



TÜRKİYE'DEKİ KELEBEK TÜRLERİNİN BASAMAKLI EVRİŞİMLİ SİNİR AĞLARI İLE SINIFLANDIRILMASI

Bahadır ELMAS 

Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü, İstanbul, TÜRKİYE
bahadir.elmas@msgsu.edu.tr

(Geliş/Received: 21.12.2020; Kabul/Accepted in Revised Form: 07.05.2021)

ÖZ: Kelebekler ekosistemdeki değişikliklere hızlı bir şekilde yanıt verebilme özelliğine sahiptir. Ayrıca çoğu kelebek türü larvaları, insan ve hayvanların yaşam ortamını ve gıda kaynaklarını etkileyen tarım ve orman zararlılarıdır. Bu nedenle kelebek türlerinin sınıflandırılması, tür araştırmalarının yanı sıra çevre koruma, tarım ve orman zararlılarının kontrolünde de önemlidir. Bu çalışmada Türkiye'deki 9 aile ve 416 kelebek türünü sınıflandırmak için yedi adet evrişimli sinir ağı transfer öğrenme yöntemiyle kullanılmıştır. Veri seti oluşturmak için 13528 görüntü toplanmış, veri artırma yöntemi ile görüntü sayısı 67640'a çıkarılmıştır. Eğitimde ezberlemenin önüne geçebilmek, ağların performansını ve güvenilirliğini artırmak için Stratified Shuffle Split, K fold cross validation yöntemleri kullanılmıştır. Tür sayısının fazlalığı, türlerin desen ve renk benzerliği nedeniyle ağların düşük başarı oranını artırmak için iki basamaklı ağ modeli kullanılmıştır. Modelde birinci basamakta bir, ikinci basamakta paralel bağlı dokuz ağ vardır. Birinci basamaktaki ailelere göre sınıflandırmada %95.88, ikinci basamaktaki tür sınıflandırmada ise %91.99 ile %100 arasında başarı oranı elde edilmiştir.

Anahtar Kelimeler: Türkiye Kelebek Türleri, Kelebek Türlerinin Tanımlanması, Basamaklı Evrişimli Sinir Ağlar, Önceden Eğitilmiş Ağlar, Transfer Öğrenme

Classification of Butterfly Species in Turkey with Cascaded Convolutional Neural Networks


ABSTRACT: Butterflies have the ability to respond quickly to changes in the ecosystem. In addition, most butterfly species larvae are agricultural and forest pests that affect the habitats and food resources of humans and animals. Therefore, classification of butterfly species is important in environmental protection, agriculture and forest pest control as well as species research. In this study, seven convolutional neural network transfer learning methods were used to classify 9 families and 416 butterfly species in Turkey. In order to create a dataset, 13528 images were collected, and the number of images was increased to 67640 by data augmentation method. Stratified Shuffle Split, K fold cross validation methods were used to prevent memorization and increase the performance and reliability of networks. A cascaded network model was used to increase the low success rate of networks due to the excess number of species, the pattern and color similarity of species. In the model, there is one network on the first layer and nine networks connected in parallel on the second layer. A success rate of 95.88% was achieved in the classification according to families in the first layer and 91.99% to 100% in the classification of species in the second layer.

Key Words: Turkey Butterfly Species, Identification of Butterfly Species, Cascaded Convolutional Neural Networks, Pre-Trained Networks, Transfer Learning.

GİRİŞ (INTRODUCTION)

Kelebekler, hayvanlar âleminin eklem bacaklılar şubesinde yer alan böcekler sınıfına ait Lepidoptera takımındaki canlılardır. Dünya sistematik kelebek isimleri kayıtlarında (Shou ve diğ., 2006), 17 aile, 47 alt aile, 1690 cins ve 15141 kelebek türü kayıtlıdır (Xin ve diğ., 2020). Kelebekler böcek araştırmaları alanında büyük öneme sahiptirler. Bununla birlikte, yüksek benzerlikleri, tür sayısının fazla olması nedeniyle kelebeklerin sınıflandırılması, düşük doğruluk ve yavaş tanıma hızı problemlerine sahiptir (Zhao ve diğ., 2019). Çoğu kelebek türü larvaları, insan ve hayvanların yaşam ortamını ve gıda kaynaklarını doğrudan etkileyen tarım ve orman zararlılarıdır. Ancak ekosistemin genel istikrarında önemli rol oynarlar. Kısa bir ömre sahip olmaları ve bu değişikliklere hızlı bir şekilde yanıt verebildikleri için, ince ekosistem değişikliklerini belirlemede özellikle etkilidirler (Wang, W. ve diğ., 2019). Bu nedenle kelebek türlerinin otomatik olarak sınıflandırılması ile ilgili araştırmalar, sadece türlerin tanımlanması araştırmalarında değil, çevre koruma, tarım ve orman zararlılarının kontrolü gibi pratik çalışmalarda büyük önem taşımaktadır (Xue ve diğ., 2019; Xin ve diğ., 2020). Kelebekler taksonomik karakterlere göre doğru bir şekilde sınıflandırılması yılların tecrübesine sahip sınırlı sayıda uzmanları tarafından yapılabilir. Fakat taksonomistlerin ve eğitilmiş insanların sayısı günümüzde önemli ölçüde azalmıştır (Almryad ve Kutucu, 2020). Kelebek türleri arasındaki ayrım, uzmanlık ve zaman gerektirir, ancak görüntülerden özellikler çıkararak kelebek türlerini sınıflandıran yöntemlerin geliştirilmesi bu soruna çözüm olacaktır.

Mevcut kelebek türlerini sınıflandırma araştırmalarında iki temel sorun vardır. Birincisi; kelebek veri setinin toplanması zordur ve kelebek veri setine dâhil olan kelekelerin sayısı kapsamlı değildir. İkincisi; kelebek fotoğrafları numune ve doğal ortam fotoğrafları olmak üzere ikiye ayrılır. Sınıflandırma araştırmalarının büyük bir bölümü Şekil 1'de verildiği gibi numune fotoğraflarına dayanır. Numune fotoğrafları belirgin morfolojik özelliklere sahip desen fotoğraflarıdır. Bu tür fotoğraflarla yapılan sınıflandırma çözümleri doğal ortam fotoğrafları ile test edildiğinde başarı oranı düşüktür (Zhao ve diğ., 2019; Xin ve diğ., 2020).



Şekil 1. Kelebek numune fotoğrafları (Zhao vd., 2019).

Figure 1. Butterfly sample photos



Şekil 2. Doğal ortam kelebek fotoğrafları (Zhao vd., 2019).

Figure 2. Natural environment butterfly photos

Numune fotoğraflarıyla, doğal ortam fotoğraflarına dayalı sınıflandırma karşılaştırıldığında, doğal ortam sınıflandırması daha zordur (Xin ve diğ., 2020). Şekil 2'de görülebileceği gibi doğal ortam fotoğraf karesinde kelebek ya çok küçük kalmıştır ya kanat desenleri yeterince net değildir ya da diğer nesnelerin desenleri arasında renk ve desen olarak geri planda kalmıştır (Zhao ve diğ., 2019). Bu çalışmada yukarıdaki iki sorunun çözümüne katkı sağlamak amacıyla, Türkiye sınırları içerisindeki tüm kelebek türlerini kapsayan, %94.4'ü doğal ve %5.6'sı numune fotoğraflarından oluşan yeni bir veri seti oluşturulmuştur.

Türkiye barındırdığı kelebek türü sayısı ile Avrupa'daki tüm ülkelerden daha zengin bir ülkedir. Tüm Avrupa'da 482 tür bulunurken, Türkiye sınırları içerisinde 416 kelebek türü bulunmaktadır. Bu kelebek

türlerinin 45'i ise endemiktir. Türkiye'deki 9 aileye ait tür sayıları Çizelge 1'de, bu ailelere ait türlerin illere göre dağılımı ise Çizelge 2'de verilmiştir (Kelebek-Turk, 2020; Trakel, 2020).

Çizelge 1. Türkiye'deki aile ve tür sayıları.

Table 1. Family and species numbers in Turkey

Aile Adı	Tür Sayısı
Argynnidæ Ailesi	55
Danaidæ Ailesi	1
Hesperiidæ Ailesi	43
Libytheidæ Ailesi	1
Lycaenidæ Ailesi	182
Papilionidæ Ailesi	13
Pieridæ Ailesi	39
Riodinidæ Ailesi	1
Satyridæ Ailesi	81

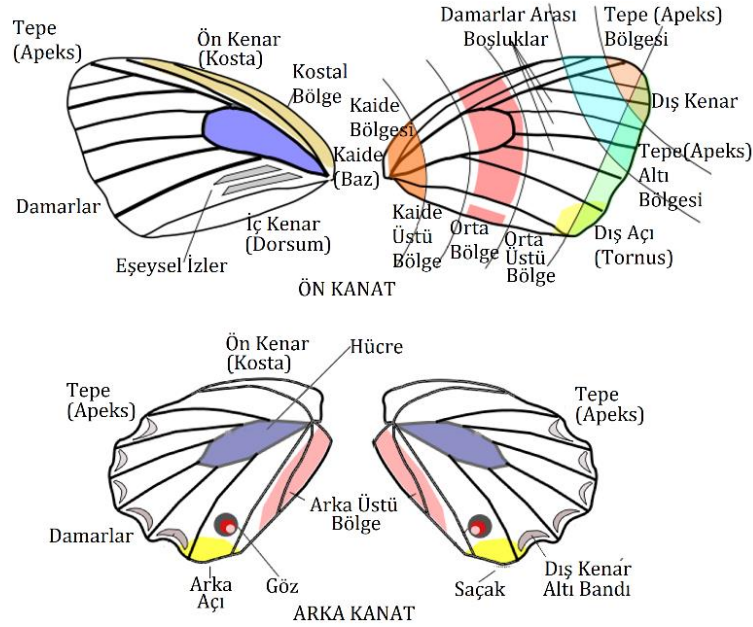
Çizelge 2. İllere göre kelebek türü dağılımı.

Table 2. Butterfly species distribution by city

İller	Tür Sav.	İller	Tür Sav.	İller	Tür Sav.	İller	Tür Sav.	İller	Tür Sav.
Adana	119	Bitlis	109	Gümüşhane	168	Kocaeli	109	Sinop	55
Adıyaman	77	Bolu	163	Hakkâri	129	Konya	166	Sivas	158
Afyon	99	Burdur	113	Hatay	110	Kütahya	146	Şanlıurfa	53
Ağrı	5	Bursa	144	Iğdır	43	Malatya	187	Şırnak	54
Aksaray	45	Çanakkale	114	Isparta	163	Manisa	104	Tekirdağ	88
Amasya	106	Çankırı	46	İstanbul	96	Mardin	79	Tokat	151
Ankara	173	Çorum	137	İzmir	117	Mersin	141	Trabzon	88
Antalya	167	Denizli	165	Kahramanmaraş	198	Muğla	122	Tunceli	121
Ardahan	116	Diyarbakır	72	Karabük	102	Muş	22	Uşak	30
Artvin	184	Düzce	44	Karaman	150	Nevşehir	73	Van	167
Aydın	53	Edirne	110	Kars	64	Niğde	85	Yalova	55
Balıkesir	108	Elazığ	137	Kastamonu	80	Ordu	41	Yozgat	62
Bartın	36	Erzincan	64	Kayseri	170	Osmaniye	164	Zonguldak	100
Batman	10	Erzurum	210	Kırkkale	19	Rize	118		
Bayburt	78	Eskişehir	161	Kırklareli	128	Sakarya	78		
Bilecik	109	Gaziantep	42	Kırşehir	71	Samsun	59		
Bingöl	21	Giresun	159	Kilis	6	Siirt	145		

Kelebekler Türkiye'de nesli yüksek oranda tehlike altındaki canlı gruplarından. Neredeyse her 10 kelebek türünden birinin nesli yok olma tehlikesiyle karşı karşıyadır (Karaçetin ve Welch, 2011; Kelebek-Turk, 2020). Türkiye'deki endemik kelebeklerin %29'u tehlike altında veya tehlike altına girmeye yakın durumdadır. Endemik türlerin %49'u hakkında ise veri yetersizdir. Türkiye'deki 416 kelebek türünün %67'si düşük riskli iken %15'i hakkında yeterli veri yoktur. Ayrıca Türkiye'deki 26 kelebek türünün, kritik ve tehlikede kategorisinde iken 11 kelebek türününse neslinin tehlide yakın durumda olduğu tespit edilmiştir (Karaçetin, 2011). Yapılaşma, tarım ve su ürünleri yetiştiriciliği, enerji üretimi, madencilik, ulaşım koridorları, geçim ya da ticaret için biyolojik kaynak kullanımı, istilacı türler ve genler, kirlilik, jeolojik olaylar, iklim değişikliği kelebekleri tehdit eden faktörler olarak ön plana çıkmaktadır (Karaçetin, 2011). Kelebek türlerini ve sayılarını korumak için; alan koruma, alan yönetimi, tür yönetimi, eğitim, farkındalık yaratma, mevzuat, politika, bilgi ve araştırma gibi eylemler gerekmektedir (Karaçetin, 2011). Kelebekler insan sağlığı için gerekli olan çevre sağlığının mükemmel göstergeleridir. Bir bölgedeki kelebeklerin sayısal yoğunluk ve dağılımındaki düşüş, genellikle o çevrenin bozulduğuna işaret eder. Bu nedenle, kelebeklerin yereldeki çeşitlilik ve sayılarının izlenmesi insan sağlığı için gerekli çevresel önlemlerin alınmasında önemli bir araç olabilir (Karaçetin ve Welch, 2011). Bu nedenle, Kelebek türlerinin kolay ve hızlı bir şekilde sınıflandırılması büyük önem taşımaktadır.

Bu çalışmada Türkiye'deki tüm kelebek türlerinin tanımlanması için son yıllarda görsel tanımlamada yüksek başarı oranı gösteren evrişimli sinir ağları transfer öğrenme yöntemiyle kullanılmıştır. Evrişimli sinir ağlarının görsel tanımlamadaki bu başarısını keleklerin tanımlanmasında çok önemli bir unsur olan kelebek kanat şekilleri ve desenlerinde de göstereceği düşünülmüştür. Bu amaçla oluşturulacak veri setinde kelebek kanatları ön plana çıkarılmıştır. Sınıflandırmada çok önemli unsur olan kelebek kanadının anatomisi Şekil 3'te verilmiştir (Cebeci, 2020).



Şekil 3. Kelebek kanadının anatomisi.

Figure 3. Anatomy of the butterfly wing

Çalışmaya ışık tutması amacıyla literatürde 2014-2020 yılları arasında yapılmış 22 çalışma incelenmiştir. Literatür taraması sonucunda evrişimli sinir ağları ile Transfer Öğrenme yönteminin birçok çalışmada kullanıldığı ve başarılı olduğu sonucuna varılmıştır. İncelenen söz konusu çalışmalarda varılan diğer bir sonuç ise AlexNet, ResNet, VGG ağlarının başarılı sonuçlar verdiği ve yaygın olarak kullanıldığıdır. Bu bilgiler ışığında çalışmada evrişimli sinir ağları ile transfer öğrenme yöntemi benimsenmiş ve AlexNet, ResNet18, ResNet50, ResNet101, VGG16, VGG19, DenseNet201 ağları kullanılmıştır. Literatürde Türkiye'ye özgü bir çalışma yapılmadığı, evrişimli sinir ağlarının eğitimine uygun düzenli ve büyük bir veri seti olmadığı görülmüştür. Çok sayıda veri seti, doğa severlerin fotoğraf çekimleri, dergiler, kitaplar ve WEB sayfaları incelenerek yeni bir veri seti oluşturulmuştur. Eğitimde ezberlemenin önüne geçebilmek, ağların performansını ve güvenilirliğini artırmak için, veri artırma, Stratified Shuffle Split (Katmanlı Karışık Bölme), K fold cross validation (K-katlamalı Çapraz doğrulama) gibi yöntemler kullanılmıştır. Tür sayısının fazlalığı, türlerin desen ve renk benzerliği nedeniyle ağların tek başına yeteri derecede başarılı olmadığı sonucuna varılması üzerine basamaklı (cascade) ağ yapısı kullanılmış ve hedeflenen sonuca ulaşılmıştır.

KAYNAK ARAŞTIRMASI (LITERATURE SURVEY)

Son yıllarda, keleklerin otomatik olarak sınıflandırılması gittikçe daha fazla araştırmacının dikkatini çekmiş ve kelebek sınıflandırma uygulamaları hakkında birçok araştırma yapılmıştır. Andres Hernandez Serna ve Luz Fernanda Jimenez Segura, Avrupa ve Güney Amerika'daki balık, bitki ve kelebek türlerini sınıflandırmak için fotoğraflık görüntüleri kullanan yapay sinir ağları kullanılmıştır. Veri setindeki kelebek türü sayısı 11 olup görüntü sayısı 92'dir. Çalışmalarında kelebek sınıflandırmada %93.25 başarı oranı elde etmişlerdir (Serna ve Segura, 2014). Seung-Ho Kang ve arkadaşları kelekleri kanat şekillerine göre sınıflandırmak için üç katmanlı yapay sinir ağı tasarlamışlardır. Yapay sinir ağını

eğitmek için geri yayılım öğrenme algoritmasını kullanmışlardır. Çalışmalarında 15 kelebek türünün 150 görüntüsü ile elde ettikleri başarı oranı %80.3'tür (Kang ve diğ., 2014). Yılmaz Kaya ve arkadaşları görüntülerdeki özel dokuları tespit etmek için LBP (Local Binary Pattern) üzerine inşa edilen iki yeni tanımlayıcı önerilmiştir. Çalışmalarını 14 türe ait ve her birinden 10'ar adet görüntünün bulunduğu 140 kelebek görüntüsü üzerinde test etmişler ve yapay sinir ağı ile yaptıkları sınıflandırmada %95.71 başarı oranı elde etmişlerdir (Kaya, Ertuğrul ve diğ., 2015). Yılmaz Kaya ve arkadaşlarının diğer bir çalışmasında kelebekleri sınıflandırmak için, geleneksel tanımlama yöntemlerine alternatif olarak otomatik olarak sınıflandırma için bir bilgisayarla görme yöntemi önerilmiştir. Yöntem, LBP ve yapay sinir ağına dayanmaktadır. Önerilen yöntemin etkililiğini değerlendirmek için beş türe ait toplam 50 kelebek görüntüsü kullanılmışlar ve %98 başarı oranı elde etmişlerdir (Kaya, Kayci ve diğ., 2015).


Erik Rodner ve arkadaşları 675 kelebek türüne ait 2120 görüntü içeren Ecuador ve 331 kelebek türüne ait 2310 görüntü içeren Costa Rica veri setlerini kullanarak kelebek sınıflandırması yapmışlardır. Çalışmalarında AlexNet ağını kullanmışlar, Ecuador veri setinde %55.7, Costa Rica veri setinde ise %79.2 başarı elde etmişlerdir (Rodner ve diğ., 2015). Juan Andres Carvajal ve arkadaşları, kelebek sınıflandırması yapmak için AlexNet, VGG16 ve VGG19 olmak üzere üç evrişimli sinir ağını kullanmışlardır. Araştırmalarında Sangay National Park (Petit, 2020) veri setindeki 15 kelebek türüne ait 2110 görüntüyü kullanmış ve %92 başarı elde etmişlerdir (Carvajal ve diğ., 2016). Zhou Ai-Ming ve arkadaşları, 6 ailenin 1117 kelebek türünü sınıflandırmak için CaffeNet modelini ve SVM (Support Vector Machine) sınıflandırıcı kullanmışlardır. CaffeNet modelinin ortalama başarı oranı %95.8 iken, Gabor özelliklerine dayalı SVM sınıflandırıcısı ortalama %94.8 başarı oranına sahiptir (Ming ve diğ., 2017). Qi Chang ve arkadaşları Kuzey Amerika'daki 636 kelebek türüne ait 14270 görüntüden oluşan yeni bir veri seti oluşturmuşlardır. Çalışmalarında ResNet18, ResNet34, VGG19, Inception-v3 ağlarında transfer öğrenme yöntemi kullanmışlar ve ResNet18'de %92.6 başarı elde etmişlerdir (Chang ve diğ., 2017). Juanying Xie ve arkadaşları 1176 kelebek türünün 4270 standart desen görüntüsünü ve 111 türün doğal yaşam ortamından 1425 görüntüsünü içeren Çin'deki tüm kelebek türlerinden oluşan bir kelebek veri seti oluşturmuşlardır. Kelebek sınıflandırma sistemini için Faster R-CNN derin öğrenme tekniğini önermişlerdir. ZF, VGG CNN M1024 ve VGG16 olmak üzere üç model kullanmışlardır. ZF'de %59.8, VGG CNN M1024'de %64.5 ve VGG16'da % 72.8'e başarı oranına ulaşmışlardır (Xie ve diğ., 2018). Lili Zhu ve Petros Spachos, 10 kelebek türünün 832 görüntüsü içeren Leeds Butterfly (Wang, J. ve diğ., 2009) veri seti üzerinde eğitim ve test yaparak geleneksel makine öğrenimi, derin öğrenme ve transfer öğrenme yöntemlerini kullanmışlardır. SVM'de %52.8, 4-Conv CNN'de %98.44, VGG19'da ise %98.53 başarı oranına ulaşmışlardır (Zhu ve Spachos, 2019). Ruoyan Zhao ve arkadaşları, 111 türe ait 5695 fotoğraftan oluşan veri setinde R-CNN kullanılarak kelebek sınıflandırması yapmışlar ve %70.4 başarı oranına ulaşmışlardır (Ruoyan ve diğ., 2019). Nur Nabila Kamaron Arzar ve arkadaşları, önceden eğitilmiş bir model olan GoogLeNet'i kullanan bir evrişimli sinir ağı önermişlerdir. Dört kelebek türüne ait 120 görüntü ile çalıştırdıkları modelde % 97.5 başarı elde etmişlerdir (Arzar ve diğ., 2019). Zhongqi Lin ve arkadaşları kelebek görüntüleri için S-CCNN (Skip-Connections Convolutional Neural Network) sınıflandırma yöntemini önermişlerdir. Toplam 56 türe ait 24836 laboratuvar görüntüsü kullanılırken, veri artırma yöntemi ile bu görüntüleri 173852'ye çıkarmışlardır. Yöntemlerinin başarı oranı %93.36'dır (Lin ve diğ., 2019). Manuel López-Antequera ve arkadaşları, COSFIRE modelinin CNN tabanlı bir kombinasyonunu önermişlerdir. Bu yöntemde, SVM sınıflandırıcısını eğitmek için CNN-COSFIRE özellik vektörünü kullanmışlardır. Önerdikleri yöntemi 7 türe ait toplam 619 görüntü üzerine uygulamışlar %96.57 başarı oranı elde etmişlerdir (Antequera ve diğ., 2019). Lin Nie ve arkadaşları, 82 kelebek türüne ait iç mekân ve dış mekân fotoğrafları içeren yeni bir kelebek veri seti oluşturmuşlar, kelebek sınıflandırmasında AlexNet, VGGNet ve ResNet olmak üzere üç evrişimli sinir ağının performansını incelemişlerdir. Çalışmalarının sonucunda ResNet ağında %95 ile en yüksek sınıflandırma başarısı elde etmişlerdir (Nie ve diğ., 2017). Ayad Saad Almyrad ve arkadaşları 10 kelebek türüne ait 17769 görüntü içeren bir veri seti oluşturmuşlardır. Kelebek türlerin sınıflandırılmasında VGG16, VGG19 ve ResNet50 evrişimli sinir ağlarını kullanmışlardır. Deneysel sonuçlarda %80 başarı elde etmişlerdir (Almyrad ve Kutucu, 2020). Çizelge 3'te 2014 ile 2020 yılları arasında yapılan yukarıdaki çalışmalar ve kullanılan yöntemler kronolojik olarak verilmiştir.

Çizelge 3. Literatür çalışmaları ve kullanılan yöntemler.*Table 3. Literature studies and methods used.*

Yapılan Çalışmalar	Tarih	Yöntem
Serna ve Segura	2014	Yapay Sinir Ağları
Kang ve diğ.	2014	Yapay Sinir Ağları
Kaya, Ertuğrul ve diğ.	2015	LBP
Kaya, Kayci ve diğ.	2015	LBP ve Yapay Sinir Ağı
Rodner ve diğ.	2015	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet)
Rodner ve diğ.	2015	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet)
Carvajal ve diğ.	2016	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet, VGG16 ve VGG19)
Ming ve diğ.	2017	CaffeNet
Ming ve diğ.	2017	SVM
Chang ve diğ.	2017	Evrişimli Sinir Ağları-Transfer Öğrenme (ResNet18, ResNet34, VGG19, Inception-v3)
Nie ve diğ.	2017	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet, VGGNet ve ResNet)
Xie ve diğ.	2018	Faster R-CNN (ZF)
Xie ve diğ.	2018	Faster R-CNN (VGG CNN M1024)
Xie ve diğ.	2018	Faster R-CNN (VGG16)
Zhu ve Spachos	2019	Makine Öğrenmesi (SVM)
Zhu ve Spachos	2019	Derin Öğrenme (4-Conv CNN)
Zhu ve Spachos	2019	Evrişimli Sinir Ağları-Transfer Öğrenme (VGG19)
Ruoyan ve diğ.	2019	R-CNN
Arzar ve diğ.	2019	Evrişimli Sinir Ağları-Transfer Öğrenme (GoogLeNet)
Lin ve diğ.	2019	S-CCNN (Skip-Connections Convolutional Neural Network)
Antequera ve diğ.	2019	Evrişimli Sinir Ağları-COSFIRE (SVM)
Almryad ve Kutucu	2020	Evrişimli Sinir Ağları-Transfer Öğrenme (VGG16, VGG19 ve ResNet50)

EVRIŞİMLİ SİNİR AĞLARI VE TRANSFER ÖĞRENME (CONVOLUTIONAL NEURAL NETWORKS AND TRANSFER LEARNING)

Derin sinir ağları bilgisayarlı görme, konuşma, tanıma ve robotik içeren için birçok yapay zekâ uygulamasında yaygın olarak kullanılmaktadır. Derin sinir ağlarının yaygın bir şekli ise çoklu evrişimli katmanlardan oluşan evrişimli sinir ağlarıdır (Gürkan ve Hanilçi, 2020). Evrişimli sinir ağları, ızgara benzeri bilinen bir topolojiye sahip veriyi işlemek için kullanılan bir tür sinir ağı olup bir derin öğrenme yöntemidir (Goodfellow ve diğ., 2015). İleri beslemeli mimariye sahiptir ve tamamen bağlı katmanlara sahip ağlara kıyasla daha iyi genelleme yapar (Nebauer, 1998; Indolia ve diğ., 2018). Daha çok örüntü tanıma, sınıflandırma, sinyal işleme, sözlük, ilaç, tıp, finans ve savunma sanayinde kullanılmaktadır. Evrişimli sinir ağları çoğunlukla Şekil 4'deki gibi Convolution, Rectified Linear Unit (ReLU), Pooling ve Fully Connected Layers katmanlarından oluşur (Lawrence ve diğ., 1997; Indolia ve diğ., 2018; Yamashita ve diğ., 2018; Baykal ve diğ., 2019; MathWorks, 2020).

**Şekil 4.** Evrişimli Sinir Ağlar*Figure 4. Convolutional Neural Networks*

Yeni bir evrişimli sinir ağı tasarlanmasının ve eğitmenin ilk adımı ağ mimarisini tanımlamaktır. Ağ mimarisi, dâhil edilen katmanların türlerine ve sayılarına bağlı olarak değişebilir. Dâhil edilen katmanların türleri ve sayısı, uygulamaya veya verilere bağlıdır. Uygulamada kategorik yanıtlar varsa, bir softmax ve sınıflandırma katmanına sahip olunmalı. Yanıt sürekli ise, ağın sonunda bir regresyon katmanının olması gerekir. Yalnızca bir veya iki evrişimli katmana sahip küçük bir ağ az sayıda gri tonlamalı görüntü verisini öğrenmek için yeterli olabilir. Diğer taraftan milyonlarca renkli görüntü içeren karmaşık veriler için daha karmaşık ağlara ihtiyaç duyulur (MathWorks, 2020). Evrişimli sinir ağlarında Şekil 4'te gösterildiği gibi ilk katmanlarda verilen girdi üzerinde, filtrelerle özellik çıkarımı gerçekleştirilir. Aynı zamanda bir yandan hesaplama maliyetini düşürmek diğer yandan ise girdiden öğrenilen özelliklerin özet bilgisini diğer katmanlara aktarmak için boyut düşürme fonksiyonları kullanılır. Daha sonra girdiden elde edilen özellikler tek boyutlu bir vektör haline getirilir ve tam bağlantılı katman veya katmanlara girdi olarak verilip, sınıflandırma işlemi gerçekleştirilir. Ağın filtreler ve ağırlıklar altındaki performansı kayıp fonksiyonu ile hesaplanır ve öğrenilebilir parametreler yani filtreler ve ağırlıklar geri yayılım yoluyla kayıp değerine göre güncellenir (Nebauer, 1998). Evrişimli sinir ağlarının her biri farklı mimari kullanarak eğitim işlemi gerçekleştirilmektedir. Bu çalışmada kullanılan evrişimli sinir ağları; AlexNet, DenseNet201, ResNet18, ResNet50, ResNet101, VGG16, VGG19'dur. Çizelge 4 ve Çizelge 5'te söz konusu ağların katman, derinlik, parametre sayısı, görüntü giriş boyutları ve ağ mimarileri verilmiştir (Zhou ve diğ., 2016; He ve diğ., 2016; Ye ve diğ., 2019; Theckedath ve Sedamkar, 2020).

Çizelge 4. Ağların katman, derinlik, parametre sayısı ve görüntü giriş boyutları

Table 4. Layer, depth, number of parameters and image input sizes of networks

	AlexNet	ResNet-18	ResNet-50	ResNet-101	VGG16	VGG19
Derinlik	8	18	50	101	16	19
Katman	25	72	177	347	41	47
Parametre (Milyon)	61	11.7	25.6	44.6	138	144
Resim Giriş Boyutu	227x227	224x224	224x224	224x224	224x224	224x224

Çizelge 5. Ağ mimarileri

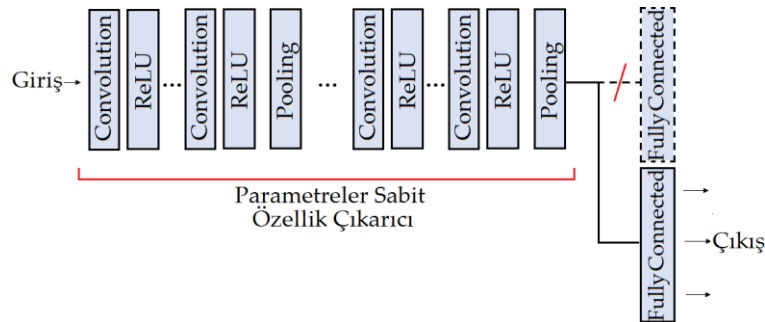
Table 5. Network architectures

AlexNet	DenseNet201	ResNet-18	ResNet-50	ResNet-101	VGG16	VGG19
11x11con,96 max-pool	7x7,con max-pool	7x7,con,64 max-pool	7x7,con,64 max-pool	7x7,con,64 max-pool	[3x3con,64]x2 max-pool	[3x3con,64]x2 max-pool
5x5con,256 max-pool	1x1,con 3x3,con x6	3x3con,64 3x3con,64 x2	1x1con,64 3x3con,64 x3	1x1con,64 3x3con,64 x3	[3x3con,128]x2 max-pool	[3x3con,128]x2 max-pool
3x3con,384 3x3con,384	1x1,con aver-pool	3x3con,128 3x3con,128 x2	1x1con,256 1x1con,128 x2	1x1con,256 1x1con,128 x4	[3x3con,256]x3 max-pool	[3x3con,256]x4 max-pool
3x3con,256 max-pool	1x1,con 3x3,con x12	3x3con,256 3x3con,256 x2	3x3con,128 1x1con,512 x2	3x3con,128 1x1con,512 x4	[3x3con,512]x3 max-pool	[3x3con,512]x4 max-pool
fc4096 fc4096	1x1,con aver-pool	3x3con,512 3x3con,512 x2	1x1con,256 3x3con,256 x6	1x1con,256 3x3con,256 x3	[3x3con,512]x3 max-pool	[3x3con,512]x4 max-pool
fc1000 softmax	1x1con 3x3,con x48	aver-pool fc1000	1x1con,1024 1x1con,512 x3	1x1con,1024 1x1con,512 x3	fc4096 fc4096 fc1000	fc4096 fc4096 fc1000
	aver-pool 1x1,con 3x3,con x32		1x1con,2048 aver-pool fc1000	1x1con,2048 aver-pool fc1000	softmax	softmax
	aver-pool fc1000,softmax		softmax	softmax		

Bazı evrişimli sinir ağlarının eğitilmesi, ağın karmaşıklığı ya da veri setinin büyüklüğü nedeniyle standart bilgisayar işlemcilerinde gerçekleştirmek oldukça zordur. Bu nedenle güçlü grafik işleme birimlerine ihtiyaç duyulur. Uzun süren eğitimler sonucunda eğitilmiş birçok modelden problem için uygun bir model seçilerek problemin çözümünde kullanılabilir. Eğitilmiş bir ağın, ilgili ikinci bir görevde yeniden tasarlandığı, hızlı ilerleme ve gelişmiş performans sağlayan bu makine öğrenmesi tekniğine transfer öğrenme denir. Transfer öğrenme, ağın eğitilmesi için yeterli zaman yok ve donanım yetersizse,

ne kadar veri olduğuna dair endişelenmeden, bir derin öğrenme modeli oluşturmanın en hızlı ve en kolay yoludur. Geleneksel makine öğrenme teknikleri, her görevi sıfırdan öğrenmeye çalışırken, transfer öğrenme teknikleri, önceki görevlerden elde ettiği bilgileri yeni bir görevi öğrenme hedefine aktarır (Pan ve Yang, 2010). Öğrenilen niteliklerin taşınabilir olması derin öğrenmeyi eski ve sık öğrenme yaklaşımlarından ayıran en önemli avantajlarından biridir ve derin öğrenmeyi küçük veri problemlerinde etkin yapar (Chollet, 2017).


Evrişimli sinir ağlar giriş ve ara katmanlar genellikle kenar, doku, desen, gibi üst seviye özellikleri öğrenirken son katmanlar daha spesifik özellikleri öğrenir. Bu yüzden giriş ve ara katmanlar korunurken son katman probleme uygun şekilde tasarlanıp, mevcut veri setiyle eğiterek hızlı bir şekilde yeni bir model elde edilir (Brownlee, 2020). Veri ve hedef görev, orijinal modelin üzerinde çalıştığı veri ve hedef görevle benzerlik gösteriyorsa, bu yaklaşım en iyi sonucu verir. Bununla birlikte, bir modeli sıfırdan eğitmek için yeterli veri varsa ve görevler o kadar yakın olmasa da önceden eğitilmiş bir model kullanarak parametreleri başlatmak, rasgele başlatmadan daha iyi sonuçlar verebilir. Ayrıca sahip olunan veri problemleri ve miktarı yetersiz ise; bu veri için tasarlanmış özel model, önce genel bir görev için hazırlanmış büyük bir veri kümesi kullanılarak eğitilip daha sonra mevcut veri ile eğitilebilir. Bu yöntemde aktarılan şey temel olarak parametrelerin başlangıç değerleridir. Ağırlıkları rastgele başlatmak yerine önceden eğitilmiş bir ağı kullanarak başlatmak; ağı öğrenmede iyi bir başlangıç yapmasını, öğrenme gelişiminde daha dik eğimi ve daha yüksek performans elde etmesini sağlayarak yakınsamayı hızlandırır. Ayrıca yeterli veri olmadığı durumlarda, transfer öğrenme ağı aşırı öğrenmeden koruyarak eğitmek için iyi bir seçenektir. Şekil 5'teki gibi Tam Bağlı katman dışındaki tüm katmanları aktarmak en yaygın transfer öğrenme türüdür. Bu çalışmada da bu yöntemin kullanılması tercih edilmiştir.



Şekil 5. Tam bağlı katmanların probleme göre tasarımı.

Figure 5. Design of fully connected layers according to the problem

Ayrıca önceden eğitilmiş bir ağı Şekil 6'daki gibi ilk n katmanını bir hedef ağı aktarıp geri kalan katmanları rastgele başlatmak da mümkündür. Aktarılan kısmın, ilk katmanlar olması da gerekmez. Görevler aynıysa ancak girdi verilerinin türü biraz farklıysa, son katmanları da aktarmak mümkündür.




Şekil 6. İlk ve son katmanların transferi

Figure 6. Transfer of the first and last layers

Transfer öğrenme pek çok görev için kullanılabilir. Ancak bir model başka bir modele aktarmak her zaman mümkün değildir. Veri türünün ve görevin oldukça farklı olduğu durumlar bu kapsama girer. Transfer öğreniminin uygulanamayabileceği bir durum, özellikleri aktarılabilecek model ile aktarılan modelin mimarisinin uyumsuzluk durumudur. Farklı mimarilere sahip modeller arasında bilgi aktarımını sağlayan teknik model ise Şekil 7'de verilen damıtmadır. Önceden eğitilmiş bir modelin

damıtılması; yeni modeli, doğrudan veriler üzerinde eğitmek yerine önceden eğitilmiş modelin çıktılarını taklit edecek şekilde eğitilmesidir. Bu yaklaşım özellikle kaynak modelden daha küçük bir modelin eğitilmesinde oldukça verimlidir.



Şekil 7. Eğitilmiş bir modelin damıtılması

Figure 7. Distillation of a training model


Çalışma için oluşturulmuş veri seti, ağlara giriş katmanında verilmiştir. Ağların giriş katmanından sınıflandırma katmanına kadar olan ara katmanlar Şekil 5'teki gibi korunmuştur. Çalışmada kullanılan ağlar 1000 sınıflandırma yaparken bu çalışmada birinci yöntemde 416 türü, ikinci yöntemde önce 9 aile sonra aile tür sayısına bağlı olarak 1 ile 171 arasında sınıflandırma yapmaktadır. Ağlardan AlexNet, VGG16 ve VGG19'da havuzlama katmanında maksimum havuzlama yöntemi kullanılırken, DenseNet201, ResNet18, ResNet50 ve ResNet101 ağlarında ise maksimum ve ortalama havuzlama yöntemi kullanılmıştır. Çalışmada kullanılan ağlar oluşturulan veri setiyle MATLAB ortamında eğitilmiştir (MATLAB R2019a). Eğitimde kullanılan bilgisayarın işletim sistemi 64 bit, işlemcisi Intel(R) Core(TM) i7-7820HQ CPU @ 2.90 GHz, RAM'i 16 GB olup ekran kartı Radeon Pro 560'dır.

VERİ SETİNİN TOPLANMASI (DATA SET COLLECTION)

Tanımlayıcı sistemler geliştirilirken karşılaşılan en büyük sorun güvenilir ve performans artırıcı veri setlerinin olmamasıdır. Türkiye'deki kelebek veri setleri; doğaseverlerin fotoğraf çekimleri ve çeşitli yayınlardaki fotoğraflardan oluşmaktadır. Söz konusu veri setlerindeki tür başına görüntü sayısı yeterli olmayıp, türler arasında görüntü sayı dengesi yoktur. Çalışma için toplanan fotoğrafların %94.36'sı doğadan çekilen fotoğraflar olup, fotoğraf karesine kelebeklerle birlikte çok fazla nesne ve bu nesnelere ait renk ve/veya desen vardır. Kelebek tanımlamada kelebek kanat desenlerinin ve şeklinin çekilen fotoğraflarda ön plana çıkması sınıflandırma ve tanımlama başarısını artıracak önemli bir unsurdur. Toplanarak bir araya getirilen fotoğrafların önemli bir bölümünde kelebek, çekilen fotoğraf karesinde ya çok küçük kalmıştır ya kanat desenleri ve şekilleri yeterince net değildir ya da diğer nesnelere ait renk ve desen olarak geri planda kalmıştır. Söz konusu sorunları çözmek amacıyla; görüntüler kırpma ve kesme yöntemleriyle yeniden düzenlenmiştir. Özellikle kelebek ön-arka kanat desen ve şekillerinin fotoğraflarda belirgin olarak görülmesine özen gösterilmiştir. Bunun yanı sıra düzenleme yapılırken fotoğraf karesinin kelebek görüntüsüyle birlikte doğal ortam nesne, desen ve renkleri de içermesi sağlanmıştır. Böylece bu veri setiyle eğitilecek ağ, numune fotoğraflarının yanı sıra doğal ortam fotoğraflarını da sınıflandırılabilir.

İzlenen bu yöntem sonucunda Türkiye'deki Argynnidae, Danaidae, Hesperidae, Libytheidae, Lycaenidae, Papilionidae Pieridae, Riodinidae ve Satyridae olmak üzere dokuz kelebek ailesine ait 416 kelebek türünün, çekim açısı, pozisyonları, mesafesi ve arka planları dikkate alınarak veri seti oluşturmak amacıyla çok sayıda veri seti, doğaseverlerin fotoğraf çekimleri, dergiler, kitaplar ve WEB sayfaları gözden geçirilmiştir. Bu süreç sonunda 12766 doğal ortam fotoğrafı söz konusu kaynaklardan toplanarak bir veri seti oluşturulmuştur. Ayrıca veri setine 762 adet laboratuvar ortamında çekilmiş numune fotoğraflar eklenmiştir. Böylece veri setindeki kelebek görüntü sayısı 13528'e ulaşmıştır. Bunun yanı sıra Türkiye sınırları içerisinde birer adet türü bulunan Danaidae, Libytheidae ve Riodinidae ailesinden yedişer adet daha tür görüntüleri toplanmış ve bu ailelere ait ağ eğitiminde kullanılmıştır.


Sinir ağlarında küçük veri setleri modellerin veriyi ezberlemesine, dolayısıyla modellerin düşük doğrulukta çalışmasına neden olmaktadır. Bu sorunu çözmek için ise veri artırımı yöntemleri uygulanır. Veri artırımı resimler için; döndürme, öteleme, kırpma, soldurma, ölçeklendirme gibi teknikler ile orijinal veriden sentetik kopyalarının üretme işlemidir (Mash ve diğ., 2016). Çalışmada veri setindeki her bir görüntüye Şekil 8'deki gibi sağa 90°, sola 90°, dikey ve yatay çevirme işlemi uygulanmıştır. Bu işlemlerin sonucunda görüntü sayısı 13528'den 67640'a çıkmıştır. Veri artırımı işlemi sonucunda ikinci metotda kelebek ailesini sınıflandırmada %17.23, tür sınıflandırmada ise ortalama %12.5 başarı oranı artmıştır.



Şekil 8. Veri artırımı
Figure 8. Data Augmentation


DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Ağların eğitilmesi süreçlerinde veri seti, eğitim ve doğrulama veri seti olmak üzere iki gruba ayrılır. Ağ başarı oranı eğitim ve doğrulama veri setine bağlı olarak yüksek değişirliğe (variance) sahiptir (Chollet, 2017). Eğitim ve doğrulama veri setinin tüm veri setini temsil etmesi için çeşitli yöntemler geliştirilmiştir. Çalışmada literatürde yaygın olarak kullanılan iki yöntem uygulanmıştır. Birinci yöntem; Stratified Shuffle Split olarak adlandırılan yöntemdir (Kaggle, 2020; Medium, 2020; Github, 2020). Veri setinden her defasında Şekil 9'daki gibi rastgele veri alınarak, verinin %10'u doğrulama geri kalanı ise eğitim amaçlı kullanılmıştır. Bu işlem 10 defa tekrarlanmış ve her bir ağ 10'ar defa eğitilmiştir. Daha sonra elde edilen doğrulama sonuçlarının ortalama değeri alınmıştır.



Şekil 9. Katmanlı Karışık Bölme
Figure 9. Stratified Shuffle Split

Kullanılan ikinci yöntem ise K-fold cross validation yöntemidir. Bu yöntemde; Şekil 10'daki gibi veri seti 10 parçaya ayrılmış, ağ 9 parça veriyle eğitilmiş, kalan veri doğrulama için kullanılmıştır (Chollet, 2017). Bu işlem 10 defa tekrarlanmış ve her bir ağ 10'ar defa eğitilmiş daha sonra doğrulama sonuçlarının ortalama değeri alınmıştır.

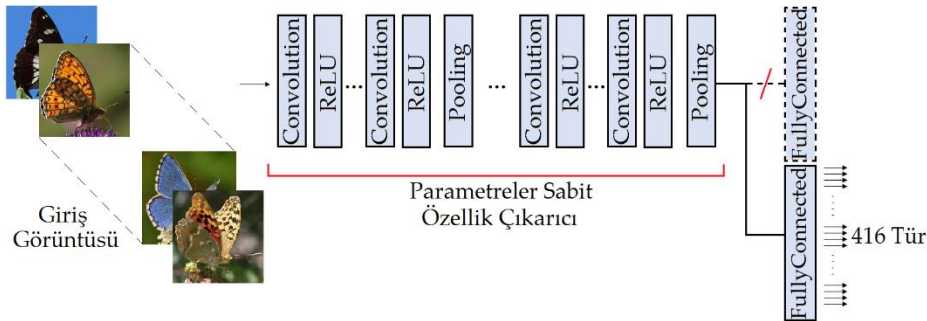


Şekil 10. K-katlamalı Çapraz doğrulama

Figure 10. K-fold Cross Validation

Her iki yöntem çalışmanın değerlendirmesi sürecinde kullanılmış, elde edilen sonuçlar karşılaştırılmış ve birbirine oldukça yakın sonuçlar elde edilmiştir. Çalışmada verilen sonuçlar her iki yöntemin ortalama değeridir.


Kelebek türlerinin sınıflandırılması için iki metot izlenmiştir. Birinci yöntemde; Şekil 11’de verildiği gibi 416 kelebek türünü sınıflandırmak amacıyla önceden eğitilmiş evrişimli sinir ağlarının çıkış katmanı 416 yapılmış ve çalışma için oluşturulan veri setleriyle ağlar eğitilerek sınıflandırma gerçekleştirilmiştir.



Şekil 11. Birinci yöntemde kullanılan ağ mimarisi.

Figure 11. Network architecture used in the first method.

Kelebek kanatlarının desen karmaşıklığı ve benzerliği kelebek sınıflandırmayı zorlaştıran bir unsurdur. Özellikle veri setindeki kelebek tür sayısı arttıkça bu daha da önemli bir unsur haline gelmektedir. Şekil 12’deki grafikten de görülebileceği gibi çalışmada kullanılan en başarılı üç ağın performansı veri setine yeni aileler, dolayısıyla yeni türler eklendikçe düşmüştür.



Şekil 12. Tür sayısı artışı-ağ başarısı

Figure 12. Species increase-network accuracy

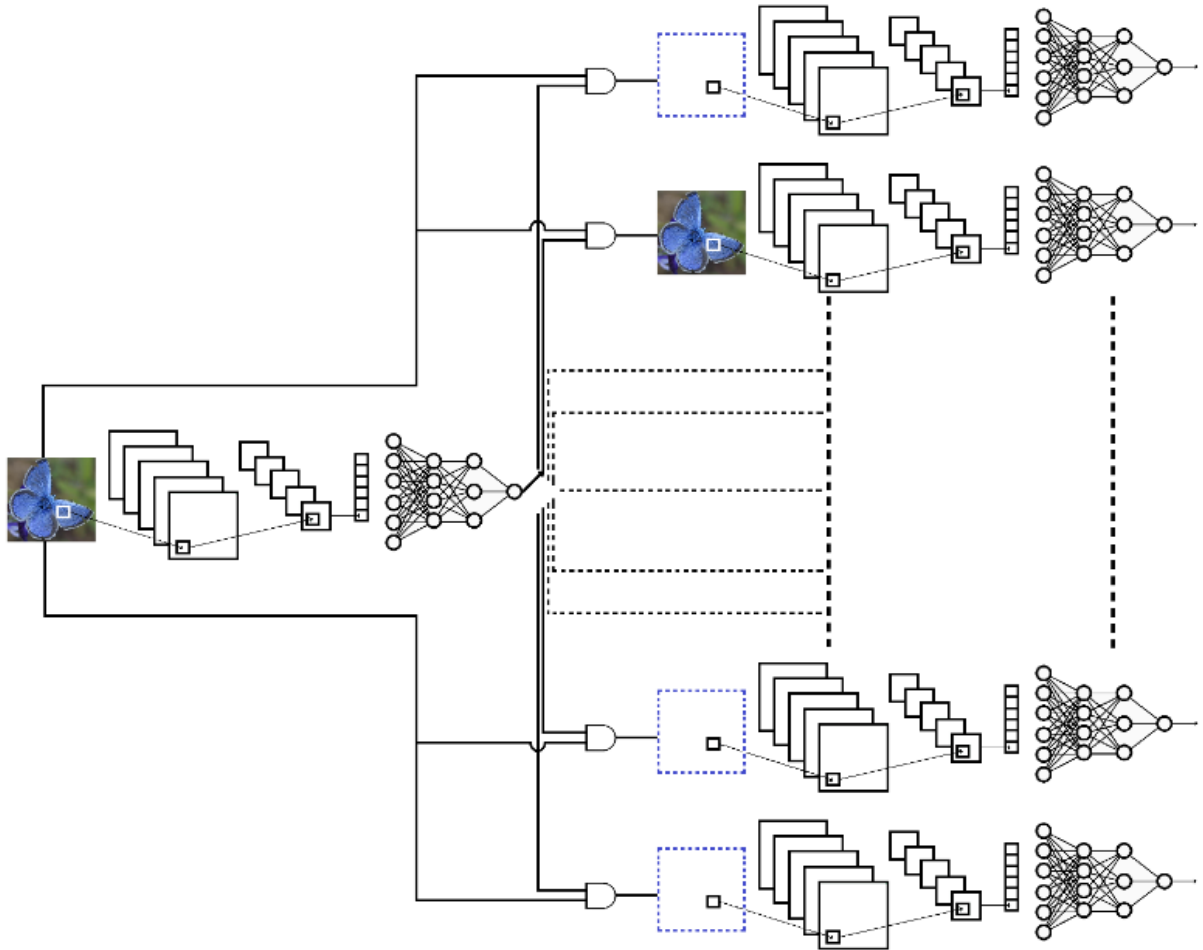
Çalışmada kullanılan yedi ağın 416 türü sınıflandırma performansları Çizelge 6'da verilmiştir. Ağların 416 kelebek türünü sınıflandırma performansları %36.67 ile %68.05 arasında değişmektedir.

Çizelge 6. Birinci yöntemde göre 416 türün sınıflandırma performansları.

Table 6. Identification performances of 416 species according to the first method.

Ağlar	Ağ Doğruluk
AlexNet	51.13
DenseNet201	68.05
ResNet18	51.96
ResNet50	66.59
ResNet101	63.33
VGG16	41.29
VGG19	36.67

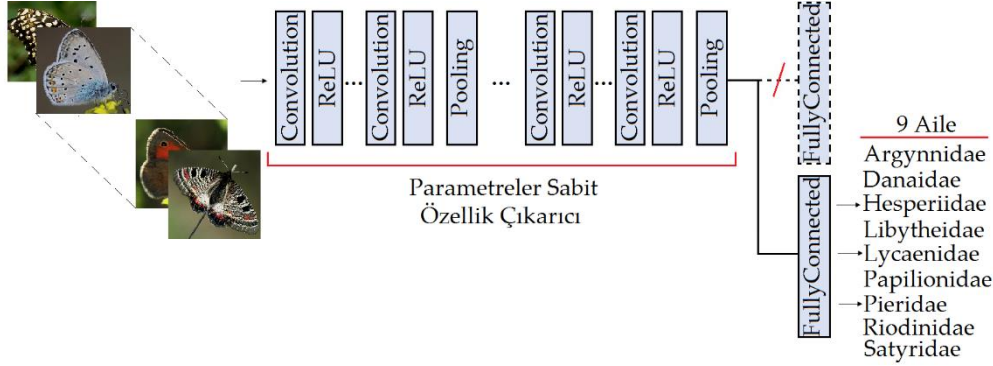
Elde edilen sonuçlar, çalışmada hedeflenen sonuçlardan çok uzaktır. Bu nedenle ikinci bir yöntem geliştirilmiştir. Bu yöntemdeki model Şekil 13'te verilmiştir. Model evrişimli sinir ağlarının basamaklı (cascaded) bağlanmasından oluşmaktadır. Birinci basamakta bir, ikinci basamakta birbirine paralel dokuz evrişimli sinir ağı vardır. Birinci basamaktaki evrişimli sinir ağı, aynı aile ait kelebek fotoğraflarının bir araya getirilmesiyle oluşan dokuz klasördeki veriyle eğitilmiştir. Bu basamaktaki ağ aile sınıflandırması yapmaktadır. İkinci basamaktaki dokuz ağın her biri ise söz konusu aileye ait veri setiyle tür sınıflandırması için ayrı ayrı eğitilmiştir.



Şekil 13. İkinci yöntemde kullanılan ağ mimarisi.

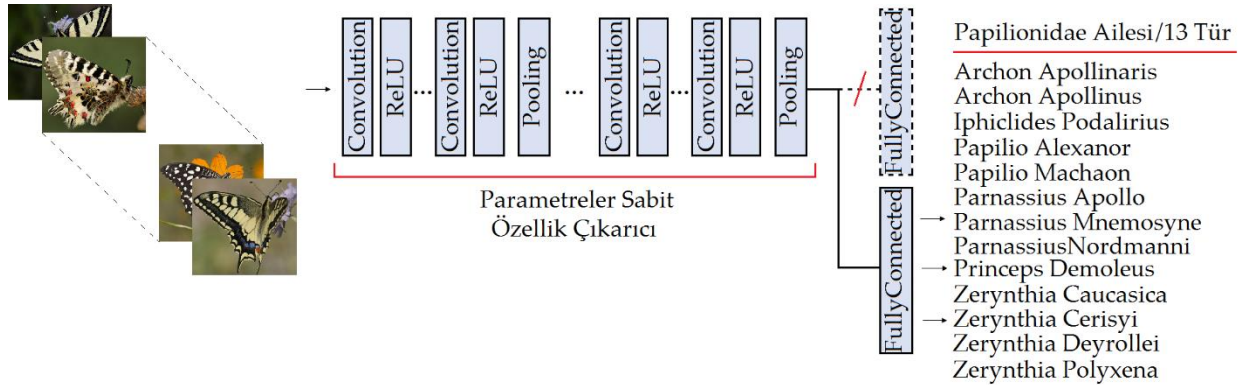
Figure 13. The network architecture used in the second method.

Modelin çalışma prensibi şu şekildedir; birinci basamaktaki ağın doğruluk sonucuna göre ikinci basamaktaki ağın girişine söz konusu kelebek görüntüsü yazılım aracılığıyla yönlendirilir ve ağ çalışması aktiflenir. Çıkan sonuç kelebek görüntüsünün hangi aileye ait olduğu ve bu ailenin hangi türü olduğu bilgisidir. Şekil 14'te birinci basamakta dokuz ailenin sınıflandırmasını gerçekleştiren evrişimli sinir ağ'ın yapısı, Şekil 15'te ise ikinci basamaktaki dokuz ağdan biri olan Papilionidae ailesinin ağ yapısı verilmiştir.



Şekil 14. İkinci yöntemin birinci katmana ait ağ mimarisi.

Figure 14. First-layer network architecture of the second method



Şekil 15. İkinci yöntemin ikinci katmana ait ağ mimarisi (Papilionidae Ailesi için).

Figure 15. Second-layer network architecture of the second method (For the family Papilionidae)

Çizelge 7'de çalışmada kullanılan yedi ağın birinci basamaktaki aile sınıflandırma doğruluk sonuçları verilmiştir.

Çizelge 7. Birinci katmanın aile sınıflandırma doğruluğu.

Table 7. Family classification accuracy of first layer.

Ağlar	Ağ Doğruluk
AlexNet	87.31
DenseNet201	95.88
ResNet18	91.86
ResNet50	94.14
ResNet101	95.23
VGG16	88.91
VGG19	89.66

Birinci basamaktaki sınıflandırma doğruluğu %87.31 ile %95.88 arasında değişmektedir. Çizelge 8'de ise çalışmada kullanılan her bir ağın ikinci basamaktaki tür sınıflandırma sonuçlarıdır.

Çizelge 8. İkinci Katmandaki Ağların Tür Sınıflandırma Oranları.*Table 8. Species Classification Rates of Networks in The Second Layer*

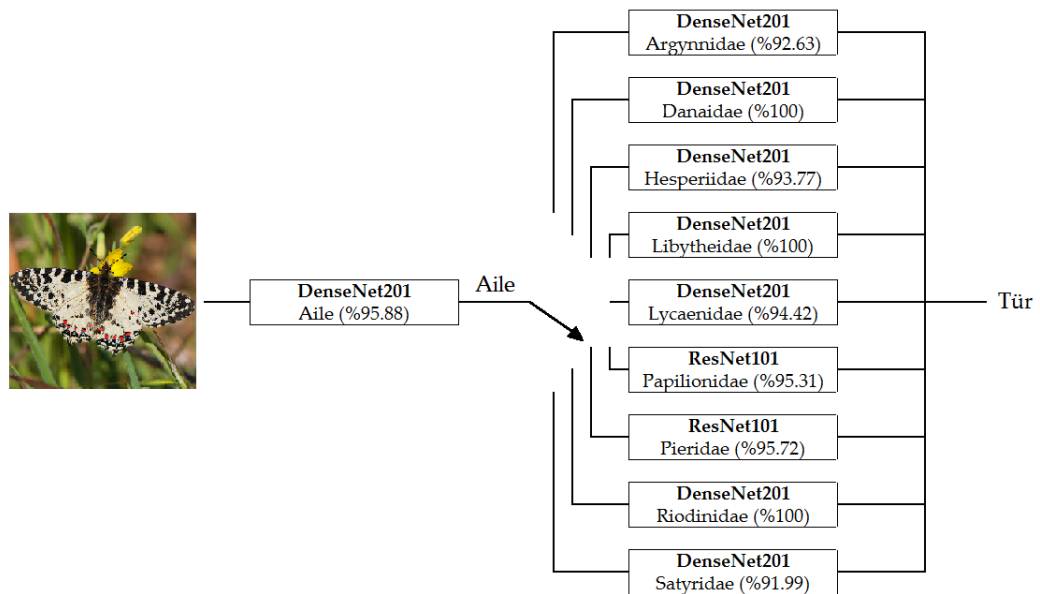
	AlexNet	DenseNet201	ResNet18	ResNet50	ResNet101	VGG16	VGG19
Argynnidae	76.68	92.63	85.30	92.08	90.67	82.75	85.94
Danaidae	100	100	100	100	100	100	100
Hesperiidae	85.18	93.77	87.22	90.86	91.82	79.74	86.07
Libytheidae	100	100	100	100	100	100	100
Lycaenidae	81.41	94.42	86.77	92.01	92.40	83.58	89.39
Papilionidae	87.73	94.82	92.59	93.35	95.31	88.05	82.88
Pieridae	87.67	95.33	92.33	93.35	95.72	87.48	81.34
Riodinidae	100	100	100	100	100	100	100
Satyridae	67.09	91.99	82.56	85.62	91.12	78.59	81.28

Çizelge 8'deki ağ başarı verileri incelendiğinde; Argynnidae, Danaidae, Hesperiidae, Libytheidae, Lycaenidae, Riodinidae ve Satyridae ailelerinin tür sınıflandırmasında DenseNet 201, Papilionidae ve Pieridae ailelerinin tür sınıflandırmasında ise ResNet101 ağının daha başarılı olduğu görülebilir. Bu iki ağın ikinci basamaktaki tür sınıflandırma başarı oranları Çizelge 9'da görülebileceği gibi %91.99 ile %100 arasında değişmektedir.

Çizelge 9. DenseNet201 ve ResNet101 Ağlarının Tür Sınıflandırma Oranları.*Table 9. Species Identification Rates of DenseNet 201 and ResNet 101 Networks*

Aile	DenseNet201	ResNet101
Argynnidae	92.63	---
Danaidae	100	---
Hesperiidae	93.77	---
Libytheidae	100	---
Lycaenidae	94.42	---
Papilionidae	---	95.31
Pieridae	---	95.72
Riodinidae	100	---
Satyridae	91.99	---

DeneySEL çalışmalar sonucunda Çizelge 9'dan hareketle yöntemin basamaklı (cascaded) ağ yapısı Şekil 16'daki gibi belirlenmiştir.

**Şekil 16.** Basamaklı Ağ.*Figure 16. Cascaded Network.*


Birinci yöntemde en başarılı ağ için tür sınıflandırma başarı oranı %68.05 iken, ikinci yöntemde en başarılı ağın tür sınıflandırma başarı oranı aileye göre %91.99 ile %100 arasında değişmektedir. İkinci yöntemin sınıflandırma performansı birinci yöntemde göre %35 ile %46 arasında artmıştır. Şekil 16'daki modelin Stratified Shuffle Split ve K-fold cross validation yöntemi kullanılarak eğitim ve test sürelerinin ortalama değer tablosu Çizelge 10'da verilmiştir.

Çizelge 10. Eğitim ve test süreleri

Table 10. Training and testing times

Birinci Basamak			İkinci Basamak		
Ağ	Eğitim Süresi	Test Süresi	Ağ	Eğitim Süresi	Test Süresi
Aile (DenseNet201)	66475 sn	6533 sn	Argynnidae (DenseNet201)	9115 sn	537 sn
			Danaidae (DenseNet201)	6645 sn	342 sn
			Hesperiidae (DenseNet201)	5889 sn	313 sn
			Libytheidae (DenseNet201)	5770 sn	296 sn
			Lycaenidae (DenseNet201)	29791 sn	1612 sn
			Papilionidae (ResNet101)	10982 sn	516 sn
			Pieridae (ResNet101)	6059 sn	315 sn
			Riodinidae (DenseNet201)	6917 sn	385 sn
			Satyridae (DenseNet201)	7810 sn	361 sn

Yöntemin başarısını test etmek amacıyla rastgele seçilen Şekil 17'deki Papilionidae ailesinden Zerynthia Cerisyi görüntüsü birinci katmandaki ağın girişine verilmiştir.



Şekil 17. Papilionidae ailesi-Zerynthia Cerisyi.

Figure 17. Papilionidae family-Zerynthia Cerisyi

Birinci basamaktaki DenseNet201 ağının aile sınıflandırma Hata Matrisi (Confusion Matrisi) Şekil 18'de Hata, Precision, Recall ve F1 Score değerleri Çizelge 11'de verilmiştir.

	Argynnide	Danaidae	Hesperiidae	Libytheidae	Lycaenidae	Papilionidae	Pieridae	Riodinidae	Satyridae
Argynnide	8593 0,93	0 0,00	197 0,02	96 0,01	0 0,00	104 0,01	97 0,01	0 0,00	183 0,02
Danaidae	0 0,00	6645 1,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
Hesperiidae	152 0,03	0 0,00	5228 0,94	69 0,01	0 0,00	0 0,00	43 0,01	0 0,00	73 0,01
Libytheidae	0 0,00	0 0,00	0 0,00	5770 1,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
Lycaenidae	283 0,02	0 0,00	171 0,01	0 0,00	13195 0,94	0 0,00	182 0,01	0 0,00	194 0,01
Papilionidae	138 0,02	0 0,00	0 0,00	67 0,01	0 0,00	6898 0,95	83 0,01	0 0,00	74 0,01
Pieridae	75 0,01	0 0,00	59 0,01	0 0,00	0 0,00	89 0,01	5885 0,95	0 0,00	77 0,01
Riodinidae	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	5620 1,00	0 0,00
Satyridae	194 0,03	0 0,00	152 0,02	88 0,01	0 0,00	72 0,01	75 0,01	0 0,00	6719 0,92

Şekil 18. Birinci katmanın hata matrisi.

Figure 18. The confusion matrix of the first layer.

Çizelge 11. Sınıflandırma metrikleri

Table 11. Classification metrics

Metrikler	Oran	Metrikler	Oran
Hata	0,0412	Recall	0,9593
Precision	0,9588	F1 Score	0,9589

Bu matristeki Papilionidae ailesinin ilgili satırı Şekil 19'da verilmiştir. İlgili satırdan görüleceği üzere Zerynthia Cerisyi kelebek görüntüsünün Papilionidae ailesine ait olduğu %95 başarı oranı ile belirlenmiştir.

Papilionidae	138	0	0	67	0	6898	83	0	74
	0,02	0,00	0,00	0,01	0,00	0,95	0,01	0,00	0,01

Şekil 19. Papilionidae ailesinin hata matrisindeki satırı

Figure 19. Row in the confusion matrix of the family Papilionidae

Modelin çalışma prensibi gereği kelebek görüntüsü ikinci katmandaki Papilionidae ailesine ait altıncı ağız girişine yazılım aracılığıyla yönlendirilmiş ve söz konusu ağız çalışması aktiflenmiştir. İkinci basamaktaki ResNet101 ağızının Papilionidae ailesine ait tür sınıflandırma Hata Matrisi Şekil 20'de Hata, Precision, Recall ve F1 Score değerleri Çizelge 12'de verilmiştir.

	Archon apollinaris	Archon Apollinus	Iphiclides Podalirius	Papilio Alexanor	Papilio Machaon	Parnassius Apollo	Parnassius Mnemosyne	Parnassius Nordmanni	Princeps Demoleus	Zerynthia Caucasica	Zerynthia Cerisyi	Zerynthia Deyrollei	Zerynthia Polyxena
Archon apollinaris	523 1,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
Archon Apollinus	0 0,00	413 0,95	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	22 0,05	0 0,00
Iphiclides Podalirius	0 0,00	0 0,00	471 0,90	0 0,00	25 0,05	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	28 0,05	0 0,00	0 0,00
Papilio Alexanor	0 0,00	0 0,00	0 0,00	452 1,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
Papilio Machaon	0 0,00	0 0,00	0 0,00	0 0,00	609 1,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
Parnassius Apollo	0 0,00	0 0,00	27 0,05	0 0,00	0 0,00	507 0,95	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
Parnassius Mnemosyne	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	587 1,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
Parnassius Nordmanni	0 0,00	0 0,00	0 0,00	0 0,00	15 0,02	0 0,00	0 0,00	721 0,98	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
Princeps Demoleus	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	591 1,00	0 0,00	0 0,00	0 0,00	0 0,00
Zerynthia Caucasica	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	421 0,85	53 0,11	23 0,05	0 0,00
Zerynthia Cerisyi	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	535 0,95	0 0,00	29 0,05
Zerynthia Deyrollei	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	123 0,19	523 0,81	0 0,00
Zerynthia Polyxena	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	562 1,00

Şekil 20. İkinci katmanın hata matrisi.

Figure 20. The confusion matrix of the second layer.

Çizelge 12. Sınıflandırma metrikleri

Table 12. Classification metrics

Metrikler	Oran	Metrikler	Oran
Hata Oranı	0,0475	Recall	0,9600
Precision	0,9525	F1 Score	0,9540

Hata Matrisinde Zerynthia Cerisyi kelebek türünün ilgili satırı Şekil 21’de verilmiştir. Türün sınıflandırma başarı oranı %95’dir.

Zerynthia Cerisyi	0	0	0	0	0	0	0	0	0	0	535	0	29
	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,95	0,00	0,05

Şekil 21. Zerynthia Cerisyi tür sınıflandırma doğruluğu

Figure 21. Zerynthia Cerisyi species identification accuracy

Papilionidae ailesinden Zerynthia Cerisyi ait birinci ve ikinci basamaktaki sınıflandırma süreleri Çizelge 13’te verilmiştir. Kelebeğin toplam sınıflandırma süresi 2,04 sn’dir. Diğer ailelere ait sınıflandırma denemelerinde ise süre 3 saniyenin altında kalmıştır.

Çizelge 13. Zerynthia Cerisyi ait sınıflandırma süreleri

Table 13. Classification times of Zerynthia Cerisyi

Birinci Basamak		İkinci Basamak	
Ağ	Sınıflandırma Süresi	Ağ	Sınıflandırma Süresi
Aile (DenseNet201)	1,03 sn	Papilionidae (ResNet101)	1,01 sn

Literatür incelendiğinde bu çalışma Türkiye’deki kelebek türlerinin tamamını içermesi açısından tek çalışmadır. Bunun yanı sıra Çizelge 14’te de görüleceği gibi tür, görüntü sayısı ve başarı oranı olarak gerek Türkiye’deki gerekse diğer kelebek türleri inceleyen çalışmalar ile karşılaştırıldığında kayda değer bir başarı göstermiştir. Özellikle tür-başarı ilişkisi dikkate alındığında tatmin edici sonuçlar elde edilmiştir.

Çizelge 14. literatür karşılaştırma tablosu

Table 14. literature comparison chart

Yapılan Çalışmalar	Kullanılan Yöntemler	Tür Say.	Gör. Say.	Baş. Ora.(%)
Serna ve Segura, 2014	Yapay Sinir Ağları	11	92	92,25
Kang ve diğ., 2014	Yapay Sinir Ağları	15	150	80,3
Kaya, Ertuğrul ve diğ. 2015	LBP	14	140	95,71
Kaya, Kayci ve diğ., 2015	LBP ve Yapay Sinir Ağı	5	50	98
Rodner ve diğ., 2015	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet)	675	2120	55,7
Rodner ve diğ., 2015	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet)	331	2310	79,2
Carvajal ve diğ., 2016	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet, VGG16 ve VGG19)	15	2110	92
Ming ve diğ., 2017	CaffeNet	1117		95,8
Ming ve diğ., 2017	SVM	1117		94,8
Chang ve diğ., 2017	Evrişimli Sinir Ağları-Transfer Öğrenme (ResNet18, ResNet34, VGG19,	636	14270	92,6
Nie ve diğ., 2017	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet, VGGNet ve ResNet)	82		95
Xie ve diğ., 2018	Faster R-CNN (ZF)	1287	5695	59,8
Xie ve diğ., 2018	Faster R-CNN (VGG CNN M1024)	1287	5695	64,5
Xie ve diğ., 2018	Faster R-CNN (VGG16)	1287	5695	72,8
Zhu ve Spachos, 2019	Makine Öğrenmesi (SVM)	10	832	52,8
Zhu ve Spachos, 2019	Derin Öğrenme (4-Conv CNN)	10	832	98,44
Zhu ve Spachos, 2019	Evrişimli Sinir Ağları-Transfer Öğrenme (VGG19)	10	832	98,53
Ruoyan ve diğ., 2019	R-CNN	111	5695	70,4
Arzar ve diğ., 2019	Evrişimli Sinir Ağları-Transfer Öğrenme (GoogLeNet)	4	120	97,5
Lin ve diğ., 2019	S-CCNN (Skip-Connections Convolutional Neural Network)	56	173852	93,36
Antequera ve diğ., 2019	Evrişimli Sinir Ağları-COSFIRE (SVM)	7	619	96,57
Almryad ve Kutucu, 2020	Evrişimli Sinir Ağları-Transfer Öğrenme (VGG16, VGG19 ve ResNet50)	10	17769	80
Çalışma	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet, DenseNet201, ResNet18, ResNet50, ResNet101, VGG16 ve VGG19)	9 aile	67640	95,88
Çalışma	Evrişimli Sinir Ağları-Transfer Öğrenme (AlexNet, DenseNet201, ResNet18, ResNet50, ResNet101, VGG16 ve VGG19)	416	67640	91,99 ile 100

SONUÇ VE TARTIŞMA (RESULT AND DISCUSSION)

Birçok kaynaktan toplanarak ve düzenlenerek oluşturulan yeni veri setinde yüksek başarı gösteren ve ileriye dönük iyi bir çözüm olduğunu ispatlayan bu görsel tür sınıflandırması; kelebek türlerinin sınıflandırılmasında, zararlı kelebek türlerinin tespitinde, yaşamsal açıdan önemli kelebek türlerinin koruma altına alınmasında ve ekosistem değişikliklerinin belirlenmesinde yararlı olabilecek bir problem çözümüdür.

DeneySEL çalışmalarda önceden eğitilmiş ağlarının başarı oranının, aile sayısı dolayısıyla tür sayısı arttıkça kelebeklerin ön ve arka kanat desen benzerliğinden dolayı çok düştüğü görülmüştür. Hedeflenen başarı oranına ulaşmak amacıyla basamaklı (cascade) ağ yapısı modeli kullanılmış, bunun sonucu olarak başarı oranı yükseltilmiştir. Modelde birinci basamaktaki ailelere göre sınıflandırmada %95.88, ikinci basamaktaki tür sınıflandırmada ise %91.99 ile %100 arasında başarı oranı elde edilmiştir. Elde edilen yüksek başarı oranı kullanılan modelin benzer problemler için iyi bir çözüm olacağını göstermektedir.

Bu çalışma; probleme, veriye ve ağa uygun transfer öğrenme yöntemi seçildiğinde önceden eğitilmiş ağların bu ve benzeri problemlere iyi çözümler getireceğini göstermesi açısından önemlidir. Çalışmanın diğer önemli bir sonucu, üzerinde birçok tanımlayıcı özellik taşıyan kelebek ön ve arka kanadının, kelebek tanımlamada çok önemli rol oynadığını göstermesidir.

Çalışmanın temel amaçlarından biri, kelebek görüntülerinden kelebek türlerinin tanımında karşılaşılan veri kümesi eksikliğine veya yetersizliğine katkıda bulunmaktır. Bu amaçla Türkiye'deki 9 aile ve 416 kelebek türüne ait 13528 görüntü toplanmış, veri artırma yöntemi ile görüntü sayısı 67640'a çıkarılarak yeni bir veri seti oluşturulmuştur. Çalışma sonrasında; Türkiye'deki kelebek türlerini kapsayan bir projeye çalışmanın geliştirilmesi, veri setinin daha da büyütülmesi ve kamuya açılması planlanmaktadır.

Çalışmada kullanılan ağların katman sayısı ve derinliği arttıkça ağ başarı oranı artmıştır. Ağ parametre sayısı arttıkça ise başarı oranının düştüğü gözlenmiştir. Veri boyutunun ağ parametre sayısına göre çok küçük kalması bu sonucu neden olmuştur. Ayrıca parti büyüklüğünün ağ başarı oranını etkilediği gözlenmiştir. Bu sonuçlar transfer öğrenme yönteminin kullanıldığı problem çözümlerinde dikkat edilmesi gereken unsurlardır.

Çalışma bir başlangıç çalışması olup yüksek performans gösteren ağ mimarileri ve çalışma esnasında kazanılan tecrübeler yeni proje kapsamında probleme özgü ağ tasarımının yapıldığı modelde kullanılacaktır. Yeni projede tasarım ve eğitim süreci Python programlama dili ile gerçekleştirilecektir. Proje tamamlandığında uygulamanın kullanımı için bir WEB sayfası oluşturulacak, kullanıcılar WEB sayfasına yükledikleri görüntüden kelebek aile ve türünü öğrenebilecektir.

KAYNAKLAR (REFERENCES)

- Almryad, A.S., Kutucu, H., 2020, "Automatic identification for field butterflies by convolutional neural networks", *Engineering Science and Technology an International Journal*, Vol. 23, No. 1, pp. 189–195.
- Antequera, M.L., Vallina, M.L., Strisciuglio, N., Petkov, N., 2019, "Place and Object Recognition by CNN-Based COSFIRE Filters", *IEEE Access*, Vol 7, pp. 66157–66166.
- Arzar, N.N.K., Sabri, N., Johari, N.F.M., Shari, A.A., Noordin, M.R.M., Ibrahim, S., 2019, "Butterfly Species Identification Using Convolutional Neural Network (CNN)", *2019 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS), Shah Alam-Malaysia*, 221–224.
- Baykal, E., Doğan, H., Ercin, M.E., Ersoz, S., Ekinci, M., 2019, "Transfer learning with pre-trained deep convolutional neural networks for serous cell classification", *Multimedia Tools and Applications*, pp. 1-19.
- Brownle, J., "Machine Learning Mastery. A Gentle Introduction to Transfer Learning for Deep Learning", <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>, ziyaret tarihi: 11 Kasım 2020.

- Carvajal, J.A., Romero, D., Sappa, A.D., 2016, "Fine-tuning based deep convolutional networks for lepidopterous genus recognition", *In Proceedings of the Iberoamerican Congress on Pattern Recognition*, Lima-Peru, 467–475.
- Cebeci, Z., <http://www.adamerkelebek.org/MenuDetay.asp?MenuId=21&altMenuId=61>, ziyaret tarihi: 11 Kasım 2020.
- Chang, Q., Qu, H., Wu, P., Yi, J., 2017, "Fine-Grained butterfly and moth classification using deep convolutional neural networks", *Semantic Scholar*.
- Chollet F., 2017, *Deep Learning with Python*, Manning Publications, New York, United States.
- Github, "Cross-Validation: Why and how to do it", <https://srikarvaka.github.io/model-evaluation/Cross-validation/>, ziyaret tarihi: 12 Ekim 2020.
- Goodfellow, I., Bengio, Y., Courville, A., 2015, *Deep Learning*, The MIT Press, Cambridge, Massachusetts, United States.
- Gürkan, H., Hanilçi, A., 2020 "Evrişimsel sinir ağı ve QRS imgeleri kullanarak EKG tabanlı biyometrik tanıma yöntemi", *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, Vol. 26, No. 2, pp. 318-327.
- He, K., Zhang, X., Ren, S., Sun, J., 2016, "Deep Residual Learning for Image Recognition", *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, United States, 770-778.
- Indolia, S., Goswami, A.K., Mishra, S.P., Asopa, P., 2018, "Conceptual Understanding of Convolutional Neural Network-A Deep Learning Approach", *Procedia Computer Science*, Vol. 132, pp. 679-688.
- Kaggle, "Stratified Shuffle Split Working with less data", <https://www.kaggle.com/viswanathanc/stratifiedshufflesplit-working-with-less-data>, ziyaret tarihi: 12 Ekim 2020.
- Kang, S.H., Cho, J.H., Lee, S.H., 2014, "Identification of butterfly based on their shapes when viewed from different angles using an artificial neural network", *Journal of Asia-Pacific Entomology*, Vol. 17, No. 2, pp. 143–149.
- Karaçetin, E., Welch, H.J., 2011, *Türkiye'deki Kelebeklerin Kırmızı Kitabı*, Doğa Koruma Merkezi, Ankara, Türkiye.
- Karaçetin, E., Welch, H.J., Turak, A., Balkız, Ö., Welch, G., 2011, *Türkiye'deki Kelebeklerin Koruma Stratejisi*, Doğa Koruma Merkezi, Ankara, Türkiye.
- Kaya, Y., Ertuğrul, Ö.F., Tekin, R., 2015, "Two novel local binary pattern descriptors for texture analysis", *Applied Soft Computing*, Vol. 34, pp. 728–735.
- Kaya, Y., Kayci, L., Uyar, M., 2015, "Automatic identification of butterfly species based on local binary patterns and artificial neural network", *Applied Soft Computing*, Vol. 28, pp. 132–137.
- Kelebek-Turk, "Türkiye'nin Kelebekleri", <https://www.kelebek-turk.com/families.php>, ziyaret tarihi: 11 Kasım 2020.
- Lawrence, S., Giles, C.L., Tsoi, A.C., Back, A.D., 1997, "Face recognition: A convolutional neural-network approach", *IEEE Transactions on Neural Networks*, Vol. 8, No. 1, pp. 98-113.
- Lin, Z., Jia, J., Gao, W., Huang, F., 2019, "Fine-grained visual categorization of butterfly specimens at sub-species level via a convolutional neural network with skip-connections", *Neurocomputing*, Vol. 384, pp. 295–313.
- Mash, R., Borghetti, B., Pecarina, J., 2016, "Improved Aircraft Recognition for Aerial Refueling through Data Augmentation in Convolutional Neural Networks", *12th International Symposium on Visual Computing Advances in Visual Computing*, Las Vegas, Vol. 12, pp. 113-122.
- MathWorks, <https://www.mathworks.com/help/deeplearning/ug/introduction-to-convolutional-neural-networks.html>, ziyaret tarihi: 11 Kasım 2020.
- Medium, "StratifiedKFold v.s KFold v.s", <https://xzz201920.medium.com/stratifiedkfold-v-s-kfold-v-s-stratifiedshufflesplit-ffcae5bfdf>, ziyaret tarihi: 12 Ekim 2020.
- Ming, Z.A., Peng, M.P., Yu, X.T., Ning, W.J., Jin, F., Zhong, S.Z., Lei, T.Y., Qing, Y., 2017, "Automatic identification of butterfly specimen images at the family level based on deep learning method", *Acta Entomologica Sinica*, Vol. 60, pp. 1339–1348.

- Nebauer, C., 1998, "Evaluation of convolutional neural networks for visual recognition", *IEEE Transactions on Neural Networks*, Vol. 9, No. 4, pp. 685- 696.
- Nie, L., Wang, K., Fan, X., Gao, Y., "Fine-grained butterfly recognition with deep residual networks: A new baseline and benchmark", *2017 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*, Sydney-Australia, 1-7, 29 November-01 December 2017.
- Pan, S.J., Yang, Q., 2010, "A survey on transfer learning", *IEEE Transactions on Knowledge and Data Engineering*, Vol. 22, No. 10, pp. 1345-1359.
- Petit, J.C., "Inventory of the butterfly species of sangay national park-Ecuador", <http://www.sangay.eu/index.php?lang=en>, ziyaret tarihi: 11 Kasım 2020
- Rodner, E., Simon, M., Brehm, G., Pietsch, S., Wägele, J.W., Denzler, J., 2015, "Fine-grained recognition datasets for biodiversity analysis", <http://www.inf-cv.uni-jena.de/fgvcbiodiv>, ziyaret tarihi: 11 Kasım 2020.
- Ruoyan, Z., Cuixia, L., Shuai, Y., Xinru, F., 2019, "Butterfly Recognition Based on Faster R-CNN", *Journal of Physics: Conference Series*, Vol. 1176, No.3.
- Serna, A.H., Segura, L.F.J., 2014, "Automatic identification of species with neural networks", *PeerJ*, e563.
- Shou, J., Zhou, Y., Li, Y., 2006, "Systematic Butterfly Names of the World", *Shaanxi Science and Technology Press*, Xi'an, China.
- Theckedath, D., Sedamkar, R.R., 2020, "Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks", *Springer Nature Computer Science*, Vol. 79, pp. 1-7.
- Trakel, "İl tür sayıları", <http://www.trakel.org/kelebekler/?fsx=il-tur-listesi>, ziyaret tarihi: 11 Kasım 2020.
- Wang, J., Markert, K., Everingham, M., 2009, "Learning models for object recognition from natural language descriptions", *In Proceedings of the 20th British Machine Vision Conference*, London, UK.
- Wang, W., Zhang, J., Wang, F., 2019, "Attention bilinear pooling for fine-grained classification", *Symmetry*, Vol. 11, No. 8, p. 1033.
- Xie, J., Hou, Q., Shi, Y., Peng, L., Jing, L., Zhuang, F., Zhang, J., Tang, X., Xu, S., 2018, "The automatic identification of butterfly species", *Journal of Computer Research and Development*, Vol. 55, No. 8, pp. 1609-1618.
- Xin, D., Chen, Y.W., Li, J., 2020, "Fine-Grained Butterfly Classification in Ecological Images Using Squeeze-And-Excitation and Spatial Attention Modules", *Applied Sciences*, Vol. 10, No. 5, p. 1681.
- Xue, A., Li, F., Xiong, Y., 2019, "Automatic Identification of Butterfly Species Based on Gray-Level Co-occurrence Matrix Features of Image Block", *Journal of Shanghai Jiaotong University (Science)*, Vol. 24, No. 2, pp. 220-225.
- Yamashita, R., Nishio, M., Do, R.K.G., Togashi, K., 2018, "Convolutional neural networks: an overview and application in radiology", *Insights Imaging*, Vol. 9, pp. 611-629.
- Ye, H., Han, H., Zhu, L., Duan, Q., 2019, "Vegetable pest image recognition method based on improved VGG convolution neural network", *Journal of Physics: Conference Series*, Vol. 1237, No. 3, 032018.
- Zhao, R., Li, C., Ye, S., Fang, X., 2019, "Butterfly Recognition Based on Faster R-CNN", *Journal of Physics: Conference Series*, Vol. 1176, No. 3.
- Zhou, Y., Nejati, H., Do, T.T., Cheung, N.M., Cheah, L., 2016, "Image-based vehicle analysis using deep neural network: A systematic study", *IEEE international conference on digital signal processing*, 276-280.
- Zhu, L., Spachos, P., 2019, "Butterfly Classification with Machine Learning Methodologies for an Android Application", *2019 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, Ottawa-Canada.