



POLİTEKNİK DERGİSİ

*JOURNAL of POLYTECHNIC*

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



# Derin öğrenme ile kuş türü sınıflandırma: karşılaştırmalı bir çalışma

## *Bird species classification using deep learning: a comparative study*

Yazar(lar) (Author(s)): Mehtap MUTLU BİLGİN<sup>1</sup>, Kevser ÖZDEM<sup>2</sup>, M. Ali AKCAYOL<sup>3</sup>

ORCID<sup>1</sup>: 0000-0003-0545-2252

ORCID<sup>2</sup>: 0000-0002-6695-200X

ORCID<sup>3</sup>: 0000-0002-6615-1237

**Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article):** Bilgin M. M., Özdem K. ve Akcayol M. A., “Derin öğrenme ile kuş türü sınıflandırma: karşılaştırmalı bir çalışma”, *Politeknik Dergisi*, 25(3): 1251-1260, (2022).

**Erişim linki (To link to this article):** <http://dergipark.org.tr/politeknik/archive>

**DOI:** 10.2339/politeknik.904933

# Derin Öğrenme ile Kuş Türü Sınıflandırma: Karşılaştırmalı Bir Çalışma

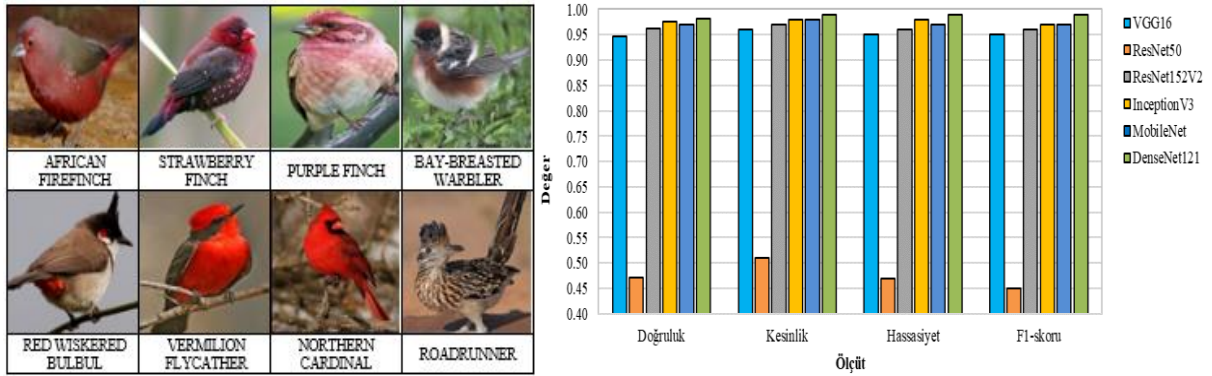
## Bird Species Classification Using Deep Learning: A Comparative Study

### Önemli noktalar (Highlights)

- ❖ Derin öğrenme kullanarak sınıflandırma / Classification using deep learning
- ❖ VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet ve DenseNet121 modelleri ile kuş türü tahmini Bird species prediction with VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet and DenseNet121
- ❖ Farklı derin öğrenme modelleri için elde edilen deneysel sonuçların kapsamlı bir şekilde karşılaştırması Comprehensive comparison of experimental results obtained for different deep learning models

### Grafik Özet (Graphical Abstract)

Bu çalışmada kuş türlerinin sınıflandırması için altı farklı derin öğrenme modeli uygulanmış ve deneysel sonuçlar kapsamlı bir şekilde karşılaştırılmıştır. / In this study, six different deep learning models have been applied for the classification of bird species and the experimental results have been compared comprehensively.



Şekil. Kuş görüntüleri ve modellerin karşılaştırması /Figure. Bird images and comparison of models

### Amaç (Aim)

Bu çalışmanın amacı kuş görüntüleri üzerinde derin öğrenme ile kuş türü sınıflandırma gerçekleştirmektir. / The aim of this study is to perform bird species classification using deep learning on bird images.

### Tasarım ve Yöntem (Design & Methodology)

Bu çalışmada VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet ve DenseNet121 derin öğrenme modelleri kapsamlı bir şekilde karşılaştırılmıştır. / In this study, VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet and DenseNet121 deep learning models are compared comprehensively.

### Özgünlük (Originality)

Bu çalışma, bu kadar fazla kuş türü ve veri kullanarak çok sayıda mimariyi kapsamlı olarak analiz eden ilk çalışmadır. Çalışmada elde edilen başarı oranı göz önüne alındığında uygulanabilirliği oldukça yüksektir. / This study is the first to comprehensively analyze a large number of architectures, using so many bird species and data. Considering the success rate obtained, applicability of the study is quite high.

### Bulgular (Findings)

Deneysel sonuçlar, DenseNet121 modelinin kuş türü sınıflandırmada diğer modellerden daha başarılı olduğunu göstermiştir. / The experimental results have shown that DenseNet121 model is more successful than other models, in bird species classification.

### Sonuç (Conclusion)

Geliştirilen uygulama ile bir görüntüdeki kuşun türü farklı derin öğrenme modelleri ile tahmin edilmektedir. / With the developed application, the species of the bird in an image is predicted using different deep learning models.

### Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

# Derin Öğrenme ile Kuş Türü Sınıflandırma: Karşılaştırmalı Bir Çalışma

*Araştırma Makalesi / Research Article*

**Mehtap MUTLU BİLGİN, Kevser ÖZDEM\*, M. Ali AKCAYOL**

Mühendislik Fakültesi, Bilgisayar Müh. Bölümü, Gazi Üniversitesi, Türkiye

(Geliş/Received : 29.03.2021 ; Kabul/Accepted : 23.08.2021 ; Erken Görünüm/Early View : 07.09.2021)

## ÖZ

Kuş türlerini görüntü üzerinden sınıflandırmaya yönelik çalışmalar hem görüntü içerisindeki renk ve desen çokluğu hem de birbirine çok yakın görsel özelliklere sahip olmalarından dolayı oldukça zordur. Bu çalışmada kuş türlerinin sınıflandırması için altı farklı derin öğrenme modeli uygulanmış ve deneysel sonuçlar kapsamlı bir şekilde karşılaştırılmıştır. Veri kümesi olarak 225 kuş türüne sahip toplam 31316 kuş görüntüsü olan 250 Bird Species isimli veri kümesi kullanılmıştır. Çalışmada 1125 tane görüntü test ve 1125 tane görüntü ise doğrulama için kullanılmıştır. Veri kümesi üzerinde sırasıyla VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet ve DenseNet121 derin öğrenme modellerinin doğruluk, kesinlik, hassasiyet ve F1-skoru değerlerine göre karşılaştırması yapılmıştır. Yapılan deneysel çalışmalarda, VGG16 ile %94,6, ResNet50 ile %47,2, ResNet152V2 ile %96,2, InceptionV3 ile %97,5, MobileNet ile %96,9 ve DenseNet121 ile %98,2 doğruluk değerleri elde edilmiştir. En yüksek kesinlik değeri 0,99, hassasiyet değeri 0,99 ve F1-skoru değeri 0,99 olarak DenseNet121 ile elde edilmiştir.

**Anahtar Kelimeler:** Kuş türü sınıflandırma, VGG16, resnet50, resnet152v2, inceptionv3, mobilenet, densenet121.

## Bird Species Classification Using Deep Learning: A Comparative Study

### ABSTRACT

Studies to classify bird species on the basis of images are very difficult due to both the abundance of colors and patterns in the image, and their very close visual characteristics. In this study, six different deep learning models have been applied for the classification of bird species and the experimental results have been compared comprehensively. A dataset named 250 Bird Species, which includes a total of 31316 bird images with 225 bird species, was used as dataset. In the study, 1125 images have been used for the test and 1125 images for the validation. The comparison of VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet and DenseNet121 deep learning models have been made on the dataset respectively, according to the accuracy, precision, recall and F1-score values. In experimental studies, 94.6% accuracy value has been obtained with VGG16, 47.2% with ResNet50, 96.2% with ResNet152V2, 97.5% with InceptionV3, 96.9% with MobileNet and 98.2% with DenseNet121. DenseNet121 obtained the highest precision value as 0.99, sensitivity value as 0.99 and F1-score value as 0.99.

**Keywords:** Bird species classification, VGG16, resnet50, resnet152v2, inceptionv3, mobilenet, densenet121.

### 1. GİRİŞ (INTRODUCTION)

Kuşlar, birbirinden farklı renkleri, tüyleri, boyutları ve ötüşleri ile dünyadaki nadide canlılardır. Bilim adamları tarafından oluşturulmuş 40 takım içerisinde, yaklaşık 10000 farklı kuş türü mevcuttur. En çok görülen ve ilgi çeken canlı gruplarından biri olarak kuşlar, dünya üzerindeki en yaygın hayvan grubu olarak bilinmektedir. Diğer canlılarda olduğu gibi kuş türleri de biyoçeşitlilik araştırmalarının temellerini oluşturmaktadır. Ancak bir türün nasıl oluştuğu ile ilgili süreç, karmaşık ve üzerinde tartışılmakta olan bir konudur [1, 2].

Literatürde derin öğrenmenin sınıflandırma alanındaki kullanımına yönelik çok sayıda çalışma bulunmaktadır. Ancak, derin öğrenme kullanılarak kuş türlerinin tespit edilmesi üzerinde çalışmaların devam ettiği ve oldukça zor bir sınıflandırma problemidir [13-15].

Ge ve arkadaşları tarafından 2015 yılında gerçekleştirilen bir çalışmada, ince taneli kuş türlerinin sınıflandırılması için hiyerarşik alt küme öğrenmeye dayalı yeni bir yöntem önerilmiştir [3]. Önerilen yöntemde, Convolutional Neural Network (CNN) kullanılarak veri kümesinden özellikler türetilmektedir. Güçlü görsel korelasyonlara sahip sınıfların alt kümeler halinde gruplandırıldığı bir benzerlik ağacı oluşturulmaktadır. Daha sonra, görsel olarak benzer sınıfların ayırt edilebilmesi için güçlü ayırt etme gücüne sahip bir sınıflandırıcı kullanılarak her bir alt küme için öğrenme gerçekleştirilmektedir. Caltech200-2011 kuş veri kümesinde gerçekleştirilen deneysel çalışmalarda %72,70 oranında doğruluk değeri elde edilmiştir.

Niemi ve arkadaşları tarafından 2018 yılında yapılan çalışmada otomatik kuş tanımlama için yeni bir sistem önerilmiştir [4]. Görüntü sınıflandırma için derin öğrenme algoritması ile eğitilmiş CNN modeli kullanılmıştır. Ayrıca, görüntülerin döndürüldüğü ve istenen renk sıcaklıklarına göre dönüştürüldüğü bir veri

\*Sorumlu Yazar (Corresponding Author)  
e-posta : kevserozdem@gazi.edu.tr

büyütme yöntemi önerilmiştir. Nihai tanımlama, radar tarafından sağlanan parametrelerin bir birleşimine ve görüntü sınıflandırıcının tahminlerine dayanmaktadır. Önerilen sistem manuel olarak toplanan 9312 orijinal görüntüyü içeren bir veri kümesinde test edilmiştir. Görüntü sınıflandırma hassasiyeti 0,9463 olarak elde edilmiştir. Bu çalışmada, beyaz kuyruklu kartal ve küçük kara sırtlı martı isimli iki önemli kuş türü için Receiver Operating Characteristic (ROC) eğrisi altında kalan alanlar sırasıyla 0,9993 ve 0,9496 olarak bulunmuştur.

Liu ve arkadaşları tarafından 2018 yılında gerçekleştirilen çalışmada Little Birds in Aerial Imagery (LBAI) kuş tespiti için yeni bir veri kümesi olarak sunulmuştur [5]. Çalışmada, bu veri kümesi kullanılarak derin öğrenme yöntemlerinin düşük çözünürlüklü küçük nesne algılamadaki performansları iyileştirilmektedir. LBAI, boyutları 10 piksel ile 40 piksel arasında değişen kuşları içermektedir. Yapılan deneysel çalışmalarda, U-Net ve Mask Region-based CNN (R-CNN) gibi küçük örnek segmentasyon yöntemlerine ek olarak You Only Look Once (YOLO) v2, Single Stage Headless (SSH) ve Tiny Face gibi nesne algılama yöntemlerini içeren derin öğrenme mimarileri de LBAI verisine uygulanmıştır. Deneysel sonuçlar SSH'nin kolay durumlar için en başarılı yöntem olduğunu göstermiştir. Tiny Face ise zor durumlarda, yani karmaşık bir arka planın kuşları tespit etmeyi zorlaştırdığı durumlarda, diğer yöntemlere göre en iyi performansı sağlamıştır. Küçük örnek segmentasyon yöntemleri arasında ise U-Net, Mask R-CNN'e göre daha iyi performans elde etmiştir.

Das ve arkadaşlarının 2018 yılında yayımlanan çalışmasında, çok aşamalı eğitim ile transfer öğrenmeye dayalı bir yöntem tanıtılmıştır [6]. Görüntülerden kuşların hem lokalizasyonunu hem de türünü elde etmek için PreTrained Mask R-CNN, InceptionV3 ve InceptionResnetV2 ağlarından oluşan bir topluluk modeli kullanılmıştır. Computer Vision and Image Processing (CVIP) 2018 kuş türleri yarışmasında sağlanan yüksek çözünürlüklü görüntülerden oluşan veri kümesi üzerinde gerçekleştirilen veri artırmanın sonucunda eğitim veri kümesi 150 görüntüden 1330 görüntüye yükseltilmiştir. Deneysel sonuçlarda, F1 skoru değeri 0,5567 olarak elde edilmiştir.

Huang ve arkadaşları tarafından 2019 yılında, 27 Tayvan endemik kuş türünün tanınması üzerine bir çalışma yapılmıştır [7]. Çalışmada, 27 kuş türüne ait 3563 görüntüden oluşan veri kümesi kullanılarak bir derin öğrenme platformu geliştirilmiştir. Görüntülerdeki belirgin özelliklerin yerleştirilmesi için CNN modeli kullanılmıştır. Özellik çıkarımını iyileştirmek için önceki ve mevcut katmanların çıktılarını doğrusal olarak birleştiren bir bağlantı atlama yöntemi ve olasılık dağılımı elde etmek için softmax fonksiyonu kullanılmıştır. Geliştirilen sistem eğitim veri kümesi için %98,70 doğrulukla kuşları algılayıp ayırt edebilmektedir. Deneysel sonuçlara göre bu doğruluk değeri normal bir CNN modelinde %93,98, Support Vector Machine (SVM) modelinde ise %89,00 olarak elde edilebilmiştir. Test kümesi üzerinde yapılan deneylerde ise, ortalama

hassasiyet, kesinlik ve doğruluk değerleri sırasıyla %93,79, %96,11 ve %95,37 olarak elde edilmiştir.

Hong ve arkadaşlarının 2019 yılında yayımlanan çalışmasında, Region-based Fully Convolutional Network (R-FCN), Faster R-CNN, Retinanet, Single Shot MultiBox Detector (SSD) ve YOLO gibi kuş algılama modelleri oluşturulmuştur [8]. Tüm modellerin performansı, hesaplama hızları ve ortalama hassasiyetleri karşılaştırılmıştır. Eğitim için 113466 kuşun görüntülerini içeren 21914 hava fotoğrafı, doğrulama için 3847 hava fotoğrafı ve 20178 kuş görüntüsü kullanılmıştır. Test için ise 17462 kuşa ait toplam 3513 hava fotoğrafı kullanılmıştır. Deneysel sonuçlar, modeller arasında R-CNN'nin en doğru, YOLO modelinin ise daha kısa sürede sonuçlar ürettiğini göstermiştir. Derin öğrenme tabanlı modellerin İnsansız Hava Aracı (İHA) hava fotoğrafları kullanılarak kuş tespiti ve nihayetinde vahşi hayvanları izlemek için uygun olduğu belirtilmiştir.

Islam ve arkadaşlarının 2019 yılında gerçekleştirdikleri çalışmada, Bangladeşli kuşları türlerine göre tanımlamak için bir makine öğrenmesi yaklaşımı önerilmektedir [9]. Kuş görüntülerinden özelliklerin çıkarılması için Visual Geometry Group-16 (VGG16) ağı kullanılmıştır. Sınıflandırmayı gerçekleştirmek için Bangladeş'in farklı kuş türlerinin resimlerini içeren bir veri kümesi kullanılmıştır. Çeşitli sınıflandırma yöntemleri karşılaştırılmış ve her biri için farklı sonuçlar elde edilmiştir. Deneysel sonuçlarda, Random Forest ve k-Nearest Neighbor (k-NN) gibi sınıflandırma yöntemlerine kıyasla SVM ile %89 oranında bir doğrulukla en iyi performans sağlanmıştır.

Gavali ve arkadaşlarının 2019 yılında yaptıkları çalışma, kuş türü tespitinde eğitim ve test amaçlı olarak Caltech-UCSD Birds 200 [CUB-200-2011] veri kümesi kullanılmıştır [10]. Çalışmada, 200 farklı kuş türü ve 11788 resim içeren veri kümesindeki görüntüler, gri tonlama formatına dönüştürülmüştür. Ubuntu 16.04 işletim sistemi ve TensorFlow kütüphanesi kullanılarak yapılan deneysel analizlerde önerilen algoritmanın %80 ile %90 arasında bir tanımlama doğruluğuna ulaştığı gösterilmiştir.

Raquel ve arkadaşları tarafından 2019 yılında gerçekleştirilen çalışmada, Filipin kuş türlerinin derin öğrenme kullanılarak sınıflandırması için bir yaklaşım sunulmuştur [11]. Mevcut kuş türü veri kümelerinin çoğunun Kuzey Amerika gibi belirli bölgelerdeki kuşlarla sınırlı olduğu belirtilerek Filipin kuş türleri için bir veri kümesi oluşturulmuştur. CNN ağlarının görüntü sınıflandırmadaki performansının çok verimli olduğu ancak, sınıflandırmada yüksek bir doğruluk elde etmek için çok büyük bir veri kümesi ve önemli miktarda eğitim süresi gerektiği anlatılmıştır. Bu nedenle, Google'ın 1000 farklı kategoriye sahip olan InceptionV3 isimli önceden eğitilmiş modeli, TensorFlow kullanılarak 50 Filipin kuş türünü sınıflandırmak için yeniden eğitilmiştir. Deneysel sonuçlarda, Filipin kuş türleri sınıflandırması için %94 oranında bir doğruluk elde edilmiştir.

Ragıp ve arkadaşlarının 2020 yılında yaptıkları çalışmaya göre Residual Network (ResNet), derin öğrenmede kullanılan en iyi önceden eğitilmiş CNN ağlarından biridir [12]. Çalışmada, giriş görüntülerinden kuşları tek tek tanımlayabilen bir derin öğrenme modeli önerilmiştir. Görüntüleri kodlamak için temel modele sahip önceden eğitilmiş ResNet modelinden yararlanılmıştır. Kuşlar, insan bakış açısından farklı boyutlarda, şekillerde, renklerde görülebilmektedir. Bu nedenle, yürütülen deneylerde, tanıma performansını artırmak için farklı boyutlarda ve hızda kuşlar kullanılmıştır. Yapılan sınıflandırmada %97,98 oranında bir doğruluk değeri elde edilmiştir.

Gavali ve arkadaşları, 2020 yılında yayımlanan çalışmalarında, kuş türleri sınıflandırması için Deep CNN (D-CNN) kullanmıştır [13]. Çalışmada, eğitim ve test için Caltech-UCSD Birds 200 [CUB-200-2011] verileri kullanılmıştır. Sınıflandırma, D-CNN ve paralel işlem GPU teknolojisi kullanılarak gerçekleştirilmiştir. TensorFlow kitaplığına sahip Linux işletim sistemlerinde ve 2 GB RAM ile NVIDIA Geforce GTX 680 kullanılarak gerçekleştirilen deneysel sonuçlar, D-CNN algoritmasının kuş türlerini %88,33 oranında tahmin edebileceğini göstermektedir.

Raj ve arkadaşları tarafından 2020 yılında yapılan çalışmada, kuş gözlemcilerinin, kuşları doğal ortamlarında tanımlayabilmeleri için bir araç geliştirilmiştir [14]. Bunun için, 60 kuş türünü tanıyabilecek bir derin öğrenme modeli önerilmiştir. Bu modelde, CNN algoritmasını kullanarak kuş görüntülerinden bilgi çıkarılmaktadır. Microsoft'a ait Bing Görsel Arama API v7 kullanılarak 8218 görüntü içeren yeni bir veri kümesi oluşturulmuştur. Verilerin 80:20 oranında rastgele bölünmesi sağlandıktan sonra yapılan deneylerde, eğitim kümesinde sınıflandırma doğruluk oranı %93,19, test kümesinde ise %84,91 olarak elde edilmiştir. Deneylerin tamamı TensorFlow kütüphanesi ve Adam Optimizer kullanılarak Windows 10 işletim sistemi üzerinde gerçekleştirilmiştir.

Chakraborti ve arkadaşlarının 2020 yılında yayımlanan makalesinde, kuş türlerinin ayrıntılı görsel sınıflandırması için Collaborative Convolutional Network (CoCoNet) adı verilen uçtan uca derin bir ağ sunulmuştur [15]. Ağ, bir seferde bir görüntüyü almak yerine eğitim örneklerini bir bütün olarak alarak özellikleri öğrenmesi sağlanmaktadır. Çalışmada, temsili bir örnek olarak ince taneli kuş türleri sınıflandırma problemi üzerinde deneyler yapılmıştır, ancak yöntemin diğer benzer görevlere de uygulanabileceği belirtilmiştir.

Bu çalışmada, derin öğrenme ile kuş türü sınıflandırma üzerine yapılan çalışmaların analizi yapılmıştır. VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet ve DenseNet121 derin öğrenme mimarileri 225 kuş türüne ait 33566 görüntüden oluşan bir veri kümesi üzerinde test edilmiştir. Farklı derin öğrenme mimarilerine ait test sonuçları, doğruluk, kesinlik, hassasiyet ve F1-skoru değerlendirme ölçütleri kullanılarak karşılaştırmalı olarak sunulmuştur. En yüksek kesinlik değeri 0,99,

hassasiyet değeri 0,99 ve F1-skor değeri 0,99 olarak DenseNet121 ile elde edilmiştir.

## 2. KUŞ TÜRÜ SINIFLANDIRMA (BIRD SPECIES CLASSIFICATION)

Günümüzde, türleri ve popülasyonları karşılaştırmak için temel olarak, tek nükleotid polimorfizmleri veya mikrosatelitler gibi çok sayıda belirteçten yararlanan genomik ve transkriptomik yaklaşımlar kullanılmaktadır. [16]. Kuşların sınıflandırılmasında ise genetik farklılıklar, biyocoğrafya, tüy desenleri ve ötüş şekilleri gibi kriterler büyük rol oynamaktadır [2].

Kuş türlerinin tanınması, sahip oldukları özellikler bakımından oldukça güçtür. Son zamanlarda gelişen yapay zeka teknolojileri ile canlıların sınıflandırılması bu alanın konusu olmaya başlamıştır. Özellikle makine öğrenmesinin gündeme gelmesi ile türlerin tanınması konusunda birçok araştırma yapılmıştır. Klasik görüntü işleme yöntemlerinden yararlanılarak gerçekleştirilen çalışmalarda, öncelikle türlerin ayırt edilebileceği özelliklerin çıkartılması gerekmektedir [29-32]. Araştırmalara bakıldığında makine öğrenmesinin bir alt dalı olan derin öğrenmenin, sağladığı kolaylıkların da bir sonucu olarak bu alanda çokça kullanılmaya başlandığı saptanmıştır. Derin öğrenme, bilgisayarların deneyimlerden öğrenmesini sağlayan bir makine öğrenimi biçimidir. Bilgisayar, deneyimden kendisi bilgi topladığı için ihtiyaç duyduğu tüm bilgilerin bir insan tarafından sağlanmasına gerek kalmamaktadır. Derin öğrenme, bilgisayarın dünyayı kavramlar hiyerarşisi açısından anlamasını sağlamaktadır. Kavramların hiyerarşisi, bilgisayarın karmaşık kavramları daha basit olanlardan oluşturarak öğrenmesini sağlamaktadır [17].

Derin öğrenme alanında kuş türlerinin tanınması ile ilgili literatüre bakıldığında en çok kullanılan yöntemin CNN olduğu görülmektedir. En popüler derin sinir ağlarından biri olan CNN, adını evrişim adı verilen matrisler arasındaki matematiksel doğrusal işlemde almaktadır. Evrişimli katman, doğrusal olmayan katman, havuz katmanı ve tam bağlantılı katman gibi birden çok katmandan oluşmaktadır. Doğrusal olmayan katman, üretilen çıktıyı sınırlayarak ayarlamak için kullanılmaktadır. Havuz katmanı, aşağı örnekleme yaparak daha sonraki katmanlar için karmaşıklığı azaltmaktadır. Tam bağlantılı katmandaki her düğüm, önceki ve sonraki katmandaki her düğüme doğrudan bağlanmaktadır. CNN, makine öğrenimi problemlerinde mükemmel bir performansa sahiptir. Özellikle ImageNet gibi görüntü verileriyle ilgili uygulamalarda verimli sonuçlar elde edilmiştir [18].

Kuş türü sınıflandırma uygulamalarında CNN'in yanı sıra Retinanet, YOLO, SSH, Tiny Face, Random Forest, k-NN, SVM gibi modeller de kullanılmaktadır. Ayrıca çoğu modelde transfer öğrenme yönteminden faydalanılmaktadır [3-15]. Transfer öğrenimi, yeni ancak benzer problemleri çok daha hızlı ve etkili bir şekilde çözmek için önceden edinilmiş bilgileri kullanan bir çerçeve sağlamaktadır. Klasik yöntemlerin aksine

transfer öğrenme yöntemleri, yardımcı alanlardaki verilerden toplanan bilgileri, hedef alandaki tahmine dayalı modellemeyi kolaylaştırmak için kullanılmaktadır [19]. Hedef alandaki model sıfırdan eğitilmediği için eğitim verisi talebi ve eğitim süresi önemli ölçüde azalmaktadır [20].

### 3. VERİ KÜMESİ (DATASET)

Modelin eğitimi aşamasında, Kaggle platformundan elde edilen 225 kuş türüne ait görüntülerin bulunduğu 250 Bird Species isimli bir veri kümesi kullanılmıştır [21]. Bu veri kümesi, 31316 adet eğitim görüntüsü (tür başına 100'den fazla görüntü), 1125 adet test görüntüsü (tür başına 5 görüntü) ve 1125 adet doğrulama görüntüsü (tür başına 5 görüntü) olmak üzere üç klasöre ayrılmıştır. Her klasör, her kuş türü için bir tane olmak üzere 225 alt klasör içermektedir. Tüm görüntüler jpg formatında, 224 X 224 X 3 boyutlarında ve renkli görüntülerdir. Veri kümesinde bulunan kuş türlerinden bazıları Çizelge 1.'de sunulmuştur.


Kuş türlerinin sınıflandırılması, sahip oldukları özellikler bakımından klasik yöntemlerde olduğu gibi derin

öğrenmede de gerçekleştirilmesi zor ve karmaşık bir işlemdir. Özellikle geniş ve benzer kuş türlerini içeren bir veri kümesi kullanıldığında, yüksek başarımın sağlanabilmesi için ayırt edebilirliği yüksek modeller geliştirilmesi gerekmektedir.

### 4. KUŞ TÜRÜ SINIFLANDIRMADA KULLANILAN DERİN ÖĞRENME MİMARİLERİ (DEEP LEARNING ARCHITECTURES USED IN BIRD SPECIES CLASSIFICATION)

Bu çalışmada, kuş türü tahmini için bir uygulama geliştirilmiştir. Kullanıcıların, uygulamaya yükleyeceği görüntüden kuş türünün tahmin edilmesi amaçlanmıştır. Bunun için, farklı mimariler denenmiş ve tahmin oranları karşılaştırılmıştır. Kuş türlerinin tahmini için eğitilen modellerde derin öğrenme mimarilerinden CNN kullanılmıştır. Modeller; VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet ve DenseNet121 derin öğrenme mimarileri ve transfer öğrenme yöntemi uygulanarak geliştirilmiştir.

Çizelge 1. Veri kümesinden örnek kuş türleri (Sample bird species from dataset)


					
AFRICAN FIREFINCH	STRAWBERRY FINCH	PURPLE FINCH	BAY-BREADED WARBLER	EASTERN ROSELLA	SPANGLED COTINGA
					
RED WISKERED BULBUL	VERMILION FLYCATCHER	NORTHERN CARDINAL	ROADRUNNER	CARMINE BEE- EATER	WILSONS BIRD OF PARADISE
					
CRESTED CARACARA	RAZORBILL	TIT MOUSE	VARIED THRUSH	BALTIMORE ORIOLE	YELLOW CACIQUE
					
WHITE CHEEKED TURACO	WATTLED CURASSOW	RED FACED CORMORANT	JABIRU	SPOONBILL	SNOWY EGRET

VGG16 modeli Oxford Üniversitesi bilim adamları Simonyan ve Zisserman tarafından 2014 yılında yayımlanan makalede [22] önerilen evrişimli bir sinir ağı modelidir. Model, 1000 sınıfa sahip 14 milyondan fazla görüntüden oluşan ImageNet veri kümesinde %92,7 oranında bir test doğruluğuna ulaşmıştır. VGG16'da, çok sayıda hiper parametreye sahip olmak yerine 3 X 3 filtrelri evrişim ve 2 X 2 filtrelri havuz katmanlarına sahip olmaya odaklanılmıştır. Çıktı için 2 tam bağlı katman ve bir softmax katmanına sahiptir. VGG16'daki 16, 16 ağırlıklı katmana sahip olduğunu ifade etmektedir. Bu ağ oldukça büyük bir ağıdır ve yaklaşık 138 milyon parametreye sahiptir. VGG16 mimarisi, Şekil 1.'de sunulmuştur.

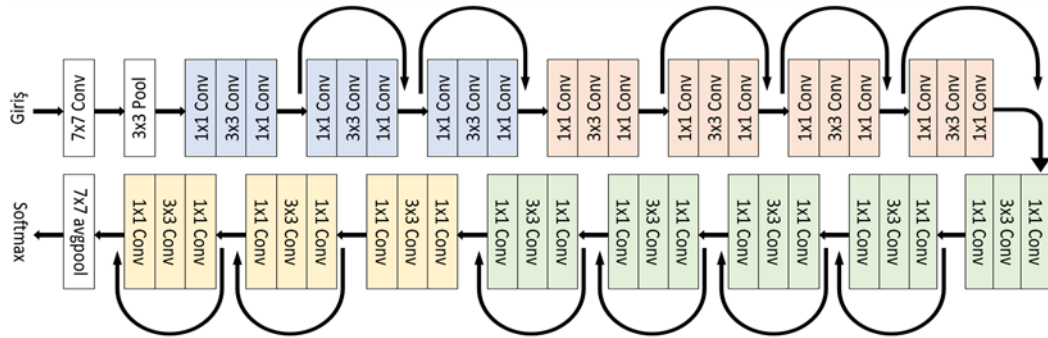
ResNet, yüzlerce veya binlerce evrişimli katmana sahip bir CNN mimarisidir. Bu mimari, güçlü performansa sahip çok sayıda katman içermektedir. ResNet, bir katmandan diğerine nihai tahmine ulaşmak için gereken delta'yı tahmin etmektedir. Gradyanın akması için

alternatif kısayola izin vererek kaybolan gradyan problemini azaltmaktadır. ResNet'te kullanılan kimlik eşleme, mevcut katman gerekli değilse modelin bir CNN ağırlık katmanını atlmasına izin vermektedir. Bu, eğitim kümesine aşırı uyum (ezberleme) sorununu önlemeye yardımcı olmaktadır. ResNet50, 50 katmana sahip bir ResNet versiyonudur [23, 24]. Şekil 2.'de görsel olarak sunulmuştur. ResNetV2 ile orijinal ResNet (V1) arasındaki temel fark, V2'nin her ağırlık katmanından önce toplu normalleştirme kullanmasıdır. ResNet, görüntü tanıma ve yerelleştirme görevleri alanında birçok görsel tanıma görevinin önemini gösteren güçlü bir performansa sahiptir [24].

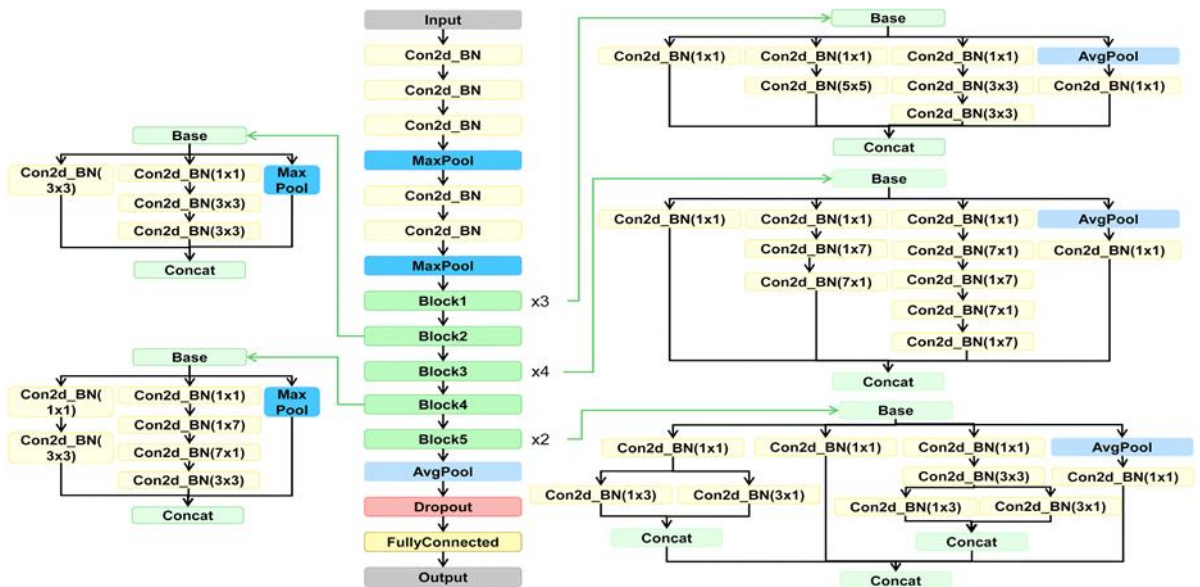
InceptionV3, Google tarafından geliştirilmiş ve ImageNet üzerinde önceden eğitilmiş çok derin bir ConvNet'tir. Bu model için varsayılan giriş boyutu üç kanalda 299 X 299'dur [25]. InceptionV3 mimarisi genel olarak Şekil 3.'te verilmiştir.



Şekil 1. VGG16 mimarisi (VGG16 architecture)




Şekil 2. ResNet50 mimarisi (ResNet50 architecture)



Şekil 3. InceptionV3 mimarisi (InceptionV3 architecture) [33]

MobileNet mimarileri sıg ve derin sinir ağıları oluşturmak için ayrılabilir modüler bir mimariye dayanmaktadır. Bu mimaride, gecikme ve doğruluk arasında verimli bir denge sağlayan iki basit küresel hiperparametre bulunmaktadır. Bu hiper parametreler, model oluşturucunun, problemin kısıtlamalarına dayalı olarak uygulamaları için doğru boyutlu modeli seçmesine izin vermektedir [26]. MobileNet mimarine ait detaylar Şekil 4.'te sunulmuştur.



Şekil 4. MobileNet mimarisi (MobileNet architecture) [34]

DenseNet, her katmanı ileri beslemeli bir şekilde diğer katmana bağlayan yoğun evrişimli ağıdır. Geleneksel ağlarda L katman için L kadar bağlantı bulunmaktadır.


DenseNet ağlarında ise  $L(L+1)/2$  direk bağlantı vardır. Her katman için, önceki tüm katmanların özellik haritaları girdi olarak alınmakta ve kendi özellik haritaları sonraki tüm katmanlara girdi olarak aktarılmaktadır. DenseNet, kaybolan gradyan problemini hafifletmekte, özellik yayılımını güçlendirmekte, özelliğin yeniden kullanımını teşvik etmekte ve parametre sayısını önemli ölçüde azaltmaktadır. Bu ağlar, yüksek performans elde etmek için daha az hesaplama gerektirmektedir [27]. Farklı DenseNet versiyonları bulunmakla birlikte DenseNet121 mimarisinin detayları Şekil 5.'te sunulmuştur.

Bu algoritmalara ait kuş türü tahmin sonuçlarının görüntülenebileceği bir kullanıcı arayüzü geliştirilmiştir. Kullanıcı, sisteme kuş görüntüsünü yükledikten sonra tercih ettiği yöntemleri seçerek çalıştırdığında, kuş görüntüsüne ait tahmin sonuçlarını oransal olarak görebilmektedir.

## 5. DENEYSEL SONUÇLAR (THE EXPERIMENTAL RESULTS)

Deneyel sonuçlar için bir uygulama geliştirilmiştir. Uygulama Python programlama dili ile TensorFlow ve Keras derin öğrenme kütüphaneleri kullanılarak Google Colabs ortamında geliştirilmiştir. Yazılımın arayüzü için frontend tarafında ReactJs, backend tarafında Python ile oluşturulan web servisi kullanılmıştır.

Altı farklı CNN mimarisi kullanılarak elde edilen modellere ait deneyel sonuçların karşılaştırması ve değerlendirmesi yapılmıştır. Modellere göre doğruluk (accuracy) ve kayıp (loss) değerlerini içeren eğitim ve test sonuçları Çizelge 2.'de sunulmuştur. Doğruluk değeri, model başarısının ölçülmesinde yaygın olarak kullanılan en basit yöntemdir. Doğru sınıflandırılmış örnek sayısının toplam örnek sayısına oranı alınarak hesaplanmaktadır [13].



Şekil 5. DenseNet121 mimarisi (DenseNet121 architecture)

Çizelge 2. Modellere göre eğitim ve test sonuçları (Train and test results according to the models)

Model	Eğitim		Test	
	Doğruluk	Kayıp	Doğruluk	Kayıp
VGG16	0,998	0,006	0,946	0,218
ResNet50	0,553	2,541	0,472	2,264
ResNet152V2	0,996	0,016	0,962	0,284
InceptionV3	0,992	0,021	0,975	0,105
MobileNet	0,998	0,005	0,969	0,153
DenseNet121	0,997	0,008	0,982	0,090



Kayıp değerlerinin hesaplanmasında çok sınıflı sınıflandırma problemlerinde tercih edilen, Keras kütüphanesine ait categorical cross-entropy (CCE) fonksiyonu kullanılmıştır. Bu fonksiyon aşağıda sunulmuştur [35].

$$CCE = -\frac{1}{N} + \sum_{i=1}^N \sum_{c=1}^C (p_{ic} \log(y_{ic})) \quad (1)$$

Burada N toplam gözlem sayısı, C toplam sınıf sayısı olmak üzere,  $p_{ic}$  c. sınıfa ait i. gözlem için hedef (doğru sonuç) ve  $y_{ic}$  tahmin edilen olasılık dağılımıdır. Modellerin eğitimi sırasında kayıp değerinin zaman içerisindeki değişimini gösteren grafikler oluşturulmuştur. Bu grafikler her model için eğitim ve doğrulama verisi olarak ayrı ayrı Şekil 6.'da sunulmuştur.

Her bir model için doğruluk değerine ek olarak, literatürde yaygın olarak kullanılan kesinlik (precision), hassasiyet (recall) ve F1-skoru (F1-score) ölçütleri hesaplanmıştır.

Kesinlik, belirtilen sınıf için doğru olarak tahmin edilmiş örnek sayısının (DP), bu sınıfta olduğu öngörülen tüm örnek sayısına (DP + YP) oranıdır. Bu oran aşağıda verilmiştir.

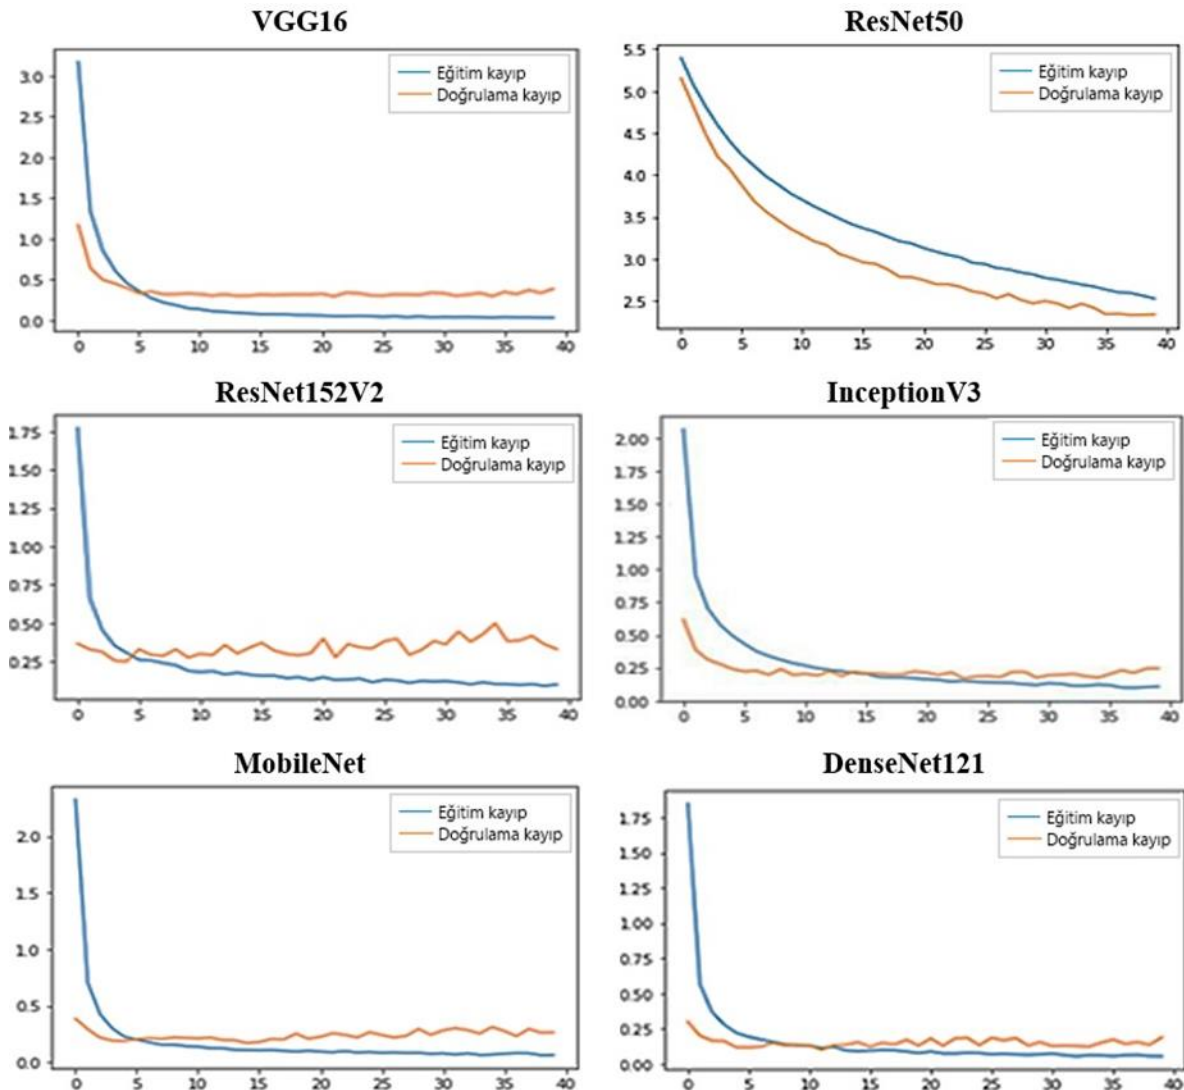
$$Kesinlik = \frac{DP}{DP+YP} \quad (2)$$

Hassasiyet, belirtilen sınıf için doğru olarak tahmin edilmiş örnek sayısının (DP) bu sınıfta olması gereken tüm örnek sayısına (DP + YN) oranı olarak aşağıda verildiği şekilde ifade edilebilmektedir.

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

Kesinlik ve hassasiyet ölçütlerini beraber değerlendirmek daha doğru sonuçlar vermektedir. Bu nedenle, aşağıda verildiği üzere, F1-skoru kullanılarak kesinlik ve hassasiyetin harmonik ortalaması alınmaktadır [28].

$$F1 \text{ skoru} = \frac{2*hassasiyet*kesinlik}{hassasiyet+kesinlik} \quad (4)$$



Şekil 6. Kayıp grafikleri (Loss graphics)

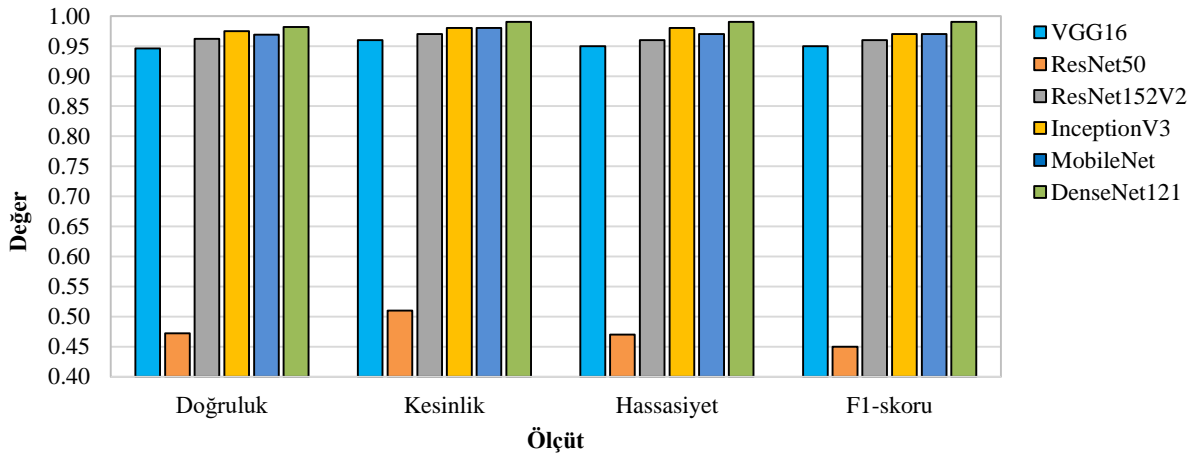
Hata, doğruluk değerinin tersi olarak değerlendirilebilmektedir. Yanlış sınıflandırılmış örnek sayısının toplam örnek sayısına oranı alınarak aşağıda verilen şekilde hesaplanabilmektedir.

$$Hata = \frac{YP+YN}{DP+DN+YP+YN} \quad (5)$$

Test kümesinde yapılan kuş türü tahminlerine ait başarı ölçütleri, farklı mimarilere göre Çizelge 3.'te verilmiştir. Test edilen modellerin, belirtilen tüm ölçütlere göre karşılaştırmalı grafiği Şekil 7.'de sunulmuştur.

**Çizelge 3.** Modellere göre başarı ölçütleri (Evaluation metrics according to the models)

Model	Doğruluk	Kesinlik	Hassasiyet	F1-skoru	Hata
VGG16	0,95	0,96	0,95	0,95	0,05
ResNet50	0,47	0,51	0,47	0,45	0,53
ResNet152V2	0,96	0,97	0,96	0,96	0,04
InceptionV3	0,98	0,98	0,98	0,97	0,02
MobileNet	0,97	0,98	0,97	0,97	0,03
DenseNet121	0,98	0,99	0,99	0,99	0,02



**Şekil 7.** VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet ve DenseNet121 modellerinin karşılaştırması (Comparison of VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet and DenseNet121 models)

Altı farklı mimari kullanılarak elde edilen deneysel sonuçların detaylı karşılaştırması ve değerlendirmesi yapılmıştır. Deneysel sonuçlar, modellerin çeşitli kuş türlerini başarıyla tanıdığını göstermiştir. 31317 eğitim görüntüsü, 1125 doğrulama görüntüsü ve 1125 test görüntüsü ile gerçekleştirilen çalışmada eğitim verisi üzerinde elde edilen sonuçlar VGG16 için %99,8, ResNet50 için %55,3, ResNet152V2 için %99,6, InceptionV3 için %99,2, MobileNet için %99,8 ve DenseNet121 için %99,7 doğruluktur. ResNet50 dışındaki diğer mimarilerde birbirlerine çok yakın sonuçlar elde edilmiştir. ResNet50'nin diğer mimarilerle arasındaki en büyük fark havuz katmanlarına fazla yer vermemesidir. Düşük başarı oranının buna bağlı olduğu ya da ezberlemeyi önleyici atlanabilir katmanların ihtiyaç duyulduğu halde atlanmış olabileceği düşünülmektedir.

Test verisi üzerinde ise VGG16 ile %94,6, ResNet50 ile %47,2, ResNet152V2 ile %96,2, InceptionV3 ile %97,5, MobileNet ile %96,9 ve DenseNet121 ile %98,2 doğruluğa ulaşılmıştır. Farklı mimarilere ait bu sonuçlar incelendiğinde, hepsi ile yaklaşık olarak benzer sonuçlar elde edilmiş olmasına karşın en yüksek başarımın

InceptionV3 ve DenseNet121 ile sağlandığı söylenebilmektedir. Diğer başarı ölçütleri için sonuçlara bakıldığında DenseNet121 mimarisinin hassasiyet, kesinlik ve F1-skorunda elde ettiği %99'luk başarı ile diğerlerinin önüne geçtiği görülmektedir. DenseNet121 mimarisini, InceptionV3 ve MobileNet takip etmektedir.

## 6. SONUÇLAR (CONCLUSIONS)

Bu çalışmada VGG16, ResNet50, ResNet152V2, InceptionV3, MobileNet ve DenseNet121 derin öğrenme modelleri kullanılarak kuş türü sınıflandırması gerçekleştirilmiştir. Bu amaçla geliştirilen uygulama kullanılarak 225 kuş türüne ait toplam 33566 kuş görüntüsünden oluşan 250 Bird Species isimli veri kümesi üzerinde elde edilen deneysel sonuçlar kapsamlı bir şekilde karşılaştırılmıştır. Veri kümesinde bulunan 1125 tane görüntü test ve 1125 tane görüntü doğrulama için kullanılmıştır. Uygulanan altı farklı derin öğrenme modelinin doğruluk, kesinlik, hassasiyet ve F1-skoru değerlerine göre karşılaştırması yapılmıştır. Gerçekleştirilen deneysel çalışmaların sonucunda, VGG16 ile %94,6, ResNet50 ile %47,2, ResNet152V2

ile %96,2, InceptionV3 ile %97,5, MobileNet ile %96,9 ve DenseNet121 ile %98,2 doğruluk değeri elde edilmiştir. Kesinlik, hassasiyet ve F1-skoru ölçütleri için en başarılı sonuç DenseNet121 kullanılarak elde edilmiştir. DenseNet121 mimarisi kullanılarak yapılan tahminlerde bu ölçütler için %99 oranında başarı sağlanmıştır.

#### ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

#### YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

**Mehtap MUTLU BİLGİN:** Deney ve testleri gerçekleştirmiştir.

**Kevser ÖZDEM:** Derin öğrenme modelini geliştirmiştir.

**M. Ali AKCAYOL:** Sonuçları analiz etmiş ve yorumlamıştır.

#### ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

#### KAYNAKLAR (REFERENCES)

- [1] Sangster G., "Integrative taxonomy of birds: the nature and delimitation of species", *Bird Species How They Arise Modify and Vanish*, Springer, Cham, (2018).
- [2] Gill F. B., "Species taxonomy of birds: which null hypothesis?", *The Auk: Ornithological Advances*, 131(2): 150-161, (2014).
- [3] Ge Z., McCool C., Sanderson C., Bewley A., Chen Z. and Corke P., "Fine-grained bird species recognition via hierarchical subset learning", *IEEE International Conference on Image Processing (ICIP2015)*, 561-565, (2015).
- [4] Niemi J. and Tantt J. T., "Deep learning case study for automatic bird identification", *Applied Sciences*, 8(11): 2089, (2018).
- [5] Liu Y., Sun P., Highsmith M. R., Wergeles N. M., Sartwell J., Raedeke A. and Shang Y., "Performance comparison of deep learning techniques for recognizing birds in aerial images", *IEEE Third International Conference on Data Science in Cyberspace (DSC2018)*, 317-324, (2018).
- [6] Kumar A. and Das S. D., "Bird Species Classification Using Transfer Learning with Multistage Training", *Workshop on Computer Vision Applications*, 28-38, (2018).
- [7] Huang Y. P. and Basanta H., "Bird image retrieval and recognition using a deep learning platform", *IEEE Access*, 7: 66980-66989, (2019).
- [8] Hong S. J., Han Y., Kim S. Y., Lee A. Y. and Kim G., "Application of deep-learning methods to bird detection using unmanned aerial vehicle imagery", *Sensors*, 19(7): 1651, (2019).
- [9] Islam S., Khan S. I. A., Abedin M. M., Habibullah K. M. and Das, A. K., "Bird Species Classification from an Image Using VGG-16 Network", *Proceedings of 7th International Conference on Computer and Communications Management*, 38-42, (2019).
- [10] Gavali P., Mhetre M. P. A., Patil M. N. C., Bamane M. N. S., and Buva M. H. D., "Bird Species Identification using Deep Learning", *Int. J. Eng. Res. Technol*, 8: 68-72, (2019).
- [11] Raquel C. R., Alarcon K. M. A. and Figueroa L. L., "Image classification of Philippine bird species using deep learning", *Proceedings of the Workshop on Computation: Theory and Practice (WCPT)*, 93, (2019).
- [12] Ragib K. M., Shithi R. T., Haq S. A., Hasan M., Sakib K. M. and Farah T., "PakhiChini: Automatic Bird Species Identification Using Deep Learning", *Fourth World Conference on Smart Trends in Systems, Security and Sustainability (WorldS4)*, 1-6, (2020).
- [13] Gavali P. and Banu J. S., "Bird Species Identification using Deep Learning on GPU platform", *International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE, 2020)*, 1-6, (2020).
- [14] Raj S., Garyali S., Kumar S. and Shidnal S., "Image based Bird Species Identification using Convolutional Neural Network", *International Journal of Engineering Research & Technology (IJERT)*, 9(6): 346, (2020).
- [15] Chakraborti T., McCane B., Mills S. and Pal, U., "CoCoNet: A Collaborative Convolutional Network applied to fine-grained bird species classification", *35th International Conference on Image and Vision Computing New Zealand (IVCNZ)*, 1-6, (2020).
- [16] Trense D. and Tietze D. T., "Studying Speciation: Genomic Essentials and Approaches", *Bird Species How They Arise Modify and Vanish*, Springer, Cham, (2018).
- [17] Goodfellow I., Bengio Y., Courville A. and Bengio Y., "Deep learning" 1. *Cambridge: MIT press*, 2, (2016).
- [18] Albawi S., Mohammed T. A. and Al-Zawi S., "Understanding of a convolutional neural network", *International Conference on Engineering and Technology (ICET)*, 1-6, (2017).
- [19] Lu J., Behbood V., Hao P., Zuo H., Xue S. and Zhang G., "Transfer learning using computational intelligence: A survey", *Knowledge-Based Systems*, 80: 14-23, (2015).
- [20] Tan C., Sun F., Kong T., Zhang W., Yang C. and Liu C., "A survey on deep transfer learning", *International conference on artificial neural networks*, 270-279, (2018).
- [21] <https://www.kaggle.com/gpiosenka/100-bird-species/version/30>
- [22] Simonyan K. and Zisserman A., "Very deep convolutional networks for large-scale image recognition", *arXiv:1409.1556*, (2014).
- [23] He K., Zhang X., Ren S. and Sun J., "Deep residual learning for image recognition", *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778, (2016).

- [24] Elshennawy N. M. and Ibrahim D. M., “Deep-Pneumonia Framework Using Deep Learning Models Based on Chest X-Ray Images”, *Diagnostics*, 10(9): 649, (2020).
- [25] Gulli A. and Pal S., “Deep learning with Keras”, *Packt Publishing Ltd.*, 101, (2017).
- [26] Howard A. G., Zhu M., Chen B., Kalenichenko D., Wang W., Weyand T. and Adam H., “Mobilenets: Efficient convolutional neural networks for mobile vision applications”, *arXiv:1704.04861*, (2017).
- [27] Huang G., Liu Z., Van Der Maaten L. and Weinberger K. Q., “Densely connected convolutional networks”, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708, (2017).
- [28] Coşkun C. and Baykal A., “Veri madenciliğinde sınıflandırma algoritmalarının bir örnek üzerinde karşılaştırılması”, *Akademik Bilişim*, 1-8, (2011).
- [29] Marini A., Facon J. and Koerich A. L., “Bird species classification based on color features”, *IEEE International Conference on Systems, Man, and Cybernetics*, 4336-4341, (2013).
- [30] Lucio D. R., Maldonado Y. and da Costa G., “Bird species classification using spectrograms”, *Latin American Computing Conference (CLEI)*, 1-11, (2015).
- [31] Nanni L., Costa Y. M., Lucio D. R., Silla C. N. and Brahmam S., “Combining visual and acoustic features for bird species classification”, *IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI2016)*, 396-401, (2016).
- [32] Pang C., Yao H. and Sun X., “Discriminative features for bird species classification”, *Proceedings of International Conference on Internet Multimedia Computing and Service*, 256-260, (2014).
- [33] Li L., Chen Y., Shen Z., Zhang X., Sang J., Ding Y. and Yu C., “Convolutional neural network for the diagnosis of early gastric cancer based on magnifying narrow band imaging”, *Gastric Cancer*, 23(1): 126-132, (2020).
- [34] Qin Z., Zhang Z., Chen X., Wang C. and Peng, Y., “Fdmobilenet: Improved mobilenet with a fast downsampling strategy”, *25th IEEE International Conference on Image Processing (ICIP)*, 1363-1367, (2018).
- [35] Rusiecki A., “Trimmed robust loss function for training deep neural networks with label noise”, *International Conference on Artificial Intelligence and Soft Computing*, 215-222, (2019).