

Evrişimsel Sinir Ağları ile Örümcek Kuşugillerin Bazı Türlerinin Sınıflandırılması

Mahmut Tokmak^{1*}, Akın Kırac²

Özet: Kuşlar, yaşadığımız çevrenin ayrılmaz bir parçasıdır ve doğa için son derece önemlidir. Kuş türleri sınıflandırması, biyoloji ve çevre araştırmalarındaki umut verici uygulamaları nedeniyle bilgisayar görüntü işleme alanında giderek daha fazla ilgi görmektedir. Kuş türlerinin sınıflandırılması, doğal yaşam alanı ile ilgili arka planlar, ortam ışığı ve tespit edilmek istenen kuşun duruşu gibi etmenler nedeniyle zorlu bir problem olarak tanımlanmaktadır. Bu çalışmada; Örümcek Kuşugiller familyasından Lanius cinsine ait üç tür Evrişimsel Sinir Ağları (ESA) ResNet-152 mimarisi kullanılarak sınıflandırılmıştır. Sonuç olarak; sınıflandırmaya ait yapılan testler ile %96,59 doğruluk değerine, %96,62 kesinlik değerine, %96,59 duyarlılık değerine, %96,60 F1-skoru değerine erişilmiştir. Bu yöntemin ayırt edilmesi zor olan aynı cinse ait türlerin tanınabilmesinde, sınıflandırılmasında başarılı olduğu görülmüştür.

Anahtar Kelimeler: Evrişimsel Sinir Ağları, ResNet-152, Örümcek Kuşu, Sınıflandırma

Classification of Some Species of Shrikes Family by Convolutional Neural Networks

Abstract: Birds are an integral part of nature and are extremely important to nature. Bird species classification is gaining more and more attention in the field of computer image processing due to its promising applications in biology and environmental research. Classification of bird species is defined as a difficult problem due to factors such as natural habitat backgrounds, ambient light and the posture of the bird to be detected. In this study; Three species belonging to the genus Lanius from the Shrikes-family were classified using Convolutional Neural Networks ResNet-152 architecture. As a result; An accuracy of 96.59%, precision of 96.62%, recall of 96.59%, F1-score of 96.60% was achieved with the tests performed for the classification. It has been observed that this method is successful in recognizing and classifying species belonging to the same genus that are difficult to distinguish.

Keywords: Convolutional Neural Networks, Resnet-152, Shrike, Classification

¹**Address (Adres):** Isparta Uygulamalı Bilimler Üniversitesi, Gelendost Meslek Yüksekokulu, Isparta, Türkiye

²**Address (Adres):** Çanakkale Onsekiz Mart Üniversitesi, Çanakkale Teknik Bilimler Meslek Yüksekokulu, Çanakkale, Türkiye

***Corresponding author (Sorumlu Yazar):** mahmuttokmak@isparta.edu.tr

Citation (Atıf): Tokmak, M., Kırac, A. (2021). Evrişimsel Sinir Ağları ile Örümcek Kuşugillerin Bazı Türlerinin Sınıflandırılması. Bilge International Journal of Science and Technology Research, 5 (1): 72-79.

1. GİRİŞ

Ekosistemdeki dengenin sağlanması açısından kuşlar hayati önem taşımaktadırlar. Kuşların incelenmesi, çevremizdeki dünyayı daha iyi anlamaya ve doğa ile ilgili önemli bilgileri kavramaya yardımcı olması açısından önem arz etmektedir. Kuş tanımlama, ornitologlar için iyi bilinen bir sorundur. Çevre bilimciler ekosistemleri anlamak için genellikle kuşları inceleyerek analizlerini yapmaktadırlar çünkü kuş türleri çevresel değişikliklere duyarlıdır (Hussain vd., 2018; Islam vd., 2019).

Türkiye biyolojik çeşitliliğinin en önemli unsurlarından biri olan kuşlar Aves sınıfı içerisinde yer alırlar ve ülkemizde 450'den fazla kuş türü temsil edilirler (Gündoğdu vd., 2005; Osmanoglu ve Özdemir, 2014; Süel vd., 2019). Bugün halen kuş türlerinin teşhisi araştırmacılar tarafından geleneksel olarak dürbün, teleskop ve tür ayırma yardımcı kuş kitapları yardımıyla yapılmaktadır.

Gelişen teknoloji ve disiplinler arası çalışmalar neticesinde Derin Öğrenme (Deep Learning: DL) yöntemleri görüntü işleme, ses tanıma, doğal dil işleme, zaman serisi analizi, kötü amaçlı yazılım tespiti gibi birçok alanda kullanılmaktadır (Tokmak ve Küçüksille, 2019).

DL hayvan türlerini sınıflandırma amacıyla kullanılan yöntemler arasında yer almaktadır (Chege, 2020; Graving vd., 2019; Moallem vd., 2021; Willi vd., 2019). Bu hayvanlar arasında yer alan kuş türlerinin sınıflandırılması amacıyla DL yöntemlerinden biri olan ESA yönteminin son yıllarda yoğun olarak kullanıldığı görülmektedir. ESA yönteminde ise, Inception Nets, AlexNet, VGG16, ResNet-18, ResNet-34, ResNet-101, ResNet-152 mimarilerinin kullanıldığı görülmüştür (Alter ve Wang, 2017; Islam vd., 2019; Kennelly ve Green, 2020; Kumar ve Das, 2018). Bu çalışmalar incelendiğinde farklı familyalara ve farklı cinslere dahil olan kuş türleri, hatta kuş teşhisinde uzman olmayan biri tarafından da farklı türlere ayrılacak veri setlerinin kullanıldığı görülmektedir.

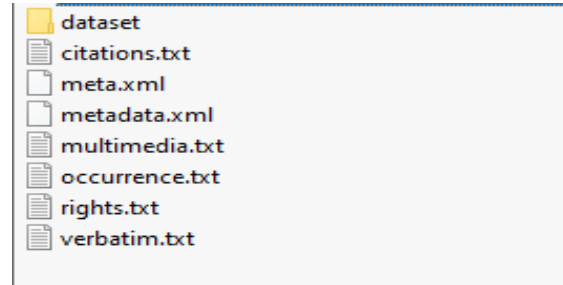
Kuş türlerinin bir görüntüden tanımlanması, şekil ve görünüm açısından çarpıcı biçimde değişen farklı kuş türleri, görüntülerin arka planı, fotoğraflardaki ışık koşulları ve pozdaki aşırı değişkenlik gibi sorunlar nedeniyle zorlu bir problem olarak tanımlanmaktadır (Alter ve Wang, 2017; Hussain vd., 2018).

Bu çalışmada aynı familyanın aynı cinsine ait, kuş teşhisinde uzaman araştırmacıların dahi teşhiste zorluk çekebileceği, aynı alan ve habitatta var/bulunma olasılığı yüksek 3 kuş türü belirlenmiştir. Çalışma verisini oluşturan bu kuşlar, Passeriformes (Ötücü Kuşlar) takımı içerisinde yer alan Lanidae familyası olarak bilinen örümcek kuşgüllerin *Lanius* cinsine ait *Lanius nubicus* (LN), *Lanius collurio* (LC) ve *Lanius senator* (LS) türleridir. Bu üç tür ağaçlık ve çalılık bölgelerde yaşamaktadırlar. Özellikle ilkbahar ve yaz aylarında Akdeniz bölgesinde; örneğin Isparta- Sütçüler Yazılı Kanyon Tabiat Parkı'nda bu üç tür aynı anda aynı alan içerisinde gözlemlenebilmektedir (Gündoğdu vd., 2005; IUCN, 2021).

2. MATERYAL VE YÖNTEM

2.1. Veri seti

Çalışmada kullanılan resimler GBIF (Global Biodiversity Information Facility) internet sitesinden indirilmiştir. GBIF dünyadaki her tür yaşamla ilgili verilere açık erişim sağlamayı amaçlayan, uluslararası bir ağ ve veri alt yapısıdır (GBIF, 2021a). Bu siteden indirilen veriler hazır veri setleri olmadığı için, indirilen dosyalardan veriler seçilerek bir veri seti oluşturulmuştur. Önerilen çalışmada kullanılan üç tür örümcek kuşu için sitede ayrı ayrı arama yapılarak veriler sıkıştırılmış bir dosya halinde indirilmiştir. Sıkıştırılmış dosya içerisinde tür ile ilgili Şekil 1'de gösterilen dosyalar ve klasör mevcuttur. "multimedia.txt" dosyası içinde resimler veya o tür ile ilgili ses dosyaların içerdiği Url adresleri bulunmaktadır. Bu Url adreslerinden Python programlama dili kullanılarak yazılan bir uygulama ile resimler indirilmiştir.



Şekil 1. Sıkıştırılmış dosya içeriği

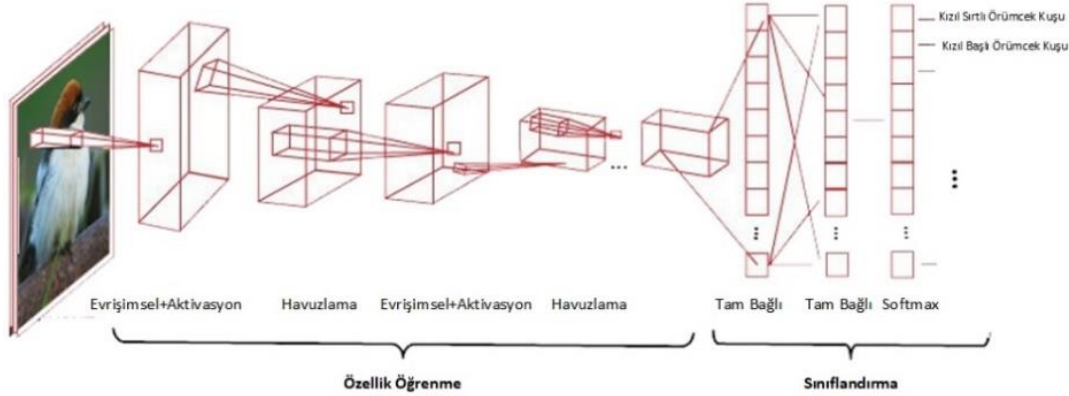
Bu resimler incelenip ölü olarak resmedilen kuşlar, sadece kuş tüylerini içeren resimler elimine edilerek LC için 639 tane resim, LS için 560 tane resim, LN için 420 resim seçilmiştir (GBIF, 2021b; GBIF, 2021c; GBIF, 2021d). Şekil 2'de bu kuşlardan örnekler gösterilmiştir.



Şekil 2. Veri setindeki kuşlardan seçilen örnekler

2.2. Evrişimsel sinir ağları

ESA, son yıllarda görüntü işlemeden ses tanımayaya, örüntü tanıma ile ilgili çeşitli alanlarda fark yaratan başarılı sonuçlar elde etmiştir (Albawi vd., 2017; Hussain vd., 2018). Denetimli öğrenme algoritması olarak ESA, özellikle görüntü bölütleme, örüntü tanıma, saptama ve sınıflandırma işlemlerinde yaygın olarak kullanılan bir derin öğrenme yöntemidir (Lu vd., 2020). ESA, öğrenme yoluyla kendi kendini optimize eden nöronlardan oluşmaları bakımından geleneksel yapay sinir ağlarına benzer yapıdadır ve çok katmanlı algılayıcıların bir türüdür



Şekil 3. ESA mimarisini

Evrişimsel katmanda giriş filtreleme ve özellik haritaları elde etme işlemi yapılır. Havuzlama katmanında özellik haritalarından oluşan örneklerin özeti çıkarılarak parametre sayısı azaltılmış ve ağı daha hızlı bir şekilde öğrenmesi sağlanabilmektedir. Tam bağlantılı katmandaki her nöron kendinden önce gelen katmandan gelen tüm girişlere bağlı olarak çıkış üretir. Her katman bir önceki katmanın sonucuna göre özellik çıkarır ve tüm katmanları birleştirip eğiterek özellik yapısını öğrenebilmektedir. Burada amaçlanan, düşük seviye detaylardan başlayıp yüksek seviye detaylara kadar etkili bir öğrenme gerçekleştirebilmektir (Acı ve Çırak, 2019; Büyükarıkan ve Ülker, 2020).

ESA'nın eğitilmesi ve test edilmesi işlemleri için Google Colaboratory ya da kısaca Colab bulut sistemi kullanılmıştır. Bu sistem NVIDIA Tesla K80 GPU ile büyük veriler üzerinde çok fazla hesaplama işlemi hızlı bir şekilde yapabilmekte, içerisinde birçok Python ve derin öğrenme kütüphanesini hazır olarak bulundurmakta ayrıca ücretsiz olarak hizmet vermektedir (Colab, 2021).

Bu çalışmada; standart ESA olarak önceden eğitilmiş Resnet-152 kullanılmıştır. Kullanılan modelin eğitimi ve testi için fast.ai kütüphanesi kullanılmıştır (fast.ai, 2021). Modelde verilerin %80'i eğitim için %20'si test için rastgele olarak ayrılmıştır. Giriş verileri için batch_size parametresi 64 olarak ayarlanmış ve modelde kullanılan epok değeri 50 olarak belirlenmiştir.

(Büyükarıkan ve Ülker, 2020; O'Shea ve Nash, 2015; Türkoğlu vd., 2020).

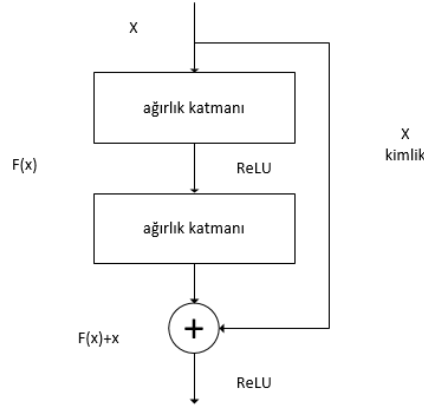
Bir ESA, giriş katmanı, çıkış katmanı ve birden çok gizli katmandan oluşmaktadır. Gizli katmanlar ise tipik olarak evrişimsel katman (convolutional layer), havuzlama katmanı (pooling layer), tamamen bağlı katman (fully connected layer) ve normalleştirme katmanlarından (normalisation layer, ReLU) oluşmaktadır. Daha karmaşık modeller için ek katmanlar kullanılabilir (Hussain vd., 2018; O'Shea ve Nash, 2015). Genel bir ESA Şekil 3'te gösterilmiştir.

2.3. ResNet mimarisini


ResNet ESA mimarisini; ImageNet veri seti üzerinde eğitilmiş ve %3,57 hata oranına erişerek bu başarı oranı ile ILSVRC-2015 yarışmasının sınıflandırma görevinde birinciliği kazanmıştır. ILSVRC & COCO 2015 yarışmasının ImageNet algılama, ImageNet yerelleştirme, COCO algılama ve COCO segmentasyonu görevlerinde de birinciliği kazanmıştır (He vd., 2016).

ESA'da derinliğin artırılması yani katman sayısının artırılması modelin eğitim doğruluğu performansını arttırmaktadır. Fakat derinlik arttıkça bozulma ve gradyan kaybolma sorunu oluşmaktadır. Bu sorunların önüne geçmek amacıyla ResNet mimarisini, ara katmanları birbirine bağlayan artık bloklar (Residual block) eklemektedir. Eklenen artık bloklar sayesinde, doğabilecek bozulma ve gradyan kaybolma sorunlarının önüne geçerek daha derin mimarilerin oluşturulabilmesine olanak sağlanmış olmaktadır. Şekil 4'te gösterilen artık blokta, girişten çıkışa bir bağlantı yapılarak, x değeri $F(x)$ fonksiyonuna eklenmektedir. Ekleme işleminden sonra $F(x)+x$ fonksiyonu birlikte ReLU'den geçirilmektedir. Bu sayede önceki katmanlarda eğitilen değerler takip eden katmana daha güçlü olarak iletilmesi hedeflenmektedir.

ResNet'in klasik mimarisini ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152 çeşitlerini içermektedir ve Şekil 5'te ResNet-152 mimarisini gösterilmiştir (Han vd., 2018; He vd., 2016; Lu vd., 2020; Talo, 2019).



Şekil 4. Artık blok (He vd., 2016)



Şekil 5. ResNet-152 mimarisi (Han vd., 2018)

3. BULGULAR

Çalışmada kullanılan; LC, LN ve LS'den oluşan üç türe ait veri setinde 1296 tane resim eğitim için kullanılmış, 323 tanesi test için ayrılmıştır.

Kurulan modelde veri seti gerekli klasörlerden okunduktan sonra, veri seti içindeki sınıflardan rastgele seçilen örnek görüntüler Şekil 6'da gösterilmiştir.



Şekil 6. Veri seti örnek görünüm

Kurulan modelin başarımının değerlendirilebilmesi için kullanılan; doğru sınıflandırılan sınıf örneklerinin oranı

olan doğruluk değeri Eşitlik 1'de, pozitif olarak tahmin edilen örneklerin gerçekte ne kadarının pozitif olduğunu ifade eden kesinlik (precision) değeri Eşitlik 2'de, gerçek pozitif değerlerin ne kadarının doğru olduğunu ifade eden duyarlılık (recall) değeri Eşitlik 3'te, kesinlik ve duyarlılık değerlerinin harmonik ortalaması olan F1-skoru (F1 score) Eşitlik 4'te gösterilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+FN+TN+FP} \quad (1)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2)$$

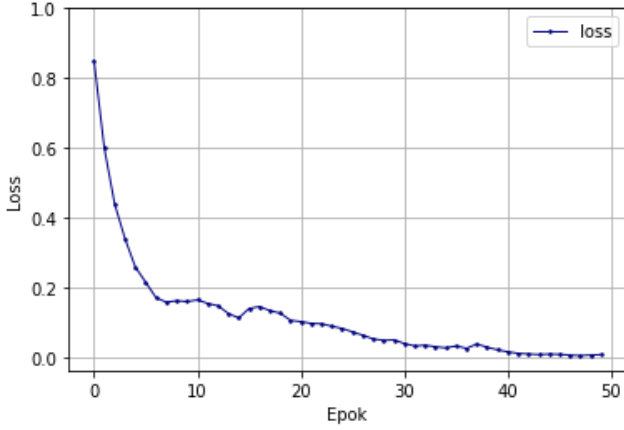
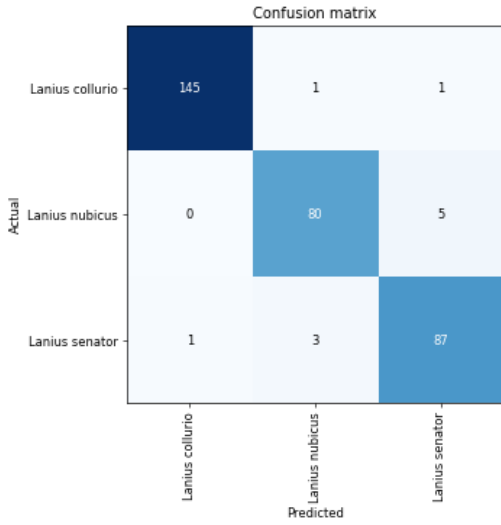
$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3)$$

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

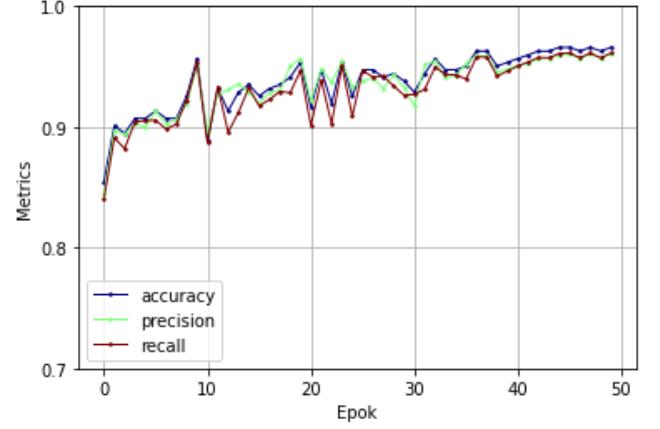
Çalışmada önerilen ESA Resnet-152 mimarisi ile kurulan modelde %96,59 doğruluk değerine, %96,62 kesinlik değerine, %96,59 duyarlılık değerine, %96,60 F1-skoru değerine erişilmiştir ve Çizelge 1'de gösterilmiştir. Modelin kayıp değeri (Loss) 0.004871'e kadar düşürülmüş ve Şekil 7'de gösterilmiştir.

Çizelge 1. Model performans metrikleri

	Kesinlik	Duyarlılık	F1-skoru	Destek
<i>Lanius senator</i>	0.9932	0.9864	0.9898	147
<i>Lanius collurio</i>	0.9524	0.9412	0.9467	85
<i>Lanius nubicus</i>	0.9355	0.9560	0.9457	91
Makro ortalama	0.9603	0.9612	0.9607	323
Ağırlıklı ortalama	0.9662	0.9659	0.9660	323
Doğruluk				0.9659

**Şekil 7.** Model kayıp (loss) grafiği**Şekil 8.** Karmaşıklık (confusion) matrisi

Şekil 8'deki model tahmini karmaşıklık matrisine bakıldığında; LC için 145 tanesini doğru olarak sınıflandırmış bir tanesini LN, bir tanesini LS olarak yanlış tahmin ederek yanlış sınıflandırmıştır, LN için 80 tanesini doğru sınıflandırmış beş tanesini de LS tahmin ederek yanlış sınıflandırmıştır, LS için 87 tanesini doğru sınıflandırmış, bir tanesini LC, 3 tanesini de LN tahmin ederek yanlış olarak sınıflandırmıştır.

**Şekil 9.** Model doğruluk, kesinlik, duyarlılık grafiği

Modelin performans ölçütlerinden olan doğruluk, kesinlik, duyarlılık değerleri ile ilgili grafik Şekil 9'da gösterilmiş, modelin tahmin ettiği ve gerçekte olan sonuçları gösteren örneklerin bulunduğu görsel Şekil 10'da gösterilmiştir.



Şekil 10. Model tahmin sonuç görselleri

4. TARTIŞMA VE SONUÇLAR

Kuşlar, yaşadığımız çevrenin ayrılmaz bir parçasıdır ve doğa için son derece önemlidir. Kuş türleri sınıflandırması, biyoloji ve çevre araştırmalarındaki umut verici uygulamaları nedeniyle bilgisayar görüntü işleme alanında giderek daha fazla ilgi görmektedir. Kuş türlerinin sınıflandırılmasında, doğal yaşam alanı ile ilgili arka plandaki sorunlar, ortam ışığı, ve tespit edilmek istenen kuşun duruşu gibi faktörler zorlaştırıcı bir etki yaratmaktadır.

Son yıllarda kuş türlerinin teşhisi konusu, uzmanların dışında kuş gözlemciliği gibi faaliyetlerle oldukça artmıştır. Kuşların uzaktan dürbün ve teleskop gibi ekipmanlarla birlikte kuş teşhisi yardımcı el kitapları yardımıyla teşhisi halen kullanılan en iyi yöntemdir. Bunun yanı sıra kuşlar gelişmiş objektifler ve görüntüleme teknolojileri sayesinde doğa fotoğrafçıların ilgi odağı olmuşlardır. Bu nedenle kuşlar diğer hayvan sınıflarına göre teşhisleri isimlendirilmeleri açısından daha popüler hale gelmişlerdir.

Yine son yıllarda insan faktörünü dışarda bırakan yapay zeka alanındaki gelişmeler bir çok alanda deneme ve geliştirilme aşamasında oldukça ilgi görmüştür. Günümüzde görüntüden faydalanılarak yapılan birçok sınıflandırma tıp bilimlerinden doğa bilimlerine kadar pek

çok alanda en az hata oranı ve iş zamanı tasarrufu sağlaması ile de uygulama açısından kabul görmüştür.

Literatürde son yıllarda kuşlar ile yapılan ESA çalışmaları artmaktadır. Bu çalışmalarda başarı oranları yeterli görülse de veri setleri incelendiğinde, sınıflandırılması yapılan türlerin farklı, takım, familya ve cinslere ait oldukları görülmüştür (Dipta Das ve Kumar, 2018; Islam vd., 2019). %55-89 arasında değişen bu sonuçların kuş sistematikçileri dışındaki bir kişinin dahi ayırt edebileceği bir veri seti ile elde edildiği görülmüştür. Önerilen çalışma ise aynı familyanın aynı cinsine ait birbirinden ayrılması uzmanlar tarafından bile güçlükle yapılabilen, aynı habitatta aynı anda karşılaşılabileceğimiz üç örümcek kuşu türü üzerine yapılmıştır. %96,59'lık doğruluk değeri, %96,62 kesinlik değeri, %96,59 duyarlılık değeri, %96,60 F1-skoru değerlerine erişilerek bahsedilen hususlar dahilinde oldukça başarılı sonuçlar elde edilmiştir. Şekil 2' deki örnekler incelendiğinde bu türlerin birbirine çok benzediği görülmektedir. Şekil 8' deki karmaşıklık matrisi de bu benzerlikten kaynaklanan hatalara işaret etmektedir. Elde edilen görüntülerin arka planı, fotoğraflardaki ışık koşulları ve resmedilen kuşun duruş özelliklerinin sonuçlara etki ettiği tespit edilmiştir.

Bu bağlamda; ESA, ResNet-152 mimarisinin kuş türlerinin sınıflandırılması için oldukça kullanışlı olduğu ortaya konmuştur. İlerleyen çalışmalarda, daha çok kuş türü için,

daha fazla veri sağlanıp, hata oranını minimuma indirerek kuş teşhisine faydalı olan makine ve teçhizatlar geliştirilebilir.

KAYNAKLAR

- Acı, Ç., Çırak, A. (2019). Türkçe Haber Metinlerinin Konvolüsyonel Sinir Ağları ve Word2Vec Kullanılarak Sınıflandırılması. *Bilişim Teknolojileri Dergisi*, 219-228. <https://doi.org/10.17671/gazibtd.457917>
- Albawi, S., Mohammed, T. A., Al-Zawi, S. (2017). Understanding of a convolutional neural network. 2017 International Conference on Engineering and Technology (ICET), 1-6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Alter, A. L., Wang, K. M. (2017). An Exploration of Computer Vision Techniques for Bird Species Classification. Stanford University.
- Büyükarıkcan, B., Ülker, E. (2020). Aydınlatma Özniteliği Kullanılarak Evrimsel Sinir Ağı Modelleri İle Meyve Sınıflandırma. *Uludağ University Journal of The Faculty of Engineering*, 81-100. <https://doi.org/10.17482/uumfd.628166>
- Chege, H. N. (2020). Prototyping Artificial Intelligent Classifiers using Deep Learning. Authorea Preprints.
- Colab, (2021). Google Colaboratory, <https://colab.research.google.com/> (Erişim Tarihi: 21.01.2021).
- Dipta Das, S., Kumar, A. (2018). Bird Species Classification using Transfer Learning with Multistage Training. arXiv e-prints, arXiv-1810.
- fast.ai, (2021). fast.ai, <https://www.fast.ai/> (Erişim Tarihi: 10.02.2021).
- GBIF, (2021a). Global Biodiversity Information Facility, <https://www.gbif.org/what-is-gbif> (Erişim Tarihi: 14.02.2021).
- GBIF, (2021b). Global Biodiversity Information Facility, <https://doi.org/10.15468/dl.ychdz8> (Erişim Tarihi: 09.01.2021).
- GBIF, (2021c). Global Biodiversity Information Facility, <https://doi.org/10.15468/dl.gwtcd2> (Erişim Tarihi: 09.01.2021).
- GBIF, (2021d). Global Biodiversity Information Facility, <https://doi.org/10.15468/dl.4m9re7> (Erişim Tarihi: 21.01.2021).
- Graving, J. M., Chae, D., Naik, H., Li, L., Koger, B., Costelloe, B. R., Couzin, I. D. (2019). DeepPoseKit, a software toolkit for fast and robust animal pose estimation using deep learning. *Elife*, 8, e47994.
- Gündoğdu, E., Ünal, Y., Sarıkaya, O. (2005). Yazılı Kanyon Tabiat Parkı Kuş ve Memeli Türleri Üzerine Araştırmalar. *Korunan Doğal Alanlar Sempozyumu, Isparta*, 8-10.
- Han, S. S., Park, G. H., Lim, W., Kim, M. S., Na, J. I., Park, I., Chang, S. E. (2018). Deep neural networks show an equivalent and often superior performance to dermatologists in onychomycosis diagnosis: Automatic construction of onychomycosis datasets by region-based convolutional deep neural network. *PloS one*, 13(1), e0191493.
- He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Hussain, M., Bird, J. J., Faria, D. R. (2018). A study on cnn transfer learning for image classification. *UK Workshop on computational Intelligence*, 191-202.
- Islam, S., Khan, S. I. A., Abedin, M. M., Habibullah, K. M., Das, A. K. (2019). Bird species classification from an image using vgg-16 network. *Proceedings of the 2019 7th International Conference on Computer and Communications Management*, 38-42.
- IUCN, (2021). IUCN Red List of Threatened Species, <https://www.iucnredlist.org/> (Erişim Tarihi: 23.02.2021).
- Kennelly, S., Green, R. (2020). Classifying Bird Feeder Photos. 2020 35th International Conference on Image and Vision Computing New Zealand (IVCNZ), 1-6.
- Kumar, A., Das, S. D. (2018). Bird Species Classification Using Transfer Learning with Multistage Training. *Workshop on Computer Vision Applications*, 28-38.
- Lu, Z., Bai, Y., Chen, Y., Su, C., Lu, S., Zhan, T., Hong, X., Wang, S. (2020). The classification of gliomas based on a pyramid dilated convolution resnet model. *Pattern Recognition Letters*, 133, 173-179.
- Moallem, G., Pathirage, D. D., Reznick, J., Gallagher, J., Sari-Sarraf, H. (2021). An explainable deep vision system for animal classification and detection in trail-camera images with automatic post-deployment retraining. *Knowledge-Based Systems*, 106815.
- O'Shea, K., Nash, R. (2015). An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458.
- Osmanoğlu, T., Özdemir, İ. (2014). Isparta-Gölcük Tabiat Parkı ormanında meşcere yapısı ile kuş türü zenginliği arasındaki ilişkiler. *Biyolojik Çeşitlilik ve Koruma*, 7(3), 78-86.
- Süel, H., Oğurlu, İ., Ertuğrul, E. T. (2019). Karacaören I Baraj Gölünün Kuş Faunası. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 9(1), 22-28.
- Talo, M. (2019). Pneumonia Detection from Radiography Images using Convolutional Neural Networks. 2019 27th Signal Processing and Communications Applications Conference (SIU), 1-4. <https://doi.org/10.1109/SIU.2019.8806614>
- Tokmak, M., Küçükşille, E. U. (2019). Kötü Amaçlı Windows Çalıştırılabilir Dosyalarının Derin Öğrenme ile Tespiti. *Bilge International Journal of Science and Technology Research*, 3(1), 67-76. <https://doi.org/10.30516/bilgesci.531801>

- Türkođlu, M., Hanbay, K., Saraç SiVriKaya, I., Hanbay, D. (2020). Derin Evriřimsel Sinir Ađı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9(1), 334-345. <https://doi.org/10.17798/bitlisfen.562101>
- Willi, M., Pitman, R. T., Cardoso, A. W., Locke, C., Swanson, A., Boyer, A., Veldthuis, M., Fortson, L. (2019). Identifying animal species in camera trap images using deep learning and citizen science. *Methods in Ecology and Evolution*, 10(1), 80-91. <https://doi.org/10.1111/2041-210X.13099>