



**BİTKİ GÖRÜNTÜLERİNDEKİ ZARARLI
BÖCEKLERİN DERİN ÖĞRENME İLE
TANINMASI**

Yüksek Lisans Tezi

Şevval Ezgi EZE

Eskişehir, 2024

BITKİ GÖRÜNTÜLERİNDEKİ ZARARLI BÖCEKLERİN DERİN ÖĞRENME İLE TANINMASI

Şevval Ezgi EZE

Yüksek Lisans Tezi

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Bilimleri Bilim Dalı

Danışman: Dr. Öğr. Üyesi Selcan KAPLAN BERKAYA

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Haziran 2024

JÜRİ VE ENSTİTÜ ONAYI

Şevval Ezgi EZE'nin BİTKİ GÖRÜNTÜLERİNDEKİ ZARARLI BÖCEKLERİN DERİN ÖĞRENME İLE TANINMASI başlıklı çalışması 13/06/2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Bilgisayar Mühendisliği Anabilim dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Dr. Öğr. Üyesi Selcan KAPLAN
BERKAYA

Üye

: Dr. Öğr. Üyesi Sevcan YILMAZ
GÜNDÜZ

Üye

: Dr. Öğr. Üyesi Efnan ŞORA GÜNAL

Prof. Dr. Semra KURAMA

Lisansüstü Eğitim Enstitüsü Müdürü

DANIřMAN ONAYI

Daniřmanlıęını yrttęm Yksek Lisans ęrencisi řevval Ezgi EZE, BİTKİ GRNTLERİNDEKİ ZARARLI BCEKLERİN DERİN ęRENME İLE TANINMASI bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduęu tez tarafımca incelenmiř ve ęrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı

Dr. ęr. yesi Selcan KAPLAN BERKAYA

ÖZET

BİTKİ GÖRÜNTÜLERİNDEKİ ZARARLI BÖCEKLERİN DERİN ÖĞRENME İLE TANINMASI

Şevval Ezgi EZE

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Bilimleri Bilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Haziran 2024

Danışman: Dr. Öğr. Üyesi Selcan KAPLAN BERKAYA

Bitki zararlılarının erken dönemde, etkili bir şekilde tespit edilip kontrol altına alınmalarını sağlamak bitkilerin korunmasına, ürün veriminin artırılmasına ve tarım ekonomisindeki kayıpların azaltılmasına yardımcı olmaktadır. Bu tez çalışmasında, tarımsal üretime önemli bir tehdit oluşturan bitki zararlılarının tanımlanmasına yönelik derin öğrenme yaklaşımları önerilmektedir. Önerilen ilk yöntemde sınıflandırma, önceden eğitilmiş farklı derin sinir ağları (DNN) kullanılarak transfer öğrenme yoluyla gerçekleştirilmektedir. İkinci yöntemde ise; bu ağların derin katmanlarından çıkarılan öznitelikler ile Destek Vektör Makinesi (SVM) sınıflandırıcısından yararlanılmaktadır. Üçüncü yöntem, görüntü transformatörü olarak bilinen transformatör mimarisini kullanan bir sinir ağı modelinin kullanılmasını içerir. Son olarak, birden fazla modelden gelen tahminleri birleştirerek daha güçlü ve daha doğru tahminler elde etmeyi amaçlayan bir yaklaşım olan topluluk öğrenimi, yukarıdaki üç farklı yöntemden en iyi performans gösteren modelleri birleştirmek için kullanılmıştır. Ayrıca yeşil renk kanalı çıkarımı, veri artırımı, histogram eşitleme, derin öğrenme tabanlı segmentasyon ile arka plan eliminasyonu gibi farklı görüntü ön işleme teknikleri ayrı ayrı ve birlikte kullanılarak kapsamlı bir performans analizi yapılmıştır. Deneyler, sırasıyla 10 ve 40 zararlı türü içeren Li ve D0 veri setleri üzerinde gerçekleştirilmiştir. Li veri setinde çoğunluk oylama yöntemi kullanılan topluluk öğrenimi ile %98.35, D0 veri setinde ise %99.78 doğruluk ile en yüksek performans elde edilmiştir. Sonuçlar, önerilen modellerin bitki zararlısı kontrolünde etkin bir şekilde kullanılabileceğini göstermektedir.

Anahtar Sözcükler: Derin öğrenme, Görüntü ön işleme, Bitki zararlısı sınıflandırma, Topluluk öğrenimi, Akıllı tarım.

ABSTRACT

DEEP LEARNING-BASED RECOGNITION OF INSECT PESTS IN PLANT IMAGES

Şevval Ezgi EZE

Department of Computer Engineering

Programme in Computer Science

Eskişehir Technical University, Institute of Graduate Programs, June 2024

Supervisor: Asst. Prof. Dr. Selcan KAPLAN BERKAYA

Early and effective insect pest detection and control help to protect plants, increase crop yields, and reduce losses in the agricultural economy. In this dissertation, deep learning approaches for identifying insect pests, which pose a significant threat to agricultural production, are proposed. The first proposed method involves classification through transfer learning using different pre-trained deep neural networks (DNN). In the second method, features extracted from deep layers of these networks with the Support Vector Machine (SVM) classifier are utilized, Third method involves the use of a neural network model that uses transformer architecture known as the vision transformer. Finally, ensemble learning, an approach that combines predictions from multiple models to achieve stronger and more accurate predictions, is used to merge the best-performing models from the three different methods mentioned above. Additionally, a comprehensive performance analysis was conducted using various image preprocessing techniques both individually and in combination, including green color channel extraction, data augmentation, histogram equalization, and deep learning-based segmentation with background elimination. Experiments were carried out on the Li and D0 datasets, which contain 10 and 40 plant pest species, respectively. The highest performance was achieved with 98.35% accuracy using the majority voting method in the Li dataset, and 99.78% accuracy in the D0 dataset. The results demonstrate that the proposed models can be effectively used in insect pest control.

Keywords: Deep learning, Image preprocessing, Insect pest classification, Ensemble learning, Smart agriculture.

TEŞEKKÜR

Tez çalışmam boyunca danışmanlığımı yürüten, kıymetli bilgi birikimiyle bütün sorularımda bana yol gösteren, desteğini ve rehberliğini hiçbir zaman esirgemeyen değerli danışman hocam Dr. Öğr. Üyesi Selcan KAPLAN BERKAYA'ya teşekkür eder, saygılarımı sunarım.

Tüm hayatım boyunca maddi ve manevi emek vererek yanımda olan, beni her zaman destekleyen, sonsuz sevgi ve fedakarlıkları ile her zaman daha iyiye yönlendiren bu hayattaki en büyük şansım sevgili aileme; anneme, babama ve kardeşime teşekkür eder, minnettarlığımı sunarım.

Son olarak çalışmam süresince beni her zaman motive eden ve desteklerini esirgemeyip yanımda olan değerli arkadaşlarıma teşekkür ederim.

Şevval Ezgi EZE

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Şevval Ezgi EZE

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER.....	VIII
TABLolar DİZİNİ.....	X
ŞEKİLLER DİZİNİ.....	XI
SİMGELER VE KISALTMALAR DİZİNİ.....	XII
1. GİRİŞ	1
2. VERİ SETİ	5
2.1. Li Veri Seti.....	5
2.2. D0 Veri Seti.....	6
2.3. Ön İşleme Teknikleri	8
2.3.1. Segmentasyon ile arka plan eliminasyonu	10
3. ÖNERİLEN DERİN ÖĞRENME TABANLI SINIFLANDIRMA YÖNTEMLERİ.....	12
3.1. Önceden Eğitilmiş Derin Sinir Ağları	12
3.1.1. ResNet.....	14
3.1.2. GoogLeNet	16
3.1.3. DenseNet.....	16
3.1.4. NASNet-Large	17
3.1.5. VGGNet.....	18
3.2. Transfer Öğrenme.....	20

3.3. Destek Vektör Makinesi	21
3.4. ViT	23
3.5. Topluluk Öğrenme	24
4. DENEYSEL ÇALIŞMALAR.....	28
5. SONUÇLAR VE TARTIŞMA.....	34
KAYNAKÇA.....	38
ÖZGEÇMİŞ	



TABLÖLAR DİZİNİ

Sayfa

Tablo 2.1. Li veri seti içeriği.....	6
Tablo 2.2. D0 veri seti içeriği.....	7
Tablo 4.1. Önerilen modellerin orijinal Li veri setindeki performansları (Acc/Pre/Rec/F1)	28
Tablo 4.2. Önerilen modellerin orijinal D0 veri setindeki performansları (Acc/Pre/Rec/F1)	29
Tablo 4.3. ResNet-101 ile farklı ön işleme yöntemleri ile elde edilen performansları (Acc/Pre/Rec/F1).....	31
Tablo 4.4. Veri artırımı sonrası modellerin Li veri setindeki en iyi performansları (Acc/Pre/Rec/F1)	32
Tablo 4.5. Veri artırımı sonrası modellerin D0 veri setindeki en iyi performansları (Acc/Pre/Rec/F1)	32
Tablo 4.6. Veri artırımı sonrası modellerin Li veri setindeki performansların en iyileri ile topluluk öğrenme kombinasyonları (Acc/Pre/Rec/F1).....	33
Tablo 4.7. Veri artırımı sonrası modellerin D0 veri setindeki performansların en iyileri ile topluluk öğrenme kombinasyonları (Acc/Pre/Rec/F1).....	33
Tablo 5.1. Önerilen çalışmanın literatürde yer alan benzer çalışmalar ile karşılaştırması	35

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Li veri setindeki 10 farklı sınıfa ait örnek görüntüler (a) Cydia Pomonella, (b) Gryllotalpa, (c) Leafhopper, (d) Locust, (e) Oriental Fruit Fly, (f) Pieris Rapae Linnaeus, (g) Snail, (h) Spodoptera Litura, (i) Stinkbug, (j) Weevil	5
Şekil 2.2. D0 veri setindeki 40 farklı sınıfa ait örnek görüntüler	6
Şekil 2.3. Ön işleme teknikleri uygulanmış örnek görüntüler. (a) Orijinal görüntü, (b) 90° döndürme + X yansıma, (c) 120° döndürme + Y yansıma, (d) X yansıma + Y yansıma (e) G kanalı çıkarımı, (f) Histogram eşitleme	10
Şekil 2.4. U-Net mimarisi (Ronneberger vd., 2015)	11
Şekil 3.1. CNN mimarisinin basit yapısı	13
Şekil 3.2. ResNet tarafından VGG-19'dan ilham alan 34 katmanlı düz ağ mimarisi (He vd., 2016)	15
Şekil 3.3. GoogLeNet modülü (Szegedy vd., 2015).....	16
Şekil 3.4. DenseNet mimarisi (Huang vd., 2017).....	17
Şekil 3.5. NASNet-Large mimarisi (Zoph vd., 2018)	18
Şekil 3.6. VGG-16 mimarisi (Tammina, 2019).....	19
Şekil 3.7. Transfer öğrenimi akış şeması.....	20
Şekil 3.8. Çalışmada kullanılan transfer öğrenme mimarisi.....	21
Şekil 3.9. SVM sınıflandırma örneği (Meyer ve Wien, 2001)	22
Şekil 3.10. Önerilen modelin akış şeması.....	23
Şekil 3.11. ViT mimarisi	24
Şekil 3.12. Çoğunluk oylama ile birleştirilen torbalama yöntemi yapısı	25
Şekil 3.13. Yığma yöntemi yapısı	25
Şekil 3.14. Artırma yöntemi yapısı.....	26
Şekil 3.15. Önerilen modelin akış şeması.....	27
Şekil 4.1. Kullanılan veri setlerine ait örnek görüntülerdeki ResNet-101 aktivasyon haritası (a) Li, (b) D0	30

SİMGELER VE KISALTMALAR DİZİNİ

DNN	: Deep Neural Network (Derin Sinir Ağı)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
CNN	: Convolutional Neural Network (Evrışimli Sinir Ağı)
ViT	: Vision Transformer (Görüntü Transformatörü)



1. GİRİŞ

Tarım, insan yaşamı için gerekli olan bitkisel ürünlerin üretilmesi, kalitesinin artırılması, işlenmesi ve değerlendirilmesini kapsayan bir alandır. Tarım sektörü birçok ülkenin ekonomisi için hayati öneme sahiptir ve küresel nüfusun gıda ihtiyaçlarının karşılanmasında önemli bir role sahiptir. Bu sebeple tarımda mahsul verimliliğini korumak, sürdürülebilirliği sağlamak ve ürün kayıplarını önlemek oldukça önemlidir ve tarımla ilgili çoğu çalışmada, ürünü korumaya yönelik olarak iklim değişikliğinin mahsuller üzerindeki yan etkisi, toprak sağlığının bozulması, su kıtlığı, haşere ve hastalık yönetimi gibi çözüme ihtiyaç duyan sorunlara, yenilikçi teknolojiler ile cevap veren konular ele alınmaktadır.

Tarımdaki en büyük zorluklardan biri, tarımsal üretimde mahsulün kalitesini olumsuz yönde etkileyen, bitkilerin gelişimini engelleyen, fiziksel görünümünü etkileyen zararlı böceklerdir. Zararlıların tanınması ve önlem alınması, mahsullerin sağlıklı bir şekilde büyümesini sağlar ve kalitesini büyük ölçüde etkiler. Zararlı böcekleri sınıflandırmak, karmaşık yapıları ve çeşitli türler arasındaki görünüm benzerlikleri göz önüne alındığında önemli bir zorluk teşkil etmektedir. Çiftçilerin zararlıları tespit etmek için kullandıkları mevcut yöntem manuel gözlemdir. Bu yöntemde çiftçiler hava şartlarına ve bitkilerin büyüme aşamalarına göre günlük haşere kontrolü yapmaktadır. Bu nedenle manuel gözlem yorucu, hataya açık ve zaman alıcıdır (Li vd., 2020). Mahsullerdeki bitki zararlılarının zamanında tespit edilmesi ve sınıflandırılması, özellikle mahsul hastalıklarından ve tarım ürünlerinde önemli kayıplardan sorumlu olan zararlıların yayılmasının engellenmesi açısından hayati öneme sahiptir. İstilacı böceklerin otomatik olarak tanınması, onların tespit edilmesini ve ortadan kaldırılmasını önemli ölçüde hızlandıracaktır (Nanni vd., 2020). Zararlılarla mücadelede etkin yöntemlerin kullanılması gereklidir. Bu nedenle tarımsal sorunların çözümü oldukça aktif bir araştırma alanı haline gelmiştir ve sorunun çözümüne yönelik olarak son zamanlarda görüntü işleme ve derin öğrenme tekniklerine dayalı çeşitli bilgisayar destekli yöntemler geliştirilmiştir.

(Xia vd., 2018) çalışmasında 24 sınıflı mahsul zararlılarını içeren Xie1 veri setindeki (Xie vd., 2015) görüntülerde böceklerin hızlı ve doğru bir şekilde tespit edilmesi için VGG-19 ağı kullanılmıştır. Ayrıca yazarlar, ön işleme adımı olarak, veri setinin küçük olması sebebiyle tüm görüntüleri 90°, 180°, 270° açılarda döndürerek veri artırımı, aynı zamanda verilerin geçerliliğini sağlamak amacıyla görüntülerdeki piksel değerlerini

rastgele deęiřtiren, bazı piksel noktalarını beyazlatan bazı piksel noktalarını karartan tuz ve biber gürültüsünü görüntüleme eklemiřler ve %89.22 mAP (mean Average Precision) deęerine ulařmıřlardır. (Xie vd., 2018) alıřmasında yazarlar hařere görüntülerinin sınıflandırılmasında ok seviyeli öğrenme özniteliklerini ieren temsilleri oluřturmak iin üç adım izlemiřlerdir. İlk adım olan denetimsiz sözlük öğrenme ařamasında, görüntü paralarından özniteliklerin ıkarılması hedeflenmiřtir. İkinci adım, öznitelik kodlama ařamasında görüntü paralarının öznitelikleri, önceden oluřturulan sözlüęe göre kodlanır. Üüncü ve son adımda ok seviyeli bir örnekleme süreci uygulanır. Bu süreçte, para düzeyindeki özniteliklerin yanlış hizalama sorununu özmek iin filtreler birden ok ölekte uygulanır ve bu eřitli havuzlama seviyeleriyle birleřtirilerek özniteliklerin daha doęru bir řekilde ıkarılmasını saęlamaktadır. Bu üç adımın birleřimi ile hařere görüntülerinin ok seviyeli öğrenme özniteliklerine dönüřtürölmesini saęlamıřlardır. Deneyleri dört veri seti üzerinde gerekleřtirmiřlerdir. Kendi oluřturdukları D0 veri setinde %89.30 doęruluk deęeri olmak üzere en yüksek sonucu D1 (Xiao vd., 2012) veri setinde %98.60 sınıflandırma doęruluęu ile elde etmiřlerdir.

(Thenmozhi ve Reddy, 2019) alıřmasında yazarlar, AlexNet, ResNet, GoogLeNet ve VGGNet gibi önceden eęitilmiş derin sinir aęlarını üç farklı genel veri seti NBAIR, Xie1 (Xie vd., 2015) ve D0 (Xie vd., 2018) üzerinde transfer öğrenme yöntemini kullanarak deneylerini gerekleřtirmiřlerdir. Aęın ařırı uyumunu önlemek iin yansıtma, öleklendirme, döndürme ve görüntülerin konumunu deęiřtirme gibi veri artırma teknikleri uygulamıřlardır. Önerdikleri CNN modelinin performansını eřitli hiper parametrelerin etkisini ölerek karřılařtırmıřlardır. Deneyler sonucunda ulařtıkları doęruluk deęerleri NBAIR'de %96.75, Xie1'de %97.47 ve D0'da %95.97'dir. (Li vd., 2020) alıřmasında ise yazarlar, manuel olarak toplanan ve on farklı mahsul zararlısı türünü ieren Li olarak adlandırdıkları yeni bir veri seti oluřturmuřlardır. Bu veri setinde zararlı sınıflandırması iin önceden eęitilmiş VGG-16, VGG-19, ResNet-50, ResNet-152 ve GoogLeNet aęları kullanarak yaptıkları deneyler sonucunda en yüksek performans olan %96.67 doęruluk deęerine ince ayar yaptıkları GoogLeNet modeliyle ulařmıřlardır.

(Wu vd., 2019) alıřmalarında, 102 sınıfa ait 75.000'den fazla görüntü ieren IP102 adlı büyük ölekli bir veri seti tanıtılmıřtır. SVM ve K-En yakın komřu sınıflandırıcısını kullanarak %49.50 doęruluk elde etmiřlerdir. (Nanni vd., 2020) alıřmalarında, bitki zararlılarını sınıflandırmak iin görüntünün en önemli piksellerini vurgulamak amacıyla belirginlik yöntemleri ve evriřimsel sinir aęlarının (CNN) kombinasyonuna dayanan

otomatik bir sınıflandırıcı önermişlerdir. Önerdikleri yöntemin performans değerlendirmesini, 10 sınıflı küçük ölçekli bir veri seti olan (Deng vd., 2018) ve 102 sınıflı IP102 veri seti (Wu vd., 2019) üzerinde gerçekleştirmişlerdir. Önerilen yaklaşımları ile, küçük ölçekli veri setinde %92.43 ve IP102 veri setinde %61.93 başarı oranına ulaşmışlardır. Yazarlar (Yang vd., 2021) çalışmalarında, Li (Li vd., 2020), IP102 (Wu vd., 2019) ve kendi önerdikleri veri seti dahil olmak üzere üç farklı bitki zararlısı veri setini kullanmışlardır. Veri setlerinde, zararlıların boyutu ve görüntülerdeki karmaşık arka plan gibi zorlukların üstesinden gelmek için, zararlı tanıma problemi için Uzamsal Transformatör Ağları ve ResNet-50 ağlarına dayanan bir CNN modeli önermişlerdir. Performans karşılaştırmaları yaptıklarında, önerilen yöntemlerinin kullandıkları veri setlerinde yapılan önceki modellerden daha iyi performans gösterdiğini ortaya koymuşlardır. Önerilen yöntemleri ile, Li (10 sınıf), önerilen (58 sınıf) ve IP102 (102 sınıf) veri setlerinde sırasıyla %96.78, %96.50 ve %73.29 sınıflandırma doğrulukları elde etmişlerdir. Yazarlar (Nanni vd., 2022) çalışmalarında, çeşitli Adam optimizasyon ve veri artırma yöntemlerinden oluşan CNN toplulukları (EfficientNetB0, ResNet-50, GoogLeNet, ShuffleNet, MobileNetv2 ve DenseNet201) oluşturmuşlardır. Önerdikleri topluluk yöntemi ile Deng (Deng vd., 2018), IP102 (Wu vd., 2019) ve Xie2 (D0) (Xie vd., 2018) veri setlerinde sırasıyla %95.52, %74.11 ve %99.81 başarı oranlarına ulaşmışlardır.

Bitki zararlıları bir tarlayı istila ettiğinde onları yok etmek zordur ve mahsul veriminde büyük kayıplara neden olurlar. Dünya çapında yaygın olmaları ve hızlı üreme oranları nedeniyle, bitki zararlılarının etkili bir şekilde tespit edilmesi ve zamanında kontrolü için birçok çalışma araştırma konusu olarak, zararlılara odaklanmaktadır. Bu çalışmada bitki zararlılarının tespiti ve sınıflandırılması için derin öğrenmeye dayalı yeni yöntemler önerilmiştir. Öncelikle orijinal veri setinde yapılan deneyler göz önünde bulundurularak sınıflandırma aşamalarının performansının artırılması için görüntülerin kalitesinin artırılması ve görsel özelliklerinin iyileştirilmesine ihtiyaç duyulmasından dolayı, farklı görüntü ön işleme teknikleri kullanılmıştır. Burada, yeşil renk kanalı çıkarımı, veri artırımı, histogram eşitleme, segmentasyon ile arka plan eliminasyonu gibi farklı görüntü ön işleme teknikleri ayrı ayrı ve birlikte kullanılarak kapsamlı bir performans analizi yapılmıştır. Deneyler, sırasıyla 10 ve 40 bitki zararlısı türü içeren Li ve D0 veri setleri üzerinde gerçekleştirilmiştir. Önerilen ilk iki yaklaşımda sırasıyla, ResNet-101, GoogLeNet, DenseNet-201 ve NASNet-Large gibi önceden eğitilmiş farklı

DNN ile transfer öğrenimi ve bu ağlardan çıkarılan derin öznitelikler ile SVM sınıflandırıcısı kullanılarak sınıflandırma yapılmıştır. Ayrıca, transformatör mimarisini kullanan bir derin öğrenme modeli olan ViT ile sınıflandırma yapılmıştır. Son yaklaşım olarak, diğer çalışmalardan farklı olarak, yukarıda belirtilen en iyi performans gösteren üç yöntemin sonuçlarının çoğunluk oyuyla birleştirilmesiyle sınıflandırma yapılmıştır.


Bu tez çalışması aşağıdaki şekilde organize edilmiştir: Bölüm 2’de çalışmada kullanılan veri setleri tanıtılmakta, ön işleme teknikleri ve veri artırma yöntemleri hakkında ayrıntılı bilgi verilmektedir. Bölüm 3’te önerilen derin öğrenme tabanlı modeller sunulmaktadır. Bölüm 4’te deneysel çalışmalar ve kapsamlı sonuçlar yer almaktadır. Son olarak Bölüm 5’te sonuçlar, tartışmalar ve literatürdeki son çalışmalar ile performans karşılaştırmaları yer almaktadır.

2. VERİ SETİ

Bu tez çalışmasında, önerilen yöntemlerin performansını değerlendirmek için iki farklı veri seti kullanılmıştır. Bu veri setlerine ait detaylı açıklamalar alt bölümlerde verilmiştir.

2.1. Li Veri Seti

Çalışmada ilk olarak, Li ve arkadaşları tarafından oluşturulan ve Gryllotalpa, Leafhopper, Locust, Oriental Fruit Fly, Pieris Rapae Linnaeus, Snail, Spodoptera Litura, Stinkbug, Cydia Pomonella, Weevil olmak üzere 10 farklı sınıfa ait, toplamda 5689 görüntü içeren bir veri seti kullanılmıştır (Li vd., 2020). Veri seti, Google, Baidu, Yahoo ve Bing gibi popüler arama motorlarından elde edilen görsellerle birlikte, Li ve arkadaşları tarafından cep telefonu kullanılarak dış mekân çekimleri yapılarak oluşturulmuştur. Bu haşereler genellikle küçük boyutlara sahiptir ve doğal ortamlarında çıplak gözle hızlı bir şekilde tespit etmek zor olabilir. Şekil 2.1'de, veri setindeki sınıflara ait örnek görüntüler bulunmaktadır. Bu veri seti içeriği, Tablo 2.1'de detaylı bir şekilde listelenmiştir.



Şekil 2.1. Li veri setindeki 10 farklı sınıfa ait örnek görüntüler (a) *Cydia Pomonella*, (b) *Gryllotalpa*, (c) *Leafhopper*, (d) *Locust*, (e) *Oriental Fruit Fly*, (f) *Pieris Rapae Linnaeus*, (g) *Snail*, (h) *Spodoptera Litura*, (i) *Stinkbug*, (j) *Weevil*

Tablo 2.1. *Li veri seti içeriği*

No	Sınıf Adı	Eğitim	Test	Toplam
1	Cydia Pomonella	291	124	415
2	Gryllotalpa	356	152	508
3	Leafhopper	298	128	426
4	Locust	516	221	737
5	Oriental Fruit Fly	328	140	468
6	Pieris Rapae Linnaeus	396	170	566
7	Snail	750	322	1072
8	Spodoptera Litura	306	131	437
9	Stinkbug	476	204	680
10	Weevil	392	168	560
Toplam		4109	1760	5869

2.2. D0 Veri Seti

Kullanılan ikinci veri seti, (Xie vd., 2018) çalışmasında oluşturulan mısır, soya fasulyesi, buğday ve kanola dahil olmak üzere birçok yaygın tarla ürününde bulunan türlerin çoğunu kapsayan 40 farklı böcek sınıfını içeren ve 4508 görüntüden oluşan D0 veri setidir. Şekil 2.2 'de, D0 veri setindeki sınıflara ait örnek görüntüler bulunmaktadır. Bu veri seti içeriği, Tablo 2.2’de detaylı bir şekilde listelenmiştir.



Şekil 2.2. *D0 veri setindeki 40 farklı sınıfa ait örnek görüntüler*

Tablo 2.2. *D0 veri seti içeriği*

No	Sınıf Adı	Eğitim	Test	Toplam
1	Aulacophora Indica	55	23	78
2	Bemisia Tabaci	103	44	147
3	Callitettix Versicolor	109	47	156
4	Ceroplastes Ceriferus	70	30	100
5	Ceutorhynchus Asper Roelofs	102	44	146
6	Chauliops Fallax Scott	48	20	68
7	Chilo Supperssalis	65	28	93
8	Chromatomyia Horticola	80	34	114
9	Cicadella Viridis	97	41	138
10	Cletus Punctiger	118	51	169
11	Corythucha Ciliata	63	27	90
12	Corythucha Marmorata	69	29	98
13	Dicladispa Armigera	105	45	150
14	Diostrombus.Politus Uhler	167	71	238
15	Dolerus Tritici Chu	62	26	88
16	Dolycoris Baccarum	61	26	87
17	Dryocosmus Kuriphilus	35	15	50
18	Empoasca Flavescens	93	40	133
19	Eurydema Dominulus	105	45	150
20	Graphosoma Rubrolineata	81	35	116
21	Halyomorpha Halys	71	30	101
22	Iscadia Inexacta	55	24	79
23	Laodelphax Striatellus	43	18	61
24	Leptocorisa Acuta	93	40	133
25	Luperomorpha Suturalis	71	30	101
26	Lycorma Delicatula	64	28	92
27	Maruca Testulalis Gryer	51	22	73
28	Nezara Viridula	122	53	175
29	Nilaparvata Lugens	43	18	61
30	Phyllotreta Striolata	131	56	187
31	Pieris Rapae	50	21	71
32	Plutella Xylostella	48	20	68
33	Porthesia Taiwana Shiraki	99	42	141
34	Riptortus Pedestris	77	33	110
35	Scotinophara Lurida	82	35	117
36	Sesamia Inferens	88	38	126
37	Spilosoma Obliqua	46	20	66
38	Spodoptera Litura	91	39	130
39	Stollia Ventralis	50	22	72
40	Strongyloides Variegatus	94	41	135
Toplam		3157	1351	4508

2.3. Ön İşleme Teknikleri

Veriler, genellikle gürültü, bozulma, eksik ve tutarsız bilgiler gibi çeşitli sorunlar içerebilir. Bu nedenle, veri analizi ve diğer veri odaklı uygulamalarda güvenilir sonuçlar elde etmek için öncelikle ön işleme adımlarının gerçekleştirilmesi gerekmektedir. Veri ön işleme, verilerdeki gürültüyü azaltmak, eksik veya tutarsız verileri düzeltmek, gereksiz özellikleri temizlemek ve genel olarak veri setinin homojenliğini sağlamak için kullanılan çeşitli teknikleri içermektedir. Sınıflandırma veya tespit uygulamalarında kullanılan veri setlerini hazırlamak için farklı ön işleme yöntemleri mevcuttur. Bu yöntemler, döndürme, yansıma, arka plan elimine etme, veri artırımı ve renk modeli dönüşümü gibi sınıflandırma algoritmalarının daha güvenilir ve etkili olmasını sağlamak için kritik öneme sahip olan uygulamalardır (Maharana vd., 2022).


Görüntü ön işleme sürecinde, farklı renk kanalları ve renk modelleri önemli bir rol oynar. Görüntülerin renklerini temsil etmek için kullanılan Kırmızı (R), Yeşil (G), ve Mavi (B) olmak üzere üç temel renk bileşeni bulunmaktadır. Bu renk bileşenleri, bir görüntünün renk paletini oluşturan temel yapı taşlarıdır. Yüksek bir R değeri, görüntüdeki kırmızı tonların belirginliğini artırırken, yüksek bir G değeri yeşil tonların ve yüksek bir B değeri de mavi tonların belirginliğini artırır. Bu bileşenler, farklı oranlarda birleşerek renklerin zenginliğini oluşturur ve görsel deneyimi çeşitlendirir. Renk kanallarının ayrı ayrı kullanımı ile karmaşık görüntü işleme problemleri basit parçalara ayrılır ve daha sonraki algoritma adımları için işlem kolaylığı sağlanır. Bu çalışmada farklı modellerin bitki zararlısı sınıflandırma için önerilmesinin yanı sıra, görüntü ön işleme sürecinde, belirli renk kanalı, histogram eşitleme, segmentasyon ile arka plan eliminasyonu ve veri artırımının sınıflandırma performansına etkisi araştırılmaktadır.

Çalışmada kullanılan ön işleme teknikleri, belirli renk kanalı üzerinden görüntülere renk ayarı, kontrast artırma ve renk dengelemesi yapılması gibi işlemleri içermektedir. Histogram eşitleme, zayıf kontrastlı görüntülerin kontrastını artırır ve görüntünün piksel değerlerinin dağılımını değiştirerek görüntüyü daha net ve detaylı hale getirir. Görüntülerdeki zararlıların genellikle yeşil bitkiler üzerinde olduğu değerlendirilerek, modele girdi olarak görüntünün G kanalı verilmiştir. Bu yeşil renk kanalının çıkarılmasıyla görüntüdeki zararlılar daha belirgin hale gelmiştir. Görüntülerde arka plan karmaşıklığından kaynaklı böceği tespit edememe durumunu ortadan kaldırmaya yönelik derin öğrenme tabanlı bir segmentasyon yöntemi olan ve piksel düzeyinde arka plana ait

olasılık haritasını tahmin eden U-Net tabanlı mimari (Ronneberger vd., 2015) kullanılarak bitki zararlıları segmente edilip, ardından arka plan elimine edilmiştir.

Veri setindeki görüntülerin artırımı, bitki zararlılarının tanınması, tespiti ve kullanılan modelin öğrenimi açısından kolaylık sağlamaktadır (Nanni vd., 2020). Veri artırımı işlemi; iki veri setinde de test verileri sabit tutularak, eğitim verilerine çeşitli döndürme ve yansıtma yöntemleri uygulanarak gerçekleştirilmiştir. Görüntüler, 90° döndürme ve X yansıma, 120° döndürme ve Y yansıma gibi yöntemlerle artırılmıştır. Veri artırımı sonrasında her sınıf için üç kat artırım yapılmıştır. Görüntülerde veri artırımı, görüntü sınıflandırma problemlerinde farklı tekniklerle (döndürme, ölçeklendirme, yansıma vb.) mevcut veri setini çoğaltarak modelin genelleme yeteneğini iyileştirir ve aşırı öğrenmeyi azaltır. Bu yöntem, özellikle küçük veri setlerinde faydalıdır, çünkü modelin daha çeşitli ve zengin bir veri ile eğitilmesini sağlar, böylece doğruluk oranlarını artırır ve modelin daha sağlam hale gelmesine yardımcı olur. Ayrıca, veri artırımı sınıflar arasındaki dengesizliği gidererek her sınıfı eşit derecede öğrenmeyi teşvik eder ve modelin gerçek dünya senaryolarında daha iyi performans göstermesine katkıda bulunur (Shorten ve Khoshgoftaar, 2019).

Tüm ön işleme sürecine ait örnek görüntüler Şekil 2.3'te sunulmaktadır. Kullanılan her bir yöntemin sonucu, veri setlerinde sınıflandırma performansı açısından kapsamlı bir şekilde değerlendirilmiştir.



Şekil 2.3. Ön işleme teknikleri uygulanmış örnek görüntüler. (a) Orijinal görüntü, (b) 90° döndürme + X yansıma, (c) 120° döndürme + Y yansıma, (d) X yansıma + Y yansıma (e) G kanalı çıkarımı, (f) Histogram eşitleme

2.3.1. Segmentasyon ile arka plan eliminasyonu

Bu çalışmada görüntülerde arka plan karmaşıklığından kaynaklı bitki zararlısını tespit edememe durumunu ortadan kaldırmaya yönelik derin öğrenme tabanlı bir segmentasyon yöntemi olan U-Net mimarisi kullanılmıştır. Bu yöntem kullanılarak bitki zararlıları segmente edilip, ardından arka plan elimine edilmiştir.

U-Net mimarisi (Ronneberger vd., 2015), görüntü segmentasyonu ve genel görüntülerde arka plan segmentasyonu gibi görevler için tasarlanmış bir CNN'dir. Kodlayıcı (encoder) ve çözücü (decoder) olmak üzere iki ana bileşenden oluşur. Kodlayıcı, görüntünün özellik haritasını oluşturan evrişim katmanlarından oluşurken, çözücü, özellik haritasını girdi görüntüsünün boyutlarına geri dönüştüren evrişim ve dekonvolüsyon katmanlarından oluşur. Kodlayıcıdaki evrişim işlemleri boyunca görüntünün boyutları azalırken, çözücüdeki dekonvolüsyon işlemleriyle görüntünün boyutları tekrar artırılır. Hiyerarşik özellik çıkarma mekanizmasıyla U-Net, sınırlı açıklamalı verilerle bile hassas segmentasyon sonuçları elde ederek çeşitli bilgisayarlı görme uygulamalarında yaygın olarak kullanılmasını sağlar. U-Net mimarisi Şekil 2.4'te verilmiştir.

3. ÖNERİLEN DERİN ÖĞRENME TABANLI SINIFLANDIRMA YÖNTEMLERİ

Bu tez çalışması kapsamında, derin öğrenme alanında yaygın olarak kullanılan önceden eğitilmiş çeşitli DNN'ler ile transfer öğrenimi yapılmıştır. Aynı zamanda, önceden eğitilmiş DNN'lerden elde edilen derin öznitelikler ile SVM sınıflandırıcısından yararlanılmıştır. Bu yaklaşım, öznitelik çıkarma ve sınıflandırma süreçlerini bir araya getirerek, veri setinin karmaşıklığını ele almak için etkili bir yöntem olmuştur. Ayrıca görüntü transformatörü olarak bilinen transformatör mimarisini kullanan bir sinir ağı modeli de kullanılmıştır. Son yöntem olarak, birden fazla modelden gelen tahminleri birleştirerek daha güçlü ve daha doğru tahminler elde etmeyi amaçlayan bir yaklaşım olan topluluk öğrenimi, yukarıdaki üç farklı yöntemden en iyi performans gösteren modelleri birleştirmek için kullanılmıştır.

3.1. Önceden Eğitilmiş Derin Sinir Ağları


DNN, birçok doğal sinyalin daha yüksek seviyeli öznitelikler elde etmek için düşük seviyeli özniteliklerin birleştirilmesinden faydalanır. Nesne tanıma, yüz tanıma, nesne tespiti, dil işleme ve özellikle görüntü tanıma ve sınıflandırma gibi görsel veri işleme problemlerinde çeşitli çalışmalarca başarısını kanıtlamış olan CNN, derin öğrenme alanındaki en önemli ağlardan biridir (Sze vd., 2017). CNN mimarisinin temel yapısı giriş katmanı, evrişim katmanı, RELU katmanı, havuzlama katmanı, tam bağlantılı katman ve çıkış katmanlarından oluşur.

Başlangıçta, ham veri seti doğrudan bir görüntünün piksel değerleri olarak girildiği giriş katmanına girilir. Evrişim katmanında, öznitelik haritası olarak da bilinen bir aktivasyon haritası üretmek için girişe belirli bir filtre uygulanır. Bu harita, bir görüntüdeki kenarlar veya dokular gibi girdide algılanan belirli özelliklerin konumlarını vurgular. Her evrişim işleminin ardından bir ReLU aktivasyon fonksiyonu uygulanır. Bu fonksiyon, ağıın görüntüdeki özellikler arasındaki doğrusal olmayan ilişkileri öğrenmesine yardımcı olur ve böylece ağı farklı örüntüleri tanımlamak için daha sağlam hale getirir. Havuzlama katmanı daha sonra alt örnekleme gerçekleştirerek, temel bilgileri korurken öznitelik haritalarının boyutunu azaltır. Genellikle maksimum havuzlama yoluyla yürütülen bu süreç, hesaplama yükünü azaltır, verimliliği artırır ve aşırı uyum risklerini azaltır. Havuzlamanın evrişimden sonra uygulanması, CNN'nin girdi verilerinden önemli öznitelikleri etkili bir şekilde çıkarmasını ve özetlemesini sağlayarak

görüntü tanıma ve sınıflandırma gibi görevlerde performansı artırır. Mimari daha fazla katmanla derinleştikçe ağ, girdi verilerinden farklı özellikleri daha iyi çıkarabilir ve öğrenebilir, böylece sınıflandırma doğruluğu artar (Gu vd., 2018).

Tamamen bağlı katmanda tüm özellik haritaları girdi olarak birbirine bağlanır. Genel olarak, sonraki katmandaki nöronların düğümleri, bir önceki katmandaki nöronların düğümlerine bağlanır, ancak her katmandaki düğümlerin bağlantısı yoktur. Bu katman, çeşitli koşullar için bir olasılık elde etmek amacıyla önceki evrişimlerin soyutlanmış özelliklerini entegre eder ve normalleştirir. Son olarak çıkış katmanında ise nöron sayısı gerekli koşullara göre ayarlanır. Sınıflandırma gerekiyorsa nöron sayısı genellikle sınıflandırılacak kategori sayısı ile ilişkilidir (Khan vd., 2018).

Her katmanla birlikte CNN'nin karmaşıklığı artar ve görüntünün daha büyük bölümleri tanımlanır. Önceki katmanlar renkler ve kenarlar gibi basit özelliklere odaklanır. Görüntü verileri CNN'in katmanları boyunca ilerledikçe, amaçlanan nesneyi nihayet tanımlayana kadar nesnenin daha büyük öğelerini veya şekillerini tanımaya başlar. Şekil 3.1'de CNN mimarisinin basit yapısı verilmiştir.




Şekil 3.1. CNN mimarisinin basit yapısı

ImageNet, 1 milyonun üzerinde görüntü ve 1000 sınıftan oluşan geniş kapsamlı bir veri setidir. Görüntüler, köpekler, kediler, arabalar, ağaçlar gibi çok çeşitli kategorilere ayrılmıştır. ILSVRC yarışmasında, ImageNet veri seti kullanılarak en iyi görüntü sınıflandırma ve nesne algılama modelleri belirlenmiş aynı zamanda sinir ağlarının performansını artırmak ve genelleme yeteneklerini geliştirmek için kullanılmıştır (Krizhevsky vd., 2017). Çalışmada ImageNet veri seti üzerinde eğitilmiş farklı ağlar kullanılmıştır. Kullanılan önceden eğitilmiş ağlar hakkında detaylı bilgiler alt bölümlerde verilmiştir.

3.1.1. ResNet

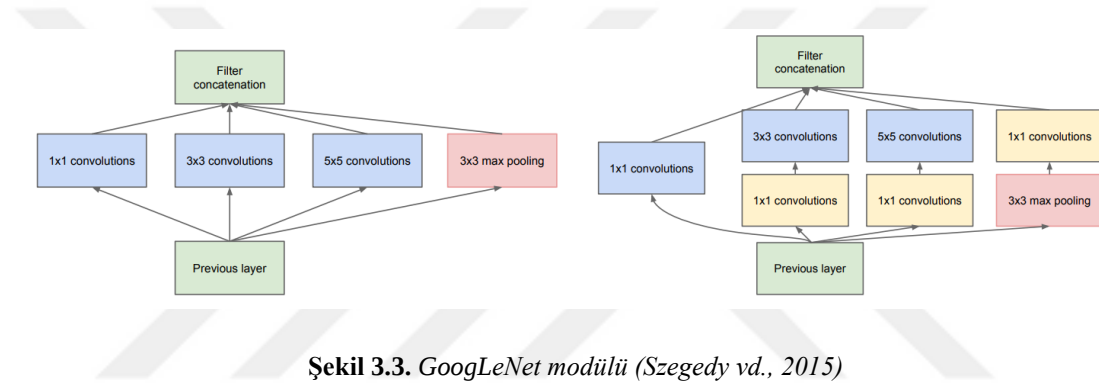
ResNet (He vd., 2016), verilerin eğitimini kolaylaştırmak için oluşturulan bir sinir ağıdır. Genel olarak, ResNet mimarisinin bileşenleri öncelikle başlangıç katmanı, genellikle bir evrişim katmanı ve ardından bir normalizasyon katmanı bulunur. Son katmanlar havuzlama ve tam bağlantılı katmanlar ise sınıflandırma için kullanılır. Artık bloklar (Residual blocks), ResNet'in temel yapı taşlarıdır. Artık bloklar, kestirme bağlantılar (shortcut connections) kullanarak girişin çıktıya doğrudan eklenmesini sağlar. Bu kestirme bağlantılar sayesinde, özellikle çok derin ağlarda gradyanların kaybolmasını önler ve öğrenmeyi kolaylaştırır. ResNet'in farklı versiyonları vardır, en yaygın olanları ResNet-18, ResNet-34, ResNet-50, ResNet-101 ve ResNet-152'dir. Bu çalışmada, önceden eğitilmiş 72 alt katmanlı ResNet-18 ve 347 alt katmana sahip olan ResNet-101 modelleri kullanılmıştır. ResNet görüntü boyutları 224x224 şeklindedir. Mimarisi Şekil 3.2'de verilmiştir.



Şekil 3.2. ResNet tarafından VGG-19'dan ilham alan 34 katmanlı düz ağ mimarisi (He vd., 2016)

3.1.2. GoogLeNet

2015 yılında Christian Szegedy ve arkadaşları (Szegedy vd., 2015) tarafından, görüntü sınıflandırma ve tespit için tasarlanmış bir CNN modelidir. GoogLeNet, 22 katman derinliğinde bir transfer öğrenme modelidir. Bu mimarinin ana ayırt edici özelliği, ağ içindeki bilgi işlem kaynaklarının gelişmiş kullanımıdır. Bu kaynaklar hesaplama bütçesini sabit tutarken ağı derinliğini ve genişliğini artırmaya izin veren bir tasarıma sahiptir. Model, görüntü sınıflandırma, nesne tespiti ve nesne tanıma gibi görsel görevlerde kullanılabilir. GoogLeNet'in görüntü boyutları 224x224 şeklindedir. Mimarisi Şekil 3.3'te verilmiştir.



3.1.3. DenseNet


DenseNet (Huang vd., 2017), her katmanın önceki tüm katmanlardan girdi aldığı ve çıktılarını sonraki tüm katmanlara aktardığı, özellik yayılımını ve gradyan akışını geliştiren, yoğun bağlantısıyla bilinen derin evrişimli bir sinir ağıdır. Bu mimari, verimli parametre kullanımına izin verir ve yok olan gradyan sorununu azaltarak daha derin ağların eğitimini kolaylaştırır. Bu çalışmada kullanılan model DenseNet-201, 201 katman derinliğine ve 224×224 görüntü giriş boyutuna sahiptir. Geniş bir görüntü yelpazesi için öğrenilmiş zengin özellik temsillerine sahiptir. Önceden eğitilmiş DenseNet modelleri, çeşitli görevlerde güçlü temel performanslarından yararlanarak transfer öğrenimi için yaygın olarak kullanılır. DenseNet mimarisi Şekil 3.4'te verilmiştir.

Layers	Output Size	DenseNet-121	DenseNet-169	DenseNet-201	DenseNet-264
Convolution	112×112	7×7 conv, stride 2			
Pooling	56×56	3×3 max pool, stride 2			
Dense Block (1)	56×56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56×56	1×1 conv			
	28×28	2×2 average pool, stride 2			
Dense Block (2)	28×28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28×28	1×1 conv			
	14×14	2×2 average pool, stride 2			
Dense Block (3)	14×14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 64$
Transition Layer (3)	14×14	1×1 conv			
	7×7	2×2 average pool, stride 2			
Dense Block (4)	7×7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 32$	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 48$
Classification Layer	1×1	7×7 global average pool			
		1000D fully-connected, softmax			

Şekil 3.4. DenseNet mimarisi (Huang vd., 2017)

3.1.4. NASNet-Large


NASNet-Large (Zoph vd., 2018), sınıflandırma uygulamalarında yüksek performans elde etmek ve aynı zamanda hesaplama açısından verimli olmak için tasarlanmış otomatik olarak oluşturulmuş bir derin sinir ağıdır. Belirli bir sırayla tekrarlanan çok sayıda normal ve indirgeme hücresinden oluşur. Her hücre, NAS işlemi sırasında optimize edilen evrişimler, havuzlama ve doğrusal olmayan aktivasyonlar gibi birden fazla işlemde oluşur. Görüntü tanıma görevleri için yüksek verimli ve doğru bir model oluşturmak amacıyla NAS'tan yararlanarak otomatik sinir mimarisi tasarımında önemli bir ilerleme sağlamaktadır. NASNet-Large'ın çok sayıda parametresi vardır (yaklaşık 88 milyon), bu da onun yüksek doğruluğuna katkıda bulunur. NASNet-Large, 331x331 piksel boyutundaki giriş görüntülerini işlemek üzere tasarlanmıştır. Mimarisi Şekil 3.5'te verilmiştir.



Şekil 3.5. NASNet-Large mimarisi (Zoph vd., 2018)

3.1.5. VGGNet


VGGNet (Simonyan ve Zisserman, 2014), K. Simonyan ve A. Zisserman tarafından sunulan, katmanları boyunca küçük 3x3 evrişimli filtreler kullanan bir evrişimli sinir ağıdır. Bu sinir ağının belirgin özelliği, ağ yapısının diğer modellere göre çok daha derin olmasıdır. VGGNet, 16 veya 19 katmanlı VGG-16 ve VGG-19 isimli iki farklı versiyona sahiptir. VGG-16’da 13 evrişim katmanı ve 3 tam bağlantılı katman bulunurken, VGG-19’da ise 16 evrişim katmanı ve 3 tam bağlantılı katman yer almaktadır. VGGNet görüntü boyutları 224x224 şeklindedir. VGG-16 mimarisi Şekil 3.6’da verilmiştir.



Şekil 3.6. VGG-16 mimarisi (Tammina, 2019)


3.2. Transfer Öğrenme

Derin öğrenme tabanlı yaklaşımların doğruluğu veri setinin büyüklüğü ile doğru orantılıdır. Eğitim verilerinin toplanması bazen pahalı veya zor olabilir. Bu nedenle, farklı alanlardan daha kolay elde edilen verilerle eğitilmiş, yüksek performanslı modeller oluşturmaya ihtiyaç duyulabilir. Bu yaklaşım, transfer öğrenme olarak adlandırılmaktadır (Torrey ve Shavlik, 2010). Transfer öğrenme, bir makine öğrenimi yöntemidir. Bu yöntemde, önceden eğitilmiş bir model, birçok veri setinde kullanılabilir ve bu modelin öğrendiği öznelilikler, diğer görevlerde de faydalı olabilir. Bu nedenle, önceden eğitilmiş modeldeki bazı katmanlar, yeni görev için yeniden eğitilir veya önceden eğitilmiş modelden bazı öznelilikler alınarak yeni bir model oluşturulur. Bu yaklaşım, model eğitimi sırasında zaman ve kaynak tasarrufu yaparak genellikle daha iyi sonuçlar elde edilmesini sağlar. Transfer öğrenme, daha az eğitim verisi kullanılarak bile yüksek performans elde edilebilmesine olanak sağlar. Segmentasyon, nesne tanıma, sınıflandırma gibi çeşitli uygulamalar, önceden eğitilmiş ağlar yardımıyla transfer öğrenme kullanılarak gerçekleştirilebilir. Transfer öğrenimi akış şeması Şekil 3.7’de verilmiştir.



Şekil 3.7. Transfer öğrenimi akış şeması

Bu çalışmada transfer öğrenimi yapılması için öncelikle girdi görüntüsü boyutları kullanılan ağların gerektirdiği boyutlara indirgenmiştir. Ağın son iki katmanı kullanılan veri setine uygun olarak yenileri ile değiştirilmiştir. Sırasıyla Li ve D0 veri seti için, tam bağlantılı katmandaki sınıf sayıları 10 ve 40 olarak ayarlanmıştır. Çalışmada kullanılan transfer öğrenme mimarisi Şekil 3.8’de verilmiştir.




Şekil 3.8. Çalışmada kullanılan transfer öğrenme mimarisi

3.3. Destek Vektör Makinesi


SVM (Cortes ve Vapnik, 1995), iki gruplu sınıflandırma problemleri için kullanılan denetimli bir makine öğrenme algoritmasıdır. Özellikle yüksek boyutlu alanlarda etkili olup sağlamlığı ve doğruluğu ile tanınır. SVM, iki sınıfı ayırmak için bir hiper düzlem kullanır. Bu hiper düzlem, $w \cdot x + b = 0$ denklemi ile tanımlanır. w : Ağırlık vektörü (weight vector), x : Özellik vektörü (feature vector), b : Bias terimi (bias term)'dir. Yüksek boyutlu bir uzayda farklı sınıflara ait veri noktalarını ayıran en uygun hiper düzlemi bularak, her sınıfın en yakın noktaları (destek vektörleri) arasındaki mesafe (margin) maksimuma çıkararak çalışır. SVM'in amacı margin'i maksimize etmek için $\|w\|$ 'yi en aza indirmektir. Amaç fonksiyonu $\min_{w,b} \frac{1}{2} \|w\|^2$, SVM'in iki sınıfı en iyi şekilde ayıran hiper düzlemi bulmasına yardımcı olur. Bu fonksiyon, marjini maksimize ederek modelin genelleme kabiliyetini artırır ve daha sağlam bir sınıflandırma sağlar.

Doğrusal, polinom ve radyal temel fonksiyon çekirdekleri gibi çeşitli çekirdek fonksiyonlarını kullanarak doğrusal ve doğrusal olmayan sınıflandırmayı yönetebildikleri için çok yönlüdürler. SVM sınıflandırma örneği Şekil 3.9'da verilmiştir. Algoritmanın aşırı uyumdan kaçınarak karmaşık, yüksek boyutlu veri kümelerini işleme yeteneği sayesinde metin ve görüntü sınıflandırması, biyoinformatik ve daha fazlası dahil olmak üzere çeşitli alanlarda kullanılmaktadır.



Şekil 3.9. SVM sınıflandırma örneği (Meyer ve Wien, 2001)


Bu çalışmada kullanılan ikinci yaklaşımda, önceden eğitilmiş DNN'lerin çeşitli katmanlarından elde edilen derin öznitelikler ile SVM sınıflandırıcısı kullanılmaktadır. Önceden eğitilmiş ağların ara katmanlarından çıkarılan sığ öznitelikler, verinin temel özniteliklerini temsil eder. Bu öznitelikler genellikle düşük seviyeli, basit ve yerel öznitelikleri içerir. Önceden eğitilmiş ağların son katmanından çıkarılan derin öznitelikler ise, daha karmaşık ve soyut düzeyde veri özniteliklerini temsil eder. Bu öznitelikler genellikle daha yüksek seviyeli anlam taşırlar. Derin katmanlar, daha önceki katmanların alt düzey özniteliklerini kullanarak daha yüksek seviyeli öznitelikleri oluşturur. Şekil 3.10'da önerilen ilk iki yaklaşıma ait derin öğrenme tabanlı sınıflandırma modellerinin akış şeması verilmiştir.



Şekil 3.10. Önerilen modelin akış şeması

3.4. ViT


ViT (Vision Transformer), görüntü girişlerini özellik vektörlerine kodlamak için transformatör mimarisini kullanan bir sinir ağı modelidir. Ağ iki ana bileşenden oluşur: omurga ve kafa. Omurga, ağın kodlama adımından sorumludur. Omurga, giriş görüntülerini alır ve bir özellik vektörünün çıktısını alır. Tahminlerin yapılmasından kafa bölümü sorumludur ve kodlanmış özellik vektörlerini tahmin puanlarıyla eşleştirir. ViT ölçeklenebilirlik ve esneklik açısından avantajlara sahiptir. Daha fazla katman ve daha büyük parça boyutlarıyla ölçeklendirilebilir; bu da daha büyük veri kümeleri ve bilgi işlem kaynaklarıyla önemli iyileştirmeler gösterir ve önemli mimari değişikliklere gerek kalmadan farklı görüntü boyutlarına ve görevlere kolayca uyarlanabilirler (Dosovitskiy vd., 2020). Şekil 3.11’de ViT mimarisi verilmiştir.



Şekil 3.11. ViT mimarisi


3.5. Topluluk Öğrenme

Topluluk öğrenimi, daha iyi tahmin performansı üretmek için birden fazla modeli birleştiren, tek modelli yaklaşımlara göre doğruluk ve sağlamlık açısından önemli avantajlar sunan güçlü bir tekniktir (Zhang ve Ma, 2012). Bir oylama topluluğunda, farklı modeller bağımsız olarak eğitilir ve tahminlerinde çoğunluk oylaması veya ağırlıklı oylama kullanılabilir. Birden fazla modeli birleştirerek, topluluk yöntemleri genellikle bireysel modellerden daha yüksek doğruluk elde eder. Topluluk öğrenimi, temelde torbalama (bagging), yığma (stacking) ve artırma (boosting) şeklinde üç ana yöntemle gerçekleştirilir. Bu yöntemler, farklı modellerin tahminlerini birleştirerek daha iyi genelleştirilmiş sonuçlar elde etmeyi hedefler. Torbalama yöntemi, veri setinin rastgele örnekleri alınarak birden fazla model eğitilir ve bu modellerin tahminleri birleştirilir. Makine öğreniminde kullanılan topluluk öğrenme yöntemlerinden biri olan rastgele ormanlar, torbalama yönteminin en bilinen örneklerinden biridir. Bu yaklaşım, her bir modelin hata payını azaltarak genel performansı artırır (Breiman, 1996). Şekil 3.12’de çoğunluk oylama ile birleştirilen torbalama yönteminin yapısı verilmiştir.




Şekil 3.12. Çoğunluk oylama ile birleştirilen torbalama yöntemi yapısı

Yığma yöntemi, farklı türdeki modelleri birleştirir. İlk olarak, farklı modeller aynı veri seti üzerinde eğitilir ve her bir modelin tahminleri bir araya getirilir. Daha sonra, bu tahminler, bir başka model tarafından tekrar eğitilir ve birinci seviyedeki modellerin tahminlerini girdi olarak kullanarak sonuncu tahmini yapar. Bu yaklaşım, farklı model türlerinin güçlü yönlerini bir araya getirerek daha doğru tahminler elde etmeyi sağlar (Wolpert, 1992). Şekil 3.13'te yığma yönteminin yapısı verilmiştir.




Şekil 3.13. Yığma yöntemi yapısı

Artırma yöntemi, zayıf modelleri ardışık olarak eğitir. Her yeni model, bir önceki modelin hatalarını düzelterek daha iyi tahminler yapmayı amaçlar ve her bir adımda model performansını sürekli iyileştirerek güçlü bir topluluk modeli oluşturur. AdaBoost ve Gradient Boosting artırma yönteminin yaygın örneklerindendir (Freund ve Schapire, 1996). Şekil 3.14'te artırma yönteminin yapısı verilmiştir.



Şekil 3.14. Artırma yöntemi yapısı

Bu çalışmada, çoğunluk oylama yöntemini kullanarak transfer öğrenmeden, SVM'den, derin özniteliklerden ve ViT modellerinden elde edilen sonuçları birleştiren topluluk öğrenmesi kullanılmıştır. Önerilen modellerin akış şeması Şekil 3.15'te gösterilmektedir.



Şekil 3.15. Önerilen modelin akış şeması

4. DENEYSEL ÇALIŞMALAR

Önerilen modellerin performanslarının değerlendirilebilmesi için kapsamlı deneysel çalışmalar gerçekleştirilmiştir. Tüm deneylerde doğruluk (Acc, ing. accuracy), kesinlik (Pre, ing. precision), duyarlılık (Rec, ing. recall) ve F1 skoru gibi standart değerlendirme ölçütleri kullanılmıştır. Bu ölçütler, her modelin sınıflandırma yeteneğini farklı açılardan değerlendirerek güvenilir bir karşılaştırma yapılmasına olanak sağlamaktadır. Deneyler; yüksek performanslı bir Intel(R) Core (TM) i7-7700HQ, 2.80GHz işlemci ve 16 GB RAM'e sahip bilgisayar ortamında ve veri analizi, görselleştirme ve modelleme gibi uygulamalar için tasarlanmış bir programlama aracı olan MATLAB 2024a kullanılarak gerçekleştirilmiştir.

Deneysel çalışmalar için tarlalarda yaygın bulunan ve mahsul verimini etkileyen bitki zararlılarının görüntülerinden oluşan orijinal 10 sınıflı Li ve 40 sınıflı D0 veri setlerindeki görüntüler, %70 eğitim ve %30 test olmak üzere iki farklı alt gruba ayrılmıştır. Eğitim alt grubu, verilerin öğrenme süreci için ve test alt grubu ise sadece performans ölçümü için kullanılmıştır. Önerilen modellerin performansları, Li veri seti için Tablo 4.1'de ve D0 veri seti için Tablo 4.2'de sunulmuştur. Tablolarda, her bir modelin Li ve D0 veri setlerindeki Acc, Pre, Rec ve F1 skorları yer almaktadır. En yüksek performansa sahip model kalın olarak işaretlenmiştir. Bu sonuçlar baz alınarak, orijinal görüntülerde en yüksek F1 skora sahip yöntem belirlenmiş, daha sonra çeşitli görüntü ön işleme yöntemlerinin performanslarının karşılaştırılması için kullanılmıştır.

Tablo 4.1. Önerilen modellerin orijinal Li veri setindeki performansları (Acc/Pre/Rec/F1)

Önceden Eğitilmiş Ağ	Transfer Öğrenme	SVM ile Derin Öznitelikler	SVM ile Sığ Öznitelikler
GoogLeNet	94.89/94.82/94.50/94.66	92.78/92.52/92.51/92.51	80.34/79.18/78.52/78.85
ResNet-101	95.91/95.69/95.60/95.65	94.89/94.56/94.66/94.61	94.66/94.42/94.33/94.37
ResNet-18	94.77/94.53/94.36/94.44	91.93/91.79/91.33/91.56	91.36/91.45/90.78/91.11
VGG-16	93.86/93.62/93.46/93.62	91.88/91.52/91.15/91.34	90.68/89.92/90.25/90.08
VGG-19	94.49/94.20/93.99/94.09	92.67/92.28/92.12/92.20	89.43/89.05/88.89/88.97

Tablo 4.1 incelendiğinde, önerilen modellerin sınıflandırma sonuçlarına göre her bir performans ölçütü için en yüksek performans ResNet-101 ağı ile transfer öğrenme yöntemi kullanılarak elde edilmiştir. Benzer şekilde, bu veri seti üzerinde kullanılan tüm önceden eğitilmiş ağlar için kullanılan yöntemler karşılaştırıldığında ise transfer

öğrenmenin diğer iki yönteme kıyasla daha iyi performans gösterdiği gözlemlenmiştir. Bu çerçevede, ikinci aşama olan farklı ön işleme yöntemleriyle gerçekleştirilen tüm deneylerde, önceden eğitilmiş ağ olarak ResNet-101'in kullanılmasına karar verilmiştir. Bu seçim, modelin genel başarı oranını artırmak ve güçlü bir temel öğrenme yeteneği sağlamak amacı ile yapılmıştır.

Tablo 4.2. Önerilen modellerin orijinal D0 veri setindeki performansları (Acc/Pre/Rec/F1)


Önceden Eğitilmiş Ağ	Transfer Öğrenme	SVM ile Derin Öznitelikler	SVM ile Sığ Öznitelikler
GoogLeNet	99.41/99.37/99.36/99.37	98.89/98.95/98.84/98.89	98.89/98.95/98.84/98.89
ResNet-101	99.56/99.57/99.59/99.58	99.41/99.45/99.43/99.43	99.41/99.49/99.33/99.41
ResNet-18	99.33/99.46/99.30/99.38	98.74/98.61/98.57/98.59	98.74/98.61/98.57/98.59
VGG-16	99.26/99.06/99.27/99.16	97.78/98.02/97.62/97.82	98.30/98.32/98.28/98.30
VGG-19	98.96/99.01/98.95/98.98	98.15/98.28/98.12/98.20	98.74/98.70/98.60/98.65

Tablo 4.2 incelendiğinde, D0 veri seti üzerinde yapılan deneylerde de Tablo 4.1'dekine benzer bir sonuç elde edilmiştir. Bu sonuç, ResNet-101 ağının D0 veri setindeki öznitelikleri de diğer ağlardan daha etkili bir şekilde çıkarabildiğini ve genelleme yeteneğinin diğer mimarilere göre daha güçlü olduğunu göstermiştir. Sonuç olarak, Tablo 4.1 ve Tablo 4.2, her iki veri setinde de ResNet-101 ağının transfer öğrenme ve SVM ile sınıflandırma sürecinde diğer ağlara kıyasla belirgin olarak daha üstün bir performans sağladığını ortaya koymaktadır. Bu sonuç, farklı ön işleme yöntemlerinin performansa etkisini ölçmek için yapılacak olan deneylerde ResNet-101'in tercih edilmesine sebep olmuştur. Ayrıca, aynı yöntemin sabit kalması, daha sonraki deneyler sırasında değişkenlikleri minimize ederek daha güvenilir ve başarılı sonuçlar elde etme olasılığını artırmaktadır.

Deneylerde hiper parametrelerin doğru ayarlanması, modelin en iyi sonuçları elde etmesi açısından kritik öneme sahiptir. Hiper parametre ayarları, modelin öğrenme sürecini ve performansını etkileyen önemli faktörlerdir. Çalışmada maksimum adım sayısı 5 ile 30 arasında ayarlanmıştır. Öğrenme oranı ve mini-batch boyutu sırasıyla 0.001 ve 64 olarak ayarlandığında modellerin en iyi sonuçları verdiği görülmüştür. Bu nedenle, kullanılan yaklaşımların etkisini değerlendirmek için yapılan diğer deneylerde parametreler bu değerlerde sabit tutulmuştur.

Derin öğrenme modelleri genellikle kullanılan ağın ne öğrendiğini ve ağa verilen girdinin hangi kısmının çıktısı sınıfından sorumlu olduğunu belirtmez. Bunu öğrenebilmek ve kullanılan ağların tahminlerine görsel açıklamalar getirmek için kullanılabilecek tekniklerden biri sınıf aktivasyon haritalamadır. Sınıf aktivasyon haritalama, eğitim setindeki ön yargıyı belirlemek ve model doğruluğunu artırmak amacıyla da kullanılmaktadır. Eğer ağın tahminleri yanlış özelliklere dayandırıldığı keşfedilirse, veri seti üzerinde değişiklik yapılarak ağ daha sağlam hale getirilebilir.

Şekil 4.1, orijinal Li ve D0 veri setlerinde, çeşitli sınıflara ait ResNet-101 ağı ile elde edilen sınıf aktivasyon haritalarını göstermektedir. Burada kırmızı bölgeler tahmin edilen sınıfa en çok katkıda bulunan bölgelerdir.



Şekil 4.1. Kullanılan veri setlerine ait örnek görüntülerdeki ResNet-101 aktivasyon haritası (a) Li, (b) D0

Tablo 4.3'te seçilen ağın performansını daha da artırmak için kullanılan çeşitli veri ön işleme yöntemleri ve sonuçları verilmiştir. Bu aşamada, veri seti öncelikle çeşitli ön işleme adımlarından geçirilmiş olup bunlar; görüntüden G kanalının çıkarılması, veri artırımı, histogram eşitleme, segmentasyon ile arka plan elimine etme ve kombinasyonları şeklindedir. Ön işleme aşamasında elde edilen görüntüler ResNet-101 ağı ile transfer öğrenme kullanılarak elde edilen modele girdi olarak verilmiştir. Sonrasında model eğitim görüntüleri ile eğitilmiştir. Veri ön işleme adımları, modelin daha etkili bir şekilde öğrenmesine ve genel performansını artırmaya yönelik çeşitli işlemleri içermektedir. Histogram eşitleme kontrastı artırırken, veri artırımı, modelin çeşitli açılardan öğrenme yeteneğini artırarak aşırı uyuma karşı daha dirençli bir yapı oluşturmaktadır.

Tablo 4.3. ResNet-101 ile farklı ön işleme yöntemleri ile elde edilen performansları (Acc/Pre/Rec/F1)

Ön İşleme Yöntemi	Li Veri Seti	D0 Veri Seti
RGB (Orijinal)	95.91/95.69/95.60/95.65	99.56/99.57/99.59/99.58
G Kanalı Çıkarımı	92.73/92.33/92.33/92.33	98.96/98.80/98.83/98.82
Veri Artırımı	96.36/96.19/95.91/96.06	99.63/99.68/99.67/99.68
Histogram Eşitleme	94.83/94.52/94.30/94.41	99.19/99.26/99.28/99.27
Histogram Eşitleme+Veri Artırımı	95.17/95.01/94.65/94.83	99.26/99.34/99.35/99.34
Segmentasyon ile Arka Plan Eliminasyonu	93.30/93.10/92.86/92.98	98.52/98.61/98.30/98.46
Veri Artırımı+Segmentasyon ile Arka Plan Eliminasyonu	93.58/93.52/92.74/93.13	98.74/98.74/98.52/98.63

Tablo 4.3 incelendiğinde, RGB görüntüler üzerindeki orijinal veri seti kullanıldığında sonuç ile kıyaslandığında, G kanalının yeterli performans gösteremediği görülmektedir. Bu durum, yeşil renk kanal çıkarımının tek başına görüntü verilerini yeterince temsil etmekte yetersiz kaldığını işaret etmektedir. Buradan modelin öznetelik çıkarımı ve sınıflandırma yeteneğini sınırladığı sonucuna varılmıştır. Histogram eşitleme orijinal veri setindeki sonuç ile yakın performans göstermiştir. Bu yöntemin renk bilgisi ve öznetelik çıkarımı süreçlerinde etkili olduğunu ortaya koymaktadır. Histogram eşitleme, görüntünün kontrastını artırarak daha belirgin özelliklerin ortaya çıkmasına olanak tanır ve daha doğru ve ayrıntılı özneteliklerin elde edilmesine katkı sağlar. Arka plan eliminasyonunun orijinal veri setindeki sonuç ile kıyaslandığında daha başarısız olduğu gözlemlenmiştir. Burada kullanılan iki aşamalı yaklaşımda, öncelikle U-net kullanılarak bitki zararlıları arka plandan ayrılmış, ilk aşama olan segmentasyon aşamasından elde edilen zararlı görüntüleri kullanılarak sınıflandırma aşamasına geçilmiştir. Bu yaklaşımın performansı, zararlı segmentasyonunun doğruluğuna ve modelin bu segmente edilmiş verilerden öğrenme yeteneğine bağlıdır. Arka plan eliminasyonunda kullanılan segmentasyon yönteminin görüntüyü maskeleyerek zararlı ve arka planın benzer olması sebebiyle yanıltıcı maskelemeler yaptığı görülmüştür. Ayrıca bazı zararlı türlerinin sınıflandırılmasında arka plan bilgisinin önemli olabileceği değerlendirilmiştir. Örneğin belirli zararlı türlerinin sadece belirli bitki türlerinde bulunması ve bu bitkilerin varlığı zararlıların sınıflandırılmasında yardımcı olabilir. Arka planı tamamen kaldırmak, bu tür bir bilgi kaybına yol açarak sınıflandırma performansını olumsuz etkileyebilmektedir. Veri artırımı ile veri setleri çeşitli yansıtma, döndürme yöntemleri ile üç kat artırılmıştır ve modelin performansı üzerinde olumlu

olarak belirgin bir etkisi olduğu gözlemlenmiştir. RGB görüntü üzerinde uygulanan veri artırımının her iki veri setinde de en yüksek başarı sonuçlarını elde etmede etkili olduğu tespit edilmiştir. Sonuç olarak, bu çalışma, ResNet-101 ağıyla birleştirilen belirli ön işleme yöntemlerinin, özellikle RGB görüntü üzerinde uygulanan veri artırımının, bitki zararlısı sınıflandırma modelinin performansını artırmada önemli bir rol oynayabileceğini göstermiştir. Bu sonuçlar, bitki zararlılarının etkili bir şekilde sınıflandırılması için uygun ön işleme stratejilerinin seçilmesinin önemini vurgulamıştır.

Ön işleme yöntemleri ile çeşitlendirilmiş veri setleri sonuçlarına bakıldığında veri artırımın daha iyi performans gösterdiği tespit edilmiştir. Daha sonraki deneylerde veri artırımı yapıldıktan sonra, ResNet-101 ağına yanı sıra literatürde yüksek performans göstermiş olan NASNet-Large, GoogLeNet ve DenseNet-201 ağları kullanılmıştır. Bunlara ek olarak ViT mimarisi kullanılmıştır. Veri artırımı sonrası elde edilen en yüksek sonuçlar kalın olarak işaretlenerek Tablo 4.4 ve Tablo 4.5'te verilmiştir.

Tablo 4.4. Veri artırımı sonrası modellerin Li veri setindeki en iyi performansları (Acc/Pre/Rec/F1)

Önceden Eğitilmiş Ağ	Transfer Öğrenme	SVM ile Derin Öznitelikler
ResNet-101	96.36/96.19/95.91/96.06	95.11/95.21/94.70/94.95
NASNet-Large	96.02/95.86/95.62/95.72	96.42/96.20/96.19/96.20
GoogLeNet	95.74/95.83/95.22/95.53	92.56/92.51/91.66/92.08
DenseNet-201	97.22/97.36/96.90/97.13	94.55/94.58/94.04/94.31
ViT	96.59/96.91/96.11/96.51	

Tablo 4.5. Veri artırımı sonrası modellerin D0 veri setindeki en iyi performansları (Acc/Pre/Rec/F1)

Önceden Eğitilmiş Ağ	Transfer Öğrenme	SVM ile Derin Öznitelikler
ResNet-101	99.63/99.68/99.67/99.68	99.48/99.52/99.45/99.49
GoogLeNet	99.70/99.68/99.67/99.68	99.70/99.68/99.67/99.68
NASNet-Large	95.78/95.45/94.90/95.17	97.93/98.10/97.79/97.95
DenseNet-201	99.70/99.68/99.67/99.68	99.56/99.53/99.54/99.54

En iyi performans gösteren modeller, sınıflandırma performansını daha da artırmak için çoğunluk oylama yoluyla topluluk öğrenimi kullanılarak birleştirilmiştir. Tablo 4.6'da veri artırımı sonrası modellerin Li veri setindeki performansların en iyileri ile topluluk öğrenme kombinasyonları elde edilmiştir. Performans sonuçları

incelendiğinde çoğunluk oylama ile Li veri setinde en yüksek doğruluk sonucu NASNet-Large ile derin öznitelikler, DenseNet-201 ile transfer öğrenme ve ViT modeli performansı çoğunluk oylama yoluyla birleştirilerek %98.35 doğruluk elde edilmiştir.

Tablo 4.6. Veri artırımı sonrası modellerin Li veri setindeki performansların en iyileri ile topluluk öğrenme kombinasyonları (Acc/Pre/Rec/F1)

Model	Performans
ResNet-101+NASNet-Large+GoogLeNet	97.22/97.01/96.90/96.95
ResNet-101+NASNet-Large+DenseNet-201	97.50/97.28/97.24/97.25
ResNet-101+NASNet-Large+ViT	97.90/97.62/97.63/97.62
ResNet-101+GoogLeNet+ViT	97.73/97.63/97.41/97.51
ResNet-101+DenseNet-201+ViT	98.13/98.05/97.84/97.93
ResNet-101+GoogLeNet+DenseNet-201	97.22/97.16/96.99/97.07
NASNet-Large+GoogLeNet+DenseNet-201	97.50/97.47/97.29/97.37
NASNet-Large+GoogLeNet+ViT	97.84/97.74/97.58/97.65
NASNet-Large+DenseNet-201+ViT	98.35/98.32/98.10/98.20
GoogLeNet+DenseNet-201+ViT	97.61/97.68/97.27/97.47

Tablo 4.7’de veri artırımı sonrası modellerin D0 veri setindeki performansların en iyileri ile topluluk öğrenme kombinasyonları elde edilmiştir. Performans sonuçları incelendiğinde çoğunluk oylama ile D0 veri setinde en yüksek iki doğruluk sonucu ResNet-101, GoogLeNet ve DenseNet-201 transfer öğrenme ve GoogLeNet DenseNet-201 ile transfer öğrenme, NASNet-Large ile derin öznitelikler performansı çoğunluk oylama yoluyla birleştirilerek %99.78 doğruluk elde edilmiştir.

Tablo 4.7. Veri artırımı sonrası modellerin D0 veri setindeki performansların en iyileri ile topluluk öğrenme kombinasyonları (Acc/Pre/Rec/F1)

Model	Performans
ResNet-101+GoogLeNet+NASNet-Large	99.63/99.63/99.62/99.62
ResNet-101+GoogLeNet+DenseNet-201	99.78/99.74/99.76/99.74
ResNet-101+NASNet-Large+DenseNet-201	99.63/99.63/99.62/99.62
GoogLeNet+NASNet-Large+DenseNet-201	99.78/99.74/99.76/99.74

5. SONUÇLAR VE TARTIŞMA

Bitki zararlılarını sınıflandırmak, karmaşık yapıları ve farklı türler arasındaki görünüm benzerlikleri nedeniyle zorlu bir iştir. Manuel gözlem hem yorucu hem de hataya açıktır ve önemli miktarda zaman tüketir. Mahsullerdeki böcek zararlılarının erken sınıflandırılması, özellikle mahsul hastalıklarına ve önemli ürün kayıplarına neden olan zararlıların yayılmasının önlenmesi açısından çok önemlidir.

Önerilen modellerin performansları kapsamlı bir şekilde analiz edilmiş ve bitki görüntülerinde zararlı tanıma alanında yapılan önceki çalışmalarla karşılaştırılmıştır. Karşılaştırma, sınıf ve görüntü sayısı, veri kümeleri, sınıflandırma yöntemleri ve performans ölçümleri gibi çeşitli hususlar dikkate alınarak gerçekleştirilmiştir. Karşılaştırmada, önerilen modellerin elde ettiği en yüksek performans dikkate alınmış ve güncel literatürdeki diğer çalışmaların sonuçlarıyla birlikte Tablo 5.1’de detaylandırılmıştır.

Tablo 5.1. Önerilen çalışmanın literatürde yer alan benzer çalışmalar ile karşılaştırması

Referans	Veri seti (#Sınıf, #Görüntü)	Ön İşleme Yöntemi	Model	Performans
(Xia vd., 2018)	Xie1 (24, 1440)	Veri artırımı	VGG-19	mAP: 89.22
(Thenmozhi ve Reddy, 2019)	D0 (40, 4508)	Veri artırımı	CNN	Acc: 95.97
	Xie1 (24, 1440)			Acc: 97.47
	NBAIR (40)			Acc: 96.75
(Li vd., 2020)	Li (10, 5869)	Veri artırımı Arka plan temizleme	GoogLeNet	Acc: 96.67
(Nanni vd., 2020)	IP102 (102, 75222)	Veri artırımı	CNN Belirginlik yöntemi	Acc: 61.93
	Deng (10, 563)			Acc: 92.43
(Yang vd., 2021)	Li (10, 5869)	Veri artırımı	STN (Spatial Transformer Networks) ResNet-50	Acc: 96.78
	IP102 (102, 75222)	Derin öznitelikler kendi oluşturdukları öznitelikler		Acc: 73.29
	Özel Veri Seti (58, 7344)	Veri artırımı		Acc: 96.50
(Nanni vd., 2022)	D0 (40, 4508)	Veri Artırımı	Ağırlıklandırma ile CNN Topluluk öğrenme	Acc: 99.81 Pre: 99.83 Rec: 99.77 F1: 99.71
	Deng (10, 563)			Acc: 95.52
	IP102 (102, 75222)			Acc: 74.11 Pre: 74.00 Rec: 74.00 F1: 73.00
(Peng vd., 2022)	D0 (40, 4508)	Veri Artırımı	Transformatör, CNN	Acc: 99.47
	IP102 (102, 75222)			Acc: 74.89
	Li (10, 5869)			Acc: 97.93
(Wang vd., 2023)	IP102 (102, 75222)	Veri artırımı	ConvNeXt ve SwinTransformer	Acc: 76.10
	D0 (40, 4508)			Acc: 98.50
	Insect (9, 2251)			Acc: 92.30
Önerilen Model	Li (10, 5869)	Veri artırımı	Çoğunluk Oylama ile Topluluk Öğrenimi	Acc: 98.35 Pre: 98.32 Rec: 98.10 F1: 98.20
	D0 (40, 4508)			Acc: 99.78 Pre: 99.74 Rec: 99.76 F1: 99.74

Literatürde pek çok çalışma, bitki görüntülerinin çeşitli veri setlerine odaklanmakta, çeşitli zararlı türleri ve sayıları, böcek tespiti, sınıflandırılması ve çeşitli yöntemler kullanılarak etiketlenmesi gibi farklı uygulama alanlarını ele almaktadır. Literatürde küçük veya büyük ölçekli farklı veri setleri ya çalışma öncesinde toplanmış ya da hazır veri setleri olmak üzere yaygın olarak Li, D0 ve IP102 veri setleri kullanılmaktadır. Ön işleme yöntemi olarak çoğunlukla veri artırımı seçilmektedir. Yöntem olarak ise derin öğrenme ve bilgisayarla görme alanında çeşitli teknikler kullanılmaktadır. Bu yöntemler arasında CNN, transfer öğrenme yöntemleri ve önceden eğitilmiş ağlar öne çıkmakta olup nesne tespiti ve tanıma, görüntü sınıflandırma, segmentasyon gibi işlemlerde verimlilik sağlamaktadır.

Bu çalışmada ilk olarak orijinal veri setinde yapılan deneyler baz alınarak model için en uygun özniteliklerin seçilmesi ve veri setinden kaynaklanan zorlukların giderilmesi ile her iki veri setinin de kalitesi artırılmıştır. Çalışmada histogram eşitleme, veri artırımı ve görüntünün G renk kanalı çıkarımı ve U-Net mimarisi kullanılarak segmentasyon ile arka planı elimine etme gibi ön işleme tekniklerinin bitki zararlısı tespit ve sınıflandırma performansına olan etkisi ölçülmüştür. Bu çalışmada, bitki zararlılarının tespiti ve sınıflandırılması için dört farklı yöntem incelenmiştir. İlk yöntemde, farklı ön işleme tekniklerinin, önceden eğitilmiş derin sinir ağlarının özniteliklerini kullanarak transfer öğrenme ile sınıflandırma performansını nasıl etkilediği araştırılmıştır. Ön işleme yöntemlerinden en yüksek performans veri artırım yöntemi ile elde edilmiştir. Tüm ön işleme yöntemlerinin performansını analiz etmek için eğitilmiş ResNet-101 ağı ile transfer öğrenme yöntemi kullanılmıştır. İkinci yöntemde ise, en iyi performansı gösteren veri artırımı yapılmış görüntüler, GoogLeNet, NASNet-Large ve DenseNet-201 gibi önceden eğitilmiş ağlarla transfer öğrenme uygulanmış ve bu ağlardan çıkarılan derin öznitelikler kullanılarak SVM sınıflandırıcısı ile sınıflandırma işlemi gerçekleştirilmiştir. Ayrıca, transformatör mimarisini kullanan bir derin öğrenme modeli olan ViT ile de sınıflandırma yapılmıştır. Son yöntem olarak ise önerilen çalışmada diğer çalışmalardan farklı olarak transfer öğrenme, derin öznitelikler ile SVM ve ViT mimarisi kullanılmış ve performansı daha da artırmak için çoğunluk oylama kullanılarak birleştirilmiştir. Bu kapsamlı yaklaşımın oldukça başarılı sonuçlar verdiği gözlenmiştir. Ayrıca literatürde incelediğimiz ve Li veri setini kullanan çalışmalar arasında en yüksek sonuca ulaşılmıştır.

Performans deęerlendirmesi aısından, nerdięimiz alıřma doęruluęun yanı sıra kesinlik, duyarlılık ve F1 puanı gibi metrikleri de iermektedir. Sınıflandırma performansını deęerlendirmek iin eřitli metrikler kullanılarak daha kapsamlı bir analiz saęlanmıřtır. Bu durum, nerdięimiz modellerin benzer alıřmaların oęundan daha kapsamlı olduęunu ortaya koymaktadır.

Derin renme tabanlı yntemlerin bitki zararlılarının tespiti ve kontrolne ynelik arařtırmalarının toplumu birok nemli řekilde etkileyebilme potansiyeli vardır: 1) Tarımsal Srdrlebilirlik ve evresel Etki: nerilen modellerin erken zararlı tespitinde yksek doęruluk oranlarına sahip olması, daha hedefe ynelik zararlı kontrol stratejilerine yol aabilir. Bu hassasiyet, geniř spektrumlu pestisitlerin kullanımını azaltarak tarımda kimyasal kullanımının azalmasına katkıda bulunur. Sonu olarak, tarımın evresel etkisi en aza indirilebilir, daha srdrlebilir uygulamalar teřvik edilir ve hedef dıřı trler ile ekosisteme verilen zarar azaltılır. 2) Ekonomik Faydalar ve Gıda Gvenlięi: Bcek zararlılarının etkili bir řekilde tespiti ve kontrol, rn veriminde artıřa ve tarımsal kayıpların azalmasına yol aabilir.

Gelecek alıřmalarda, daha geniř sınıf sayısına sahip eřitli veri setleri kullanılarak modelin genelleme kabiliyetinin artırılması hedeflenmektedir. Yeni nesil derin renme mimarileri ve geliřmiř transfer renme teknikleri ile performans iyileřtirmeleri ve hibrit modellerin etkinlięinin test edilmesi planlanmaktadır. Ek olarak, sınıflandırma srecinde hesaplama maliyetlerini azaltmak iin verimli algoritmalar ve donanım hızlandırma tekniklerinin de alıřılması planlanmaktadır.

KAYNAKÇA

- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24, 123-140.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20, 273-297.
- Deng, L., Wang, Y., Han, Z., & Yu, R. (2018). Research on insect pest image detection and recognition based on bio-inspired methods. *Biosystems Engineering*, 169, 139-148.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., & Houlsby, N. (2020). An image is worth 16x16 words: Transformers For Image Recognition at Scale. *arXiv preprint arXiv:2010.11929*.
- Freund, Y., & Schapire, R. E. (1996). Experiments with a new boosting algorithm. In *icml* (Vol. 96, pp. 148-156).
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770-778).
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4700-4708).
- Khan, S., Rahmani, H., Shah, S. A. A., Bennamoun, M., Medioni, G., & Dickinson, S. (2018). *A Guide to Convolutional Neural Networks for Computer Vision*.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Li, Y., Wang, H., Dang, L. M., Sadeghi-Niaraki, A., & Moon, H. (2020). Crop pest recognition in natural scenes using convolutional neural networks. *Computers and Electronics in Agriculture*, 169, 105174.
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, 3(1), 91-99.
- Meyer, D., & Wien, F. T. (2001). Support vector machines. *R News*, 1(3), 23-26.
- Nanni, L., Maguolo, G., & Pancino, F. (2020). Insect pest image detection and recognition based on bio-inspired methods. *Ecological Informatics*, 57, 101089.
- Nanni, L., Manfè, A., Maguolo, G., Lumini, A., & Brahmam, S. (2022). High performing ensemble of convolutional neural networks for insect pest image detection. *Ecological Informatics*, 67, 101515.
- Peng, Y., Wang, Y., 2022. CNN and transformer framework for insect pest classification. *Ecological Informatics*, 72.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-*

- assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18 (pp. 234-241). Springer International Publishing.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Sze, V., Chen, Y. H., Yang, T. J., & Emer, J. S. (2017). Efficient processing of deep neural networks: A tutorial and survey. *Proceedings of the IEEE*, 105(12), 2295-2329.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1-9).
- Tammina, S. (2019). Transfer learning using vgg-16 with deep convolutional neural network for classifying images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), 143-150.
- Thenmozhi, K., & Reddy, U. S. (2019). Crop pest classification based on deep convolutional neural network and transfer learning. *Computers and Electronics in Agriculture*, 164, 104906.
- Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* (pp. 242-264). IGI Global.
- Wang, C., Zhang, J., He, J., Luo, W., Yuan, X., & Gu, L. (2023). A two-stream network with complementary feature fusion for pest image classification. *Engineering Applications of Artificial Intelligence*, 124, 106563.
- Wolpert, D. H. (1992). Stacked generalization. *Neural networks*, 5(2), 241-259.
- Wu, X., Zhan, C., Lai, Y. K., Cheng, M. M., & Yang, J. (2019). Ip102: A large-scale benchmark dataset for insect pest recognition. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 8787-8796).
- Xia, D., Chen, P., Wang, B., Zhang, J., & Xie, C. (2018). Insect detection and classification based on an improved convolutional neural network. *Sensors*, 18(12), 4169.
- Xiao, B., Ma, J. F., & Cui, J. T. (2012). Combined blur, translation, scale and rotation invariant image recognition by Radon and pseudo-Fourier–Mellin transforms. *Pattern Recognition*, 45(1), 314-321.
- Xie, C., Wang, R., Zhang, J., Chen, P., Dong, W., Li, R., & Chen, H. (2018). Multi-level learning features for automatic classification of field crop pests. *Computers and Electronics in Agriculture*, 152, 233-241.
- Xie, C., Zhang, J., Li, R., Li, J., Hong, P., Xia, J., & Chen, P. (2015). Automatic classification for field crop insects via multiple-task sparse representation and

- multiple-kernel learning. *Computers and Electronics in Agriculture*, 119, 123-132.
- Yang, X., Luo, Y., Li, M., Yang, Z., Sun, C., & Li, W. (2021). Recognizing pests in field-based images by combining spatial and channel attention mechanism. *IEEE Access*, 9, 162448-162458.
- Zhang, C., & Ma, Y. (2012). *Ensemble machine learning: methods and applications*. Springer Science & Business Media
- Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 8697-8710).



ÖZGEÇMİŞ

ORCID NO: 0009-0005-3193-592X

Ad Soyad : Şevval Ezgi EZE

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2021, Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği

Yayınları ve/veya Bilimsel/Sanatsal Faaliyetleri:

- Eze, Ş. E., & Kaplan Berkaya, S. (2024). Görüntü Ön İşleme Teknikleri ve Derin Öğrenme ile Bitki Zararlılarının Sınıflandırılması. *Mühendislik Bilimleri ve Tasarım Dergisi*, 12(2), 455-465.