

Evrişimsel Sinir Ağı Mimarileri ve Öğrenim Aktarma ile Bitki Zararlısı Çekirge Türlerinin Sınıflandırması

Nurullah ŞAHİN^{1*}, Nuh ALPASLAN², Mustafa İLÇİN³, Davut HANBAY⁴

^{1,4} Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, İnönü Üniversitesi, Malatya, Türkiye
² Bilgisayar Mühendisliği Bölümü, Mühendislik ve Mimarlık Fakültesi, Bingöl Üniversitesi, Bingöl, Türkiye
³ Bitki Koruma Bölümü, Ziraat Fakültesi, Bingöl Üniversitesi, Bingöl, Türkiye
^{*1} nursahin.net@gmail.com, ² nalpaslan@bingol.edu.tr, ³ milcin@bingol.edu.tr, ⁴ davut.hanbay@inonu.edu.tr

(Geliş/Received: 03/01/2023;

Kabul/Accepted: 15/02/2023)

Öz: Çekirgeler, mahsullere zarar vererek her yıl milyonlarca ton gıdanın yok olmasına neden olmaktadır. Etkili ve doğru çekirge tanımlama sistemlerinin geliştirilmesi, çekirge türlerinin kontrol altına alınması ve gıda kaybının önlenmesinde kritik öneme sahiptir. Bu çalışmada, ülkemizin ve dünyanın çeşitli yerlerinde görülen 11 farklı bitki zararlısı çekirge türü çeşitli evrişimsel sinir ağı modelleri kullanılarak sınıflandırılmıştır. Çalışmada kullanılan veri seti ülkemizin Doğu ve Güneydoğu Anadolu bölgesinde gözlemlenerek elde edilmiştir. Bu çalışmanın en büyük yeniliği, ülkemizde bulunan 11 farklı bitki zararlısı çekirge türüne ait GHCD11 adında yeni bir veri setinin oluşturulmuş olmasıdır. Bunun yanında, çalışmada 11 farklı bitki zararlısı çekirge türünün otomatik olarak sınıflandırılması için Keras kütüphanesinde bulunan ve görüntü sınıflandırmasında yaygın olarak kullanılan VGG16, VGG19, ResNet50, DenseNet121, EfficientNet, MobileNet kullanılmıştır. Öğrenme aktarımı ile GHCD11 veri seti üzerinde yapılan deneysel çalışmalar sonucunda, %95 ile %99 aralığında kayda değer sınıflandırma doğrulukları elde edilmiştir. Çalışma yeni bir veri seti sunmasının yanı sıra, bitki zararlısı çekirge türlerinin evrişimsel sinir ağı mimarileri ile otomatik tanı ve tespitinin yüksek başarımla yapılabilmesini göstermesi açısından önem arz etmektedir.

Anahtar kelimeler: Çekirge, sınıflandırma, görüntü işleme, derin öğrenme, evrişimsel sinir ağı.

Classification of Plant Pest Grasshopper Species by Convolutional Neural Network Architectures and Transfer Learning

Abstract: Grasshoppers damage crops and causes millions of tons of food to be destroyed every year. The development of effective and accurate locust identification systems is critical in controlling locust species and preventing food loss. In this study, 11 different plant pest grasshopper species seen in various parts of our country and the world were classified using various convolutional neural network models. The dataset used in the study was obtained by observing the Eastern and Southeastern Anatolia regions of our country. The novelty of this study is that a dataset named GHCD11 has been created for 11 different plant pest grasshopper species in our country. In addition, VGG16, VGG19, ResNet50, DenseNet121, EfficientNet, MobileNet, which are in the Keras library and are widely used in image classification, were used for the automatic classification of 11 different grasshopper species in the study. As a result of experimental studies on the GHCD11 dataset with learning transfer, remarkable classification accuracies in the range of 95% to 99% were obtained. The study is important because it not only presents a novel dataset, but also demonstrates that automatic identification and detection of plant pest grasshopper species can be done with high accuracy using convolutional neural network architectures.

Key words: Grasshopper, classification, image processing, deep learning, convolutional neural network.

1. Giriş

Artan nüfus yoğunluğu, gıda güvenliği problemini geleceğin önemli sorunlarından biri haline getirmektedir. Tarım zararlıları ile etkili mücadele bu problemin çözümünde ve tarımsal ürünlerin verimliliğinin artırılmasında önemli bir yere sahiptir [1]. Böcekler, tarım ürünleri ile beslenerek, ürünlerde verim düşüklüğüne veya doğrudan ürün kaybına neden olabilmektedir [2]. Bu böcekler ile mücadele ve böcekleri yok etmek maliyetli bir iştir ve milyonlarca dolara mal olabilir. Doğru haşere ilaçlarının kullanılarak etkili bir mücadele yapılabilmesi için belirli düzeyde bir uzman eğitimi gerekmektedir. Ayrıca kimyasal haşere ilaçlarının kapsamlı kullanımı zararlı çevresel etkilere neden olmaktadır [3]. Bahsedilen nedenlerden ötürü tarımsal haşerelerin erken ve doğru tespiti, zararlılarla mücadele ve gıda güvenliğinin sağlanmasında kritik öneme sahiptir. Dünyada çok sayıda zararlı türü bulunmakta ve farklı türler arasında benzerlikler bulunmaktadır. Ayrıca, haşere tanımlama görevi zaman alıcı bir süreçtir ve

* Sorumlu yazar: nursahin.net@gmail.com. Yazarların ORCID Numarası: ¹ 0000-0002-3578-9959, ² 0000-0002-6828-755X, ³ 0000-0002-2542-9503, ⁴ 0000-0003-2271-7865

tarla bitkileri hakkında uzman bilgisi gerektirmektedir. Bu nedenlerden ötürü, zararlı türlerinin uzman entomologlar tarafından klasik yöntemlerle sınıflandırılması ve tanımlanması zorlu bir süreçtir. Zararlı türlerinin tam olarak anlaşılması, böcek taksonomisi ve morfolojik özelliklerin terminolojisini gerektirir. Bu nedenle, tür düzeyinde zararlı kategorilerini ayırt etmek zordur, bu da mahsul kayıplarının artmasına veya pestisitlerin yanlış/aşırı kullanımına yol açmaktadır [4]. Bahsedilen zorluklarla baş edebilmek için son yıllarda böcek tanı/tespitinde bilgisayar destekli tespit sistemleri yaygın olarak kullanılmaya başlanmıştır [5]. Bilgisayar destekli görüntü tespit sistemleri, tanıma maliyetini etkin bir şekilde azaltabilir ve hem tanıma hızı hem de verimliliği önemli ölçüde artırılabilir. [6], SIFT öznelik histogramı tabanlı bir taş sineği larvaları sınıflandırma yöntemi önermiştir. [7], görüntülerdeki beyaz sineklerin bölütlenmesi ve sayımı için pikseller arasındaki nispi farkları hesaplayan RDI algoritmasını kullanmıştır. [8], beyaz sinek görüntülerinin bölütlenmesinde, işaretçi kontrollü watershed algoritmasını kullandı ve elde edilen başarıyı ölçme için Fuzzy C-Means algoritması ile sonuçları karşılaştırdı. [9], şeker kamışı pamuk bitlerinin tespitinde C-Means algoritmasına dayanan bir model önerdi. [10], eşek arısı türlerinin sınıflandırılmasında DAISY olarak adlandırılan bir dijital otomatik tanımlama sistemini önerdiler. Önerdikleri sistem, kanat görüntüleri üzerinde kritik özelliklerin çıkarılması için Temel Bileşen Analizi (Principal Component Analysis, PCA) ve temel bileşen analizi ile elde edilen özellik vektörlerinin sınıflandırılması için Kendall- τ istatistik sınıflandırıcı yöntemlerini kullanmaktadır. [11], örümcek tür grubunu tanımlamak için otomatik bir örüntü tanıma sistemi geliştirmiş ve örümcek görüntülerinin temel şekil bilgilerini çıkarmak için dalgacık dönüşümü yöntemini, sınıflandırma işlemi için ise Çok Katmanlı Algılayıcı (Multilayer Perceptron, MLP) kullanmıştır. [12], böcek tespitinde renk özellikleri üzerinde araştırma yapmış ve renk histogramına ve gri-seviye eş oluşturma matrisine dayalı bir böcek tanımlama yöntemi önermiştir.

Geleneksel bilgisayar destekli tanı sistemleri böcek tanı tespitine oldukça katkı sağlamış olsalar da, yine de bir takım eksiklikleri bulunmaktadır. Araizlerden elde edilen görüntüler yüksek miktarda gürültü içermektedir ve bu gürültü önileme adımları ile giderilmez ise tanımlama başarımını düşürmektedir. Ayrıca geleneksel bilgisayar destekli tespit sistemleri elde edilen veri setine yüksek ölçüde bağımlıdır ve farklı veri setleri üzerinde test edildiklerinde başarımları önemli miktarda düşmektedir [13],[14]. Son yıllarda derin öğrenme tekniklerinin gelişmesi ve derin öğrenme tekniklerinin elde ettikleri yüksek başarımlar nedeniyle birçok araştırmacı bu teknolojiyi yüz tanıma [15], nesne tanıma [16], medikal görüntüleme [17], lezyon bölütleme [18] ve daha pek çok farklı alanlarda uygulamış ve dikkate değer sonuçlar elde etmişlerdir. Derin öğrenme yöntemleri gösterdikleri başarımlardan dolayı bilgisayar destekli haşere tespit yöntemlerinde de yaygın biçimde kullanılmaya başlanmıştır. [19], gelişmiş evrşimsel sinir ağına dayalı bir böcek tespiti ve sınıflandırma modeli önermiştir. Bu çalışmada, böcek görüntülerinden özellik çıkarımı için VGG19 ağı ve böceklerin gerçek konumlarını öğrenmek için bölge öneri ağı (Region Proposal Network, RPN) önerilmiştir. Daha sonra elde edilen özellik haritaları, bir boyutlu vektöre dönüştürülerek sınıflandırma yapılmıştır. [20], çeltik zararlılarının tespitinde, görüntünün segmentasyonu için GrabCut algoritması ve sınıflandırma işlemi için 8 katmandan oluşan bir evrşimsel sinir ağı modeli önermiştir. [21], AlexNet evrşimsel sinir ağına dayalı kullanılan evrşim çekirdeklerinin, böcek türlerinin sınıflandırma başarısı üzerindeki etkisini incelemiştir. [22], böcek türlerinin sınıflandırılması için böcek görüntülerini içeren bir veri seti önermiştir. Sınıflandırma için yalınlığı nedeniyle mobil uygulamalar için tasarlanmış olan MobileNet mimarisini kullanmıştır. [23], derin öğrenmeye dayalı büyük ölçekli çok sınıflı haşere tespiti ve sınıflandırması için PestNet adlı bölge tabanlı uçtan uca bir yaklaşım önermiştir. Çalışmada ilk olarak, her iki evrşimsel blok arasındaki kanal ve uzamsal bilgiyi geliştirmek için Kanal-Uzamsal Dikkat (CSA) modülünü sunulmuştur. İkinci olarak, görüntülerden çıkarılan özellik haritalarına dayalı olarak potansiyel haşere konum tespiti için bölge öneri ağı (RPN) önerilmiştir. Son olarak, sınıflandırma başarımını arttırmak için konum duyarlı skor haritası (Position-Sensitive Score Map -PSSM) modeli sunulmuştur. [24], haşere tanımlamasında, kullanılan derin ağların optimizasyonu için farklı Adam algoritmaları önermiştir. Bu çalışmada, ülkemizin ve dünyanın çeşitli yerlerinde görülen ve tarım ürünlerine zarar veren çekirge türlerinin erken tanı ve tespiti için 11 farklı çekirge türünü içeren (GrassHopper Classification Dataset-GHCD11) bir veri seti önerilmiştir. Bu veri setini oluşturan zararlı türleri ülkemizin Doğu ve Güneydoğu Anadolu bölgelerinde gözlemlenerek elde edilmiştir. Elde edilen görüntüler, ImageNet veri seti üzerinde eğitilmiş VGG16, VGG19, ResNet50, DenseNet121, EfficientNetB0, MobileNet derin öğrenme ağları, sunulan veri tabanı üzerinde öğrenme aktarımı (transfer learning) yapılarak çekirge türlerinin sınıflandırma başarısı üzerindeki etkileri gözlemlenmiştir. Önerilen veri seti çalışmanın en önemli katkılardan biridir. Bunun yanında, derin öğrenme tabanlı yöntemlerin ülkemizdeki bitki zararlısı çekirge türlerinin otomatik olarak sınıflandırılmasındaki başarımlarının gözlemlenmesi açısından, yapılan çalışma öncü niteliği taşımaktadır.

Çalışmanın devamı şu şekildedir; Bölüm 2'de, veri seti hakkında detaylı bilgi verilmiştir. Bölüm 3'te, kullanılan derin öğrenme mimarileri hakkında bilgi sunulmuştur. Bölüm 4'te deneysel sonuçlar verilmiştir ve son olarak Bölüm 5'te elde edilen sonuçlar tartışılmıştır.

2. Materyal

Bu bölümde çalışma kapsamında elde edilen *Acrida bicolor*, *Anacridium aegyptium*, *Calliptamus italicus*, *Dociostaurus maroccanus*, *Notostaurus anatolica*, *Oedipoda miniata miniata*, *Pyrgodera armata*, *Saga ephippigera*, *Schistocerca gregaria*, *Tettigonia caudata*, *Tettigonia viridissima* olmak üzere 11 farklı bitki zararlısı çekirge türü hakkında bilgiler sunulmuştur.

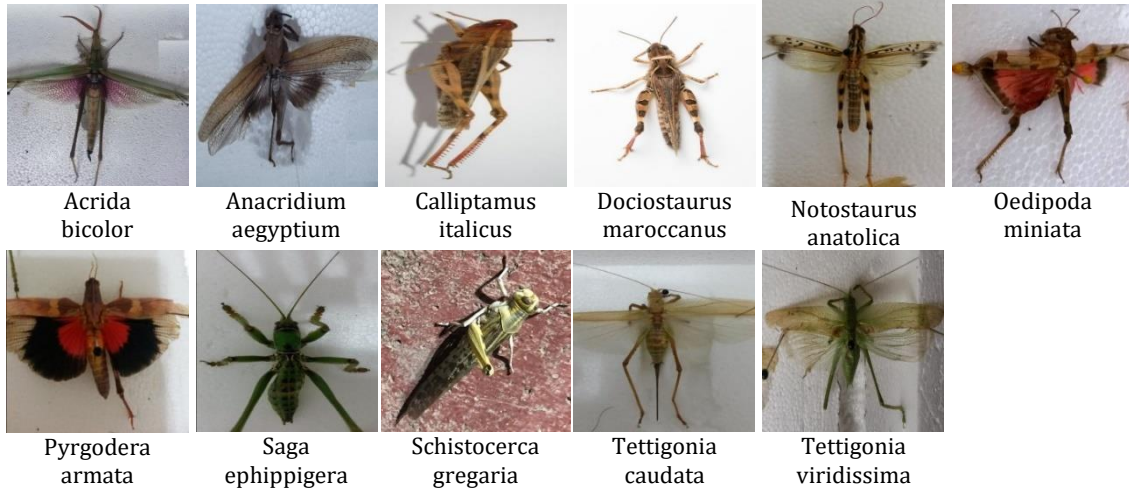
2.1 Veri Seti

Calliptamus italicus, sürü oluşturma özelliğine sahip olan ve Türkiye'nin birçok yerinde görülebilen bir türdür. Bitkisel ürünlere zarar veren bu tür, 2021 yılında Bingöl ili Adalı ilçesindeki birçok tarım arazisine zarar vermiş ve ekonomik kayıplara neden olmuştur [25]. *Dociostaurus maroccanus*, diğer bir adı ile Fas çekirgesi olarak bilinir. Bu tür bahçe ve meyve bahçeleri gibi alanlara zarar verebilir. Türkiye'nin birçok bölgesinde etkili olan bu tür, Bingöl ili kırsal alanları ve hububat tarlalarında ekonomik zarara neden olmuştur [25]. Mısır çekirgesi olarak bilinen *Anacridium aegyptium* türünün ekin alanlarında ekonomik kayıplara neden olduğu kaydedilmiştir. *A. aegyptium* önemli bir bitki zararlısı olmakla beraber, ülkemizin tahıl yetiştirilen alanlarında yaygın olarak görülebilmektedir. *Tettigonia viridissima* türleri çayır, mera ve tahıl alanlarında tespit edilmiş olup yerel olarak yaygın bir türdür. *Tettigonia caudata* türü omnivor olmasına rağmen özellikle pamuk ve yonca bitkilerine zarar verir. Bu tür, *T. viridissima* türü ile aynı cinse ve tipik benzerliklere sahiptir. *Truxalis robusta robusta*, Doğu ve Güneydoğu Anadolu bölgelerinde, özellikle ormanlık alanlarda ve pamuk bitkilerinin yoğun olduğu bölgelerde tespit edilmiştir. *Oedipoda miniata miniata*, en yaygın çekirge türlerinden biri olup, tarla ve bahçelerde kayda değer olmamakla beraber, zarar verdiği tespit edilmiştir. *Notostaurus anatolica*, nimf (instar) aşamasında toplanan belirli kanat ve bacak bantları ile tanınabilen ve vücut desenleri benzersiz olan bir türdür. *Schistocerca gregaria*, sürü oluşturma ve geniş alanlara yayılma yeteneğine sahip nadir çekirge türlerinden biridir. FAO verilerine göre 2020 yılında, Afrika kıtasında yer alan ülkelerde 20,2 milyon insanın açlıkla karşı karşıya kalmasına neden olmuştur [26]. Ciddi ekonomik kayıplara neden olur.

Pyrgodera armata, başının ve diğer vücut organlarının şekil ve rengi bakımından özgün özellikleri olan bir tür olup, zarar durumu tespit edilememiştir. Bu tür, Güneydoğu Anadolu Bölgesi Batman ili kırsal alanlarından toplanmıştır. *Saga ephippigera ephippigera* türü, etçil çekirge olarak bilinen yırtıcı bir çekirgedir. Doğu ve Güneydoğu Anadolu bölgeleri başta olmak üzere birçok yerde gözlemlenen etkili ve faydalı bir çekirge türüdür [27]. Şekil 1'de, 11 farklı çekirge türüne ait örnek görüntüler görülmektedir.

2.2 Veri Artırımı & Görüntü Yeniden Boyutlandırma

Başlangıçta, her bir çekirge türüne ait 32 adet görüntü bulunmaktadır. Elde edilen görüntüler daha sonra sınıflandırma performansına doğrudan etki edebileceğinden her tür için görüntüler elde edilirken farklı açılardan ve çekirgelerin farklı duruşlarından görüntülerin elde edilmesine özen gösterildi. Derin öğrenme mimarilerinin veri açıklığını karşılayabilmek için ise elde edilen görüntülere veri artırımı uygulandı. Veri artırımı yaparak sınıflandırma başarısını iyileştirmek, derin ağ mimarilerinin veri açıklığını gidermek ve aşırı uyumun önüne geçebilmek amacı ile, orijinal görüntülere döndürme, ölçekleme ve yansıtma gibi birtakım geometrik dönüşümler uygulanmıştır. Bu sayede veri setindeki görüntü sayısı 24 kat artırılmıştır. Nihayetinde her sınıf için 768 olmak üzere toplamda 8.448 çekirge görüntüsü elde edildi. Tablo 1 veri setimizin tür başına içerdiği görüntü sayısını gösterir. Farklı boyutlarda görüntüler içeren GHCD11 veri seti, derin ağ modelleri eğitilirken, işlem maliyetini düşürmek için 224×224 boyutuna ölçeklendirildi. Türler için görüntü sayıları Tablo 1'de sunulmuştur.



Şekil 1. On bir farklı çekirge türüne ait görüntü örnekleri

Tablo 1. GHCD11 veri setinin detaylı gösterimi

Tür Adı	G. Sayısı
Acrida bicolor	768
Anacridium aegyptium	768
Calliptamus italicus	768
Dociostaurus maroccanus	768
Notostaurus anatolica	768
Oedipoda miniata miniata	768
Pyrgoderma armata	768
Saga ephippigera	768
Schistocerca gregaria	768
Tettigonia caudata	768
Tettigonia viridissima	768

3. İlgili Çalışmalar


Bu bölümde çalışmada kullanılan VGG16, VGG19, ResNet50, DenseNet121, EfficientNetB0 ve MobileNet olmak üzere 6 farklı evrişimsel sinir ağı mimarileri hakkında bilgiler sunulmuştur.

3.1 VGG16 ve VGG19

VGG, 2014 yılında, Oxford üniversitesinden K. Simonyan ve A. Zisserman tarafından önerilen ve ILSVR-2014 yarışmasında, 1000 sınıftan oluşan 14 milyondan fazla görüntü ihtiva eden bir veri seti olan Imagenet üzerinde başarılı sonuç elde eden bir evrişimsel sinir ağı modelidir [28]. Model genel bir ifade ile AlexNet evrişimsel sinir ağı modeli üzerinde iyileştirmeler yapılarak oluşturulmuştur. Ağ giriş olarak 224×224 boyutlarına sahip olan girdiler alır. AlexNet’de, evrişim katmanlarında kullanılan büyük boyutlu filtreler (11×11 ve 5×5) birden fazla 3×3 boyutlu filtreler kullanır. Bu evrişimsel blokları, atlama değeri 2 olan 2×2 ’lik bir maksimum havuzlama işlemi takip etmektedir. Tüm mimari boyunca tutarlı bir şekilde bu evrişim ve maksimum havuzlama katmanları düzenlenmesi takip edilir. Mimari 2 adet tam bağlı katman ve bunu takip eden bir Softmax katmanı ile son bulur. Oldukça büyük bir ağ olan VGG16 mimarisi yaklaşık 138 milyon parametreye sahiptir. VGG19 mimarisi VGG16 mimarisine benzemekle birlikte fazladan 3 evrişimsel katman içerir ve yaklaşık 143 milyon parametreye sahiptir [29].

3.2 ResNet50

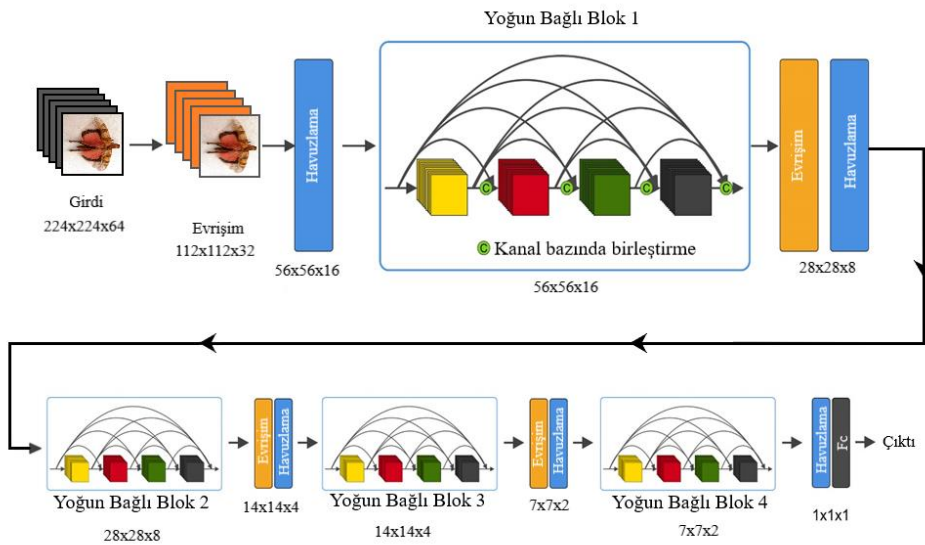
[30], tarafından 2015 yılında önerilen yenilikçi bir sinir ağı modelidir. Temel olarak VGG ağı mimarisinden esinlenmesine rağmen, ResNet ağlarını güçlü ve popüler kılan esas neden, derin öğrenme mimarilerinin temel problemlerinden biri olan derinliğin artması ile meydana gelen eğimin kaybolması problemine karşı getirdiği çözümdür. Bunun için ResNet mimarileri artık blok olarak adlandırılan bloklar kullanır. Ağ derinliği arttırıldığında üst katmanlardaki evrişimsel bloklar belirli periyotlarla alt katmanlardaki evrişim bloklarının çıktılarına bağlanarak eğimin kaybolması probleminin önüne geçer [30]. 224×224 boyutunda girdi görüntüleri alan ağ, yaklaşık 25 Milyon parametreden oluşur. VGG mimarisine göre daha az eğitilebilir parametreye sahip olan bu mimari, gösterdiği yüksek performans nedeniyle, yaygın olarak tercih edilmektedir. Şekil 2’te ResNet 50 mimarisi görülmektedir.



Şekil 2. ResNet50 mimarisi

3.3 DenseNet121


Huang ve arkadaşları tarafından önerilen DenseNet modeli girdi olarak 224×224 boyutunda görüntüler alır ve yaklaşık olarak eğitilebilir parametre sayısı 7 milyondur. DenseNet121, eğimin kaybolması probleminin üstesinden gelebilmekte bu sayede yeterli derinlikte ağların oluşturulmasına imkân vermekle beraber, ağı diğer ağlara nispeten daha az parametreye sahip olması ağı hızlı olmasını sağlar. Bu mimaride kullanılan her katman kendinden sonraki bütün katmanlara ileri beslemeli bir biçimde bağlar. Bu da demek oluyor ki, her katman için, kendinden önceki tüm katmanların özellik haritaları girdi olarak kullanılır ve her katmanın kendi özellik haritaları, kendinden sonraki katmanlar için girdi olarak kullanılır. Genel olarak ResNet mimarisine benzer bir yapı kullanmak ile beraber, DenseNet mimarisinde bir katmandan çıkan öznelikler alt katmanların tümüne girdi olarak verilir [31]. Şekil 3’te DenseNet Mimarisinin yapısı görülmektedir.



Şekil 3. DenseNet mimarisi

3.4 EfficientNetB0

Derin öğrenme mimarilerinin yaygınlaşması ile derin öğrenme ağlarının karmaşıklığı arttıkça başarımların yükseldiği görüldü. Fakat işlem maliyetleri de buna paralel olarak artıyordu. Bu problemi çözmek için son yıllarda başarımları yüksek fakat daha küçük ölçekli ağ modelleri üretmek için çalışılmaktadır. EfficientNet, bu ihtiyacı karşılamak amacı ile Google araştırma ekibinde Tan ve Le tarafından 2019 yılında, ortaya atılmıştır. Yazarlar yaptıkları incelemelerde ağın sadece derinliği, genişliği ya da çözünürlüğünü düşürmek yerine derinlik, genişlik ve çözünürlüğü belirli ölçek dahilinde birlikte küçültmenin, ağın başarımları üzerine olumlu etkileri olduğunu gözlemlemiştir. Yaptıkları gözlem neticesinde, ağın derinlik, genişlik ve çözünürlüğünü eşit olarak artırıp azaltılabilen yeni bir ölçeklendirme metodu geliştirmişlerdir. EfficientNet, B0 ile başlayıp B7'ye kadar giden, 8 farklı modelden oluşmaktadır ve model büyüdükçe kullanılan parametre sayısı artmakla birlikte, başarımları oranı da artmaktadır. Çalışmaya göre, başlangıçta temel model olan ve yaklaşık 11 Milyon eğitilebilir parametreye sahip olan EfficientNetB0 modeli oluşturulur. Daha sonra model boyutunu artırmak ve doğruluk değerini yükseltmek için temel model, bileşik ölçeklendirme yardımıyla EfficientNet-B1'den, EfficientNetB7'ye kadar genişletilebilir [32]. EfficientNet'i öne çıkaran bir diğer husus ise MBCONV katmanıdır. Kanalları önce ezip sonra genişleten ve bu sayede atlama bağlantıları ile zengin kanal katmanları birbirine bağlayan ResNet bloklarının aksine MBCONV blokları önce kanalları genişleten sonra sıkıştıran, bu sayede hesaplama miktarını azaltan bir yapıya sahiptir. Şekil 4'te, EfficientNetB0 mimarisinin yapısı görülmektedir.



Şekil 4. Efficient-B0mimarisi

3.5 MobileNet

MobileNet Andrew ve arkadaşları tarafından önerilmiş, mobil cihaz uygulamaları için uyumlu, küçük boyutlu, hızlı ve basit bir derin evrışimsel sinir ağı modelidir [33]. Normal evrışimsel bloklar yerine derinlemesine ayrıştırılabilir evrışimsel bloklar kullanılır. Derinlemesine ayrılabilir bir evrişim, derinlemesine evrişim ve noktasal evrişim olmak üzere iki işlemde meydana gelir. Derinlemesine ayrıştırılabilir evrişimlerde her girdi katmanına bir filtre uygulanır ve daha sonra nokta bazlı evrişimde, 1×1 evrişimler kullanılarak derinlik bazlı katmanlardan gelen çıktının doğrusal kombinasyonu oluşturulur. Derinlemesine ayrıştırılabilir evrişim blokları MobileNet'in performansının ana omurgasını oluşturur. Örneğin 3×3 'lük bir normal evrişimsel blok yerine 3×3 boyutunda derin bir evrişimsel blok kullanıldığında, hesaplama süresi yaklaşık 8-9 kat düşer.


4. Deneysel Sonuçlar

Bu çalışmada, 11 farklı bitki zararlısı çekirge türü içeren GHCD11 veri seti üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Bu amaçla, VGG16, VGG19, ResNet50, DenseNet121, EfficientNetB0 ve MobileNet olmak üzere 6 farklı evrışimsel sinir ağı mimarisi kullanılmıştır. Çalışma Google Colab üzerinde gerçekleştirilmiştir. Kullanılan VGG16, VGG19, ResNet50, DenseNet121, EfficientNet-B0 ve MobileNet mimarilerinin kodlamaları Python dilinde ve Keras kütüphaneleri kullanılarak yapılmıştır. Çalışmada, veri setine ait görüntüler öncelikle 224×224 boyutuna indirildi ve daha sonra veri seti sırası ile %60, %20, %20 oranında; eğitim (train), doğrulama (validation) ve test olarak ayrılmıştır. Kullanılan ağların tamamı, daha önce 'ImageNet' görüntüleri üzerinde eğitilmiş evrişimsel sinir ağlarıdır. Eğitim süreci Öğrenim Aktarımı (Transfer Learning) ile gerçekleştirilmiştir. Eğitim sürecinde optimizasyon olarak Adam Optimizasyonu, loss fonksiyonu olarak ise çapraz entropi kullanılmıştır. Eğitim süreci her CNN için 5 çağ boyunca sürdürülmüş olup, eğitim sürecinde kullanılan

parametreler Tablo 2’de gösterilmiştir. Kullanılan ağ mimarilerinin performansları doğruluk metriği kullanılarak değerlendirilmiştir. Doğruluk metriğinin nasıl hesaplandığı Denklem (1)’de gösterilmiştir.

$$accuracy = \frac{1}{p} \sum_{i=1}^p \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i} \quad (1)$$

Burada Denklem 1’de, TP gerçek pozitiflerin sayısını; TN, gerçek negatiflerin sayısını; FP, yanlış pozitiflerin sayısını; FN, yanlış negatiflerin sayısını ve p, sınıfların sayısını temsil etmektedir.



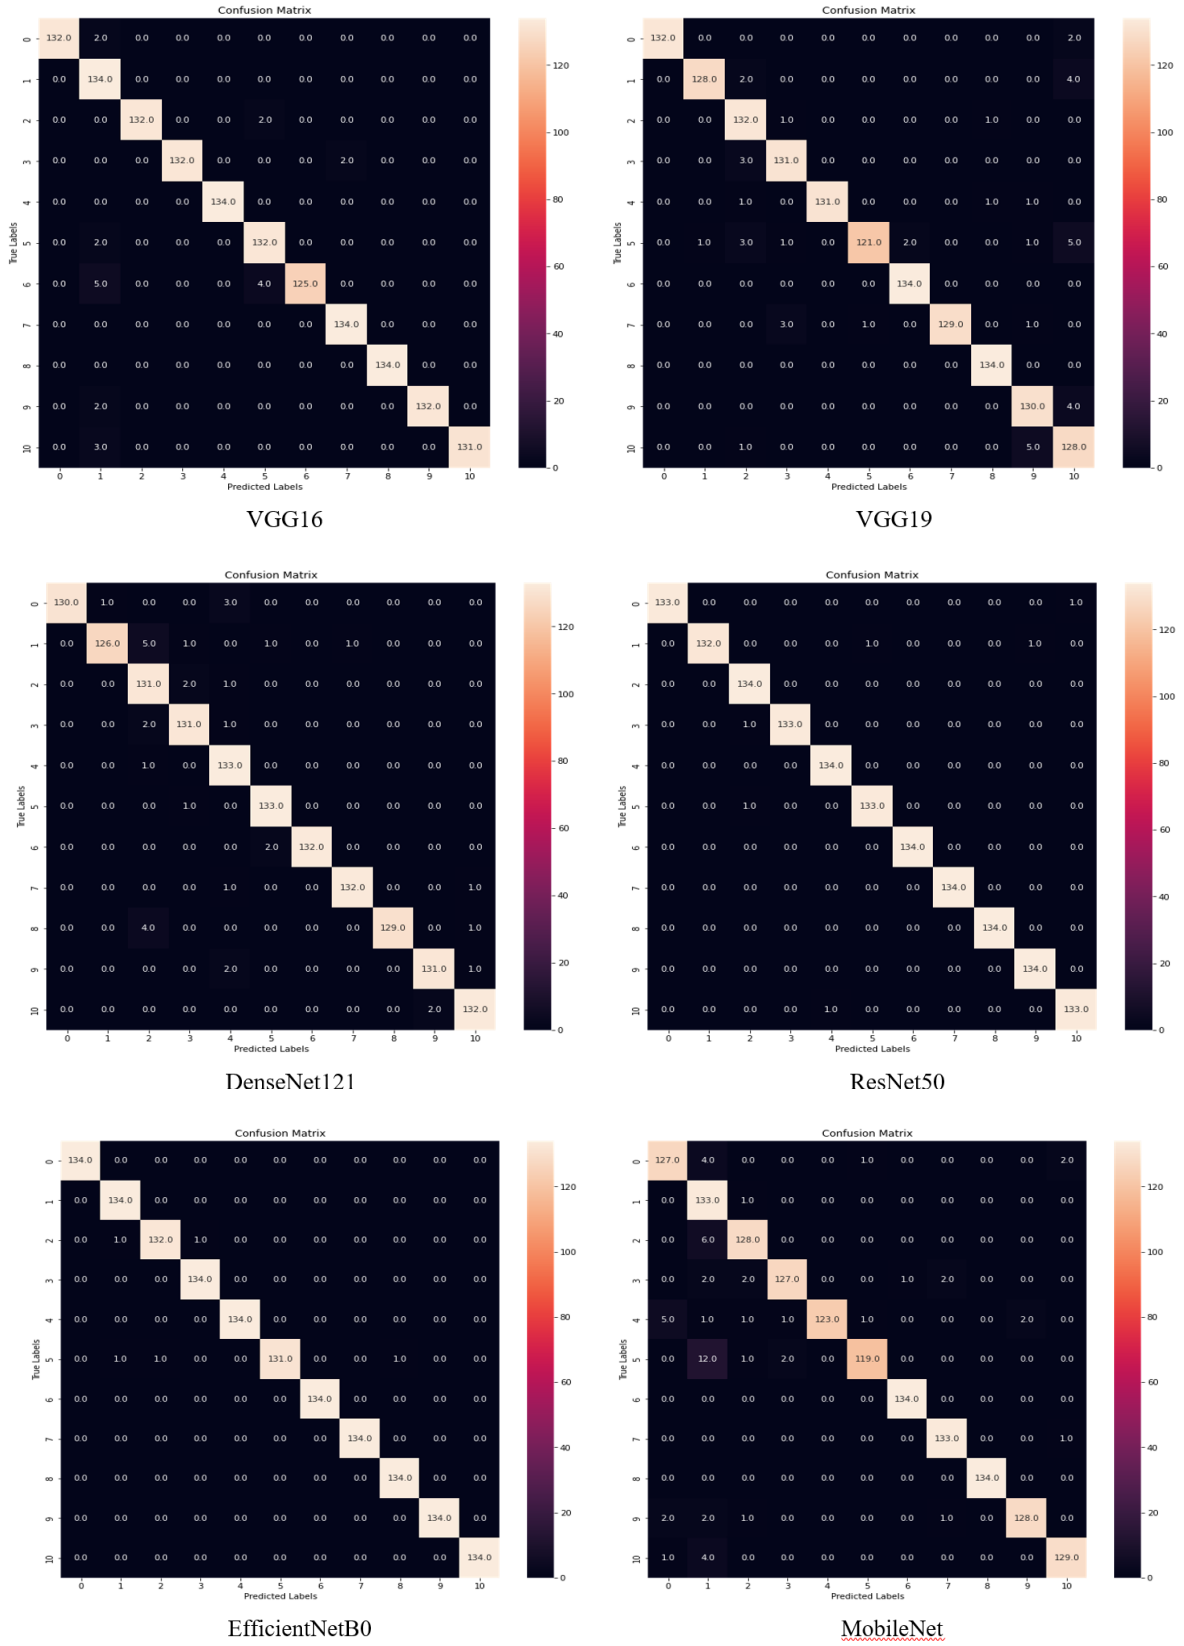
Şekil 5. Kullanılan CNN Mimarilerine ait doğruluk sonuçları

Eğitilmiş ağlar test verisi üzerinde uygulanarak, sınıflandırma başarıları elde edilmiştir. Ağların başarıları 1.474 test görüntüsü üzerinde sınanmış olup yapılan sınıflandırma sonucu en yüksek doğruluk değerini %99.661 ile EfficientNetB0 mimarisi ve en düşük doğruluk değerini %95.997 ile MobileNet mimarisinin verdiği gözlemlendi. Ayrıca, modellerin performanslarını değerlendirmek için karşıtlık matrislerinden (confusion matrix) faydalanılmıştır. Her bir CNN mimarisi için elde edilen karşıtlık matrisleri Şekil 9’da verilmiştir. Kullanılan tüm CNN mimarileri için elde edilen doğruluk değerleri Şekil 5’te verilmiştir.

Tablo 2. Mimarilerde kullanılan temel eğitim parametreleri.

CNN Modeli	Giriş Boyutu	Mini Batch Size	Öğrenme Oranı
VGG16	224×224×3	32	0.001
VGG19	224×224×3	32	0.001
ResNet50	224×224×3	32	0.001
DenseNet121	224×224×3	32	0.001
EfficientNetB0	224×224×3	32	0.001
MobileNet	224×224×3	32	0.001

Evrimsel Sınır Ağı Mimarileri ve Öğrenim Aktarma ile Bitki Zararlısı Çekirge Türlerinin Sınıflandırması



Şekil 6. Kullanılan CNN mimarilerine ait karşıtlık matrisleri

VGG16, VGG19, ResNet50, DenseNet121, EfficientNetB0 ve MobileNet CNN mimarileri GHCD11 veri seti üzerinde sırası ile %98.507, %97.015, %99.593, %97.693, %99.661, %95.997 sınıflandırma doğruluğu elde etmişlerdir. Bununla birlikte, karışıklık matrisi incelendiğinde, VGG19 ve MobileNet CNN mimarilerinin en çok “Oedipoda miniata miniata” türünü yanlış sınıflandırdığı gözlemlenmiştir. VGG16 mimarisinin “Pyrgodera armata” türünü DenseNet121 mimarisinin ise en çok “Anacridium aegyptium” türünü yanlış sınıflandırdığı gözlemlenmiştir. Yine karmaşıklık matrisinden, “Oedipoda miniata miniata”, “Pyrgodera armata” ve “Anacridium aegyptium” türlerindeki yanlış sınıflandırmanın tek bir türü içermeyip türler arasında dağılım göstermesi, bu ağların çekirge türlerine ait anahtar öznelikleri çıkarmada yeterince başarılı olamadığı düşüncesini doğursa da gerek eğitimin çağının kısa tutulması gerekse veri setinin ağların veri ihtiyacını karşılayacak boyutlara ulaşmamış olma ihtimallerinden ötürü kesin yargıda bulunmak için erken olduğu düşünülmektedir. Nispeten daha başarılı performans veren ResNet50 ve EfficientNetB0 CNN mimarilerinin her ikisinin de; “Notostaurus anatolica”, “Pyrgodera armata”, “Saga ephippigera”, “Schistocerca gregaria”, “Tettigonia caudata” türlerine ait görüntülerin tamamını doğru sınıflandırdığı gözlemlenmiştir. Bu, kısa çağlarda yapılan ağ eğitimleri ve yeterince büyük olmayan veri setlerinde dahi ResNet50 ve EfficientNetB0 ağlarının anahtar öznelikleri elde etmede, çalışmada kullanılan diğer ağlara göre daha başarılı olabileceği düşüncesini oluşturmaktadır. Ayrıca, “Saga ephippigera” türü, DenseNet121 hariç tamamında %100 doğrulukla sınıflandırılmıştır. Bu durumun nedeni, “Saga ephippigera” türünün, diğer türlere göre daha fazla ayırt edici özelliklerinin bulunmasıdır.

5. Sonuçlar

Çekirgeler, dünya çapında yıkıma neden olan küresel zararlılardır. Her yıl milyarlarca dolarlık mahsulü mahvediyorlar ve milyonlarca insan için kitlesel açlığa neden olma potansiyeline sahiptirler. Bu nedenle bitki zararlısı çekirge türlerinin otomatik tespit ve sınıflandırılması oldukça önemlidir. Bu çalışmada, öncelikle ülkemizin özellikle Doğu ve Güneydoğu Anadolu bölgelerinde görülen 11 farklı bitki zararlısı çekirge türüne ait GHCD11 adında yeni bir veri seti oluşturulmuştur. Bu veri seti çalışmanın en büyük yeniliğini oluşturmaktadır. Bunun yanında, çalışmada 11 farklı bitki zararlısı çekirge türünün otomatik olarak sınıflandırılması için görüntü sınıflandırmasında yaygın olarak kullanılan VGG16, VGG19, ResNet50, DenseNet121, EfficientNet ve MobileNet olmak üzere 6 farklı evrimsel sinir ağı modelleri kullanılmıştır. Öğrenme aktarımı yöntemi ile GHCD11 veri seti üzerinde, yukarıda bahsedilen mimariler kullanılarak yapılan sınıflandırma neticesinde; elde edilen sonuçların %95 ve %99 aralığında kayda değer sonuçlar elde ettiği gözlemlenmiştir. EfficientNetB0’ın en yüksek sınıflandırma başarısı gösterdiği gözlemlenmiştir. Bu durumun şu sebeplerden kaynaklanmış olabileceği düşünülmektedir. Birincisi EfficientNet’i diğer ağlardan ayıran ve parametre sayısını düşürürken performans kayıplarının önüne geçmesini sağlayan ve EfficientNet’in temel yapıtaşı olan MbConv katmanlarının sınıflandırma başarımını arttırmış olabileceğidir. İkincisi, yine EfficientNet’i diğer ağlardan ayıran ve ağı derinlemesine ve genişlemesine olarak belirli bir ölçekte arttırarak ilerlemesinin, GHCD11 veri setinde sınıflandırma başarımını arttırmış olabileceğidir. Üçüncü ve son olarak ise EfficientNet’in Transfer Learning için diğer ağ mimarilerine kıyasla daha uygun bir model olma durumudur. Bu bağlamda daha kesin bilgi için GHCD11 veri seti üzerinde ağların sıfırdan eğitilerek ve yine ağların fine-tune edilerek elde edilecek sonuçların mevcut sonuçlarımız ile yeniden sentezlenmesine ihtiyaç duyulmaktadır.

Sunulan yeni veri seti üzerinde, öğrenme aktarımı ile birlikte eğitilen ağların başarımının tatmin edici düzeyde olduğu düşünülmektedir. Ağ mimarilerinin yakınsama hızları göz önüne alındığında EfficientNetB0 ve ResNet50 ağlarının eğitim sürecinde daha hızlı yakınsadığı gözlemlenmiştir. Bununla birlikte gerek öğrenme aktarımı uygulanırken öğrenilebilen parametrelerin bloke edilmesi gerekse kullanılan çağ sayısının, 5 çağ ile sınırlı tutulması gibi nedenlerden dolayı, ağların yakınsama başarımları hakkında kesin bir şeyler söylemenin güç olduğu düşünülmektedir. Elde edilen sınıflandırma doğruluğunun sınıf sayısının azlığından olabileceği düşünülmekte ve sınıf sayısının ileriki çalışmalar için artırılması planlanmaktadır. Yine ağ mimarilerinin gerçek performansının daha net değerlendirilebilmesi için çevresel gürültünün olduğu dış ortam görüntüleri ile ağların eğitilmesi planlanmaktadır. Mevcut ağlara alternatif, hızlı yakınsama ve yüksek doğruluk performanslarına sahip yeni bir mimari model tasarlanması planlanmaktadır.

Çıkar Çatışmasının Beyanı

Bu çalışmada herhangi bir çıkar çatışması yoktur.

Kısaltmalar

CNN: Evrişimsel Sinir Ağı.

Kaynaklar

- [1] E. Ayan, H. Erbay, and F. Varçın, "Crop pest classification with a genetic algorithm-based weighted ensemble of deep convolutional neural networks," *Comput. Electron. Agric.*, vol. 179, Dec. 2020, doi: 10.1016/j.compag.2020.105809.
- [2] P. Gullan, P., Cranston, *The insects: an outline of entomology.*, vol. 21, no. 9. 2014.
- [3] L. Zhang, M. Lecoq, A. Latchininsky, and D. Hunter, "Locust and Grasshopper Management," 2018, doi: 10.1146/annurev-ento-011118.
- [4] C. Xie et al., "Multi-level learning features for automatic classification of field crop pests," *Comput. Electron. Agric.*, vol. 152, no. October 2016, pp. 233–241, 2018, doi: 10.1016/j.compag.2018.07.014.
- [5] M. Martineau, D. Conte, R. Raveaux, I. Arnault, D. Munier, and G. Venturini, "A survey on image-based insect classification," *Pattern Recognit.*, vol. 65, pp. 273–284, 2017, doi: 10.1016/j.patcog.2016.12.020.
- [6] N. Larios et al., "Automated insect identification through concatenated histograms of local appearance features: Feature vector generation and region detection for deformable objects," *Mach. Vis. Appl.*, vol. 19, no. 2, pp. 105–123, 2008, doi: 10.1007/s00138-007-0086-y.
- [7] S. R. Huddar, S. Gowri, K. Keerthana, S. Vasanthi, and S. R. Rupanagudi, "Novel algorithm for segmentation and automatic identification of pests on plants using image processing," 2012 3rd Int. Conf. Comput. Commun. Netw. Technol. ICCCNT 2012, no. July, 2012, doi: 10.1109/ICCCNT.2012.6396012.
- [8] A. Siva Sangari and D. Saraswady, "Analyzing the optimal performance of pest image segmentation using non linear objective assessments," *Int. J. Electr. Comput. Eng.*, vol. 6, no. 6, pp. 2789–2796, 2016, doi: 10.11591/ijece.v6i6.11564.
- [9] J. Zhao, M. Liu, and M. Yao, "Study on image recognition of insect pest of sugarcane cotton aphid based on rough set and fuzzy C-means clustering," 3rd Int. Symp. Intell. Inf. Technol. Appl. IITA 2009, vol. 2, pp. 553–555, 2009, doi: 10.1109/IITA.2009.295.
- [10] P. J. D. Weeks, M. A. O'Neill, K. J. Gaston, and I. D. Gauld, "Species-identification of wasps using principal component associative memories," *Image Vis. Comput.*, vol. 17, no. 12, pp. 861–866, 1999, doi: 10.1016/S0262-8856(98)00161-9.
- [11] M. T. Do, J. M. Harp, and K. C. Norris, "A test of a pattern recognition system for identification of spiders," *Bull. Entomol. Res.*, vol. 89, no. 3, pp. 217–224, 1999, doi: 10.1017/s0007485399000334.
- [12] L. Q. Zhu and Z. Zhang, "Auto-classification of insect images based on color histogram and GLCM," *Proc. - 2010 7th Int. Conf. Fuzzy Syst. Knowl. Discov. FSKD 2010*, vol. 6, no. Fskd, pp. 2589–2593, 2010, doi: 10.1109/FSKD.2010.5569848.
- [13] X. Cheng, Y. Zhang, Y. Chen, Y. Wu, and Y. Yue, "Pest identification via deep residual learning in complex background," *Comput. Electron. Agric.*, vol. 141, pp. 351–356, 2017, doi: 10.1016/j.compag.2017.08.005.
- [14] H. M. Ünver and E. Ayan, "Skin lesion segmentation in dermoscopic images with combination of yolo and grabcut algorithm," *Diagnostics*, vol. 9, no. 3, 2019, doi: 10.3390/diagnostics9030072.
- [15] Q. Zu, B. Hu, N. Gu, and S. Seng, "Human Centered Computing: First International Conference, HCC 2014 Phnom Penh, Cambodia, November 27-29, 2014 Revised Selected Papers," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 8944, no. 18, pp. 812–820, 2015, doi: 10.1007/978-3-319-15554-8.
- [16] Z. Q. Zhao, P. Zheng, S. T. Xu, and X. Wu, "Object Detection with Deep Learning: A Review," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 30, no. 11, pp. 3212–3232, 2019, doi: 10.1109/TNNLS.2018.2876865.

- [17] Y. Zhang, J. M. Gorriz, and Z. Dong, "Deep learning in medical image analysis," *J. Imaging*, vol. 7, no. 4, p. NA, 2021, doi: 10.3390/jimaging7040074.
- [18] N. Şahin, N. Alpaslan, and D. Hanbay, "Robust optimization of SegNet hyperparameters for skin lesion segmentation," *Multimed. Tools Appl.*, vol. 81, no. 25, pp. 36031–36051, 2022, doi: 10.1007/s11042-021-11032-6.
- [19] D. Xia, P. Chen, B. Wang, J. Zhang, and C. Xie, "Insect detection and classification based on an improved convolutional neural network," *Sensors (Switzerland)*, vol. 18, no. 12, pp. 1–12, 2018, doi: 10.3390/s18124169.
- [20] Z. Liu, J. Gao, G. Yang, H. Zhang, and Y. He, "Localization and Classification of Paddy Field Pests using a Saliency Map and Deep Convolutional Neural Network," *Sci. Rep.*, vol. 6, no. June 2015, pp. 1–12, 2016, doi: 10.1038/srep20410.
- [21] S. Lim, S. Kim, and D. Kim, "Performance effect analysis for insect classification using convolutional neural network," *Proc. - 7th IEEE Int. Conf. Control Syst. Comput. Eng. ICCSCE 2017*, vol. 2017-Novem, no. November, pp. 210–215, 2018, doi: 10.1109/ICCSCE.2017.8284406.
- [22] F. Visalli, T. Bonacci, and N. A. Borghese, "Insects Image Classification Through Deep Convolutional Neural Networks," *Smart Innov. Syst. Technol.*, vol. 184, pp. 217–228, 2021, doi: 10.1007/978-981-15-5093-5_21.
- [23] L. Liu et al., "PestNet: An End-to-End Deep Learning Approach for Large-Scale Multi-Class Pest Detection and Classification," *IEEE Access*, vol. 7, pp. 45301–45312, 2019, doi: 10.1109/ACCESS.2019.2909522.
- [24] L. Nanni, A. Manfè, G. Maguolo, A. Lumini, and S. Brahmam, "High performing ensemble of convolutional neural networks for insect pest image detection," *Ecol. Inform.*, vol. 67, 2022, doi: 10.1016/j.ecoinf.2021.101515.
- [25] M. İlçin and Ş. Çelik, "Statistical Evaluation of Damage Status of Important Grasshopper Family in Plants," *Quest Journals J. Res. Agric. Anim. Sci.*, vol. 8, no. 2, pp. 2321–9459, 2021.
- [26] "2020 | FAO | Food and Agriculture Organization of the United Nations." [Online]. Available: https://www.fao.org/news/archive/news-by-date/2020/en/?page=3&ipp=10&tx_dynalist_pi1%5Bpar%5D=YToxOntzOjE6IkwiO3M6MToiMCI7fQ%3D%3D. [Accessed: 06-Nov-2022].
- [27] M. İlçin, "Investigation of Orthoptera: Insecta Fauna of Useful, Harmful and Predator Species in the Batman Region (Turkey)," *Sci. Stay. True Here" Biol. Chem. Res.*, vol. 6, pp. 30–40, 2019.
- [28] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, 2015.
- [29] G. A. Shadeed, M. A. Tawfeeq, and S. M. Mahmoud, "Automatic medical images segmentation based on deep learning networks," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 870, no. 1, 2020, doi: 10.1088/1757-899X/870/1/012117.
- [30] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [31] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 2261–2269, 2017, doi: 10.1109/CVPR.2017.243.
- [32] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
- [33] A. G. Howard et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017.