



Süleyman Demirel Üniversitesi

YEKARUM e-DERGI

(Journal of YEKARUM)



Cilt 8 , Sayı 2 , 67-79 , 2023
E - ISSN:1309-9388

Tarımda Böcek Zararlılarının Derin Öğrenme Yöntemleri ile Tespit Edilmesi

Fatmanur ATEŞ^{1*}, Ramazan ŞENOL²

^{1*} Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Elektrik – Elektronik Mühendisliği Bölümü, Isparta, Türkiye, (ORCID: 0000-0001-5465-2483), fatmanurates@isparta.edu.tr

² Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Elektrik – Elektronik Mühendisliği Bölümü, Isparta, Türkiye (ORCID: 0000-0002-7078-3229), ramazansenol@isparta.edu.tr

(İlk Geliş Tarihi 10/11/2023 ve Kabul Tarihi 30/11/2023)

ÖZET:

Dünya genelinde gün geçtikçe insan nüfusu artış göstermektedir ve nüfusun artması ile tarım ürünlerine olan ihtiyaçta artmaktadır. Tarım alanları da nüfusun artması sebebiyle barınma gibi farklı amaçlarla kullanılmak zorunda kaldığından azalış göstermektedir. Ayrıca geçmişten günümüze bakıldığında tarımcılıkla uğraşan insan sayısında da azalma olduğu görülmektedir. Tüm bu sebepler mevcutta bulunan tarım arazilerinden elde edilebilecek ürün veriminin maksimum düzeyde olması gerektiğinin önemini gözler önüne sermektedir. Tarım alanları çeşitli sebeplerden ötürü zarar görebilmektedir ve elde edilecek mahsulün veya mahsullerin verimleri düşebilmektedir. Tarım alanlarında çıkabilecek yangınlar, ekim olacak bölge için yanlış ürün seçimi, yanlış ilaçlama, hasat zamanının geçirilmesi, yanlış gübreleme vb. gibi tarım alanlarından ürün hasadını engelleyen veya ürün hasadını aza indiren hatalara örnek olarak verilebilir. Tarım alanlarındaki bitkilere zarar veren ve elde edilecek mahsulün verimini düşüren etkenlerden biri tarım zararlısı olan böcek türleridir. Tarım ürünlerinden maksimum verimin elde edilebilmesi için tarımda böcek zararlılarının ya ortadan kaldırılması ya da zararının en aza indirgenmesi gerekmektedir. Tarımda böcek zararlılarının mahsule verdiği zararı minimuma indirebilecek için kimyasal ve biyolojik yöntemler kullanılmaktadır. Tarımda zararlı böceklerin türünün tespit edilebilmesi durumunda doğru biyolojik ya da kimyasal yöntem uygulanabilir. Bu çalışmada Kaggle açık veri platformundan alınmış olan “Dangerous Farm Insects” veri seti kullanılmıştır. Veri seti içerisinde 15 farklı türe ait böcek zararlısından alınmış görüntüler bulunmaktadır. Farklı türlere ait görüntüler etiketlenerek derin öğrenme mimarilerinden, Inception_v3, ResNet50d ve Res2Net50d modelleri ile sınıflandırılmıştır. Sonuçlar farklı performans değerlendirme metriklerinden doğruluk ve kayıp değeri kullanılarak verilmiştir. Ayrıca modellerin tahmin başarıları, karmaşıklık matrisleri verilerek sonuçlar yorumlanmıştır.

Anahtar Kelimeler: Tarım, böcek zararlıları, derin öğrenme, sınıflandırma

Detection of Insect Pests in Agriculture with Deep Learning Methods

ABSTRACT

The human population is increasing day by day throughout the world, and with the increase in population, the need for agricultural products also increases. Agricultural areas are also decreasing as they have to be used for different

purposes such as shelter due to the increase in population. In addition, when we look at the past and present, it can be seen that there is a decrease in the number of people engaged in agriculture. All these reasons reveal the importance of ensuring that the product yield that can be obtained from existing agricultural lands should be at the maximum level. Agricultural areas may be damaged for various reasons and the yield of the crop or crops may decrease. Fires that may occur in agricultural areas, wrong product selection for the area to be planted, wrong pesticide application, harvest time delay, wrong fertilization, etc. These can be given as examples of errors that prevent or reduce the harvest of crops in agricultural areas. One of the factors that damage plants in agricultural areas and reduce the yield of the crop is insect species that are agricultural pests. In order to obtain maximum efficiency from agricultural products, insect pests in agriculture must be either eliminated or their damage minimized. In agriculture, chemical and biological methods are used to minimize the damage caused by insect pests to the crop. If the type of harmful insects in agriculture can be determined, the correct biological or chemical method can be applied. In this study, the "Dangerous Farm Insects" dataset taken from the Kaggle open data platform was used. The data set includes images taken from 15 different species of insect pests. Images of different types were labeled and classified with Inception_v3, ResNest50d and Res2Net50d models from deep learning architectures. The results are given using accuracy and loss value from different performance evaluation metrics. In addition, the prediction success of the models and the complexity matrices were given and the results were interpreted.

Keywords: *Agriculture, insect pests, deep learning, classification*

1. GİRİŞ

Dünya üzerinde tarım ürünlerine olan talep nüfusun artması ve tarım alanlarının da azalmasıyla orantılı olarak artış göstermektedir. Mevcut tarım arazilerinden yüksek verimde mahsulün elde edilmesi günümüzde odaklanılan konulardandır. Mahsullerden elde edilebilecek verimi artıran en önemli etkenlerden biri öncelikle bitkinin sağlıklı olmasıdır. Sağlıksız olan bitkiler ya zamanla ölür ya da elde edilecek verimin düşmesine sebep olabilir.

Bitkilerin sağlık durumlarını etkileyen pek çok etken vardır. Bunlardan biri dünyada değişen iklim koşullarıdır. Sıcaklıkların artması ekstrem yağışlara sebep olabildiğinden ve atmosferin nem oranının artmasına sebep olabildiğinden, uzun periyotta bitkilerde farklı hastalık türlerinin gelişmesine sebep olmaktadır. Ayrıca oluşan kuraklıklar bitkilerde yaprak biti ile taşınan virüslerin artmasına sebep olmaktadır. Diğer yandan karbondioksit oranının çok fazla artış göstermesi bitkilerdeki hastalığın şiddetini artırabilir [1]. Tarım alanında Dünya genelinde üretimde oluşan kayıpların yaklaşık olarak %11'inin tarım zararlılarından kaynaklandığı ifade edilmiştir [2]. Tarımda verimin artırılabilmesi, ayrıca bitki türlerinin de korunabilmesi amacıyla önlemler alınması önem arz eder.

Tarımda zararlılara karşı mücadele yöntemleri değişkenlik göstermektedir. Bunlara; kültürel mücadele yöntemleri (temiz tohum ve fide kullanmak, sık dikim yapmamak, dengeli sulama yapmak vb.), fiziksel mücadele yöntemleri (radyasyon uygulama, su altında bırakma), mekaniksel mücadele yöntemleri (ezme, toplama vb.), uzaklaştırıcılar kullanma, tuzak bitkiler kullanma, ses ve ışık gibi fiziksel etkileyiciler kullanma, su ve besin gibi tuzaklar kullanma, biyolojik mücadele, kimyasal mücadele gibi yöntemler örnek olarak verilebilir [3].

Tarımda zararlılarla mücadele işlemi gerçekleştirilmeden önce zararlıların zamanında tespit edilebilmesi önemlidir. Zararlıların zamanında tespit edilmesi ve gereken önlemin alınması bitki hastalıklarının önüne geçilmesinde önemli olabilir. Ancak zararlı türleri çok çeşitlidir, türlerin doğru tespiti uzman bilgisi gerektirir ve zaman alıcı bir süreçtir. Bu sebeple oluşabilecek hataların önüne geçilmesinde bilgisayar destekli görüntü tespit tanıma yöntemleri uygulanmaya başlanmış yöntemlerdendir [4].

Rustia vd., yapışkanlı kâğıt tuzağı görüntüleri üzerindeki küçük boyutlu sera böcek zararlılarının çok sınıflı olarak tanınması için evrişimsel sinir ağı (CNN) temelli yöntem önermişlerdir. Seralarda yapmış oldukları deneylerde F-puanlarının 0.92 ve 0.91 olarak elde edildiğini ifade etmişlerdir [5]. Malathi ve Gopinath, çeltik mahsulünde bulunan on çeşit zararlıyı tanımak için derin evrişimli sinir ağlarını (DCNN) kullanmışlardır. Transfer öğrenme destekli ResNet-50 modelinin diğer uyguladıkları modellerden % 95.012 oranıyla daha iyi doğruluk elde ettiğini ifade etmişlerdir [6]. Ebrahimi vd., çilek bitkilerinde bulunabilecek parazitleri tespit etmek için destek vektör makineleri (SVM) temelli yöntem kullanmışlardır. Sonuçta % 2.25'ten daha az hata yüzdesi ile tespit yapabildiklerini ifade etmişlerdir [7]. Kasinathan vd., 24 böcek sınıfı üzerinde böcek tespit algoritması sunmuşlardır. CNN modeli kullanılarak 9 ve 24 sınıftan oluşan böcekler için sırasıyla %91,5 ve %90 ile yüksek sınıflandırma oranına ulaştıklarını ifade etmişlerdir [8].

Segalla vd., elma bitkisinde bulunana morina güvelerini tespit etmeyi amaçlamışlardır. Tamamen otonom olan sistemin bahçedeki böceklerin fotoğraflarını çekip, derin evrişimli sinir ağları (DNN) algoritmasıyla analiz edip ve pozitif tespit durumunda çiftçiye alarm gönderdiğini ifade etmişlerdir. LeNet ile %98.3 oranında doğruluk, VGG16 ile %88.2 oranında doğruluk elde etmişlerdir [9]. Roldán-Serrato vd. patates ve fasulye mahsullerinde yaprak dökken iki zararlıyı otomatik olarak tespit etmeyi amaçlamışlardır. Rastgele Altuzay Sınıflandırıcısı (RSC) ile %89 tanıma oranı elde ederken, Sınırlı Alıcı Alan (LIRA) ile %88'lik tanıma oranı elde ettiklerini ifade etmişlerdir [10]. Karar vd., bulut bilişime dayalı beş farklı türden oluşan tarım böcek zararlılarını tanıma görevi için daha hızlı bölge tabanlı evrişimli sinir ağını (Faster R-CNN) önermişlerdir. Sonuçta %99,0 oranında tanıma doğruluğu elde ettiklerini belirtmişlerdir [11].

Bu çalışmada CNN temelli mimarilerden olan Inception_v3, ResNeSt50d ve Res2Net50d modelleri kullanılarak 15 sınıftan oluşan tarım zararlılarının tespit edilmesi amaçlanmıştır. Sonuçta en optimum başarı %79,0 tahmin doğruluğu ve 0.708 tahmin kayıp değeri ile Res2Net50d modeliyle elde edilmiştir.

2. MATERYAL ve METOT

Çalışmada kullanılan materyal ve metot aşağıda başlıklarla açıklanmıştır.

2.1. Veri Seti

Çalışmada kullanılan veri seti “kaggle” açık erişimli internet sitesinden alınmış olup, 15 farklı bitki zararlısı için toplamda 1591 adet veri içermektedir. Tablo 1’de veri seti içerisinde bulunan bitki zararlılarının türleri ve sayıları verilmiştir. Veri seti farklı türler için aynı sayıda veri içermemektedir ancak yaklaşık olarak dengeli bir dağılıma sahip olduğu ifade edilebilir. Gerçek dünya verilerinde de zaten hemen hemen verilerin aynı sayıda olmadığı gözlenebilir. Veri setinin içerisinde seçilmiş olan örnek görüntüler ise şekil 1’de verilmiştir [12].

Tablo 1. Veri Seti İçerisindeki Bitki Zararlıları ve Sayısı [12]

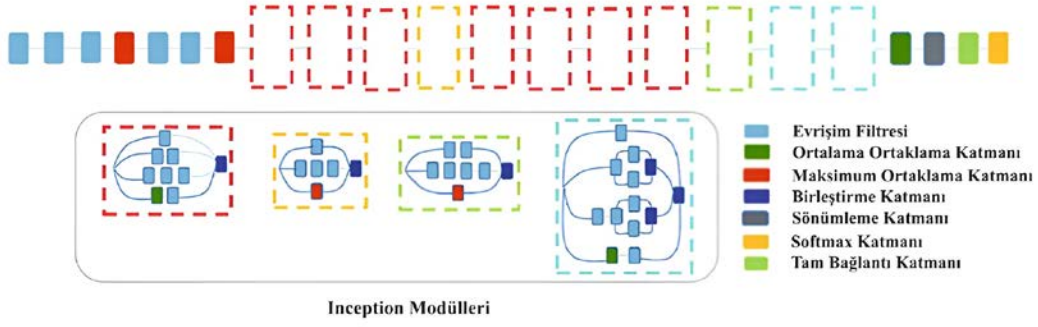
Sınıf Etiketi	Sınıf Adı (Türkçe)	Veri Sayısı
0	Afrikalılaşmış Bal Arısı – Katil Arılar (Africanized Honey Bees (Killer Bees))	97
1	Yaprak Bitleri (Aphids)	88
2	Ordu Kurtları (Armyworms)	96
3	Kahverengi Kokarca Böceği (Brown Marmorated Stink Bugs)	114
4	Lahana Döngüleyicileri (Cabbage Loopers)	104
5	Narenciye Canker (Citrus Canker)	104
6	Colorado Patates Böcekleri (Colorado Potato Beetles)	112
7	Mısır Delicileri (Corn Borers)	115
8	Mısır Kulak Kurdu (Corn Earworms)	110
9	Güz Tırtılı (Fall Armyworms)	113
10	Meyve Sinekleri (Fruit Flies)	101
11	Örümcek Akarları (Spider Mites)	119
12	Saçak Kanatlılar (Thrips)	109
13	Domates Boynuz Kurtları (Tomato Hornworms)	109
14	Batı Mısır Kök Kurtları (Western Corn Rootworms)	100



Şekil 1. Veri setinin sınıflarına ait örnekler (a) Afrikalılaşmış Bal Arısı – Katil Arılar (b) Yaprak Bitleri (c) Ordu Kurtları (d) Kahverengi Kokarca Böceği (e) Lahana Döngüleyicileri (f) Narenciye Canker (g) Colorado Patates Böcekleri (h) Mısır Delicileri (ı) Mısır Kulak Kurdu (i) Güz Tırtılı (j) Meyve Sinekleri (k) Örümcek Akarları (l) Saçak Kanatlılar (m) Domates Boynuz Kurtları (n) Batı Mısır Kök Kurtları [12]

2.2. Inception_v3 Algoritması

Inception ağı algoritması GoogleNet ağı olarak da bilinir. GoogleNet ağı, temeli CNN olan ve 2014 yılında Google tarafından önerilmiş olan bir derin öğrenme mimarisidir. Mimariye “Inception” denilmesinin sebebi, mimarinin sadece ağı parametrelerini azaltmakla kalmayıp buna ilave olarak ağı derinliğini de artırabilmesidir. Bu özelliğinden dolayı görüntü sınıflandırma işlemlerinde yaygın kullanıma sahiptir. Görüntülerden özellikler çıkarılır ve çıkarılan özelliklerden görüntülerin hedef sınıfları ile eşleşmeler yapılarak model eğitimi sağlanır. Inception_v1, Inception_v2, Inception_v3, Inception_v4 ve Inception-ResNet, GoogleNet’in temel sürümlerindedir. Inception fikrine dayanan CNN yapısı şekil 2’de verilmiştir [13], [14].




Şekil 2. CNN yapısı ve Inception v3 [14]

2.3. ResNeSt50d Algoritması

Derin öğrenme mimarilerinin ağ derinliklerini artırmanın doğruluk üzerinde olumlu etkiye sahip oldukları gözlemlenmiştir. Ancak ağ derinliğinin artmasıyla doğru orantılı olarak bir süre sonra modelinde doyuma ulaştığı gözlemlenmiştir. Bu sorunu çözebilmek adına, artık bloklara sahip ResNet mimarisi sunulmuştur ve görsel tanıma zorluklarında çok iyi performans gösterdiği ifade edilmiştir [15]. ResNeSt ise ResNet mimarisinin bir varyantıdır. ResNeSt, Zhang vd. tarafından önerilmiş olan görüntü sınıflandırma, nesne algılama ve segmentasyon işlemlerinde farklı derecelerde doğruluk iyileştirmesine sahip bir mimaridir. ResNeSt, özellik kanallarını ağırlıklandırmak için bölünmüş dikkat işlemini kullanır, bu işlem mimarinin daha zengin özellikleri öğrenmesini sağlar ayrıca daha küçük veri boyutuna sahip görevlere daha iyi uyum sağlayabilir [16], [17], [18].

2.4. Res2Net50d Algoritması

Res2Net mimarisi, Gao vd. tarafından 2019 yılında ResNet'e dayalı olarak önerilen bir diğer derin öğrenme mimarisidir. Burada ResNet'teki evrişim çekirdeklerinin boyutunu ve toplam sayısını değiştirmeden tutarken tüm evrişim çekirdeklerinin birden fazla küçük evrişim oluşturması sağlanır [19], [20]. Şekil 3'te Res2Net modülü görseli verilmiştir [21].



Şekil 3. Res2Net Modülü [21]


3. ARAŞTIRMA, SONUÇLAR ve TARTIŞMA

Çalışmada, tarımda zarara sebep olabilecek böcek görüntülerini içeren veri seti Inception_V3, ResNeSt50d ve Res2Net50d algoritmaları kullanılarak sınıflandırılmış ve sonuçlar verilmiştir. Önce veri normalleştirme, veri artırma gibi ön işlemler veri setine uygulanmıştır. Daha sonra veri seti %80 eğitim ve %20 tahmin verisi olarak ayrılmıştır. Tüm modeller 60 tur olacak şekilde eğitilmiştir. Batch boyutu 32 olarak belirlenmiştir. Tablo 2’de çalışmada eğitilen mimarilerin eğitim ve tahmin verilerinin doğruluk ve kayıpları verilmiştir. Tablo 2’de elde edilen sonuçlar yaklaşık olarak birbirine yakın olsa da çalışmalarda genellikle tahmin ya da test işlemlerine yönelik sonuçlara göre kıyaslama yapıldığından Res2Net50d modelinin optimum sonuçlar verdiği söylenebilir.


Tablo 2. Eğitim ve Tahmin İşlemlerinin Doğruluk ve Kayıp Sonuçları

Derin Öğrenme Modelleri	Eğitim ve Tahmin Değerlendirme Sonuçları			
	Eğitim Doğruluğu(%)	Tahmin Doğruluğu(%)	Eğitim Kaybı	Tahmin Kaybı
Inception_v3	84,2	75,9	0.472	0.754
ResNeSt50d	93,5	78,7	0.186	0.744
Res2Net50d	90,4	79,0	0.242	0.708

Çalışmada kullanılan mimarilerin Eğitim/Tahmin doğruluk grafikleri şekil 4’te verilmiştir. Çalışmada kullanılan mimarilerin Eğitim/Tahmin Kayıp grafikleri ise şekil 5’te verilmiştir. Şekillerde bulunan grafiklerdeki mavi çizgi ile çizilmiş kısımlar modellere ait eğitim sonuçlarını, mor ile çizilmiş kısımlar ise modellere ait tahmin sonuçlarını göstermektedir. Her turda elde edilen doğruluk ve kayıp sonuçları grafik üzerinde eğitim işlemleri için ‘o’ işareti ile tahmin işlemleri için ise ‘x’ işareti ile grafik üzerinde işaretlenmiştir.




Şekil 4. Derin Öğrenme Modellerinin Doğruluk Grafikleri (a) inception_v3 (b) ResNeSt50d (c)Res2Net50d




Şekil 5. Derin Öğrenme Modellerinin Kayıp Grafikleri (a) inception_v3 (b) ResNeSt50d (c) Res2Net50d

Çalışmada kullanılan mimarilerden Inception_v3 modelinin tahmin verilerini sınıflandırma sonuçları şekil 6’da karmaşıklık matrisi ile verilmiştir. Inception_v3 modeli etiket sınıfı ‘0’ ve ‘13’ olan sınıfları tamamen doğru sınıflandırırken, etiket sınıfı ‘9’ olan verilerin 15 tanesini yanlış sınıflandırmıştır. Tahmin veri setine ait toplamda 243 veri doğru sınıflandırılırken, 76 veri yanlış sınıflandırılmıştır.



Şekil 6. Inception_v3 modelinin tahmin verilerinin karmaşıklık matrisi

Çalışmada kullanılan mimarilerden ResNeSt50d modelinin tahmin verilerinin sınıflandırma sonuçları şekil 7’de karmaşıklık matrisi ile verilmiştir. ResNeSt50d modeli en iyi sınıflandırmayı etiket sınıfı ‘0’ olan verileri tamamen doğru sınıflandırarak gösterirken, en kötü sınıflandırma başarısını etiket sınıfı ‘9’ olan verilerin 17 tanesini yanlış sınıflandırmasıyla gerçekleştirmiştir. Tahmin veri setine ait toplamda 251 veri doğru sınıflandırılırken, 68 veri yanlış sınıflandırılmıştır.



Şekil 7. ResNeSt50d modelinin tahmin verilerinin karmaşıklık matrisi

Çalışmada kullanılan mimarilerden Res2Net50d modelinin tahmin verilerini sınıflandırma sonuçları şekil 8’de karmaşıklık matrisi ile verilmiştir. Res2Net50d modeli diğer modellerde olduğu gibi etiket sınıfı ‘0’ olan verileri tamamen doğru sınıflandırmıştır. Etiket sınıfı ‘9’ olan verilerin 13 tanesinin yanlış sınıflandırılması ile en kötü veri sınıfı tanıma başarısını ‘9’ etiketli veriler üzerinde gerçekleştirmiştir. Tahmin veri setine ait toplamda 253 veri doğru sınıflandırılırken, 66 veri yanlış sınıflandırılmıştır.

setinde bulunan canlı sınıflarına ait görüntüler artırılıp çeşitlendirilmesi durumunda derin öğrenme mimarilerinin performansları artırılabilir.

Teşekkür

Çalışmada kullanılan “Dangerous Farm Insects Dataset” veri setinin açık kaynak verilerini internet sitelerinde (Kaggle) kullanıma açan herkese teşekkür ederiz.

Çıkar Çatışması Beyanı

Yazarlar arasında çıkar çatışması yoktur.

Araştırma ve Yayın Etiği Beyanı

Çalışma, araştırma ve yayın etiğine uygundur.

KAYNAKLAR

- [1] B. Akbaş, “İklim değişikliği bitki hastalıklarının artmasına neden oluyor,” *turktarim.gov.tr*, 2018. Erişim Adresi: <http://www.turktarim.gov.tr/Haber/145/iklim-degisikligi-bitki-hastaliklarinin-artmasına-neden-oluyor> . [Erişim Tarihi: 09.09.2023].
- [2] M. Avan ve R. Kotan, “Fungusların mikrobiyal gübre veya biyopestisit olarak tarımda kullanılması,” *Uluslararası Doğu Anadolu Fen Mühendislik ve Tasarım Dergisi*, 3(1), 167-191, 2021.
- [3] A. A. Altun, “Organik tarımda zararlılarla mücadele yöntemleri,” *MAS Journal of Applied Sciences*, 7(2), 400-409, 2022.
- [4] N. Şahin, N. Alpaslan, M. İlçin, ve D. Hanbay, “Evrşimsel Sinir Ağı Mimarileri ve Öğrenim Aktarma ile Bitki Zararlısı Çekirge Türlerinin Sınıflandırması,” *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(1), 321-331, 2023.
- [5] D. J. A. Rustia, J. J. Chao, L. Y. Chiu, Y. F. Wu, J. Y. Chung, J. C. Hsu, and T. T. Lin, “Automatic greenhouse insect pest detection and recognition based on a cascaded deep learning classification method,” *Journal of Applied Entomology*, 145(3), 206-222, 2021. Doi: <https://doi.org/10.1111/jen.12834>
- [6] V. Malathi, and M. P. Gopinath, “Classification of pest detection in paddy crop based on transfer learning approach,” *Acta Agriculturae Scandinavica, Section B—Soil & Plant Science*, 71(7), 552-559, 2021. Doi: <https://doi.org/10.1080/09064710.2021.1874045>

- [7] M. A. Ebrahimi, M. H. Khoshtaghaza, S. Minaei, and B. Jamshidi, “Vision-based pest detection based on SVM classification method,” *Computers and Electronics in Agriculture*, 137, 52-58, 2017. Doi: <https://doi.org/10.1016/j.compag.2017.03.016>
- [8] T. Kasinathan, D. Singaraju, and S. R. Uyyala, “Insect classification and detection in field crops using modern machine learning techniques,” *Information Processing in Agriculture*, 8(3), 446-457, 2021. Doi: <https://doi.org/10.1016/j.inpa.2020.09.006>
- [9] A. Segalla, G. Fiacco, L. Tramarin, M. Nardello, and D. Brunelli, “Neural networks for pest detection in precision agriculture,” *In 2020 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor)* (pp. 7-12), (2020, November). IEEE. Doi: <https://doi.org/10.1109/MetroAgriFor50201.2020.9277657>
- [10] K. L. Roldán-Serrato, J. A. S. Escalante-Estrada, and M. T. Rodríguez-González, “Automatic pest detection on bean and potato crops by applying neural classifiers,” *Engineering in Agriculture, Environment and Food*, 11(4), 245-255, 2018. Doi: <https://doi.org/10.1016/j.eaef.2018.08.003>
- [11] M. E. Karar, F. Alsunaydi, S. Albusaymi, and S. Alotaibi, “A new mobile application of agricultural pests recognition using deep learning in cloud computing system,” *Alexandria Engineering Journal*, 60(5), 4423-4432, 2021. Doi: <https://doi.org/10.1016/j.aej.2021.03.009>
- [12] Kaggle “Dangerous Farm Insects Dataset,” *kaggle.com*, 2023. Erişim Adres: <https://www.kaggle.com/datasets/tarundalal/dangerous-insects-dataset> [Erişim Tarihi: 08.09.2023]
- [13] N. Dong, L. Zhao, C. H. Wu, and J. F. Chang, “Inception v3 based cervical cell classification combined with artificially extracted features,” *Applied Soft Computing*, 93, 106311, 2020. Doi: <https://doi.org/10.1016/j.asoc.2020.106311>
- [14] H. Amin, A. Darwish, and A. E. Hassanien, “Classification of COVID19 X-ray images based on transfer learning InceptionV3 deep learning model,” *In Digital Transformation and Emerging Technologies for Fighting COVID-19 Pandemic: Innovative Approaches* (pp. 111-119), 2021. Cham: Springer International Publishing. Doi: https://doi.org/10.1007/978-3-030-63307-3_7
- [15] X. Xia, X. Chai, N. Zhang, and T. Sun, “Visual classification of apple bud-types via attention-guided data enrichment network,” *Computers and Electronics in Agriculture*, 191, 106504, 2021. Doi: <https://doi.org/10.1016/j.compag.2021.106504>

- [16] Y. Li, C. Peng, Y. Zhang, Y. Zhang, and B. Lo, “Adversarial learning for semi-supervised pediatric sleep staging with single-EEG channel,” *Methods*, 204, 84-91, 2022. Doi: <https://doi.org/10.1016/j.ymeth.2022.03.013>
- [17] E. Haihong, J. He, T. Hu, L. Yuan, R. Zhang, S. Zhang, Y. Wang, M. Song, and L. Wang, “KFWC: A Knowledge-Driven Deep Learning Model for Fine-grained Classification of Wet-AMD,” *Computer Methods and Programs in Biomedicine*, 229, 107312, 2023. Doi: <https://doi.org/10.1016/j.cmpb.2022.107312>
- [18] H. Zhang, C. Wu, Z. Zhang, Y. Zhu, H. Lin, Z. Zhang, Y. Sun, T. He, J. Mueller, R. Manmatha, M. Li, and A. Smola, “Resnest: Split-attention networks,” *In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 2736-2746), 2022.
- [19] S. H. Gao, M. M. Cheng, K. Zhao, X. Y. Zhang, M. H. Yang, and P. Torr, “Res2net: A new multi-scale backbone architecture,” *IEEE transactions on pattern analysis and machine intelligence*, 43(2), 652-662, 2019. Doi: <https://doi.org/10.1109/TPAMI.2019.2938758>
- [20] Q. Tian, W. Sun, L. Zhang, H. Pan, Q. Chen, and J. Wu, “Gesture image recognition method based on DC-Res2Net and a feature fusion attention module,” *Journal of Visual Communication and Image Representation*, 95, 103891, 2023. Doi: <https://doi.org/10.1016/j.jvcir.2023.103891>
- [21] F. Yang, M. Jia, L. Lu, and M. Yin, “Adaptive zero-learning medical image fusion,” *Biomedical Signal Processing and Control*, 84, 105008, 2023. Doi: <https://doi.org/10.1016/j.bspc.2023.105008>