım geliştirmeyi amaçlamaktadır. Geliştirdiğimiz Poly-CNN modeli, özellikle görüntü sınıflandırma görevleri için optimize edilmiş bir mimariye sahiptir. Başlangıçta, evrişim katmanları, giriş görüntülerinden düşük düzeyli özelliklerini, kenarları ve köşeleri öğrenmeye odaklanacak şekilde ayarlandı. Ardından, max pooling katmanları, özellik haritalarını küçülterek önemli bilgileri vurgular, bu sayede daha yüksek seviyeli özelliklerin çıkarılmasına yardımcı olur. Tam bağlantılı katmanlar, evrişimli özelliklerin karmaşık ve anlamlı özelliklere dönüştürmek için kullanılır. Dropout katmanları, rastgele nöronları devre dışı bırakarak ezberlemeyi azaltır. Batch normalization katmanları ise eğitim sürecini hızlandırarak daha kararlı ve etkili bir model elde edilmesine katkı sağlar. Toplamda 88,516 parametre içeren bu model, ağırlıklarını öğrenerek verilere uygun bir şekilde adapte olur. Önceki yöntemlerin sınırlamalarını aşmak ve karmaşık görüntü yapısını daha etkili bir şekilde çözebilme amacıyla tasarlanmıştır. Bu modelde kullanılan parametre değerlerinde 15 epoch döngüsü için 200 Batch size

kullanılmıştır. Bu modelin girdisi  $150 \times 150 \times 3$  boyutundaki görüntülerdir.



**Şekil 9.** Poly-CNN Modelinin genel mimari yapısı

Önerdiğimiz derin öğrenme modelinin katmanlarını içeren katman yapısı ve parametre değerleri Tablo 2. de verilmiştir. Modelin ilk katmanı Rescaling katmanıdır, bu katman veri setindeki piksel değerlerini normalize etmek için kullanılır. Giriş olarak xTrain veri kümesinin şeklini kullanır. Ardından, üç adet Conv2D katmanı gelir (Conv1, Conv2, Conv3), her biri  $3 \times 3$  boyutunda filtrelerle işlenmiş özellik haritalarını çıkartır. Her Conv2D katmanın ardından bir MaxPooling2D katmanı gelir (Pool1, Pool2, Pool3), bu katmanlar özellik haritalardaki önemli bilgileri vurgular ve boyutlarını küçültür. Flatten katmanı, düzleştirme işlemi yaparak önceki katmanlardan elde edilen özelliklerini tek boyutlu bir vektöre dönüştürür. Ardından iki adet Dense katmanı

gelir (Dense1, Dense2), bu katmanlar sinir ağının öğrenmesini sağlar. Her Dense katmanın ardından bir BatchNormalization katmanı (Norm1, Norm2) gelir, bu katmanlar ağı normalleştirerek eğitimi daha stabil hale getirir. Dropout katmanları (Dropout1, Dropout2) aşırı öğrenmeyi önlemek için kullanılır, eğitim sırasında belirli bir oranda rastgele nöronları devre dışı bırakır. Son katman Dense3, çıkış sınıf sayısına (Tumor, Taş, Kist, Normal) sahip bir softmax aktivasyon fonksiyonu içerir. Bu katman, modelin verilen girişlere dayanarak sınıflar arasında olasılıkları tahmin etmesini sağlar. Her bir katmanın içeriği ağırlıklar ( $W$ ) ve bias terimleri ( $b$ ) Tablo 2'de belirtilmiştir.

**Tablo 2.** Poly-CNN Katman Yapısı ve Parametre Değerleri.

| #  | Katman Türü                | Parametre Sayısı | Ağırlıklar ( $W$ ) | Bias Terimleri ( $b$ ) | Aktivasyon | Ek Bilgi                           |
|----|----------------------------|------------------|--------------------|------------------------|------------|------------------------------------|
| 1  | Rescaling (Rescale1)       | 0                | -                  | -                      | -          | Normalizasyon Faktörü: 1/255       |
| 2  | Conv2D (Conv1)             | 160              | (3, 3, 1, 16)      | (16,)                  | ReLU       | Filtre: 16, Çekirdek Boyutu: (3,3) |
| 3  | MaxPooling2D (Pool1)       | 0                | -                  | -                      | -          | Pooling Boyutu: (2, 2)             |
| 4  | Conv2D (Conv2)             | 2320             | (3, 3, 16, 16)     | (16,)                  | ReLU       | Filtre: 16, Çekirdek Boyutu: (3,3) |
| 5  | MaxPooling2D (Pool2)       | 0                | -                  | -                      | -          | Pooling Boyutu: (2, 2)             |
| 6  | Conv2D (Conv3)             | 2320             | (3, 3, 16, 16)     | (16,)                  | ReLU       | Filtre: 16, Çekirdek Boyutu: (3,3) |
| 7  | MaxPooling2D (Pool3)       | 0                | -                  | -                      | -          | Pooling Boyutu: (2, 2)             |
| 8  | Flatten (Flatten1)         | 0                | -                  | -                      | -          |                                    |
| 9  | Dense (Dense1)             | 4112             | (1024, 16)         | (16,)                  | ReLU       | Birim Sayısı: 16                   |
| 10 | BatchNormalization (Norm1) | 32               | (16,)              | (16,)                  | -          |                                    |
| 11 | Dropout (Dropout1)         | 0                | -                  | -                      | -          | Dropout Oranı: 0.5                 |
| 12 | Dense (Dense2)             | 272              | (16, 16)           | (16,)                  | ReLU       | Birim Sayısı: 16                   |
| 13 | BatchNormalization (Norm2) | 32               | (16,)              | (16,)                  | -          |                                    |
| 14 | Dropout (Dropout2)         | 0                | -                  | -                      | -          | Dropout Oranı: 0.5                 |
| 15 | Dense (Dense3)             | 4                | (16, 4)            | (4,)                   | Softmax    | Softmax Aktivasyon Fonksiyonu, 4   |

### 3. BULGULAR VE DENEYSEL SONUÇLAR

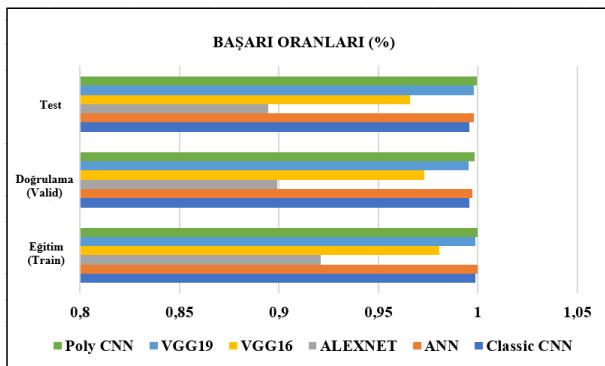
Elde edilen sonuçlar, derin öğrenme modellerinin böbrek hastalıklarını başarılı bir şekilde tespit edebildiğini ve çeşitli alt tiplerini doğru bir şekilde sınıflandırdığını göstermektedir. Özellikle, geliştirilmiş Poly-CNN modeli, yüksek doğruluk oranları ve düşük hata payları ile

öne çıkmaktadır. Ayrıca kullanılan Classic CNN, ANN, ALEXNET, VGG16, VGG19 modelleri ve geliştirilmiş Poly-CNN modeli, böbrek hastalıklarının karmaşıklığını anlama ve spesifik alt tiplerini ayırt etme konusunda yüksek başarı elde etmiştir. Çalışma, derin öğrenme yöntemlerinin böbrek hastalıklarının tespiti ve çoklu sınıflandırma görevlerinde etkili bir şekilde kullanılabileceğini göstermektedir. Bu bulgular, klinik

uygulamalarda hastalık teşhis ve yönetim süreçlerini iyileştirmek için derin öğrenme teknolojilerinin potansiyelini vurgulamaktadır.

### 3.1. Kullanılan Modellerin Eğitim (Train), Doğrulama (Valid) ve Test Başarı Oranları

Çalışmanın bu aşamasında kullanılan Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve geliştirilmiş Poly-CNN ağın Eğitim (Train), Doğrulama (Valid) ve Test Başarı Oranları (%) gösterilerek değerlendirilmiştir (Şekil 10). Uygulanan bu modellerde test için ayrılmış böbrek veri seti için yüksek doğruluk oranları sırasıyla %99,57 (Classic CNN), %99,78 (ANN), %89,44 (ALEXNET), %96,57 (VGG16), %99,78 (VGG19) ve %99,94 (Poly-CNN) gözlemlenmiştir. En yüksek doğruluğu %99,94 ile Poly-CNN sergilemiştir. Elde edilen bu sonuçlar doğrultusunda önerilen Poly-CNN araştırma çerçevesinin tekniği bilinen CNN modellerinden daha iyi performans göstermiştir.



Şekil 10. Tüm modellerin başarı oranları

Bu çalışma kapsamında, Classic CNN, ANN, ALEXNET, VGG16, VGG19 ve Poly-CNN modelleri, böbrek hastalıklarının sınıflandırılması görevinde değerlendirilmiştir. Eğitim (Train), Doğrulama (Valid) ve Test aşamalarında elde edilen başarı oranları aşağıda verilen Tablo 3'de özetlenmiştir.

Tablo 3. Tüm modellerin başarı oranlarının karşılaştırması

| MODEL           | BAŞARI ORANLARI (%) |                      |               |
|-----------------|---------------------|----------------------|---------------|
|                 | EĞİTİM<br>(Train)   | DOĞRULAMA<br>(Valid) | TEST          |
| ANN             | 0,9997              | 0,9973               | 0,9978        |
| ALEXNET         | 0,9211              | 0,8993               | 0,8944        |
| VGG16           | 0,9807              | 0,9732               | 0,9657        |
| VGG19           | 0,9988              | 0,9951               | 0,9978        |
| <b>Poly-CNN</b> | <b>0,9997</b>       | <b>0,9983</b>        | <b>0,9994</b> |
| Classic CNN     | 0,9986              | 0,9957               | 0,9957        |

Çalışmada Sınıflandırıcının performansını ölçmek için accuracy, precision, recall ve F1-score değerlendirme metrikleri kullanıldı. Sınıflandırma doğruluğunu sayısal olarak göstermek için karışıklık matrisi kullanıldı. Bu matris, makine öğreniminde sıkça kullanılan bir tekniktir ve bir sınıflandırma sistemi tarafından gerçek ve tahmini

sınıfların elde edilmesiyle ilgili bilgi sağlar [27]. Karışıklık matrisi, iki boyuta sahiptir: gerçek ve tahmini sınıflar. Her satır, bir gerçek sınıf örneğini temsil ederken, her sütun bir tahmini sınıfın durumunu gösterir.

**Gerçek Pozitif (TP):** Sınıflandırıcının pozitif sınıfı pozitif olarak doğru şekilde tahmin ettiği tahmin sayısını ifade eder.

**Gerçek Negatif (TN):** Sınıflandırıcının negatif sınıfı negatif olarak doğru şekilde tahmin ettiği tahmin sayısını ifade eder.

**Yanlış Pozitif (FP):** Sınıflandırıcının negatif sınıfı hatalı bir şekilde pozitif olarak tahmin ettiği tahmin sayısını ifade eder.

**Yanlış Negatif (FN):** Sınıflandırıcının pozitif sınıfı hatalı olarak negatif olarak tahmin ettiği tahmin sayısını ifade eder.

### True Class

| Predicted Class |          | True Class |          |
|-----------------|----------|------------|----------|
|                 |          | Positive   | Negative |
| Positive        | Positive | TP         | FP       |
|                 | Negative | FN         | TN       |
| Negative        | Positive |            |          |
|                 | Negative |            |          |

Şekil 10. İkili sınıflandırma için karışıklık matrisi

**Accuracy:** Bir modelin doğru tahmin ettiği örneklerin toplam veri kümelerine oranını temsil eder. Başka bir deyişle, doğru sınıflandırılan örneklerin, veri kümelerindeki tüm örneklerin yüzdesidir. Bu metrik, modelin genel performansını ölçer ve ne kadarının doğru tahmin edildiğini gösterir.

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

**Precision:** Pozitif olarak tahmin edilen verilerin ne kadarının doğru tahmin edildiğini gösterir. Yani, yüksek bir precision, daha az yanlış pozitif anlamına gelir. Precision, modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekten de pozitif olduğunu ölçer.

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

**Recall:** Sınıflandırıcının tamamlama yeteneğini ölçen bir metriktir. Yüksek recall, daha düşük yanlış negatifleri gösterirken, düşük recall daha yüksek yanlış negatifleri gösterir. Precision'daki iyileşme genellikle recall'daki azalmaya birlikte gelir. Recall, modelin gerçek pozitif örnekleri ne kadar iyi kapsayabildiğini belirtir ve bu, yanlış negatiflerin azalmasını anlamına gelir.

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

**F1-Score:** recall ve precision'in çarpımının, recall ve precision'in toplamına bölünmesiyle elde edilir. Bu metrik hem modelin tamamlama yeteneğini hem de doğruluk

oranını dengeli bir şekilde değerlendirir. Yani, F1-Score, yanlış negatiflerin azaltılmasıyla birlikte yanlış pozitiflerin de kontrol altında tutulup tutulmadığını gösteren bir ölçütür.

$$\text{F1 Score} = \frac{\text{TP}}{\text{TP} + \frac{1}{2}(\text{FP} + \text{FN})}$$

**Tablo 4.** Test verisi için değerlendirme metrikleri

| Classes         | Evaluation Metrics | CNN Models |             |        |        |         |               |
|-----------------|--------------------|------------|-------------|--------|--------|---------|---------------|
|                 |                    | ANN        | Classic CNN | VGG16  | VGG19  | AlexNet | Poly-CNN      |
| Cyst            | <i>precision</i>   | 1.0000     | 0.9982      | 0.9981 | 0.9982 | 0.9959  | 0.9964        |
|                 | <i>recall</i>      | 0.9982     | 0.9910      | 0.9658 | 0.9946 | 0.8815  | 1.0000        |
|                 | <i>f1-score</i>    | 0.9991     | 0.9946      | 0.9817 | 0.9964 | 0.9352  | 0.9982        |
| Normal          | <i>precision</i>   | 0.9974     | 0.9974      | 0.9303 | 1.0000 | 0.9484  | 1.0000        |
|                 | <i>recall</i>      | 1.0000     | 1.0000      | 1.0000 | 1.0000 | 0.9895  | 1.0000        |
|                 | <i>f1-score</i>    | 0.9987     | 0.9987      | 0.9639 | 1.0000 | 0.9685  | 1.0000        |
| Stone           | <i>precision</i>   | 0.9951     | 0.9760      | 0.9698 | 0.9856 | 0.5722  | 1.0000        |
|                 | <i>recall</i>      | 0.9854     | 0.9854      | 0.9324 | 0.9952 | 1.0000  | 0.9903        |
|                 | <i>f1-score</i>    | 0.9902     | 0.9807      | 0.9507 | 0.9904 | 0.7279  | 0.9951        |
| Tumor           | <i>precision</i>   | 0.9971     | 1.0000      | 1.0000 | 1.0000 | 1.0000  | 1.0000        |
|                 | <i>recall</i>      | 1.0000     | 1.0000      | 0.9096 | 1.0000 | 0.6414  | 1.0000        |
|                 | <i>f1-score</i>    | 0.9985     | 1.0000      | 0.9527 | 1.0000 | 0.7815  | 1.0000        |
| <i>accuracy</i> |                    | 0.9979     | 0.9957      | 0.9657 | 0.9979 | 0.8945  | <b>0.9989</b> |

Farklı CNN modelleriyle yapılan böbrek rahatsızlığı sınıflandırma çalışmalarındaki değerlendirme metrikleri Tablo 4'te verilmiştir. Sonuçlar incelendiğinde genel olarak başarılı sonuçlar elde edilmiştir. Özellikle Cyst ve Tumor sınıflarında modeller yüksek doğruluk göstermiş, Poly-CNN modeli genel performans açısından diğer

modellere göre öne çıkmıştır. Ancak, Stone sınıfında recall değeri biraz düşük olmuş, bu sınıfta daha fazla iyileştirme için çalışma yapılabilir. Sonuçlar, model seçiminin ve performansın sınıflara göre değişebileceğini göstererek, problem alanına özgü optimizasyonların önemini vurgular.

### 3.2. Kullanılan Modellerin Hata Çapraz Entropi Grafikleri

Böbrek veri setini kullanarak elde ettiğimiz çapraz entropi hata değerlerinin değişimini Şekil 11 üzerinde epoch değerlerine göre gösterdik. Grafikten anlaşılacağı üzere, Classic CNN'de 2. epoch'ta hata en yüksek seviyedeyken, 15. epoch'ta hata en düşük seviyeye gerilemiştir. Aynı şekilde, ANN'de 2. epoch'ta hata en yüksek, 15. epoch'ta hata en düşük seviyedir. ALEXNET'te ise 8. epoch'ta hata en yüksek, 15. epoch'ta hata en düşük düzeydedir. VGG16 modelinde 2. epoch'ta hata en yüksek, 15. epoch'ta ise hata en düşük seviyedir. VGG19'da ise hata değerleri sabit kalmıştır. Poly-CNN modelinde ise 2. epoch'ta hata en yüksek, 15. epoch'ta ise hata en düşük seviyedir.

### 3.2. Kullanılan Modellerin Sınıflandırma Doğruluğu Grafikleri

Ağırlıklar sürekli güncellenmekte olup, en iyi öğrenmeler Şekil 12'de gösterilmiştir. Grafikte anlaşıldığı üzere en iyi öğrenmeler Classic CNN'de ANN'de, ALEXNET'de VGG16'da, VGG19'da ve Poly-CNN'de 15. epoch da görülmektedir.

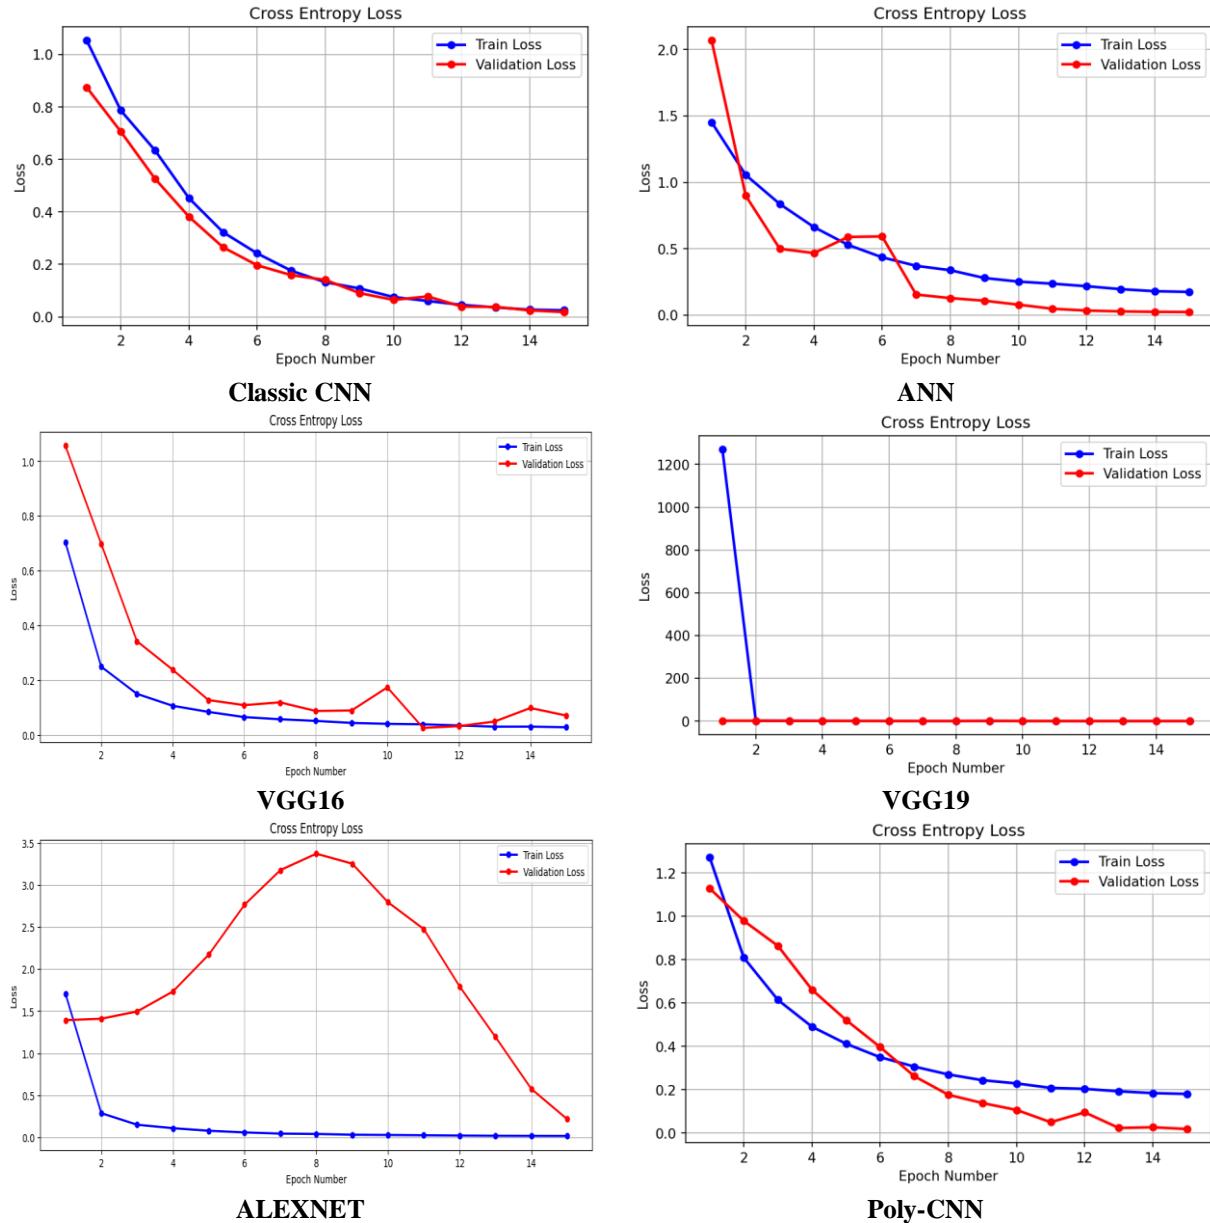
## 4. TARTIŞMA VE SONUÇ

Bilgisayarlı görüntü işleme ve derin öğrenme teknolojilerindeki hızlı ilerlemeler, tıbbi görüntüleme alanında çeşitli uygulamalar için yeni olanaklar sağlamaktadır [28]. Bu alandaki en önemli uygulamalardan biri, medikal görüntü sınıflandırmasıdır [29]. Medikal görüntü sınıflandırması, uzmanların hastalıkları teşhis etmelerine, tedavi stratejilerini belirlemelerine ve hastaların durumlarını izlemelerine yardımcı olabilecek bir araç olarak büyük bir potansiyele sahiptir.

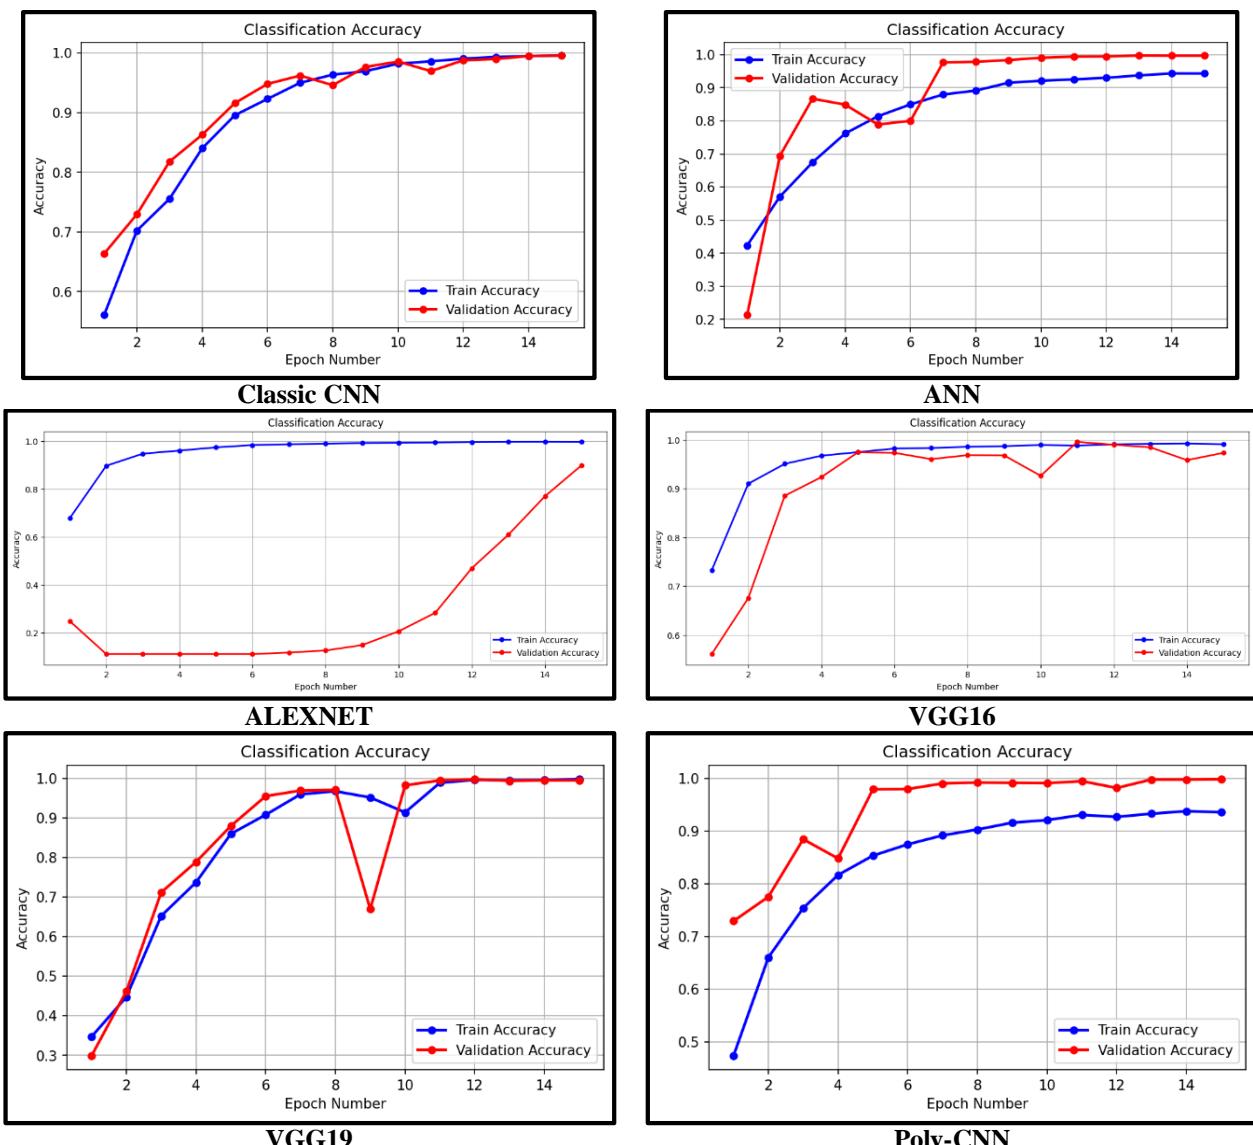
Böbrek hastalıkları, sağlık sorunları arasında önemli bir yer tutmaktadır ve erken teşhis, etkili tedavi ve hastalık izlemesi için kritik öneme sahiptir. Bu nedenle, Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve geliştirilmiş Poly-CNN ağı gibi popüler derin öğrenme mimarileri kullanılarak böbrek görüntülerinin sınıflandırılması yapılmıştır. Derin öğrenme tabanlı sınıflandırma yöntemlerini kullanarak böbrek görüntülerini başarıyla sınıflandırılmış ve bu yöntemlerin klinik uygulamalarındaki potansiyeli değerlendirilmiştir. Böbrek hastalıklarının sınıflandırmasında Classic CNN, ANN, ALEXNET, VGG16, VGG19 ağları ve geliştirilmiş Poly-CNN ağı gibi farklı derin öğrenme metodlarını kullanılarak veri seti üzerinde performans

analizleri yapılmıştır. Uygulanan bu modellerde böbrek veri seti için yüksek doğruluk oranları gözlemlenmiştir. En yüksek doğruluğu %0,9994 ile Poly-CNN sergilemiştir. Elde edilen bu sonuçlar doğrultusunda önerilen araştırma çerçevesinin tekniği bilinen Classic

CNN'den daha iyi performans gösteren Poly-CNN ortaya konulmuştur. Poly-CNN diğer çalışmalara kıyasla doğrulukta gözle görülebilir bir artış olduğundan dolayı önerilen yöntemin etkinliğini açıkça ortaya koymaktadır.



Şekil 11. Modellerin Hata Çapraz Entropi Grafikleri



Şekil 12. Modellerin Çapraz entropi hata grafikleri

Sonuç olarak bu çalışma, bilgisayar destekli tıbbi teşhis alanında bir katkı sağlamayı amaçlayan önemli bir araştırma çalışmasıdır. Derin öğrenme yöntemlerinin medikal görüntü sınıflandırması üzerindeki etkisini anlamak, hastaların daha hızlı ve doğru bir şekilde teşhis edilmesine ve tedavi edilmesine katkı sağlayabilmektedir. Bu çalışma, tıbbi görüntüleme ve derin öğrenme alanlarındaki araştırmacılar, doktorlara ve sağlık profesyonellerine faydalı olacaktır. Gelecekteki çalışmalar, daha fazla derin öğrenme modeli ve daha geniş veri setleri kullanarak bu yöntemlerin daha da optimize edilmesi hedeflenmektedir.

## Etki Hususları

### Etki kurallara uyum

Yaazarlar olarak, insan gönüllülerini ve deneysel hayvan içeren çalışmalarında gerçekleştirilen tüm prosedürleri, kurumsal ve / veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki deklarasyonuna ve daha sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun çalıştığımızı deklare ederiz.

## Finansman

Yazarlar olarak, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe almadık.

## Çıkar çatışması

Yazarlar olarak herhangi bir çıkar çatışması içinde bulunmadık.

## KAYNAKÇA

- [1] Tahir, M., Naeem, A., Malik, H., Tanveer, J., Naqvi, R.A., Lee, S.W. 2023. DSCL\_Net: Multi-Classification Deep Learning Models for Diagnosing of Skin Cancer Using Dermoscopic Images, Cancers (Basel)., 15(7). doi: 10.3390/cancers15072179.
- [2] Srikantamurthy, M.M., Rallabandi, V.P.S., Dudekula, D.B., Natarajan, S., Park, J. 2023. Classification of benign and malignant subtypes of breast cancer histopathology imaging using hybrid CNN-LSTM based transfer learning, BMC Med.

- Imaging, 23(1), 19. doi: 10.1186/s12880-023-00964-0.
- [3] Cifci, M. 2022. Derin Öğrenme Metodu Kullanarak BT Görüntülerinden Akciğer Kanseri Teşhis, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Derg., 24(71), 487–500. doi: 10.21205/deufmd.2022247114.
- [4] Gharaibeh, M., Alzu’bi, D., Abdullah, M., Hmeidi, I., Al Nasar, M.R. Abualigah, L. Gandomi, A.H. 2022. Radiology Imaging Scans for Early Diagnosis of Kidney Tumors: A Review of Data Analytics-Based Machine Learning and Deep Learning Approaches. *Big Data Cogn. Comput.* 6, 29. <https://doi.org/10.3390/bdcc6010029>
- [5] Aalami, N. 2020. Derin öğrenme yöntemlerini kullanarak görüntülerin analizi, Eskişehir Türk Dünyası Uygul. ve Araştırma Merk. Bilişim Derg., 1(1), 17–20.
- [6] Liu, X., Song, L., Liu, S., Zhang, Y. 2021. A Review of Deep-Learning-Based Medical Image Segmentation Methods, *Sustainability*, 13(3). doi: 10.3390/su13031224.
- [7] Özdemir, D., Tüzün, B.N. 2023. Classification of Brain Tumors With Deep Learning Models, *J. Sci. Reports-A*, 054, 296–306. doi: 10.5931/jrs.a.1293119.
- [8] Özdemir, D., Arslan, N.N. 2022. Analysis of Deep Transfer Learning Methods for Early Diagnosis of the Covid-19 Disease with Chest X-ray Images, Düzce Üniversitesi Bilim ve Teknol. Derg., 10(2), 628–640. doi: 10.29130/dubited.976118.
- [9] Krizhevsky, A., Sutskever, I., Hinton, G.E. 2012. Imagenet classification with deep convolutional neural networks, *Adv. Neural Inf. Process. Syst.*, 25.
- [10] Rehman, A., Naz, S., Razzak, M.I., Akram, F., Imran, M. 2020. A Deep Learning-Based Framework for Automatic Brain Tumors Classification Using Transfer Learning, *Circuits Syst. Signal Process.*, 39(2), 757–775. doi: 10.1007/s00034-019-01246-3.
- [11] Bingol, H., Yıldırım, M., Yıldırım, K., Alatas, B. 2023. Automatic classification of kidney CT images with relief based novel hybrid deep model, *Peer J. Comput. Sci.*, 9, e1717. doi: 10.7717/peerj-cs.1717.
- [12] N. Heller et al., 2021. The state of the art in kidney and kidney tumor segmentation in contrast-enhanced CT imaging: Results of the KiTS19 challenge, *Med. Image Anal.*, 67, 101821. doi: <https://doi.org/10.1016/j.media.2020.101821>.
- [13] Bhandari, M., Yogarajah, P., Kavitha, M.S., Condell, J. 2023. Exploring the Capabilities of a Lightweight CNN Model in Accurately Identifying Renal Abnormalities: Cysts, Stones, and Tumors, Using LIME and SHAP, *Appl. Sci.*, 13(5). doi: 10.3390/app13053125.
- [14] da Cruz, L.B., et al., 2022. Kidney tumor segmentation from computed tomography images using DeepLabv3+ 2.5D model, *Expert Syst. Appl.*, 192, 116270. doi: <https://doi.org/10.1016/j.eswa.2021.116270>.
- [15] Alzu’bi D., et al., 2022. Kidney Tumor Detection and Classification Based on Deep Learning Approaches: A New Dataset in CT Scans, *J. Healthc. Eng. 3861161*. doi: 10.1155/2022/3861161.
- [16] Islam, M.N., Hasan, M., Hossain, M.K., Alam, M. G. R., Uddin, M. Z., Soylu, A. 2022. Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography, *Sci. Rep.*, 12(1), 11440. doi: 10.1038/s41598-022-15634-4.
- [17] Sasikaladevi, N., Revathi, A. 2024. Digital twin of renal system with CT-radiography for the early diagnosis of chronic kidney diseases, *Biomed. Signal Process. Control.*, 88, 105632. <https://doi.org/10.1016/j.bspc.2023.105632>.
- [18] Raza A., et al., 2022. A Hybrid Deep Learning-Based Approach for Brain Tumor Classification, *Electronics*, 11(7). doi: 10.3390/electronics11071146.
- [19] Yu, A.C., Mohajer, B., Eng, J. 2022. External Validation of Deep Learning Algorithms for Radiologic Diagnosis: A Systematic Review, *Radiol. Artif. Intell.*, 4(3), e210064. doi: 10.1148/ryai.2100064.
- [20] CT Kidney Dataset: Normal-Cyst-Tumor and Stone. (2023, 06 Haziran) Erişim Adresi.” <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone>.
- [21] Tan, M., Emeksiz, C. 2023. Yüz Tanıma Sistemleri İçin Geliştirilmiş Veri Artırma Temelli Adaptif Yüz Tanıma Modeli, Düzce Üniversitesi Bilim ve Teknol. Derg., 11(2), 588–606. doi: 10.29130/dubited.1024670.
- [22] Koushik, J. 2016. Understanding Convolutional Neural Networks. <http://arxiv.org/abs/1605.09081>.
- [23] Tosunoğlu, N.G., Benli, Y.K. 2012. Forecasting of Morgan Stanley Capital International Turkey Index with Artificial Neural Networks, *Ege Acad. Rev.*, 12(4), 541–547.
- [24] Krizhevsky, A., Sutskever, I., Hinton, G.E. 2017. ImageNet Classification with Deep Convolutional Neural Networks, *Commun. ACM*, 60(6), 84–90. doi: 10.1145/3065386.
- [25] da Rocha, D.A., Ferreira, F. M. F., Peixoto, Z. M. A. 2022. Diabetic retinopathy classification using VGG16 neural network, *Res. Biomed. Eng.*, 38(2), 761–772. doi: 10.1007/s42600-022-00200-8.
- [26] Karacı, A. 2022. VGGCOV19-NET: automatic detection of COVID-19 cases from X-ray images using modified VGG19 CNN architecture and YOLO algorithm, *Neural Comput. Appl.*, 34(10), 8253–8274. doi: 10.1007/s00521-022-06918-x.
- [27] Balasubramaniam, S., Velmurugan, Y., Jaganathan, D., Dhanasekaran, S. 2023. A Modified LeNet CNN for Breast Cancer Diagnosis in Ultrasound Images, *Diagnostics*, 13(17). doi: 10.3390/diagnostics13172746.
- [28] Maqsood, S., Damaševičius, R., Maskeliūnas, R. 2022. Multi-Modal Brain Tumor Detection Using Deep Neural Network and Multiclass SVM, *Medicina (B. Aires.)*, 58(8). doi: 10.3390/medicina58081090.
- [29] Rajpurkar, P., Chen, E., Banerjee, O., Topol, E.J. 2022. AI in health and medicine, *Nat. Med.*, 28(1), 31–38. doi: 10.1038/s41591-021-01614-0.