



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BIYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME TEKNİKLERİ İLE BAZI BAĞ
HASTALIKLARININ BELİRLENMESİ**

DOKTORA TEZİ

Ziya ALTAŞ

Birinci Danışman: Doç. Dr. Mehmet Metin ÖZGÜVEN

İkinci Danışman: Doç. Dr. Kemal ADEM

TOKAT-2023

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Mehmet Metin ÖZGÜVEN danışmanlığında hazırlamış olduğum “Derin Öğrenme Teknikleri İle Bazı Bağ Hastalıklarının Belirlenmesi” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

21/12/2022

Ziya ALTAŞ

JÜRİ KABUL VE ONAY

Ziya ALTAŞ tarafından hazırlanan “**Derin Öğrenme Teknikleri ile Bazı Bağ Hastalıklarının Belirlenmesi**” adlı tez çalışmasının savunma sınavı **21/12/2022** tarihinde yapılmış olup aşağıda verilen Jüri tarafından **Oy Birliği/Oy Çokluğu** ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü **Biyosistem Mühendisliği Anabilim Dalı’nda Doktora Tezi** olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı)

İmzası

Üye (Başkan)	Prof. Dr. Yusuf YANAR	
Üye	Prof. Dr. Engin ÖZGÖZ	
Üye (Danışman)	Doç. Dr. Mehmet Metin ÖZGÜVEN	
Üye	Dr. Öğr. Üyesi Cemil KÖZKURT	
Üye	Dr. Öğr. Üyesi Serhat KILIÇARSLAN	

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

Prof. Dr. Mehmet GÜNEŞ

ÖNSÖZ

Lisans eğitimimden bu yana danışmanlığımı üstlenen, bu tez konusunda ve çeşitli konularda çalışma fırsatı sunan, beraber çalışmaktan son derece keyif aldığım, insani ve ahlaki değerleri ile örnek olan danışman hocam Sayın Doç. Dr. Mehmet Metin ÖZGÜVEN'e, bilgi ve tecrübeleri ile desteklerini esirgemeyen derin öğrenme konusunda rehber olan ikinci danışmanım Sayın Doç. Dr. Kemal ADEM hocama,

Arazi kontrolleri ve değerlendirme aşamalarında yardımcı olan ayrıca tez izleme süresince önemli katkı ve düzeltmeleri ile tezime değer katan Sayın Prof. Dr. Yusuf YANAR ve Sayın Prof. Dr. Engin ÖZGÖZ hocalarıma,

Tez Değerlendirme Jüri hocalarım olarak katkı sağlayan Sayın Dr. Öğr. Üyesi Cemil KÖZKURT'a, ve Sayın Dr. Öğr. Üyesi Serhat KILIÇARSLAN'a,

Çalışmaların yürütülmesinde desteklerini hiçbir zaman esirgemeyen güler yüzlü meslektaşlarım Biyosistem Yük. Müh. İsmail ÇINKAYA, Biyosistem Yük. Müh. Tahsin UYGUN, Biyosistem Müh. Derya GÜVEN, Biyosistem Müh. Arif ÇAM ve doktora eğitimi süresince zorlukların üstesinden birlikte geldiğimiz ve her durumda birbirimize destek olduğumuz Biyosistem Yük. Müh. İsmail TERZİ'ye,

Her zaman yanımda olan varlığıyla hayatıma neşe getiren kıymetli nişanlım Kübra TUTAL'a ve bu vesileyle büyüyen değerli aileme, hayatım boyunca maddi ve manevi her konuda destekleyen, benden hiçbir fedakârlığı esirgemeyen, beni kendime değerli hissettiren canım aileme en içten sevgi, saygı ve şükranlarımı sunarım.

Ziya ALTAŞ

21 Aralık 2022

ÖZET

DOKTARA TEZİ

DERİN ÖĞRENME TEKNİKLERİ İLE BAZI BAĞ HASTALIKLARININ BELİRLENMESİ

Ziya ALTAŞ

Biyosistem Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Mehmet Metin ÖZGÜVEN

İkinci Danışman: Doç. Dr. Kemal ADEM

Aralık 2022, xi + 81 sayfa

Türkiye, üzüm üretiminin en çok yapıldığı dünyanın en önemli bağ alanlarına sahip olan ülkelerdendir. Bağcılıkta verimliliği olumsuz etkileyen en önemli sebeplerden birisi bağ hastalıklarıdır. Bu çalışmada, bir yapay zeka yaklaşımı olan Faster R-CNN, SSD Multibox ve özgün olarak yeni geliştirilen derin öğrenme modeli kullanılarak bazı bağ hastalıkları tespit edilmiş ve sınıflandırılmıştır. Bu hastalıklar yaygın olarak görülen ve ekonomik sorun oluşturan külleme, mildiyö, ölü kol hastalığı ile asma yaprak kıvrılma virüs hastalığı (GLRaV) ve asma kısa boğum virüs (GFLV) hastalıklarıdır. Önerilen yöntem 11 000 görüntü kullanılarak eğitilmiş ve test edilmiştir. Deneysel değerlendirmeler sonucunda hastalıkların tespiti ve sınıflandırılmasında genel doğruluk oranları Faster R-CNN %92, SSD Multibox %92.21 ve geliştirilen model ile %96.95 olarak bulunmuştur. Önerilen yaklaşım, literatürdeki benzer yöntemlerden daha iyi sonuçlar vermiştir. Bu nedenle yöntemin, bazı bağ hastalıklarının tespiti ve sınıflandırılmasında, güvenilir bir şekilde kullanılabileceği sonucuna varılmıştır. Bu çalışmanın literatüre temel katkısı, fungal ve viral hastalıklardan oluşan beş farklı bağ hastalığı için büyük miktarda yeni bir veri seti oluşturulması ile hastalık tespiti ve sınıflandırılmasında özgün yeni bir derin öğrenme modelinin geliştirilmesidir.

Anahtar Kelimeler: Yapay Zeka, Derin Öğrenme, Bağcılık, Bağ Hastalıkları, Bitki Hastalıkları

ABSTRACT

DOCTORATE THESIS

DETERMINATION OF SOME VINEYARDS DISEASE WITH DEEP LEARNING TECHNIQUES

Ziya ALTAŞ

Department of Biosystems Engineering

Advisor: Assoc. Prof. Dr. Mehmet Metin ÖZGÜVEN

Second Advisor: Assoc. Prof. Dr. Kemal ADEM

December 2022, xi + 81 pages

Turkey, which has the most important vineyard areas in the world, is one of the countries where the most grapes are produced. Vineyard diseases are one of the most important reasons that negatively affect the yield in viticulture. In this study, some connective diseases were defined and classified using artificial intelligence approach, Faster R-CNN, SSD Multibox and originally newly developed deep learning model. These diseases are powdery mildew, downy mildew, dead arm disease, grapevine leaf roll-associated virus disease (GLRaV) and grapevine fan leaf nepovirus (GFLV) diseases that are common and cause economic problems. The proposed method is trained and tested using 11 000 images. As a result of the experimental evaluations, the general accuracy rates in the detection and classification of diseases were found to be 92% for Faster R-CNN, 92.21% for SSD Multibox and 96.95% with the developed model. The proposed approach gave better results than similar methods in the literature. Therefore, it has been concluded that the method can be used reliably in the detection and classification of some ligament diseases. The main contribution of this study to the literature is the creation of a large new data set for five different connective diseases consisting of fungal and viral diseases, and the development of a original new deep learning model for disease detection and classification.

Keywords: Artificial Intelligence, Deep Learning, Vineyard, Vineyard Diseases, Plant Diseases

İÇİNDEKİLER

Sayfa

ETİK SÖZLEŞME.....	i
JÜRİ KABUL VE ONAY	ii
ÖNSÖZ	iii
ÖZET	iv
ABSTRACT.....	v
İÇİNDEKİLER	vi
ÇİZELGELER LİSTESİ.....	vii
ŞEKİLLER LİSTESİ	viii
KISALTMALAR VE SİMGELER LİSTESİ	x
1. GİRİŞ	1
2. LİTERATÜR ÖZETLERİ	37
3. MATERYAL ve YÖNTEM	46
3.1. Materyal	46
3.1.1. Çalışmada değerlendirilen bağ hastalıkları	46
3.1.2. Araştırma alanları.....	46
3.1.3. Çalışmada kullanılan cihazlar	48
3.1.4. MATLAB.....	49
3.2. Yöntem.....	50
3.2.1. Görüntülerin elde edilmesi.....	50
3.2.2. Veri setinin oluşturulması	51
3.2.3. Veri ön işleme ve etiketleme.....	51
3.2.4. Modellerin geliştirilmesi	55
3.2.5. Model performans metrikleri	57
4. BULGULAR ve TARTIŞMA.....	60
4.1. Faster R-CNN Sonuçları	60
4.2. SSD Multibox Sonuçları	61
4.3. Geliştirilen Model Sonuçları	63
4.4. En İyi Sonucun Değerlendirilmesi	64
5. SONUÇ ve ÖNERİLER	71
6. KAYNAKLAR	73
7. ÖZGEÇMİŞ	78

ÇİZELGELER LİSTESİ

Sayfa

Çizelge 1. 2017-2021 yılları arası Türkiye bağ alanı ve üzüm üretimi	3
Çizelge 2. Dünya hasat edilen bağ alanları 2020 (ha)	4
Çizelge 3. GoPro Hero 7 Black kameranın teknik özellikleri	48
Çizelge 4. Akıllı telefonun teknik özellikleri.....	49
Çizelge 5. Çalışmada kullanılan bilgisayarın teknik özellikleri	49
Çizelge 6. Çalışmada oluşturulan veri seti.....	51
Çizelge 7. Faster R-CNN modelinin karışıklık matrisi (Confusion matrix).....	60
Çizelge 8. Faster R-CNN modelinin başarısının değerlendirilmesi.....	60
Çizelge 9. SSD Multibox modelinin karışıklık matrisi (Confusion matrix).....	61
Çizelge 10. SSD Multibox modelinin başarısının değerlendirilmesi.....	62
Çizelge 11. Çalışmada geliştirilen modelin karışıklık matrisi (Confusion matrix)	63
Çizelge 12. Çalışmada geliştirilen modelin başarısının değerlendirilmesi	64
Çizelge 13. CNN modellerinin başarı oranlarının karşılaştırılması.....	65
Çizelge 14. Bağ hastalıklarının tespitine yönelik çalışmaların karşılaştırılması	67

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1. 2011-2021 yılları arası on yıllık üzüm üretimi (ton)	4
Şekil 2. Türkiye bağ alanları haritası	5
Şekil 3. Türkiye üzüm üretim haritası.....	5
Şekil 4. Külleme hastalığının yapraktaki belirtileri	7
Şekil 5. Külleme hastalığının sürgün ve tanedeki belirtisi	7
Şekil 6. Bağ mildiyözü'nün yapraktaki belirtisi	8
Şekil 7. Ölü kol hastalığının sürgünlerdeki belirtisi	9
Şekil 8. Kurşuni küf hastalığının salkımlardaki zararı.....	10
Şekil 9. Kav hastalığının yaprakta, üzüm tanelerinde ve odun dokusunda belirtisi	11
Şekil 10. Bağ antraknozu'nun yaprakta (a), sürgünde (b), tanelerdeki (c, d) zararı....	12
Şekil 11. Asma yaprak kıvrılma virüslerinin yapraktaki (a, b) ve salkımdaki (c, d) belirtileri	13
Şekil 12. Asma yelpaze yaprak virüsü'nün yaprakta meydana getirdiği bozukluklar (a, b), muhtelif sarılık belirtileri (c, d, e, f) ve sürgünde meydana gelen kısa boğum araları ve zikzak gelişme (g).....	14
Şekil 13. Asma gövde çukurlaşması virüs hastalığının gövdedeki yiv oluşumu ve aşı noktasındaki şişkinlik (solda), gövdedeki kabuk kavlaması ve yiv oluşumu (sağda).....	15
Şekil 14. Asmanın kollarında (a, b, c, d) kök boğazında (e) urlanmalar	16
Şekil 15. Yapay zeka teknikleri	17
Şekil 16. Farklı yapay zeka tekniklerinde işlem aşamaları.....	18
Şekil 17. Derin öğrenme genel akış diyagramı.....	19
Şekil 18. Sinir ağının basit bir örneği	21
Şekil 19. Yapay nöron.....	21
Şekil 20. Yapay nöronda ağırlıklar	22
Şekil 21. Yapay nöronda aktivasyon fonksiyonu	23
Şekil 22. Bir evrişimli sinir ağının yapısı (CNN)	32
Şekil 23. CNN katmanları.....	33
Şekil 24. İki farklı yöntem kullanılarak elde edilen havuzlama işlemi.....	34
Şekil 25. Faster R-CNN mimarisi.....	35
Şekil 26. SSD Multibox mimarisi.....	36

Şekil 27. Çalışmada değerlendirilen bağ hastalıkları.....	46
Şekil 28. Araştırma alanları	47
Şekil 29. Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bağ alanları	47
Şekil 30. Çalışma için ayrılan sıralar	48
Şekil 31. GoPro Hero 7 Black.....	48
Şekil 32. Tane üzerinde külleme etiketi örneği.	52
Şekil 33. Yaprakta külleme etiketi örneği.....	52
Şekil 34. Mildiyö etiketi örneği	53
Şekil 35. Ölü kol etiketi örneği	53
Şekil 36. Asma yaprak kıvrılma virüs etiketi (GLRaV) örneği	54
Şekil 37. Asma kısa boğum virüs etiketi (GFLV) örneği	54
Şekil 38. Çalışmada geliştirilen model mimari.....	55
Şekil 39. Çalışmanın genel akış şeması	57
Şekil 40. Karışıklık matrisi (Confusion matrix)	58
Şekil 41. Karışıklık matrisinden hesaplanan birçok ölçümün gösterilmesi	58
Şekil 42. Faster R-CNN modelinin PR eğrisi ve ROC eğrisi	61
Şekil 43. SSD Multibox modelinin PR eğrisi ve ROC eğrisi	62
Şekil 44. Geliştirilen modelinin PR eğrisi ve ROC eğrisi	64
Şekil 45. Modellerin karşılaştırmalı doğruluk değerleri	65
Şekil 46. Modellerin karşılaştırmalı kesinlik değerleri.....	66
Şekil 47. Modellerin karşılaştırmalı duyarlılık değerleri.....	66
Şekil 48. Modellerin karşılaştırmalı F1 skor değerleri	67
Şekil 49. Faster R-CNN modelinin uygulanmasına örnek görüntüler	69
Şekil 50. Geliştirilen modelin uygulanmasına örnek görüntüler	70

KISALTMALAR

BMU: En İyi Eşleşen Birim

CPU: Merkezi İşlem Birimi

CNN: Evrişimli Sinir Ağı

DBN: Derin İnaç Ağı

FAO: Gıda ve Tarım Örgütü

FP: Yanlış Pozitif

FN: Yanlış Negatif

GAN: Üretken Çekişmeli Ağ

GFLV: Asma Kısa Boğum Virüs

GLRaV: Asma Yaprak Kıvrılma Virüs

GPU: Grafik İşleme Birimi

KNN: En Yakın Komşu

LSTM: Uzun Kısa Süreli Bellek Ağı

MATLAB: Matris Laboratuvarı

MLP: Çok Katmanlı Algılayıcı

ReLU: Düzleştirilmiş Doğrusal Birim

RGB: Kırmızı-Yeşil-Mavi

RPN: Bölge Önerme Ağı

RBFN: Radyal Temel Fonksiyon Ağı

RBM: Kısıtlı Boltzmann Makinaları

RNN: Tekrarlayan Sinir Ağı

SVM: Destek Vektör Makinesi

SOM: Kendi Kendini Düzenleyen Haritalar

SSD: Tek Atış Çoklu Kutu Dedektörü

TP: Doğru Pozitif

TN: Doğru Negatif

TUİK: Türkiye İstatistik Kurumu



1. GİRİŞ

Dünya nüfusunun hızla artması ve kentleşme, tarım alanlarının ve kişi başına düşen su gibi doğal kaynakların azalmasına yol açmaktadır. Bu nedenle tarımsal üretimde verimliliği artırmak için teknolojik ve genetik yöntemlerin kullanılması zorunlu hale gelmiştir (Ozguven, 2018; Özgüven, 2018). Bitki verimliliğini etkileyen en önemli faktörlerden biri bitki hastalıklarıdır. Bitki hastalıklarının zamanında tespit edilip önlenememesi, bitki veriminde ve kalitesinde önemli düşüşlere yol açmakta ve yetiştiriciler için önemli ekonomik kayıplara neden olmaktadır. Hastalıkların güvenilir ve zamanında tespiti, bu tür kayıpları önemli ölçüde azaltabilmektedir (Adem ve ark., 2022). Bu nedenle, bitki hastalıklarının hızlı ve doğru bir şekilde belirlenmesi ve hastalık şiddetinin değerlendirilmesi, zamanında önleme ve yönetim stratejilerinin uygulanması için esastır (Rossi, 1995; Bock ve ark, 2010; Gavhale ve Ujwalla, 2014; Ampatzidis ve ark., 2017; Cruz ve ark., 2017; Ma ve ark., 2018; Wang ve Qi, 2019).

Hastalıkların tespiti için bitki koruma uzmanlarının yaptığı gözlemler, uzmanların yaşadığı yorgunluk ve konsantrasyon kaybı, sahadan toplanan numunelerin daha sonra değerlendirilmek üzere yanıltıcı görsel değerlendirmesi, tekrarlanma ihtiyacı ve doğru uzman değerlendirmelerinin elde edilmesi için eğitim maliyetleri gibi bazı olumsuzluklar içerebilmektedir. Bu sorunların çözümü için özellikle büyük üretim alanlarında bitki hastalıklarının tanımlanmasında, hastalık şiddetinde ve hastalığın ilerlemesinde insan hatalarını azaltan daha hızlı ve pratik yöntemlere ihtiyaç duyulmaktadır (Bock ve ark., 2010; Altas ve ark., 2018).

Son yıllarda yapay zeka, görüntü işleme ve grafik işleme birimlerindeki (GPU) gelişmeler, hassas bitki koruma ve büyüme uygulamalarını genişletebilmekte ve geliştirebilmektedir. Bitki hastalıklarını tespit etmek ve sınıflandırmak için günümüzde çeşitli yapay zeka yaklaşımları kullanılmaktadır. En yaygın yaklaşımlar, K-en yakın komşular (K-NN), lojistik regresyon, karar ağacı, destek vektör makinesi (SVM) ve derin öğrenme modeli olan Evrişimli sinir ağlarıdır (CNN). Bu yaklaşımlardan görüntü tanıma ve sınıflandırma için hızlı, otomatik ve doğru bir sistem geliştirmek amacıyla son zamanlarda derin öğrenme çok dikkat çekmekte ve hızla görüntü sınıflandırma için standart bir teknik haline gelmektedir (Barbedo, 2019; Geetharamani ve Arun, 2019).

Hastalık tespiti için bilgisayarlı görü uygulamaları, özellikle görüntü işleme teknikleri ve derin öğrenme teknikleri, bitki koruma uygulamalarının daha etkin bir şekilde gerçekleştirilmesini sağlamak için büyük potansiyel faydalara sahiptir (Ozguven ve Yanar, 2022). Bir hastalık

durumunda bitkiler, hastalığın türüne göre şekil ve büyüklükleri değişen renkli benekler, bitkinin gövde ve gövde kısımlarında görülen çizgiler şeklinde görsel belirtiler göstermektedir. Bu belirtiler hastalık ilerledikçe renk, şekil ve boyut değiştirmektedir. Görüntü işleme teknikleri kullanılarak renkli cisimler ayırt edilebilmekte, bitki hastalık ve zararlılarının şiddeti belirlenebilmektedir. Görüntü işleme tekniklerine ek olarak, makine öğrenmesi yöntemleri uygulanarak anlık hastalık tespiti için uzman sistemler geliştirilebilmektedir. Özellikle makine öğrenmesinin bir alt dalı olan derin öğrenme yöntemi, bitki hastalık ve zararlılarının, zarar düzeylerinin belirlenmesi ve bitkinin gelişiminin izlenmesi yoluyla daha etkin bitkinin korunmasına olanak sağlamaktadır (Ozguven, 2020; Ozguven ve Altas, 2022).

Bilgi teknolojilerinde görülen hızlı gelişim sonucunda geliştirilen donanım, algoritma ve yazılımların tarımda kullanılmaya başlamasıyla ortaya çıkan hassas tarımda, geleneksel tarıma göre işletmecilik ve karar verme işlemlerinde önemli değişimler yaşanmıştır. Tarımda mevcut bilgi ve tecrübelerin bilgi teknolojileriyle birlikte değerlendirilmesi ile bitki görüntülerinden hastalıkları belirlemek, en önemli araştırma alanlarından biri olmuştur (Özgüven, 2018). Tarımsal üretimin öncelikli hedefi, bitkisel ve hayvansal üretimde ekonomik, sürdürülebilir ve üretken işletmeciliğin sağlanmasıdır. Bu amaçla, tarımda verimliliğin ve ürün kalitesinin artırılması, minimum girdi kullanımı, gıda güvenilirliği, doğal kaynakların ve çevrenin korunması gibi çeşitli konularda teknoloji kullanılmasıyla, tarımsal işlemlerin kolaylaştırılması ve çözüm veya iyileştirme bekleyen sorunlara alternatif çözümler geliştirilmektedir (Altaş ve ark., 2019). Bu çözüm geliştirme potansiyelinden dolayı yapay zeka uygulamalarının günümüz ve yakın gelecekteki en önemli tarımsal araştırma konularında yer alması beklenmektedir. Tarımda birçok alanda yapay zeka teknikleri kullanılarak bitkisel üretim planlamaları, bitkilerin sınıflandırılması, verim tahmini, bitki hastalık, zararlı ve yabancı otlarının tespiti, tarım robotlarında rota belirlenmesi ve uygulama kararlarının alınması, serada uygun çevre şartlarının belirlenmesi, işletme kararlarının alınması, sulama yönetimi, ürün rotasyonunun belirlenmesi, en uygun gübre ve alet-makine seçimi, hayvan hastalıklarının tespiti, uygun yem rasyonlarının hazırlanması, hayvan davranışlarının belirlenmesi gibi konularda araştırmacılar tarafından çok sayıda çalışma yapılmıştır (Terzi ve ark., 2019).

Bu tez çalışmasının amacı, ülkemiz için oldukça önemli olan bağcılıkta kısa sürede yüksek yoğunluklara ulaşarak, önemli ürün kayıplarına neden olan külleme, mildiyö, ölü kol hastalığı ile asma yaprak kıvrılma virüs hastalığı (GLRaV) ve asma kısa boğum virüs (GFLV) hastalık görüntülerine bir yapay zeka yaklaşımı olan derin öğrenme teknikleri kullanılarak hastalıkların otomatik tespit edilebilmesi ve sınıflandırma işleminin gerçekleştirilmesidir.

Bağcılık


Bağcılık için dünyanın en elverişli iklim kuşağı üzerinde bulunan ülkemiz, kültür asması (*Vitis vinifera* L.) ve bağcılık kültürünün anavatanı olması nedeniyle zengin bir gen potansiyeline ve asmanın heterozigotik yapısından dolayı çok geniş çeşit ve tip zenginliğine sahiptir. Ülkemiz bağcılığında iklimin uygun olmasından dolayı eski zamanlardan beri asma olarak isimlendirilen (*Vitis* sp.) bitki yetiştiriciliği yapılmaktadır. Asma, toprak ve iklim bakımından fazla seçici olmaması ve asmadan üzüm ve yaprak gibi ürünlerin ekonomik olarak değerlendirilme imkanına sahip olması nedeniyle birçok ailenin geçim kaynağını oluşturmaktadır. Ancak birçok hastalık bağlarda kalite ve verimi düşürerek ekonomik sorunlar meydana getirmektedir (Karabat, 2014; Altaş ve ark., 2021).

Türkiye, 2020 yılı istatistiklerine göre 6 950 930 ha'lık dünya bağ alanları içinde 400 980 ha'lık bağ alanı varlığı ve 78 034 332 ton'luk dünya yaş üzüm üretiminin 4 208 980 ton'luk kısmıyla önemli bir bağ yetiştiriciliği yapılan bir ülke konumundadır (FAO, 2022). Çizelge 1'de TUIK verilerine göre 2017-2021 yılları arası 5 yıllık Türkiye bağ alanı ve üzüm üretim değerleri verilmiştir. Çizelge 1 incelendiğinde 2021 yılında ülkemizde üretilen toplam yaş üzümün %50.59'u sofralık, %38.96'sı kurutmalık, %10.43'ü şıralık-şaraplık olarak çeşitli gıda ürünlerinin elde edilmesi amacıyla kullanılmaktadır. Üzümün diğer değerlendirme ürünlerinden sirke, pekmez, sucuk, reçel, köfter (pekmez lokumu), pestil (bastık), samsa vb. ürünlerde yoğun olarak tüketilmektedir. Son yıllarda üzüm çekirdeği sanayi, ilaç ve kozmetik alanlarda da kullanılmaya başlanmıştır. Resveratrol son yıllarda üzümünden elde edilen anti-kanserojen bir maddedir. Ayrıca asma yaprağından salamura yapılmaktadır. Bu yapraklar sarma olarak değerlendirilmektedir.

Çizelge 1. 2017-2021 yılları arası Türkiye bağ alanı ve üzüm üretimi (TUIK, 2022)

Yıllar	Alan (Dekar)	Toplam Üretim (Ton)	Toplam Sofralık Üretim (Ton)	Toplam Kurutmalık Üretim (Ton)	Toplam Şaraplık Üretim (Ton)
2017	4 169 068	4 200 000	2 109 000	1 603 000	488 000
2018	4 170 410	3 933 000	1 945 262	1 524 091	463 647
2019	4 054 387	4 100 000	2 050 000	1 599 000	451 000
2020	4 009 979	4 208 908	2 218 056	1 534 499	456 353
2021	3 902 211	3 670 000	1 856 929	1 430 160	382 911

Çizelge 2'de verilen 2020 yılı dünya hasat edilen bağ alanları (ha) incelendiğinde ise üretim alanı olarak İspanya, Çin, Fransa, İtalya ve Türkiye ilk beş büyük üretici ülke olarak göze çarpmaktadır. Ülkelerin 2011-2021 yılları arası üzüm üretim ortalaması değerlendirildiğinde ise Çin, İtalya, ABD, Fransa, İspanya ve Türkiye olarak sıralanmaktadır (Şekil 1).



Şekil 1. 2011-2021 yılları arası on yıllık üzüm üretimi (ton) (FAO, 2022)


Şekil 1’de gösterilen bu ülkelerden Fransa ve İspanya şaraplık üzüm üretimi ile ön plana çıkarken, İtalya sofralık ve şaraplık, ABD ve Çin sofralık, kurutmalık ve şaraplık ve Türkiye ise hem sofralık hem de kurutmalık üzüm üretimi ile öne çıkmaktadır. Arjantin, Şili ve Güney Afrika Cumhuriyeti Güney yarım kürede bağcılığın gelişmiş olduğu diğer ülkelerdir ve buralarda da sırasıyla sofralık, şaraplık ve kurutmalık amaçlı üretim önem taşımaktadır (Karabat, 2014).

Çizelge 2. Dünya hasat edilen bağ alanları 2020 (ha) (FAO, 2022)

Sıra No	Ülkeler	Alan (ha)
1	İspanya	931 630
2	Çin	765 038
3	Fransa	759 060
4	İtalya	703 900
5	Türkiye	400 998
6	ABD	372 311
7	Arjantin	214 798
8	Şili	200 906
9	Portekiz	175 670
10	İran	158 467


Ülkemizde 2021 yılı üretim döneminde yaklaşık 3.9 milyon dekar alanda üzüm üretimi yapılmıştır. Bölgelere göre üretim incelendiğinde, Ege’de çekirdeksiz sofralık-kurutmalık, Marmara’da sofralık-şaraplık, Akdeniz’de çekirdekli sofralık, Orta Anadolu ve Güneydoğu Anadolu’da şaraplık, çekirdekli sofralık-kurutmalık üzüm yetiştiriciliği gelişme

göstermektedir. Tüm bağ alanları (yaş, kuru ve şaraplık üzüm) bakımından incelendiğinde ise %22’lik pay ile Manisa (858 bin da) birinci sırada yer alırken, Manisa’yı Mardin (363 bin da) ve Denizli (341 bin da) takip etmektedir. TÜİK 2021 verilerine göre oluşturulan Türkiye bağ alanları haritası Şekil 2’de ve Türkiye üzüm üretim haritası ise Şekil 3’de gösterilmektedir. Şekillerde illerin yüzdelik (%) paylarına göre renklendirme yapılmıştır.



Şekil 2. Türkiye bağ alanları haritası

2021 yılı üretim döneminde ülkemizde 3.6 milyon ton üzüm üretimi gerçekleşmiştir. Şekil 3’de gösterildiği gibi üzüm üretiminde önemli bir yere sahip olan Manisa 1.3 milyon ton üretimle ülkemiz üretiminin %35.7’sini gerçekleştirmiştir. Mersin 343 bin tonluk üretimi ile ikinci sırada, 324 bin tonluk üretim ile Denizli üçüncü sırada yer almaktadır. Genel olarak değerlendirildiğinde sahip olduğu bağ alanı ve üzüm üretimiyle bağcılık sektörü ülkemizin bitkisel üretiminde önemli bir yere sahiptir.



Şekil 3. Türkiye üzüm üretim haritası

Bağ Hastalıkları


Fungal Hastalıklar

Külleme Hastalığı (Uncinula necator (Schv.) Burr.)

Mantari bir hastalıktır. Küllemeye neden olan fungus obligat bir parazittir. Hastalık etmeni nemli, sıcak ve kurak havalarda her yıl görülebilmektedir. Ancak hastalığın gelişiminde nemden çok, sıcaklık daha önemlidir. Kurak koşullarda bile gelişebilen bir mantardır. Optimum gelişme sıcaklık isteği 20-27°C arasındadır. Hastalık havalanmayan gölge ve yarı ışıklı yerlerde daha hızlı gelişmektedir. Bu nedenle asmanın havalanmasını ve iç kısımların ışık almasını sağlayan yaz budamaları çok önemlidir. Asmanın tüm yeşil aksamı küllemeye yakalanabilmektedir. Hastalığın ilk gelişme döneminde genç yapraklarda hastalık zor fark edilmektedir. Şekil 4'te gösterildiği gibi yaprağın alt yüzünde yağ lekesi görünümünde belirti oluşur ve üst yüzünde de renk açılması yapmaktadır. Yaprak yaşlandıkça parlaklığını kaybeder, kalınlaşır ve gevrekleşir. İleri dönemde, yaprağın alt ve üst yüzleri kirli beyaz renkte kül serpilmiş gibi pudramsı bir görünüm almaktadır. Hastalıklı yaprakların kenarları içe doğru kıvrılır normal şeklini kaybetmektedir. Sürgünler yeşilken enfekteli kısımlar siyaha yakın koyu kahverengindedir. Kışın bu lekeler kırmızımsı kahverengine dönüşmektedir. Salkımda, hastalığa erken yakalanan taneler küçük kalmaktadır. İrileşebilmiş veya olgunlaşmadan hemen önceki dönemde enfekte olmuş tanelerin sapı doğrultusunda çatladığı görülmektedir. Taneler, ben düşme devresine kadar enfeksiyonlara duyarlıdır. Hastalık Türkiye'nin tüm bağ bölgelerinde hemen her yıl ortaya çıkmakta ve mücadele yapılmadığında %90'a varan ürün kaybına neden olabilmektedir (Anonim, 2019c).



Şekil 4. Külleme hastalığının yapraktaki belirtileri (Akgül, 2013)



Şekil 5. Külleme hastalığının sürgün ve tanedeki belirtileri (Pearson ve Goheen, 1994)

Mildiyö (*Plasmopara viticola* (Berk. et Curt) Berl. et de Toni)

Bağ mildiyö, asmanın vejetatif gelişme dönemi sırasında ılık ve yağışlı geçen iklime sahip bölgelerde görülebilen bir hastalıktır. Etmeni obligat bir parazittir. Hastalık asmanın tüm yeşil kısımlarında görülebilmektedir. Sürgünler 25 cm iken hastalık görülmeye başlar. Hastalık ilk olarak yaprakların üzerinde sarımsı, yuvarlak, şeffaf zeytinyağı lekeleri halinde kendini göstermektedir. Lekeler gittikçe büyür, hatta tüm yaprağı sarabilir. Hastalığın sporlarının çimlenebilmesi için yaprağın üzerine su damlası olması gerekmektedir. Bu nedenle mildiyö yağmurlu havalardan sonra veya çiğ olduğu zaman salgın yapmaktadır. Yaprakta önce yağ lekeleri, daha sonra bunların alt kısmında beyazımsı bir küf tabakası oluşmaktadır. Bu lekeler

sonradan esmerleşmekte, bazen kızarmakta ve sonuçta kurumaktadır. Hava fazla yağışlı geçerse hastalık genç sürgünlere, çiçeklere ve koruklara geçmektedir. Mildiyö küllemesine benzer bir küf oluşturmaktadır. Ancak bu küf küllemesindeki gibi yaprağın her iki yüzünde değil sadece alt yüzündedir. Bu hastalık ilkbaharda çok sık yağmur yağmadıkça pek görülmez. Mildiyö hastalığı asmanın tüm yeşil kısımlarını ve ürünü doğrudan etkilediği için ekonomik önemi büyüktür. Şekil 6’da mildiyö hastalığının belirtileri gösterilmektedir (Uzun, 2015; Anonim, 2019c).



Şekil 6. Bağ mildiyösünün yapraktaki belirtisi (Anonim, 2019b)

Ölü Kol Hastalığı (*Phomopsis viticola* Sacc.)

Ölü kol (*Phomopsis viticola* Sacc.) sürgünler üzerinde 0.2-0.4 mm çapında siyah yuvarlak sert piknitleri meydana getirmektedir. Başta sürgünler olmak üzere, yapraklar, yaprak sapları, salkım ve salkım sapları, taneler hastalığa yakalanabilmektedir. Ülkemizde hastalık daha çok sürgünlerde kendini göstermektedir. Sürgünün dipten itibaren üçüncü veya beşinci gözüne kadar olan kısmında, lekeler ve çatlamlar görülmektedir. Önce ortaları koyu siyah lekeler meydana gelmektedir. Daha sonra bu lekeler birleşir, düzgün olmayan siyah çatlak ve yaraları oluşturmaktadır. Yaralar çok derin olup, odun dokusunu da çatlatabilmekte ve bu tür sürgünler daha sonra kurumaktadır. Hastalık “sürgün kuruması” adıyla da bilinmektedir. Enfekte olmuş yapraklarda önce toplu iğne ucu büyüklüğünde, etrafı sarı haleli küçük siyah lekeler meydana gelmektedir. Daha sonra bu yapraklar sararmakta, buruşmakta, kenarları yırtılmakta ve küçük kalmaktadır. Hastalanmış salkım ve tane saplarında lekeler oluşabilmektedir. Çatlayan, uzunluğuna yarılan sürgünler, sonbaharda beyazlaşarak hastalığın tipik şeklini almaktadır. Ölü

kol hastalığı sonuta asmanın kurumasına neden olduėu iin ekonomik nemi fazladır. (Anonim, 2019a). Őekil 7’de l kol hastalığının srgnlerdeki belirtisi gsterilmektedir.



Őekil 7. l kol hastalığının srgnlerdeki belirtisi (Anonim, 2019c)

Kurşuni Kf Hastalığı (*Botrytis cinerea* Pers.)

Kurşuni kf ya da gri kf olarak bilinen hastalık etmeninin eőeyli formu *Botryotinia fuckeliana* (de Bary) Whetzel, eőeysiz formu ise *Botrytis cinerea* Pers.’dir. Baėlarda etmenin yalnızca eőeysiz formu grnmektedir. Hastalığın yapraklardaki belirtileri ok yaygın deėildir. Yapraklarda kenarları sarı olan, aık kahverengi ve kuru lekeler Őeklinde grlmektedir. Srgnlerde ise hastalıklı kısımların rengi aık kahverengiye dnmektedir. Hastalıklı kısımlar boėumlara yakın yerlerde gzlenmektedir. Tanelere hastalığın bulaőması ieklenme dneminde olmaktadır. Ancak hastalık zmler olgunlaőıncaya kadar gizli kalmaktadır. Tanelerin olgunlaőma dneminde hastalık sporları su bulursa imlenmekte ve gri renkte kf oluőurmaktadır. Sporların imlenebilmesi iin taneler zerinde 12-24 saat boyunca yksek oranda nem (%92 veya yuvarısı) veya su olmalıdır. Bu nedenle olgunlaőma dnemi kurak geen yerlerde bu hastalığa pek rastlanmaz. Taneler zerindeki su yaėmurlarından ya da tanelerdeki atlaklardan veya salkım gvesi zararlısının tanede atığı deliklerden zm suyunun dıőarı ıkmasıyla saėlanmaktadır. Sık salkımlı eőitlerde hastalık daha ok grlmektedir. Taneler zerinde nce 3-5 mm apında, yuvarlak, pembemsi, kıızıla yakın lekeler grlmektedir. Daha sonra bu lekeler taneyi kaplamakta ve rengi de koyulaőmaktadır. Hastalık tane iine nfuz etmiő ise byle zmlerin depoda kkrtdioksit ile muamelesinden pek baőarı saėlanmaz (Uzun, 2015).



Şekil 8. Kurşuni küf hastalığının salkımlardaki zararı (Anonim 2019c)

Kav Hastalığı (*Stereum hirsutum* (Willd.) Pers., *Phellinus igniarius* (L.) Quél., *Fomitiporia mediterranea* M. Fisch.)

Kav hastalığına neden olan fungal etmenler birden fazladır ve Basidiomycota şubesinde yer almaktadır. Özellikle yaşlı bağlarda sorun olan Kav Hastalığı “Black measles, Apoplexy, Esca, Folletage, White root, Esca proper, Vine decline, Sunstroke” gibi farklı isimlerle anılmaktadır. Hastalık tablosunun ana nedeni patojenlerin ürettikleri lakkaz ve peroksidaz enzimlerinin asmanın odun dokusundaki lignini tahrip etmesi ve böylelikle su iletiminin sekteye uğraması sonucunda yeşil aksamda solgunluk, gelişme geriliği ve hatta kuruma belirtilerinin ortaya çıkmasıdır. Belirtiler asmanın tamamında veya yalnızca bir kısmında görülebilmektedir. Hastalığın iki belirti tipi vardır. Birincisinde hastalık kronik seyreder ve yapraklardaki belirtilerle kendisini belli etmektedir. İkincisinde ise akut bir seyir vardır ve asma aniden ölmektedir. Bu olaya apoplexy (inme) adı verilmektedir. Asmada önce gözlerin uyanmasında bir gecikme fark edilmektedir. Belirtiler çiçeklenmeden sonra, yaz aylarında veya sonbahar başlangıcında, önce sürgünün alt kısmındaki yaşlı yapraklarda başlar, sonra tüm yapraklarda ortaya çıkmaktadır. Yapraklar doğal yeşilliğini kaybeder ve zamanla sararmaktadır. Yapraklarda damar araları önce sararır, daha sonra kızıl kahverengi renge dönüşmektedir. Damarlar nispeten yeşil kalmaktadır. Bu yapraklar kurumakta ve vaktinden önce dökülmektedir. Taneler üzerindeki belirtiler tane bağlama ile olgunlaşma arasındaki herhangi bir zamanda, tüm salkımda ya da dağınık olarak tanelerin yüzeyinde önce koyu mor noktalar şeklinde ortaya çıkmaktadır. Daha sonra bu lekeler birleşerek tüm taneyi kaplayabilmektedir (Anonim 2019a).




Şekil 9. Kav hastalığının yaprakta, üzüm tanelerinde ve odun dokusunda belirtisi (Anonim 2019c)

Şekil 9’ da görüldüğü gibi, yaprak ve tanelerdeki bu belirtilere etmenlerin ürettikleri toksinler (pulluans, scytalone ve isosclerone) neden olmaktadır. Bu belirtileri sadece fungal etmenlerin varlığı değil, asmanın yaşı, çeşidi, üretim materyali, budama, yaraların korunması, iklim koşulları, toprak yapısı, sulama ve arazinin eğimi de etkilemektedir. Hastalıklı asmaların gövde ve kalın dallarının enine kesitinde, merkezin çevresinde açık renkli yumuşak dokulu hastalıklı kısmın, daha koyu renkli sert dokulu bir kuşakla çevrilmiş olduğu görülmektedir. Yıldan yıla asmanın içi kavlar, kavlama içten dışa doğru olmaktadır. Bazen çok sıcak yaz aylarında adeta yıldırım çarpmış gibi yaprakların birden bire solup kuruduğu, genç sürgünlerin bunu izlediği ve asmanın aniden öldüğü görülmektedir.

Bağ Antraknozu Hastalığı (*Elsinoe ampelina* Shear.)

Bağ Antraknozu hastalığı daha çok ilkbahar ve yaz ayları yağışlı geçen veya devamlı nemli olan bağlarda görülmektedir. Sporlarının çimlenebilmesi için havanın nemli olması yetmez, yaprak veya taneler üzerinde su damlasına da ihtiyaç vardır. Bu nedenle hastalık kurak havalarda pek görülmez. Etmen asmanın tüm yeşil kısımlarını hastalandırırsa da en çok yeni sürgünlerde ve salkımlarda görülmektedir. Yapraklarda önce küçük lekeler oluşmaktadır. Daha sonra bunların ortası gri, kenarları kırmızımsı-kahverengi veya mor bir renk almaktadır. Zamanla bu lekeler kurumakta ve yapraklar delinmektedir. Hastalık şiddetli olursa yapraklar tamamen kurumaktadır. Taneler üzerindeki lekeler başlangıçta siyahtır. Bu lekeler zamanla büyür ve ortası gri bir renk almaktadır. Bu görünüş nedeniyle hastalığa "kuş gözü çürüklüğü" adı da verilmektedir. Hastalık çelik marazı adıyla da bilinmektedir (Uzun, 2015).



Şekil 10. Bağ antraknozu'nun yaprakta (a), sürgünde (b), tanelerdeki (c, d) zararı (Anonim, 2019c)

Virüs hastalıkları

Asma Yaprak Kıvrılma Virüs Hastalığı (Grapevine leafrollassociated viruses, GLRaVs)

Asma Yaprak Kıvrılma Virüs hastalığına 11 farklı virüs neden olmaktadır. Floemde bulunan bu farklı virüslerin ayrı ayrı ya da çeşitli kombinasyonlarda bitkiyi enfekte etmesi, yaprak kıvrılma hastalığı belirtilerinin ortaya çıkmasına neden olmaktadır. Hastalık, ülkemizde bağ üretimi yapılan hemen her bölgede görülmekte olup hastalıkla ilişkili en yaygın görülen virüslerin GLRaV-1 ve GLRaV-3 olduğu tespit edilmiştir. Hastalığın yayılışı, enfekteli aşı kalemi ve virüsü latent olarak taşıyan asma anaçlarının kullanımı ile olmaktadır. Ayrıca, unlubitlerden *Planococcus ficus* ve *Planococcus citri* ile Kahverengi koşnil (*Parthenolecanium corni*) GLRaV-3'ün vektörü iken GLRaV-1'in vektörü *Parthenolecanium corni*'dir. Hastalığın belirtileri, büyüme mevsiminin sonuna doğru görülebilmektedir. İklim koşullarına bağlı olarak Ağustos ve Eylül ayı başlarından itibaren kırmızı üzüm çeşitlerinin yaşlı yapraklarında kırmızımsı lekeler gelişmektedir. Bu lekeler genişlemekte ve birleşmektedir. Yaz sonunda veya sonbaharda kırmızımsı ve sarımsı renk, yaprak ayasının tamamını kapladığı halde, ana damarlar yeşil olarak kalmaktadır. Kırmızı ve beyaz üzüm çeşitlerinin her ikisinde de yaprak ayası kalınlaşmakta, kırılmanlaşmakta ve aşağı doğru kıvrılmaktadır. Enfekteli asmalarda meyve salkımları çok kısadır. Üzümler geç ve düzensiz olgunlaşmaktadır. Sağlıklı üzüm

eřitlerinde meyveler olgun renklerini aldıđı halde, hastalıklı meyveler yeřil ve beyazımsı kalmaktadır. Kırmızı zm eřitlerinde salkımlarda dzensiz renklenme grlmektedir. Bu belirtiler mevsim sonunda srgn ucuna dođru yayılmaktadır. Beyaz zm eřitlerinde ise yapraklarda beyaz-sarı renk deđiřimlerine ve yaprak kenarlarından ařađı dođru kıvrılmalara rastlanmaktadır. Hastalıklı asmalarda genel bodurluk ve geliřme durgunluđu hemen gze arpmaktadır. Hastalık asma analarında belirti oluřturmamasına rađmen geliřmeleri zayıflatmaktadır. Bu hastalık, meyve verimini %10-70 oranında azaltabildiđi gibi, řeker oranını da dřrmektedir (řekil 11). (Anonim, 2019a).




řekil 11. Asma yaprak kıvrılma virslerinin yapraktaki (a, b) ve salkımdaki (c, d) belirtileri
(Anonim, 2019c)

Asma Kısa Bođum Virs Hastalıđı (*Grapevine fanleaf nepovirus*, GFLV)

Nepovirs cinsine ait bir virsn yol amıř olduđu hastalık ‘‘yelpaze yaprak’’ ve ‘‘bulařık soysuzlařma’’ olarak da bilinmektedir. Nepovirs; retim materyallerinden kalem, ana ve mekanik yolla; ayrıca vektr olan kamalı nematodlardan *Xiphinema index* ve *Xiphinema italiae* ile de tařınmaktadır. Hastalıđın yaprak belirtileri erken ilkbaharda geliřmekte ve vejetasyon boyunca devam etmektedir. Ancak yksek sıcaklıklarda belirtiler maskelenebilmektedir. Yapraklarda řekil bozuklukları grlmekte, yaprak simetrisi bozulmakta, yaprak ayası ukurlařmakta ve karıřmakta, yaprakta diř sayısı artmaktadır. Sarılık

belirtileri, ilkbaharda erken dönemde gelişerek asmanın bütün vejetatif organlarını (yapraklar, taze sürgün uçları ve salkım taslakları) etkilemektedir. Başlangıçta, yapraklarda birkaç sarı leke ve damar bantlaşması görülmektedir. İlerleyen dönemde ise damar aralarında çeşitli büyüklükteki benekler yayılarak yaprağın tümünün sararmasına neden olmaktadır. Bu tip belirtilere GFLV'nin dışında diğer bazı nepovirüsler de yol açmaktadır (Anonim, 2019c).



Şekil 12. Asma yelpaze yaprak virüsü'nün yaprakta meydana getirdiği bozukluklar (a, b), muhtelif sarılık belirtileri (c, d, e, f) ve sürgünde meydana gelen kısa boğum araları ve zikzak gelişme (g) (Anonim, 2019c)

Asma Gövde Çukurlaşması Virüs Hastalığı (Rugose wood complex)

Asmalarda görülen gövde çukurlaşma hastalığına 7 farklı virüs neden olmaktadır. Ülkemizde bu virüslerden Grapevine virus A, Grapevine virus B ve Grapevine rupestris stem pitting associated virus (GRSPaV) saptanmıştır. Virüs asmanın bünyesinde sistemik olarak yer almaktadır. Hastalık, asmanın tüm kültür ve yabani formlarında (*Vitis* spp.) aşıyla taşınmaktadır. Etmenlerin bazıları unlubitlerle (*Planococcus ficus* ve *Planococcus citri*) de taşınmaktadır. Enfekteli asmalarda göze çarpan ilk belirtiler, bitkilerde gelişme durgunluğu, baharda gözlerde geç uyanma, sürgünlerde zayıf gelişmedir. Bu hastalık asmanın odunsu kısmındaki belirtiler ile karakterize edilmektedir. Aşı yerinde anaç ve kalem uyumsuzluğuna benzer şişkinlikler meydana gelmekte ve kalem anaca göre daha geniş çaptadır. Gövdede kabuk

dokuda kavlamalar meydana gelmektedir. Aşı noktasındaki kabuk soyulduğunda odun yüzeyinde görülen yiv benzeri oluşumlar düzgün olmayıp, girintili çıkıntılıdır. Kabuğun iç tarafında ise çivi benzeri çıkıntılar görülmektedir. Bu durum hastalığın en tipik belirtisidir. Bu belirtiler genellikle kabuk soyulmadan fark edilmez. Şiddetli enfeksiyonlarda ise konukçuya bağlı olarak bu yivler çok daha yoğun ve derindir. Anaç ve kalem kombinasyonu arasındaki ilişkiye bağlı olarak odunsu dokulardaki belirtilerin şiddeti değişebilmektedir. Hastalık asmalarda gözle görülebilir bir bodurluğa neden olmaktadır. Enfekteli asmaların yaprakları daha ufak olup, meyve verimi az ve salkımları ufaktır. *Vitis Vinifera* L. ve asma anaçlarının çoğu bu hastalığa karşı hassastır. Aşısız asmalarda ve anaçlarda hastalık latent halde bulunmakta olup, aşılı asmalarda belirtiler ortaya çıkmakla birlikte nadiren de olsa latent enfeksiyonlar görülebilmektedir (Anonim, 2019a).



Şekil 13. Asma gövde çukurlaşması virüs hastalığının gövdedeki yiv oluşumu ve aşı noktasındaki şişkinlik (solda), gövdedeki kabuk kavlaması ve yiv oluşumu (sağda) (Anonim, 2019c)

Bakteriyel hastalıklar

Kök Ur Hastalığı (Agrobacterium vitis (Ophel ve Kerr))

Kök uru hastalığını yapan etmen bakteridir. Optimum gelişme sıcaklığı 25-30°C, minimum 0°C, maksimum gelişme sıcaklığı ise 37°C'dir. Alkali topraklarda, hafif asit karakterde olanlara oranla daha çok yayılmaktadır. Hastalık etmeni sistemik olarak asma bitkisinde, toprağa karışmış urlarda ve kök parçalarında uzun yıllar canlılığını sürdürebilmektedir. Bulaşık topraklara konukçu bitki dikildiğinde, kök veya gövdenin toprağa yakın kısımlarında kültürel işlemler, aşılama, böcek ve nematod beslenmesi gibi nedenlerle açılan taze yaralardan bitkiye giriş yapmaktadır. Hastalık, asmanın toprağa yakın kısımlarında ve kollarında görülmektedir. Köklerde genellikle ur oluşturmaz ama lokal nekrozlara ve çürümelere neden olabilmektedir. Urlar yaz başlangıcında beyaz-krem renkli ve yumuşak görünümlü olup, yaz sonunda kahverengine dönüşmektedir. Sonbaharda ise kuru ve odunsu bir yapıya bürünmektedir. Bir sezonda tüm asmayı saracak kadar büyük urlar oluşabilmektedir. Urlu bitkiler genellikle zayıf

sürgün gelişimi gösterir ve sürgünün ur üstünde kalan kısımları kuruyabilmektedir. Özellikle don olaylarının görüldüğü yerlerde asma üzerindeki don çatlakları boyunca çok sayıda urlanma olmaktadır. Bu belirtiler halk arasında “sıraca” ya da “uyuz” olarak adlandırılmaktadır. Ana kök ve kök boğazında çok sayıda ur oluştuğunda, asma bitkisinde besin elementleri ve su iletimi sekteye uğramaktadır. Hasta bitkiler olumsuz çevre koşullarına ve özellikle soğuk zararına daha duyarlı hale gelmektedir (Anonim, 2019c). Şekil 14’de kök ur hastalığı gösterilmektedir.



Şekil 14. Asmanın kollarında (a, b, c, d) kök boğazında (e) urlanmalar (Anonim, 2019c)

Derin Öğrenme

Derin öğrenme insan beyninin karmaşık problemler için gözlemleme, analiz etme, öğrenme ve karar verme gibi yeteneklerini taklit eden, denetimli veya denetimsiz olarak özellik çıkarma, dönüştürme ve sınıflandırma gibi işlemleri büyük miktarlardaki etiketlenmiş verilerden yararlanarak yapabilen bir makine öğrenmesi tekniğidir (Kayaalp ve Süzen, 2018). Temel olarak verinin temsilinden öğrenmeye dayalıdır. Bir görüntü için temsil denildiğinde; piksel başına yoğunluk değerlerinin bir vektörü veya kenar kümeleri, özel şekiller gibi özellikler düşünülebilmektedir. Bu özelliklerin içinden bazıları veriyi daha iyi temsil etmektedir (Özgüven, 2019). Derin öğrenmenin daha iyi anlaşılması için yapay zeka ve makine öğrenmesi kavramlarının bilinmesi gerekmektedir (Şekil 15).



Şekil 15. Yapay zeka teknikleri


Yapay zeka, insan zekasının sahip olduğu algılama, öğrenme, geçmiş tecrübe ve düşünme yeteneğinin bilgisayar, makine veya sistemlere kazandırılarak tahmin edilebilen veya edilemeyen yeni durumlar karşısında karar vermesini sağlama ve gerekli işlemi yapabilmesidir. Bu karar verme işlemi sırasında insan zekası tarafından ilgili konunun hangi parametrelerine bakılıp değerlendiriliyorsa, yapay zekaya bu değişkenler öğretilmekte ve karar vermenin sağlanması için de insanın zihinsel fonksiyonlarına benzeyen yorumlar yapabilen bilgisayar modelleri yardımıyla formüller oluşturulmaktadır. Böylece insanın düşünce yapısına benzer, bilgisayar yazılımlarıyla bir düşünme ve karar verme modeli oluşturulmaktadır (Özgüven, 2019). Yapay zeka uygulamalarında kullanılan yöntemler aşağıdaki gibi gruplandırılmaktadır (Alpaydın, 2004):

- ✓ Sınıflandırma: Geçmiş verilerin hangi sınıf içerisinde yer aldığı belirtildiği durumda yeni verinin hangi sınıf içerisinde yer alacağını bulma işlemidir.
- ✓ Kümeleme: Geçmiş verilerin hangi sınıf içerisinde yer aldığı belirtilmediği veya bilinmediği durumda verilerin benzerliklerine kümelere ayrıştırılması işlemidir.
- ✓ Regresyon (Eğri Uydurma): Geçmiş verilerin süreklilik gösteren sayısal değerlerden oluştuğu durumlarda, bu değerlerden bir eğri modeli üretme işlemidir.
- ✓ Özellik Belirleme: Geçmiş verilerin çok fazla olması durumunda bu verilerin sınıfını belirleyen özellikler belirlenir. Bu belirleme işlemi sırasında mevcut özelliklerden bir alt küme oluşturabileceği gibi, bunların birleşiminden yeni özellikler de oluşturulabilir.
- ✓ İlişki Çıkarımı: Bir veri ile bir başka verinin birlikte yer alma durumunun analiz edilerek en çok birlikte olan verilerin belirlenmesidir.

Makine öğrenmesi yapay zekanın bir alt dalıdır (Şekil 15). Makine öğrenmesi öncelikle çeşitli algoritmalar ve yöntemler ile geçmiş verilere bakarak, veriler arasındaki karmaşık örüntüyü belirleyecek matematiksel model tespit edilmekte, daha sonra veriler üzerinden tahmin edilmesi istenilen şey hakkında tahmin yapılmaktadır. Makine öğrenmesi yöntemleri; k-en yakın komşu algoritması, basit (naive) Bayes sınıflandırıcı, karar ağaçları, lojistik regresyon analizi, k-ortalamlar algoritması, destek vektör makinaları ve yapay sinir ağlarıdır. Bu yaklaşımların bir kısmı tahmin ve kestirim, bir kısmı kümeleme ve bir kısmı da sınıflandırma yapabilme yeteneğine sahiptir (Özgüven, 2019). Bu yöntemlerde öğrenme stratejileri şunlardır (Atalay ve Çelik, 2017):

- ✓ Denetimli öğrenme: Oluşturulan model ile bir grup girdi değerine karşılık onlara ait hedef değerleri verilerek aralarındaki ilişkiyi öğrenmesi ve hedef değerlere en yakın çıktıların üretilmesi amaçlanmaktadır.
- ✓ Denetimsiz öğrenme: Hedef değerleri olmadan sadece girdi değerleri arasındaki ilişki ortaya çıkarılmaya çalışılmaktadır. Bu ilişki(ler) yardımı ile birbirine yakın değerler kümeleme yapılmaktadır. Yeni girdi bu kümelerden hangisiyle ilişkili ise o kümeye ait olacaktır.
- ✓ Pekiştirmeli (takviyeli) öğrenme: Hedef çıktıyı vermek için bir danışman yerine, elde edilen çıkışın verilen girişe karşılık iyi ya da kötü olarak değerlendiren bir kriter kullanılmaktadır.


Şekil 16’da farklı yapay zeka tekniklerinde giriş verilerinden çıkış verilerinin elde edilmesi aşamaları gösterilmektedir.



Şekil 16. Farklı yapay zeka tekniklerinde işlem aşamaları (Badem, 2017)

Derin öğrenme özellikleri

Derin öğrenme, yapay zeka ve istatistiklerin bir alt kümesi olan makine öğrenmesinin bir alt kümesidir. Makine öğrenmesinde nicel veya kategorik analiz yapmak için farklı algoritmalar ve yöntemler kullanılmaktadır. Bu tür algoritmalar, tahminler ve çıkarımlar yapmak için verilerin karmaşık modeliyle başa çıkabilen matematiksel modeller kullanmaktadır. Derin öğrenme ise veri yapısının karmaşıklığını yönetmek için katmanlarda depolanan bilgilerin soyut dönüşümlerine dayanan daha geniş bir araç setinden yararlanmaktadır. Bu nedenle derin öğrenme, verilerin temsilinden öğrenmeye dayanmaktadır (Song ve Lee, 2013). Derin öğrenme tekniğinde, büyük miktarda etiketlenmiş eğitim verisi içerisindeki görüntülerden ilgili özellikler otomatik olarak çıkarılmakta ve sınıflandırma gibi bir görevin otomatik olarak nasıl gerçekleştirileceği öğretilmektedir (Ayon ve Islam, 2019; Özgüven, 2019; Asraf ve ark., 2020; Islam ve ark., 2020; Islam ve ark., 2021). Şekil 17’de örnek bir derin öğrenme uygulamasının genel akışı gösterilmektedir.



Şekil 17. Derin öğrenme genel akış diyagramı (Saleem ve ark., 2019)


Şekil 17 incelendiğinde, ilk olarak veri seti toplanmakta, ardından genellikle eğitim seti %80 ve test seti %20 olacak şekilde iki parçaya bölünmektedir. Ardından, derin öğrenme modelleri sıfırdan veya transfer öğrenme tekniği kullanılarak eğitilmekte ve modellerin başarısının değerlendirilmesi için performans ölçütleri kullanılmaktadır. Son olarak, görüntüleri algılamak, yerleştirmek veya sınıflandırmak için görselleştirme teknikleri/haritalamaları kullanılmaktadır (Saleem ve ark., 2019). Derin öğrenmede ön işlemeye gerek kalmadan evrişimli yapay sinir ağı (CNN) modeli oluşturulabilmekte ve sınıflandırmalar diğer makine öğrenmesi yöntemlerine göre daha hızlı ve daha doğru yapılabilmektedir (Adem, 2018; Adem ve Közkurt, 2019).

Makine öğrenmesinde hedef, daha önce hiç görünmeyen bir girdi için doğru tahminler yapılması veya karar verilmesi ve bu tahmin ve karar verme süreçlerini otomatikleştiren verimli algoritmaların geliştirilmesidir. Algoritmalar geliştirilirken kuralların oluşturulması sırasında, bir uzmanın bir kararı alırken nelere dikkat etmesi gerektiğine dair kriterler dikkate alınmalıdır. Makine öğrenmesi yöntemlerinin uygulanmasında hesaplama karmaşıklığı, eğitim karmaşıklığı ve eğitilmiş algoritma uygulaması karmaşıklığı gibi karmaşıklıklar bulunabilmektedir. Bir algoritmanın performansı test hatasına göre değerlendirilmektedir. Ayrıca bir algoritma çalışırken çok sayıda test noktası bulunabilmekte ve bu noktalarda hızlı karar alınması istenmektedir. Bu nedenle test işleminin düşük hesaplama yüküne sahip olması gerekir (Ozguven, 2023).

Derin öğrenmede önemli kavramlar

Sinir Ağı


Derin öğrenmenin temelini nöral ağlar oluşturmaktadır. Bu nöral ağların amacı, bilinmeyen bir fonksiyonun yaklaşımını belirlemektir. Sinir ağları, birbiriyle bağlantılı olan nöronlardan oluşmaktadır. Şekil 18’de basit bir sinir ağı örneği gösterilmiştir.



Şekil 18. Sinir ağının basit bir örneği

Nöron


Temel biyoloji teriminde nöronlar, aksonları boyunca dendritlerden bir uçtan diğer uca bir elektrik sinyali göndermektedir. Bu sinyaller daha sonra başka bir nörona geçirilmektedir. Bu işlemler sinir sistemi boyunca iletilerek bilgilerin beyne iletilmesini sağlamaktadır. Benzer şekilde makinelerin de insan gibi öğrenebilmesi için beyinde öğrenme sürecinde etkili olan ve beynin nöron adı verilen bilgiyi işleme kapasitesinin sinir hücreleri taklit edilmeye çalışılmaktadır. Bunun sonucunda yapay nöron kavramı ortaya çıkmıştır. Şekil 19’da örnek bir yapay nöron verilmektedir. Yapay nöronlardan oluşan ağa ise nöral ağ denilmektedir. Nöral ağda nörona gelen bir girdi alınmakta ve işlenmektedir. Ardından sonraki işlem için diğer nöronlara gönderilen bir çıktı ya da sonuç çıktısı gönderilmektedir.



Şekil 19. Yapay nöron

Ağırlıklar

Bir yapay sinir ağındaki nöronlar arasında her bağlantı bir ağırlık (weight) ile ilişkilidir. Ağırlıklar, bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini göstermektedir. Girdi, nörona geldiğinde bir ağırlık ile çarpılmaktadır. Şekil 20’de gösterildiği gibi iki girişli bir nöronda her bir nöron girişi, o girişe atanan bir ağırlığa sahiptir.



Şekil 20. Yapay nörona ağırlıklar


Bir a girdisinin w_1 ağırlığı ile ilişkilendirildiği varsayıldığında, düğümden geçtikten sonraki giriş ' $a*w_1$ ' olarak ifade edilmektedir. Ağırlıklar rastgele başlatılmakta ve bu ağırlıklar model eğitim sürecinde güncellenebilmektedir.

Sapma (Bias)

Girdiye ağırlıktan farklı ek olarak uygulanan doğrusal bileşene sapma denilmektedir. Bu sapma değeri giriş olarak tanımlanan ve girdinin ağırlık ile çarpımı sonucuna, ağırlık katsayılı girişin aralığını değiştirmek için temel olarak eklenmektedir. Sapma değerinin eklenmesi sonucunda giriş ' $a*w_1+bias$ ' olarak ifade edilmektedir. ' $a*w_1+bias$ ', dönüşümün son doğrusal bileşenidir.

Aktivasyon Fonksiyonları

Nörona gelen bilginin bir sonraki nörona iletilip ileilmeyeceğine karar vermek için kullanılmaktadır. Aktivasyon fonksiyonları nöronların toplam (Σ) fonksiyonunda üretilen çıktıların nasıl bir değişimden geçmesi gerektiğini belirlemektedir. Aktivasyon fonksiyonu olan $f()$ uygulandıktan sonraki çıktı ' $f(a*w_1+b)$ ' olmaktadır. Şekil 21'de x_1 'den x_m 'ye kadar m tane girdi ve bu girdilere karşılık gelen w_1 'den w_m 'ye kadar ağırlıklar ve sapma gösterilmektedir. Ağırlıklar önce kendilerine karşılık gelen girdi ile çarpılmakta ve sonra sapma çarpım sonucuna eklenmektedir. Ağırlık toplamalarına karşılık gelen girdi toplamalarının çarpımına sapma değeri eklenmesi sonucu oluşan ifade u olarak kabul edilmektedir. Aktivasyon fonksiyonunun u 'ya uygulanması sonucu $f(u)$ oluşmakta ve nöronda elde edilen son çıktı $y=f(u)$ olarak ifade edilmektedir. En yaygın kullanılan aktivasyon fonksiyonları sigmoid, ReLU (Rectified Linear Unit) ve Softmax aktivasyon fonksiyonlarıdır.



Şekil 21. Yapay nöronda aktivasyon fonksiyonu

Katmanlar

Farklı düzeylerde yer alan nöron gruplarıdır. Sinir ağları girdi, gizli ve çıktı olmak üzere üç ana katmandan oluşmaktadır. Ağdaki süreç katmanları ağda bulunan gizli katmanlardır. Gizli katmanlar, gelen veriler üzerindeki belirli görevleri uygulayan ve bu görevler sonucunda oluşturulan çıktıyı bir sonraki katmana aktaran katmanlardır. Orta katmanlar gizlenirken girdi ve çıktı katmanları görünür olan katmanlardır.

Çok Katmanlı Algılayıcı (MLP)

Karmaşık görevlerin gerçekleştirilebilmesi için tek bir nöron yeterli olmadığından istenen çıktıların üretilmesi için birden fazla nörondan oluşan nöron grupları kullanılmaktadır. Temel olarak en basit ağ giriş katmanı bir gizli katman ve çıkış katmanından oluşmaktadır. Tam bağlı bağlantılar olarak adlandırılan MLP’de, her bir katmanda birden fazla nöron bulunmakta ve tüm katmanlardaki nöronlar kendisinden sonraki katmanda bulunan nöronlar ile bağlantılıdır.

İleri Yayılım

Girdi verilerinin giriş katmanından gizli katmana oradan da çıkış katmanına aktarıldığını ifade eden işlemdir. İleri yayılım işleminde bilgi sadece tek yönlü ve ileri doğru yol almaktadır. Giriş katmanı, gizli katmanlar için girdiyi sağlamaktadır. Gizli katmana aktarılan bilgi, çıktı üretmesi için çıkış katmanına aktarılmakta ve çıkış katmanında da çıktı üretilerek süreç sonlandırılmaktadır. Bu yapıda geriye doğru bir hareket söz konusu değildir.

Maliyet (Kayıp) Fonksiyonu

Bir modelde oluşturulan yapay sinir ağının amacı gerçek değerlere en yakın çıktıları tahmin etmeye çalışmaktır. Modelin doğruluk değeri maliyet fonksiyonu kullanılarak hesaplanmaktadır. Maliyet fonksiyonu, gerçek değerlerin tahmininde başarı için ödüllendirmeye, başarısızlık için cezalandırmaya çalışmaktadır. Böylece modelin başarılarından veya hatalardan ders çıkarmasını sağlamaktadır. Bir modelin çalıştırılmasındaki amaç tahmin doğruluğunun artırılarak hatanın azaltılması ve maliyet fonksiyonunun minimize edilmesidir. En düşük maliyet fonksiyonu değerine sahip sinir ağı, optimize edilmiş çıktıları oluşturan ağıdır.

Öğrenme Oranı

Maliyet fonksiyonunu minimize etmek için yapılan, her tekrar sayısında (iterasyon) elde edilen en aza indirme miktarı, öğrenme oranı olarak ifade edilmektedir. Basit bir ifadeyle, maliyet fonksiyonunun minimum noktasına inme oranı öğrenme oranıdır. Problemin çözümünde en uygun sonucu elde etmek için öğrenme oranı dikkatli bir şekilde seçilmelidir. Aksi takdirde en uygun çözüm elde edilememekte ve ağı en uygun çözüme yaklaşması sonsuza dek sürebilmektedir.

Geri Yayılım

Sinir ağı tanımlandığında, düğümlere rastgele ağırlık ve sapma değerleri atanmaktadır. Tek bir iterasyon ile edilen çıktı için ağın hatası hesaplanabilmektedir. Elde edilen hata değeri, maliyet fonksiyonunun eğimi ile birlikte ağın ağırlıklarının, güncellenebilmesi için ağa geri beslenmektedir. Sonraki iterasyonlarda hatanın minimize edilmesi için bu ağırlıklar güncellenmektedir. Maliyet fonksiyonunun eğimi kullanılarak ağırlıkların güncellenmesi geri yayılım olarak ifade edilmektedir. Ağı hareketinin geriye doğru olduğu geri yayılımda eğim ile birlikte hata, çıktı katmanından geriye doğru gizli katmanlara aktararak ağırlıkların güncellenmesi sağlanmaktadır.

Yığınlar

Tüm girdinin tek seferde gönderilmesi yerine girdiler rastgele seçilmiş eşit büyüklükte, birbirinden bağımsız yığınlara bölünerek ağda eğitilmektedir. Verilerin, yığınlar şeklinde eğitilmesinde kullanılan ağ modeli, tek seferde tüm veri kümesindeki girdilerin ağa beslenmesiyle oluşturulan modele göre daha yaygındır.

Yineleme (Epoch) Sayıları

Hem ileri hem de geri yayılımda tüm girdi yığınlarının tek bir eğitim tekrar sayısı yineleme sayısı olarak ifade edilmektedir. Ağın eğitiminde kullanılacak olan yineleme sayısı seçilebilmektedir. Tekrar sayısının yüksek olması ağın daha yüksek doğruluk değerine ulaşmasını sağlayabilmektedir. Ancak çok yüksek seçilen tekrar sayısı ağın aşırı uyumuna (overfitting) sebep olabilmektedir.

Seyreltme (Dropout)

Ağın aşırı uyumunu önlemek için kullanılan seyreltme katmanında düzenleme (regülerizasyon) işlemine verilen isimdir. Eğitim esnasında gizli katmanlardaki belirli sayıda nöronun rastgele bırakılmasıdır. Eğitim, nöronların farklı bileşimlerinden oluşan çeşitli sinir ağı mimarilerinin oluşmasına neden olmaktadır. Bu düzenleme işlemi birden fazla ağın çıktısının sonuç çıktısını üretmek için bir araya getirildiği toplama işlemi olarak düşünülmektedir.

Yığın Normalizasyonu

Veri dağılımının bir sonraki katmanla aynı olmasını sağlamak için yapılan belirli kontrol noktaları oluşturma işlemidir. Ağın eğitimindeki ağırlık, eğimli inişin her bir adımında değişmektedir. Bu değişiklikler, verinin bir sonraki katmana ne şekilde gönderileceğini belirlemektedir. Veriler bir sonraki katmana gönderilmeden önce açık bir şekilde normalize edilmektedir. Çünkü sonraki katman, daha önce bu katmana gönderilen dağılımına benzeyen bir veri yığını beklemektedir.

Filtreler

Evrişimli sinir ağlarındaki bir filtre, sarmalanmış bir çıktı üretmek için girdi görüntüsünün bir bölümüyle çarpılan ağırlık matrisi gibidir. 28×28 boyutlarındaki bir görüntüde, 3×3 'lük rastgele seçilmiş bir filtre belirlenirse, bu filtre sarmalanmış (kırımlı) çıktı olarak bilinen sonucu oluşturmak için görüntünün farklı 3×3 'lük bölümleri ile çarpılması gerekmektedir. Belirlenen filtrenin boyutu genellikle orijinal görüntünün boyutundan daha küçük ölçektedir. Filtre değerleri, maliyet fonksiyonunun minimize edilmesi için yapılan geri yayılım esnasındaki ağırlık değerleri gibi güncellenmektedir.

Derin öğrenme kitaplık ve platformları

Torch

Çok boyutlu tensörler için veri yapılarının ve bunlar üzerinden matematiksel işlemlerin tanımlandığı kitaplıktır. C'deki bir uygulama ile LUA dili kullanılarak geliştirilen Torch'un Python uygulamasına PyTorch denilmektedir.

TensorFlow

Makine öğrenmesi için Google tarafından geliştirilen uçtan uca açık kaynaklı bir platformdur. Vektörler veya n boyutlu matrisler olan tensör kavramına dayanmaktadır. Geliştiricilerin yeni makine öğrenmesi teknolojilerini kolayca oluşturulup geliştirmelerine olanak tanıyan kapsamlı ve esnek bir kitaplık ekosistemine sahiptir. Çok sayıda soyutlama seviyesi bulunduğu için çözülmek istenilen probleme uygun olanı seçme imkânı sunmaktadır. Google'ın TensorFlow'u şu anda dünyanın en popüler öğrenme kitaplığıdır. TensorFlow ile sunucularda, cihazlarda ve Web'de model oluşturup eğitme ve dağıtma imkanı bulunmaktadır (Savaş, 2019).

Theano

Çok boyutlu dizileri içeren matematiksel ifadelerin verimli bir şekilde tanımlanmasına, optimize edilmesine ve değerlendirilmesine olanak tanımaktadır. Bir Python kütüphanesidir. Python'da yazılmış çok genel bir kütüphane doğrudan derin öğrenme için kullanıldığı gibi üzerine yazılmış Keras veya Lasagne gibi kütüphanelerle de kullanılabilir (Clark, 2018).

Caffe

Caffe, ifade yapısı, hız ve modülerlik göz önünde bulundurularak tasarlanmış bir derin öğrenme kitaplığıdır. Mimarisi ve uygulamaları, derin öğrenme problemlerinde kullanımını yaygınlaştırmaktadır. Bir GPU makinesinde eğitmek için tek bir etiket ayarlayarak CPU ile GPU arasında geçiş yapılabilen ve bilgisayarlar ile mobil cihazlar üzerinde kullanılmak için dağıtılabilir. Genişletilebilir yapısı ve fonksiyonelliği sayesinde, pek çok araştırmacı tarafından yenilikler ve eklemeler yapılmıştır. Ayrıca algoritmayı hızlı çalıştırma özelliğine sahiptir (Savaş, 2019).

Keras

Python ile yazılan TensorFlow üzerinde çalışan bir derin öğrenme platformudur. İçerdiği çok fazla işlevsel fonksiyon sayesinde Keras, Theano ya da Tensorflow'a göre daha kolay uygulama geliştirilebilir olduğu için yaygın kullanım alanına sahiptir. Keras, kullanıcı deneyimini ön planda tutan, kullanıcı dostu bir arayüzü olan ve önceliği makineler olmayan, insanlar için tasarlanmış bir birbiriyle tutarlı ve basit kullanımlı API (Application Programming Interface) sunmaktadır. Hata ayıklama için geri bildirim sağlamaktadır. Yeni modüllerin eklenmesi kolay olup, mevcut örneklerle yapılabilecek çözüm kümesi geniştir. Bu özellikleri araştırmalar için uygun yapıda olmasını sağlamakta ve genişletilebilmektedir. Sinir ağı katmanları, maliyet fonksiyonları, optimize ediciler, başlatma şemaları, aktivasyon fonksiyonları ve düzenleştirme şemaları, yeni modeller oluşturmak için birleştirilebilecek modüler tasarıma imkân sağlamaktadır (Clark, 2018; Savaş, 2019).

Microsoft Cognitive Toolkit (CNTK)

CNTK, sinir ağlarını yönlendirilmiş bir grafik aracılığıyla bir dizi hesaplama adımı olarak tanımlayan birleşik bir derin öğrenme platformudur. CNTK, kullanıcının ileri beslemeli DNN'ler, CNN'ler ve tekrarlayan sinir ağları (RNN'ler/ LSTM'ler) gibi popüler model tiplerini kolayca gerçekleştirmesini ve birleştirmesini sağlamaktadır. Python, C# veya C++ programlara bir kütüphane olarak dahil edilebilmekte veya kullanıcının kendi model açıklama dili (BrainScript) aracılığıyla bağımsız bir makine öğrenme aracı olarak kullanılabilir. Ek olarak, Java programlarında CNTK model değerlendirme işlevselliği kullanılabilir (Clark, 2018; Savaş, 2019).

DL4J

Java için Derin Öğrenme (DL4J), Java ve Scala için yazılmış ilk derin öğrenme kitaplığıdır. Hadoop ve Apache Spark ile koordineli çalışmaktadır (Clark, 2018).

Derin öğrenmede kullanılan algoritma türleri

Derin öğrenme algoritmaları hemen hemen her tür veriyle çalışmakta ve karmaşık sorunları çözmek için büyük miktarda bilgi işlem gücü ve bilgi gerektirmektedir. Gelişen teknoloji sayesinde derin öğrenme algoritmalarının sayısı her geçen gün artmaktadır. Son yıllarda en popüler olan algoritmalar (Bengio ve ark., 2015; Janiesch ve ark., 2021):

- Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN)
- Uzun Kısa Süreli Bellek Ağları (Long Short Term Memory Networks - LSTM)
- Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN)
- Üretken Çekişmeli Ağlar (Generative Adversarial Networks - GAN)
- Radyal Temel Fonksiyon Ağları (Radial Basis Function Networks - RBFN)
- Çok Katmanlı Algılayıcılar (Multilayer Perceptrons - MLP)
- Kendi Kendini Düzenleyen Haritalar (Self Organizing Maps - SOM)
- Derin İnanç Ağları (Deep Belief Networks - DBN)
- Kısıtlı Boltzmann Makinaları (Restricted Boltzmann Machines - RBM)
- Otomatik Kodlayıcılar

Uzun Kısa Süreli Bellek Ağları (LSTM)

LSTM'ler, uzun sürede bağımlılıkları öğrenmek ve bunlara uyum sağlamak için programlanmış Tekrarlayan Sinir Ağları (RNN) olarak tanımlanmaktadır. Temel olarak geçmişteki bilgilerin mevcut bilgiyi açıklamasında ve gelecek bilginin tahmin edilmesinde etkili bir yöntemdir. Uzun ve kısa süreli depolama katmanının ana bileşeni, depolama bloğu verilen bir birimdir. Uzun ve kısa süreli bellek bloklarının giriş, çıkış ve unutma kapıları olmak üzere üç kapısı vardır. Bu kapılar hücrenin yazılmasını, okunmasını ve sıfırlanmasını gerçekleştirmektedir. LSTM, geçmiş verileri daha uzun süre ezberleyebilmekte ve geri çağırabilmektedir. Hafızayı veya önceki girdileri sınırlayabildikleri için yaygın olarak zaman serisi tahminlerinde kullanılmaktadır. LSTM, zaman serileri tahmini uygulamalarının yanı sıra, konuşma tanıyıcılar oluşturmak, farmasötiklerde gelişme ve müzik döngülerinin kompozisyonu gibi bir dizi olayda da çalışmaktadır.

Tekrarlayan Sinir Ağları (RNN)

LSTM'lerden sağlanan girdinin RNN'lerin girdi olarak kullanılmasına izin veren bir döngü oluşturan bazı yönlendirilmiş bağlantılardan oluşmaktadır. Bu girdiler, derinlemesine gömülmekte ve LSTM'lerin ezberleme yeteneğini zorlamaktadır. Bu durum girdilerin dahili bellekte bir süre emilmesini sağlamaktadır. Bu nedenle RNN'ler, LSTM'ler tarafından korunan girdilere bağımlıdır ve LSTM'lerin senkronizasyon olgusu altında çalışmaktadır. RNN'ler çoğunlukla görüntüye altıyazı ekleme, zaman serisi analizi, el yazısı verileri tanıma ve verileri makinelerle çevirmede kullanılmaktadır. RNN'ler, süre t olarak tanımlanmışsa çıkış beslemeleri $(t-1)$ sürede takip etmektedir. Ardından, t tarafından belirlenen çıkış, $t+1$ girişi beslemektedir. Benzer şekilde, bu işlemler herhangi bir uzunlukta oluşan tüm girdiler için tekrarlanmaktadır.

Ayrıca, RNN'ler geçmiş bilgileri depolamakta ve model boyutu artırılmasına rağmen girdi boyutunda bir artış olmamaktadır.

Üretken Çekişmeli Ağlar (GAN)

GAN'lar, eğitim verileriyle eşleşen yeni veri örnekleri oluşturmak için kullanılan derin öğrenme algoritmaları olarak tanımlanmaktadır. GAN genellikle yanlış veri üretmeyi öğrenen bir üretici ve bu yanlış veriden öğrenerek kendini uyarlayan bir ayırmacı olmak üzere iki bileşenden oluşmaktadır. GAN'lar, sahte verileri ve gerçek verileri üreterek ve anlayarak simülasyonda çalışmaktadır. Bu verileri anlamaya yönelik eğitim sırasında, üretici farklı türde sahte veriler üretmektedir. Burada ayırmacı hızla uyum sağlamayı ve buna yanlış veri olarak yanıt vermeyi öğrenmektedir.

Radyal Temelli Fonksiyon Ağları (RBFN)

RBFN'ler, ileri beslemeli bir yaklaşımı izleyen ve aktivasyon fonksiyonunda radyal temelli fonksiyonları kullanan sinir ağı türleridir. Genellikle zaman serisi tahmini, regresyon testi ve sınıflandırma için kullanılan girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. RBFN'ler, eğitim veri setinde bulunan benzerlikleri ölçerek bu görevleri yerine getirmektedir. Genellikle, bu verileri girdi katmanına besleyen bir girdi vektörüne sahiptir. Böylece tanımlamayı doğrular ve önceki veri kümelerini karşılaştırarak sonuçları yayınlarlar. Girdi katmanında bu verilere duyarlı nöronlar bulunmakta ve katmandaki düğümler veri sınıfını sınıflandırmada etkilidir. Nöronlar, giriş katmanı ile yakın bütünleşme içinde çalışsalar da başlangıçta gizli katmanda bulunmaktadır. Gizli katman, çıkışın nöronun merkezine olan uzaklığıyla ters orantılı olan Gauss transfer fonksiyonlarını içermektedir. Çıkış katmanı, Gauss fonksiyonlarının nöronda parametre olarak iletildiği ve çıktının üretildiği radyal tabanlı verilerin doğrusal kombinasyonlarına sahiptir.

Çok Katmanlı Algılayıcılar (MLP)

MLP'ler, derin öğrenme teknolojisinin temelidir. Çeşitli algılayıcı katmanlarına sahip ileri beslemeli sinir ağları sınıfına aittir. Bu algılayıcıların içinde çeşitli aktivasyon fonksiyonları vardır. MLP'ler ayrıca bağlantılı giriş ve çıkış katmanlarına sahiptir ve sayıları aynıdır. Ayrıca bu iki katmanın arasında gizli kalan bir katman vardır. MLP'ler çoğunlukla görüntü ve konuşma tanıma sistemleri veya diğer bazı çeviri yazılımı türlerini oluşturmak için kullanılır. MLP'lerin çalışması, girdi katmanındaki verileri besleyerek başlar. Katmanda bulunan nöronlar, bir yönde

geçen bir bağlantı kurmak için bir grafik oluşturmaktadır. Bu girdi verilerinin ağırlığının gizli katman ile girdi katmanı arasında olduğu bulunmuştur. MLP'ler, hangi düğümlerin harekete geçmeye hazır olduğunu belirlemek için aktivasyon fonksiyonlarını kullanmaktadır. Bu aktivasyon fonksiyonları arasında tanh fonksiyonu, sigmoid ve ReLU'lar bulunmaktadır. MLP'ler, temel olarak, verilen veri setinden istenen çıktıyı elde etmek için katmanların ne tür bir korelasyona hizmet ettiğini anlamak için modelleri eğitmek için kullanılmaktadır.

Kendi Kendini Düzenleyen Haritalar (SOM)

SOM'lar, yapay ve kendi kendini organize eden sinir ağırları ile verilerin boyutlarını anlamak ve verileri görselleştirmek için tasarlanmıştır. Veriler genellikle yüksek boyutludur. SOM'lar, farklı düğümlerin ağırlıklarını başlatmakta ve ardından verilen eğitim verilerinden rastgele vektörler seçerek verilerin görselleştirilmesine yardımcı olmaktadır. Bağımlılıkların anlaşılabilmesi ve göreceli ağırlıkları bulmak için her düğümü incelemektedir. Kazanan düğüme karar verilmekte ve buna En İyi Eşleşen Birim (BMU) denilmektedir. Daha sonra SOM'lar bu kazanan düğümleri keşfetmektedir. Düğüm BMU'ya ne kadar yakınsa, ağırlığı tanıma ve daha fazla aktivite gerçekleştirme şansı o kadar fazladır. Ayrıca, BMU'ya daha yakın hiçbir düğümün kaçırılmamasını sağlamak için birden fazla yineleme yapılmaktadır.

Derin İnanç Ağları (DBN)

DBN'ler, tesadüfi etkenlere maruz değişkenlerin yanı sıra çeşitli gizli katmanlara sahip oldukları için üretken modeller olarak adlandırılmaktadır. Gizli değişken, ikili değerlere sahip olduğu için gizli birim olarak adlandırılmaktadır. DBN'ler ayrıca Boltzmann Makineleri olarak da bilinmektedir. Bunun nedeni önceki ve ardışık katmanlarla iletişim kurmak için birbirinin üzerine istiflenmesidir. DBN'ler, aşağıdan yukarıya geçiş yaklaşımını izleyen her katmandaki gizli değerde bulunan değerlerden öğrenmektedir. DBN'ler, hareketli nesneleri yakalamanın yanı sıra video ve görüntü tanıma gibi uygulamalarda kullanılmaktadır.

Kısıtlanmış Boltzmann Makineleri (RBM'ler)

RBM'ler verilen girdi setindeki olasılık dağılımından öğrenen tesadüfi değişken sinir ağırlarına benzerdir. Bu algoritma esas olarak boyut küçültme, regresyon ve sınıflandırma, konu modelleme alanında kullanılmakta ve DBN'lerin yapı taşları olarak kabul edilmektedir. RBM'ler, görünür katman ve gizli katman olmak üzere iki katmandan oluşmaktadır. Bu katmanların her ikisi de gizli birimler aracılığıyla bağlanmaktadır. RBM'lerin işleyişi, girdilerin

kabul edilmesi ve bunların sayılara çevrilmesiyle gerçekleştirilmektedir. RBM'ler, her girdinin ağırlığını hesaba katmaktadır. Bu girdi ağırlıkları yeniden yapılandırılmış girdilere dönüştürülmektedir. Daha sonra, bu çevrilmiş girdilerin her ikisi de bireysel ağırlıklarla birlikte birleştirilmektedir. Bu girdiler son olarak aktivasyonun gerçekleştirildiği görünür katmana itilmekte ve kolayca yeniden yapılandırılabilen çıktılar üretilmektedir.


Otomatik Kodlayıcılar

Otomatik kodlayıcılar, girişlerin ve çıkışların genellikle aynı olduğu verileri kopyalayan yüksek düzeyde eğitilmiş özel bir sinir ağı türüdür. Kodlayıcı, kod ve kod çözücü olmak üzere üç bileşenden oluşmaktadır. Denetimsiz öğrenme ile ilgili sorunları çözmek için tasarlanmıştır. Otomatik kodlayıcılar görüntüyü veya girişi kodlayarak boyutunu küçültmektedir. Kod çözücü görüntü düzgün görünmüyorsa, açıklama için sinir ağına iletmektedir. Ardından netleştirilmiş görüntü, yeniden yapılandırılmış görüntü olarak adlandırılarak yeni veri oluşturulmaktadır. Kodlayıcıdaki verinin girdi boyutu ile kod çözücü sonucundan oluşan yeni verinin nöron sayısı (boyutu) aynı olmaktadır.

Evrişimli sinir ağları (CNN)

İnsanlar bir görüntüye baktığında nesneleri, nesnelerin renklerini ve şekillerini, aynı tipteki nesnelerin sayısını, duruş biçimleri gibi özelliklerini rahatça söyleyebilmektedir. Aynı görüntüyü bilgisayar ise, bir sayı matrisi olarak görmektedir. Evrişimli sinir ağları ile görüntü sınıflandırma, nesne tanımlama, görüntü segmentasyonu gibi işlemler başarılı bir şekilde yapılmaktadır. CNN çok sayıda gizli katman kullanılarak görüntülerdeki farklı özelliklerin algılanmasını sağlamaktadır. Bundan dolayı görüntülerdeki nesnelerin hangi nitelikte olduğu kolay bir şekilde ayırt edilebilmektedir. Genel olarak ConvNets olarak bilinen evrişimli sinir ağları (CNN), verileri birden çok katmandan geçirmekte ve evrişim işlemlerini özellik haritaları çıkararak yapmaktadır. CNN, birden fazla evrişim ve havuzlama katmanlarından oluşmaktadır. İlk evrişim katmanları, kenarlar veya köşeler gibi küçük temel özellikleri algılayarak yeni kanallar eklemektedir. Havuzlama katmanları çözünürlüğü azaltırken kanal sayısını değiştirmemektedir. Sonraki evrişim katmanlarının daha önce tespit edilen temel özellikleri, veri kümesine özgü daha karmaşık daha büyük özelliklerle yeniden birleştirmesine olanak tanımaktadır. Evrişim katmanları filtrelerin öğrenilebilir ağırlık matrislerini kullanarak filtrelerin özelliklerini tanıırken, havuzlama katmanları da çekirdeklerinde bir ortalama veya maksimum işlevini kullanmaktadır. Hem filtreler hem de çekirdekler her seferinde adım adım dönen bir pencere olarak giriş üzerinde hareket ettirilmektedir. Bir CNN yapısı Şekil 22'de


görüldüğü gibi birden fazla evrişim, ReLU (Düzleştirilmiş Doğrusal Birim) ve havuzlama katmanına sahip olabilmektedir.



Şekil 22. Bir evrişimli sinir ağının yapısı

CNN katmanları

CNN, iki temel aşamadan oluşmaktadır. Bu aşamalardan ilki öznitelik haritalarının çıkarımı aşamasıdır. İkinci aşama ise sınıflandırma aşamasıdır. Derin öğrenme algoritmalarını, klasik makine öğrenme algoritmalarından ayıran en temel fark, CNN'lerin birinci aşaması içerisinde yer alan, etiketli görüntü verileri kullanılarak öznitelik haritalarının çıkarılması ve ardından bu öznitelik haritalarının kendi içlerinde eşlenmesi işlerinin tümü, girdi verileri (etiketli görüntü pikselleri) üzerinden tam otomatik olarak yapılmasıdır. Diğer bir ifadeyle öznitelik haritalarının çıkarılması işlemi, etiketli görüntü piksellerine farklı filtreler uygulayarak görüntünün dokuları ve bu dokuların birbiri ile olan ilişkisi hakkında bilgi edinmektir. CNN'lerin birinci aşaması sırasıyla, evrişim katmanları, ReLU katmanı ve havuzlama katmanlarından oluşmaktadır. İkinci aşamasında ise, tam bağlantılı katmanlar ve softmax katmanı bulunmaktadır (Deng ve Yu, 2013; Kim, 2017). Şekil 23'te CNN katmanları gösterilmektedir.



Şekil 23. CNN katmanları

Evrişim Katmanı


Evrişim katmanı derin öğrenmenin ilk aşamasını oluşturmaktadır. Bu katmanda girdi veriye, kayan filtreler uygulanmaktadır. Buradaki kayan filtre terimi, yatay ve dikey hareketler ile girdi veri üzerinde dolaşarak filtrelerin uygulanmasını ve girdi verisinin evrilmesini ifade etmektedir. Evrişim katmanının sayısı ve içerisinde uygulanacak olan filtre genişliği, filtre sayısı, adım aralığı (stride) ve dolgu boyutu (pad) gibi parametreler tasarlanacak ağına yapısına göre seçilmektedir.

ReLU Katmanı

Derin öğrenme algoritmalarındaki kullanılan verilerin içerisinde yapılacak işin tanımına göre anlamlı ve anlamsız veri ayırımı yapmak için farklı düzenleme teknikleri uygulanmaktadır. Bunlara örnek olarak L1/L2, Dropout, ReLU teknikleri verilebilmektedir. Dünyada en yaygın kullanılan aktivasyon fonksiyonlarından ReLU'da girdi verisinin her bir elemanına bir eşik değeri uygulanarak negatif giriş değerlerinde sıfırı, pozitif giriş değerlerinde ise giriş değerini olduğu gibi çıkışa aktarmaktadır. Verinin değeri, sıfırdan küçük ise sıfıra eşitlenmekte, sıfırdan büyük ya da sıfıra eşit ise verinin kendi değerini ilgili veriye atamaktadır. Dropout, büyük veriler ile uğraşıldığında, ağı ezberlemesinin önüne geçmek için gizli katmanlar üzerinde, belirlenen ağırlıkların tekrar durumuna göre elemeler yapması işlemidir. L1/L2 ise derin öğrenme çalışmalarının gizli katmanlarında kullanılan bir aktivasyon fonksiyonudur.

Havuzlama (Pooling) Katmanı

Aktivasyon katmanından sonra elde edilen aktivasyon haritasının özelliğini kaybetmeyecek şekilde uzamsal boyutunun azaltılması havuzlama katmanı ile mümkün olmaktadır. Daha az uzamsal bilgi daha az parametre anlamına gelmekte ve bu da modelin hesaplama performansını arttırmaktadır. Bir diğer faydası da aşırı uyumu (ezber) engellemesidir. Evrişim katmanında olduğu gibi veri üzerinde filtre gezdirme esasına dayanmaktadır. Ortalama havuzlama ve maksimum havuzlama olarak iki farklı şekilde havuzlama çalışması yapılabilmektedir. Maksimum havuzlama, belirlenen matris boyutuyla, öznelik haritası üzerinde dolaşım yapılmaktadır. Dolaşım yapılırken havuzlama matrisi içinde kalan öznelik haritası bölgesi içerisinde, maksimum değere sahip olan değer alınmaktadır. Ortalama havuzlama yönteminde ise değerlerin ortalamaları alınmaktadır (Şekil 24).



Şekil 24. İki farklı yöntem kullanılarak elde edilen havuzlama işlemi

Tam Bağlantılı (Full-Connected) Katman


Klasik bir CNN’de evrişim ve havuzlama işleminden sonra bir tam bağlı katman bulunmaktadır. Tam bağlı katman adından da anlaşılacağı üzere önceki katmana tam olarak bağlıdır. Tam bağlı katmanda yapılan işlem; bir önceki katmandan gelen veri ile ağırlık değerinin çarpılması ve sonrasında sapma hesaplaması yapılmasıdır.

Softmax Katmanı

Softmax katmanı, eğitilen ağı sunulan girdi verisi üzerinde tüm aşamalar gerçekleştirildikten sonra son aşama olan etiket tahmininin yapıldığı katmandır. Bu katmanda kullanılan softmax sınıflandırıcısı, çıkışın sınıflara ait olma olasılığının dağılımını vermektedir. Dolayısıyla 0-1 arasında değer üretmektedir. Üretilen değer 1’e yakın olması ağın tahmin ettiği nesnenin doğru olma olasılığını arttırmaktadır.

Faster R-CNN Modeli

Faster R-CNN, nesne tespiti için kullanılan bir derin öğrenme mimarisidir. Bu mimari, Şekil 25'de görüldüğü gibi üç bölümden oluşmaktadır.




Şekil 25. Faster R-CNN mimarisi (Adem ve ark., 2022)

Şekil 25'de görüldüğü gibi ilk kısımda evrişim katmanındaki filtreler ile görüntünün öznitelikleri çıkarılmış ve böylece iki boyutlu matris yapısında bir öznitelik haritası oluşturulmuştur. İkinci bölümde, sinir ağı olarak kullanılan Bölge Önerme Ağı (RPN), özellik haritalarında ilgili nesneye benzerlik olasılığını tahmin etmektedir. Tahmin katmanı aşaması olan üçüncü bölümde, Fast R-CNN ağı kullanılarak bölgelerin sınıflandırma değeri ile tahmin doğruluk oranı birleştirilerek iki çıktı katmanı oluşturulmuştur. İlk çıktı katmanı softmax sınıflandırmasını gerçekleştirirken, diğer çıktı katmanı tahmin doğruluğunu veren regresyon katmanıdır. Bu bölümde sınırlayıcı kutuların sınıfları belirlenerek puan tahminleri yapılmaktadır. Faster R-CNN modelinin getirdiği yenilik, RPN ağının doğrudan özellik haritasının bulunduğu katmana bağlanabilmesidir. Bu sayede tüm görüntülerde nesne tespiti için bir ortam sağlanmaktadır (Jiang ve Learned-Miller, 2017).

SSD Multibox Modeli

Single Shot Multi-Box Detector (SSD) modeli, görüntülerdeki nesneleri algılamak için tek bir CNN kullandığı için bu alandaki en hızlı çalışan algoritmalarından biridir (Liu ve ark., 2016; Ning ve ark., 2017). Yüksek çözünürlüklü görüntülerde nesne algılama ve sınıflandırma için yaygın olarak kullanılmaktadır (Liu ve ark., 2019). Nesne tespiti için belirlediği alanlarda sabit boyutlu sınırlayıcı kutular oluşturmakta ve belirlenen her kutu için tahmin puanı hesaplanmaktadır. Eğitim aşamasında, modeldeki tüm parametreler, geriye yayılım algoritması ve kayıp değerleri ile güncellenmektedir (Li ve Zhou, 2017). Bu sayede optimum filtre parametreleri belirlenmekte ve kayıp değeri en aza indirilmektedir. Bu aşamadaki tüm hesaplamaları tek bir ağda yaparak örnekleme aşamasını ortadan kaldırdığı için diğer nesne algılama yapan modellere göre uygulaması çok kolay ve basittir (Ghoury ve ark., 2019). SSD Multibox mimarisi, Şekil 26'de gösterilmektedir.



Şekil 26. SSD Multibox mimarisi (Adem ve ark., 2022)

2. LİTERATÜR ÖZETLERİ

Fuentes ve ark. (2017) çalışmalarında, domates bitkilerinde Yaprak Küf, Gri Küf, Kanser, Veba, Yaprak Kemirgeni, Düşük Sıcaklık, Külleme, Beyaz Sinek hastalık ve zararlıları tespit etmek için derin öğrenme yaklaşımını önermektedirler. Daha Hızlı Bölge Tabanlı Evrişimli Sinir Ağı (Faster R-CNN), Bölge Tabanlı Tamamen Evrişimli Ağ (R-FCN) ve Tek Çekim Çoklu Kutu Dedektör (SSD) derin öğrenme modellerini kullanmışlardır. Araştırmacılar derin öğrenme modellerinin eğitimi ve testi için dokuz hastalık ve zararlı sınıfı içeren 5 000 adet görüntü kullanmışlardır. Deneylerini gerçekleştirmek için veri setini %80 eğitim, %10 doğrulama ve %10 test seti olarak ayırmışlardır. Yaptıkları çalışma sonucunda modellerin başarı oranları Faster R-CNN %83, R-FCN %85.98 ve SSD %82.53 olarak elde ettiklerini bildirmişlerdir. R-FCN modelinin, Faster R-CNN ve SSD modellerine göre daha başarılı şekilde hastalık ve zararlıları tespit ettiğini raporlamışlardır.

Lu ve ark. (2017) yaptıkları çalışmada, çeltik hastalıklarının otomatik olarak tanımlanması ve tespiti için CNN modeli kullanmışlardır. Veri setleri Mantar Hastalığı, Kahverengi Leke, Bakteriyel Yaprak Yanıklığı, Bakteriyel Solgunluk, Bakanae Hastalığı, Tohum Yanıklığı, Kabuk Yanıklığı, Kabuk Çürüklüğü, Bakteriyel Kabuk Çürüklüğü, Sahte Leke çeltik hastalıklarını içermektedir. Araştırmacılar CNN modelin eğitimi ve testi için hastalıklı ve sağlıklı çeltik yaprağı ve sapı görüntüleri içeren 500 adet görüntü kullanmışlardır. Çalışmalarında kullanılan CNN modeli ile %95.48 doğruluk elde edilmiş ve önerilen yöntemin etkin şekilde uygulanabilir olduğu bildirilmiştir. Ek olarak kullandıkları CNN modelini, destek vektör makinesi (SVM) ve parçacık sürüsü optimizasyonu (PSO) ile karşılaştırmışlardır. CNN modeli %95.48 doğruluk oranı ile SVM %91 ve PSO %88 modellerinden daha yüksek bir başarı oranının elde edildiğini raporlamışlardır.

DeChant ve ark. (2017) çalışmalarında, mısır bitkisinde Kuzey Yaprak Yanıklığı (NLB) hastalığını otomatik olarak tespit etmek için bir sistem önermişlerdir. Araştırmacılar CNN modelinin eğitim ve test işlemleri için sağlıklı ve hastalıklı yaprak görüntüleri içeren toplam 1 796 görüntü kullanmışlardır. Veri setlerini %70'i eğitim, %15'i doğrulama ve %15 test görüntüsü olarak bölmüşlerdir. Önerdikleri sistemin, test seti görüntülerinde %96.7 doğruluk elde edildiğini bildirmişlerdir.

Rangarajan ve ark. (2018) çalışmalarında, domates bitkisi hastalığı sınıflandırması için AlexNet ve VGG16 olmak üzere iki derin öğrenme modeli önermişlerdir. Veri setlerini Sağlıklı, Geç Yanıklık, Yaprak Küf, İki Noktalı Kırmızı Örümcek Hasarı, Erken Yanıklık,

Mozaik Virüsü, Sarı Yaprak Kıvrılması Virüsü Hastalığı olmak üzere 7 sınıf içeren domates yaprağı görüntüleri oluşturmaktadır. Araştırmacılar, 13 262 görüntü kullanılan çalışmalarında sınıflandırma doğruluğu VGG16 için %97.29 ve AlexNet için %97.49 bulunduğunu bildirmişlerdir.

Barbedo (2018), derin öğrenme ile bitki hastalıklarının sınıflandırılması üzerine bir araştırma yapmıştır. Çalışmasında 12 bitki türünde 56 hastalık için 1 383 görüntü içeren veri seti kullanmıştır. Görüntülerin %80'i eğitim, %20'si doğrulama için kullanmıştır. Deneylerini orijinal ve arka planı kaldırmış görüntüler üzerinde iki farklı şekilde gerçekleştirmiştir. Deneysel sonuçları orijinal görüntülerde %84, arka planı kaldırılmış görüntülerde %87 genel doğruluk elde edildiğini bildirmiştir. Araştırmacı elde ettiği sonuçlar neticesinde CNN'lerin bitki patolojisi problemleri ile başa çıkabilen güçlü araçlar olduğunu raporlamıştır.

Türkoğlu ve Hanbay (2018) yaptıkları çalışmada, kayısıda çil hastalığı tespiti için önceden eğitilmiş CNN'e dayalı AlexNet, VGG16 ve VGG19 derin öğrenme modellerini kullanmışlardır. Bu modellerden elde edilen öznitelikler K-En Yakın Komşu (KNN) yöntemi kullanılarak sınıflandırılmıştır. Önerdikleri yöntemin başarısının test edilmesi için kullanılan veri seti 308 sağlıklı, 652 çil hastalığı olmak üzere toplam 960 yaprak görüntüsü içermektedir. Veri setlerini %90'i eğitim ve %10'u test setini oluşturacak şekilde rastgele bölmüşlerdir. Yaptıkları çalışma sonucunda, VGG16 modeli %94.8 olarak en yüksek doğruluk elde edildiğini ve bunu sırasıyla VGG19 %92.9, AlexNet %89.7 olarak takip edildiğini raporlamışlardır.

Ferentinos (2018) çalışmasında, otomatik bir bitki hastalığı tespit ve teşhis sistemi oluşturmak için AlexNet, AlexNetOWTBn, GoogLeNet, Overfeat ve VGG CNN modellerini kullanmıştır. Modellerin eğitim ve test işlemlerini 25 bitki türünü içeren 58 farklı sınıfa sahip 87 848 adet görüntü kullanarak gerçekleştirmiştir. Veri setini %80'i eğitim ve %20'si test setini oluşturacak şekilde rastgele bölmüştür. Araştırmacı test seti görüntüleri üzerinden AlexNet %99.06, AlexNetOWTBn %99.44, GoogLeNet 97.27, Overfeat %98.96 ve VGG %99.48 başarı oranı elde ettiğini bildirmiştir. Ayrıca bu yüksek performans seviyelerine dayanarak, CNN'lerin bitki hastalıklarının otomatik olarak tespiti ve teşhisi için oldukça uygun olduğunu, mobil cihazlarda kullanım için mobil uygulamalara entegrasyonunun mümkün olabileceğini raporlamıştır.

Kerkech ve ark. (2018) yaptıkları çalışmada, bağ hastalıklarının otomatik tespiti için Aşırı Yeşil (ExG), Aşırı Kırmızı (ExR), Aşırı Yeşil-Kırmızı (ExGR), Yeşil-Kırmızı Bitki İndeksi (GRVI), Normalleştirilmiş Fark İndeksleri (NDI) ve Kırmızı-Yeşil İndeksi (RGI) bitki örtüsü indeksleri

kullanarak CNN performanslarını incelemişler ve karşılaştırmışlardır. Veri setleri 4 410 adet görüntü içermektedir. Çalışmaları sonucunda, vejetasyon indekslerinin kombinasyonunda ExG-ExR %95.79, ExG-ExR-ExGR %95.80, ExG-ExR-GRVI %95.86, ExG-ExR-NDI %95.65, ExG-ExR-RGI %95.82 başarı oranı elde edildiğini bildirmişlerdir.

Ashqar ve Abu-Naser (2018) yaptıkları çalışmada, domateste Erken Yanıklık, Yaprak Lekesi, Yaprak Küfü, Bakteri Lekesi ve Sarı Yaprak Kıvrılma Virüsü hastalıklarını CNN modeli kullanarak belirlemişlerdir. Çalışmalarında modelin eğitilmesi ve test edilmesi için sağlıklı ve hastalıklı 9 000 yaprak görüntüsü kullanmışlardır. Model test setinde %99.84'lük bir doğruluk elde edildiğini bildirmişlerdir.

Dhakal ve Shakya (2018) bitki hastalıklarının tespiti üzerine yaptıkları çalışmada, hazır veri seti kullanılarak domateste Bakteriyel Leke, Sarı Yaprak Kıvrılma Virüsü, Geç Yanıklık hastalıklarını derin öğrenme ile belirlemişlerdir. Çalışma sonucunda genel doğruluk %98.59'luk bir performans göstererek bitki hastalığı tespitinde büyük bir başarı olduğunu raporlamışlardır.

Sharma ve ark. (2019) çalışmalarında, domates bitkisinde Geç Yanıklık, Yaprak Küfü, İki Noktalı Kırmızı Örümcek Hasarı, Bakteriyel Leke, Erken Yanıklık, Siyah Leke, Yaprak Lekesi, Mozaik Virüsü, Sarı Yaprak Kıvrılması Virüsü hastalığını CNN modelleri ile tespit etmişlerdir. Modellerin eğitim ve test işlemleri için toplam 17 929 görüntü kullanmışlardır. Veri seti üzerinde aynı CNN modeli, hem tam görüntüler kullanılarak hem de segmentli görüntüler kullanılarak eğitilmiştir. Çalışma sonucunda model başarı oranı tam görüntüler için %42.3 segmentli görüntüler için %98.6 elde edildiğini bildirmişlerdir. Araştırmacılar, otomatik yöntemlerin hastalıkların zamanında tespiti için uzman olmayan kişilere kolaylık sağlayacağı raporlanmıştır.

Too ve ark. (2019) yaptıkları çalışmada, bitki hastalıklarının otomatik tespit edilmesi için VGG 16, Inception V4, 50-101-152 katmanlı ResNet ve 121 katmanlı DenseNet CNN modelleri kullanmışlardır. Kullandıkları veri seti 14 bitki için 38 farklı sınıf içeren 54 306 adet görüntüden oluşmaktadır. Veri setindeki görüntüler %80'i eğitim, %20'i test için kullanmışlardır. Deneysel çalışmaları sonucunda test görüntüleri üzerinde elde ettikleri başarı oranları VGG 16 %81.83, Inception V4 %98.08, ResNet 50 %99.59, ResNet 101 %99.66 ResNet 152 %99.59 ve DenseNet 121 %99.75 olarak bulunduğunu raporlamışlardır. Elde edilen sonuçlar neticesinde, DenseNet modelinin bitkilerin görüntü tabanlı hastalık tanımlama görevi için iyi bir mimari olduğunu bildirmişlerdir.

Barbedo (2019) yaptığı çalışmada, GoogLeNet derin öğrenme modelini kullanarak bireysel lezyonlardan ve lekelerden bitki hastalık tespitini gerçekleştirmiştir. Modelin eğitim ve test işlemleri için 14 bitki türünü içeren 56 farklı sınıfa sahip 46 409 adet görüntü kullanmıştır. Veri setini %80'i eğitim ve %20'si test setini oluşturacak şekilde rastgele bölmüştür. Çalışmasında orijinal görüntüleri kullanarak elde ettiği genel doğruluk %82 iken bireysel leke görüntüleri kullanarak elde ettiği genel doğruluk %94 olduğunu bildirmiştir. Araştırmacı bu sonuçlar neticesinde yeterli veri olduğu sürece derin öğrenme tekniklerinin bitki hastalıklarının tespiti ve tanınması için etkili bir yöntem olduğunu raporlamıştır.

Sorte ve ark. (2019) çalışmalarında, kahve bitkisinde otomatik hastalık tanıma sistemi geliştirmek için Yaprak Leke ve Pas haslığını AlexNet modeli ile belirlemişlerdir. Araştırmacılar derin öğrenme modelinin eğitimi ve testi için 2 250 adet görüntü kullanmışlardır. Deneylerini gerçekleştirmek için veri setini %80 eğitim, %10 doğrulama ve %10 test seti olarak ayırmışlardır. Çalışmaları sonucunda, Yaprak Leke hastalığı için %98, Pas hastalığı için %97 doğruluk elde edildiğini bildirmişlerdir.

Alruwaili ve ark. (2019) yaptıkları çalışmada, zeytin hastalıklarının tespiti ve sınıflandırması için CNN'e dayalı AlexNet modelini önermişlerdir. Çalışmalarında 14 bitki türü için farklı 52 sınıf içeren 54 306 yaprak görüntüsünü veri seti olarak kullanmışlardır. Veri setindeki görüntülerin %80'i eğitim aşamasında %20'si test aşamasında kullanmışlardır. Çalışmaları sonucunda önerilen yöntem %99.11'lik bir genel doğruluk elde ettiğini bildirmişlerdir. Ek olarak genel kesinlik, duyarlılık ve F1 skor değerleri sırasıyla %99.49, %99.11 ve %99.29 olduğunu raporlamışlardır.

Geetharamani ve Arun (2019) yaptıkları çalışmada, bitki hastalıklarının tanımlanması için CNN modeli kullanmışlardır. Veri seti olarak 39 sınıf içeren 54 305 adet görüntü kullanarak modeli eğitmişlerdir. Deneylerini gerçekleştirmek için veri setini %90 eğitim, %5 doğrulama ve %5 test seti olarak ayırmışlardır. Çalışma sonucunda modelin genel olarak %96.46 sınıflandırma doğruluğuna ulaştığını bildirmişlerdir. Önerilen modelin, geleneksel makine öğrenimi yaklaşımlarıyla karşılaştırılmış ve SVM %50.69, Lojistik Regresyon %80.99, Karar Ağacı %72.23 ve K-NN %87.86 değerlerinden daha yüksek doğruluk elde edildiğini raporlamışlardır.

Ozguven ve Adem (2019) çalışmalarında, şeker pancarında yaprak lekesi hastalığının (*Cercospora beticola* Sacc.) otomatik tespiti için bir CNN modelinin parametreleri değiştirilerek güncellenmiş Faster R-CNN mimarisi ve Faster R-CNN mimarisi önermişlerdir.

Modellerin eğitilmesi ve test edilmesi için 155 görüntü kullanmışlardır. Deneylerini gerçekleştirmek için veri setini %85 eğitim, %15 test seti olarak ayırmışlardır. Test görüntüleri üzerinden toplam doğru sınıflandırma oranı %95.48 olarak bulunduğunu bildirmişlerdir. Ek olarak, önerilen yaklaşım görüntüye ve tespit edilecek bölgelere göre CNN parametrelerindeki değişikliklerin Faster R-CNN mimarisinin başarısını artırabileceğini raporlamışlardır.

Cruz ve ark. (2019) çalışmalarında, Asma Sarılığı (GY) hastalığını AlexNet, GoogLeNet, Inceptionv3, ResNet-50, ResNet-101 ve SqueezeNet CNN modelleri kullanarak belirlemişlerdir. Modellerin eğitilmesi ve test edilmesi için 2 680 yaprak görüntüsü kullanmışlardır. Deneylerini gerçekleştirmek için veri setini %80 eğitim, %20 test seti olarak ayırmışlardır. Deneysel çalışmaları sonucunda test görüntüleri üzerinde elde etikleri başarı oranları AlexNet %97.63, GoogLeNet %96.36, Inceptionv3 %98.43, ResNet-50 %99.18, ResNet-101 %99.33, SqueezeNet %93.77 olarak bulunduğunu raporlamışlardır.

Zhong ve Zhao (2020) çalışmalarında, Genel Uyuz, Ciddi Uyuz, Gri Nokta, Genel Sedir Pas ve Ciddi Sedir Pas elma yaprağı hastalıklarının tespiti için DenseNet-121 derin öğrenme modeli kullanmışlardır. Veri seti olarak 2 462 elma yaprağı görüntüsü kullanılmıştır. Modelin eğitim ve test işlemleri için veri setindeki görüntülerin %85'i eğitim, %15'i doğrulama için ayırmışlardır. Araştırmacılar önerilen yöntemin test seti görüntülerinde Genel Uyuz %71.15, Ciddi Uyuz %74.47, Gri Nokta %97.97, Genel Sedir Pas %91.42 ve Ciddi Sedir Pas %85.71 doğruluk elde edildiğini bildirmişlerdir.

Esgario ve ark. (2020) çalışmalarında, kahve yapraklarındaki biyotik etkenlerin neden olduğu stres şiddetini tanımlayabilen ve tahmin edebilen pratik bir sistem tasarlamak için AlexNet, GoogLeNet, VGG16, ResNet-50, MobilNetV2 CNN modellerini kullanmışlardır. Çalışmalarında kullandıkları veri seti 2 147 arabica kahve yaprağı görüntülerini içermektedir. Veri setlerini %80'i eğitim ve %20'si test setini oluşturacak şekilde ayırmışlardır. Çalışmaları sonucunda ResNet50 modeli biyotik stres sınıflandırması için %95.24 ve şiddet tahmini için %86.51 doğruluk, AlexNet modeli biyotik stres sınıflandırması için %91.67 ve şiddet tahmini için %86.90 doğruluk, GoogLeNet modeli biyotik stres sınıflandırması için %94.05 ve şiddet tahmini için %82.94 doğruluk, VGG16 modeli biyotik stres sınıflandırması için %94.44 ve şiddet tahmini için %86.51 doğruluk, MobilNetV2 modeli ise biyotik stres sınıflandırması için %94.44 ve şiddet tahmini için %84.13 doğruluk elde edildiğini bildirmişlerdir. Araştırmacılar deneysel sonuçlar neticesinde, önerilen sistemin kahve plantasyonlarındaki biyotik streslerin

tanımlanması ve nicellendirilmesinde yardımcı olmak için uygun bir araç olabileceğini raporlamışlardır.

Chen ve ark. (2020) çalışmalarında, bitki hastalıklarının otomatik olarak tanımlanması ve tespiti için INC-VGGN adı verilen geliştirdikleri derin öğrenme mimarisini kullanmışlardır. Çalışmalarında 500 çeltik ve 466 mısır yaprak görüntüsü içeren toplam 966 görüntü kullanılmışlardır. Modelin eğitim ve test işlemleri için veri setindeki görüntülerin %70'i eğitim, %30'u doğrulama için ayırmışlardır. Araştırmacılar yaptıkları çalışma sonucunda çeltik hastalıklarının ortalama %92, mısır hastalıklarının ortalama %80.38 doğruluk ile tespit edildiğini raporlamışlardır.

Sethy ve ark. (2020) yaptıkları çalışmada, çeltikte Bakteriyel Yanıklık, Kahverengi Leke, Tungro ve Yanıklık hastalıklarının tanımlanması için ResNet+SVM yaklaşımında CNN modelinin performansını incelemişlerdir. Veri seti, 5 932 çeltik yaprağı görüntüsü içermektedir. Modelin eğitim ve test işlemleri için veri setindeki görüntülerin %80'i eğitim, %20'si doğrulama için ayırmışlardır. Çalışmaları sonucunda elde ettikleri başarı oranları Bakteriyel Yanıklık %98.38, Kahverengi Leke %96.70, Tungro %100 ve Yanıklık %96.43 olduğunu bildirmişlerdir.

Mishra ve ark. (2020) çalışmalarında, mısır bitkisinde Pas ve Kuzey Yaprak Yanıklığı hastalıklarının tespiti için CNN'e dayanan gerçek zamanlı bir yöntem sunmuşlardır. Derin öğrenme modellerinin eğitimi ve testi için 4 382 adet görüntü kullanmışlardır. Deneylerini gerçekleştirmek için veri setini %70 eğitim, %10 doğrulama ve %20 test seti olarak ayırmışlardır. Çalışmaları sonucunda elde ettikleri başarı oranları Pas hastalığı için %96.32, Kuzey Yaprak Yanıklığı için %98.88 olduğunu bildirmişlerdir. Ek olarak, CNN modeli akıllı telefonda yakalanan canlı görüntülerde ortalama %88.66 doğruluk elde edildiğini raporlamışlardır. Araştırmacılar sundukları mısır bitkisi hastalık tanıma modelinin, Raspberry-Pi veya akıllı telefon ve drone'lar gibi akıllı cihazlarda çalışabileceğini vurgulamışlardır.

Agarwal ve ark. (2020) çalışmalarında, Geç Yanıklık, Yaprak Küfü, İki Noktalı Kırmızı Örümcek Hasarı, Erken Yanıklık, Mozaik Virüsü, Sarı Yaprak Kıvrılması Virüsü, Yaprak Lekesi, Bakteriyel Leke domates hastalıklarını tespit etmek için CNN tabanlı bir model geliştirmişlerdir. Veri setlerinde 10 000 görüntü kullanmışlardır. Deneylerini gerçekleştirmek için veri setini %70 eğitim, %20 doğrulama ve %10 test seti olarak ayırmışlardır. Sınıflandırma doğruluğu sınıflara göre %76 ile %100 arasında değişmekte olduğunu bildirmişlerdir.

Araştırmacılar önerilen modelin ortalama doğruluğunun 9 hastalık ve 1 sağlıklı sınıf için %91.2 olduğunu bildirmişlerdir.

Karthik ve ark. (2020) yaptıkları çalışmada, domates yapraklarındaki Erken Yanıklık, Geç Yanıklık ve Yaprak Küfü hastalıklarını tespit etmek için CNN'e dayalı derin öğrenme modeli geliştirmişlerdir. Deneyde kullandıkları veri seti 120 000 görüntü içermektedir. Deneylerini gerçekleştirmek için veri setini %70 eğitim, %20 doğrulama ve %10 test seti olarak ayırmışlardır. Araştırmacılar önerilen yöntemin, toplam %98'lik bir doğruluk elde edildiğini bildirmişlerdir.

Darwish ve ark. (2020) çalışmalarında, mısır bitkisinde Gri Yaprak Lekesi, Kuzey Yaprak Yanıklık ve Pas hastalığının tespiti için VGG16 ve VGG19 olmak üzere önceden eğitilmiş CNN modeli geliştirmişlerdir. Çalışmalarında veri seti olarak 15 408 görüntü kullanmışlardır. Modelin eğitim ve test işlemleri için veri setindeki görüntülerin %80'i eğitim, %20'si doğrulama için ayırmışlardır. Araştırmacılar çalışmanın sonucunda VGG16 modeli için Gri Yaprak Lekesi %96, Kuzey Yaprak Yanıklık %93 ve Pas hastalığı %100 VGG19 modeli için Gri Yaprak Lekesi %91, Kuzey Yaprak Yanıklık %96 ve Pas hastalığı %100 doğruluk elde edildiği bildirilmiştir.

Guti'erre ve ark. (2021) yaptıkları çalışmada, asma yapraklarında mildiyö ve örümcek akarı semptomlarının tespiti ve ayırt edilmesi için derin öğrenme modeli kullanmışlardır. Çalışmalarında veri seti olarak 841 görüntü kullanmışlardır. Deneylerini gerçekleştirmek için veri setini %65 eğitim, %15 doğrulama ve %20 test seti olarak ayırmışlardır. Hastalık ve zararlının ikili sınıflandırmasında (Mildiyö+Örümcek Akarı) %91 doğruluk elde edildiğini bildirmişlerdir. Bu yüksek doğruluk, tarla koşullarında alınan asma yaprağı görüntülerinin sınıflandırılması için derin öğrenme ve bilgisayarla görme tekniklerinin etkinlik gösterdiğini vurgulamışlardır. Ek olarak örümcek akarı ile mildiyö belirtilerini ayırt edebilen karmaşık özelliklerin otomatik olarak bulunduğunu raporlamışlardır.

Lu ve ark. (2022) yaptıkları çalışmada, bağ yaprağı Mildiyö, Külleme, Kahverengi Leke, Siyah Leke, Yaprak Yanıklığı, Esca, Besin Eksiklik, Bağ Yaprak Uyuzu, Yaprak Güvesi, Virüs hastalık tespiti için Ghost-Convolution ve Transformer ağlarına dayalı etkili ve doğru bir yaklaşım önermişlerdir. Araştırmacılar 11 sınıf içeren 12 615 görüntü veri seti kullanmışlardır. Deneylerini gerçekleştirmek için veri setini %70 eğitim, %10 doğrulama ve %20 test seti olarak ayırmışlardır. Test görüntüleri üzerinde %98.14 genel doğruluk değeri elde edildiğini bildirmişlerdir.

Guo ve ark. (2022) yaptıkları çalışmada, bağda Külleme, Antraknoz, Kahverengi Leke, Kurşuni Küf, Siyah Leke ve Mildiyö hastalığını tespit etmek için Faster R-CNN, SSD ve YoloX modellerini uygulamışlardır. Modelleri eğitmek ve test etmek için 2 300 görüntüyü veri seti olarak kullanmışlardır. Veri setindeki görüntülerin %90'i eğitim, %10'u doğrulama için ayırmışlardır. Çalışma sonunda Faster R-CNN %79.12, YoloX %83.22, SSD %76.23 doğruluk oranı elde edildiğini bildirmişlerdir. Araştırmacılar yaptıkları çalışma ile bağ yaprağı hastalığı tespitindeki sorunlara çözümler getirildiğini ve tarımsal üretimde bağ hastalıklarının ve semptomlarının otomatik analizi için bir referans sağlandığını raporlamışlardır.

Literatür taramalarında çeşitli araştırmacılar tarafından bitki hastalıklarının derin öğrenme ile tespiti ve sınıflandırılmasına yönelik yapılan çalışmalar incelendiğinde tespit edilen detaylar aşağıda sıralanmıştır;

- Çalışmaların bir kısmı doğal koşullarda bir kısmı ise sabit bir arka plan kullanılarak gerçekleştirildiği görülmektedir. Bu durum bazı avantajlar veya dezavantajlar sağlamaktadır. Sabit bir arka planda alınan görüntülerde modelin çalışmasının daha kolay olduğu ve başarı oranının daha yüksek çıkmasına katkı sağladığı belirlenmiştir. Doğal koşullarda alınan görüntüler üzerinden bu durumun tersi olabilmektedir. Ancak doğal koşullarda başarının artırılması, ileride yapılacak gerçek zamanlı sistemler için oldukça önem taşımaktadır.
- Yapılan çalışmaların bazılarında hazır görüntüler bazılarında ise görüntüleme cihazları ile toplanan veriler kullanılarak gerçekleştirildiği görülmektedir. Bitki hastalıkları konularında yapılan çalışmalar ile literatüre büyük katkılar sağlanmaktadır. Böylece tarımsal faaliyetleri iyileştirmek için gerekli çalışmaların yapılmasının önü açılacaktır.
- Özellikle bağ hastalıkları konusunda büyük miktarda veri bulunmamasına rağmen külleme ve mildiyö hastalıkları çalışılmıştır.
- Bazı çalışmalar sadece derin öğrenme modeli ile gerçekleştirilebildiği gibi, başarı oranını artırmak için makine öğrenmesi veya görüntü işlemeyle birlikte kullanılarak da gerçekleştirildiği görülmüştür.
- Çalışmaların genelinde daha önceden eğitilmiş modeller kullanılarak transfer öğrenme uygulandığı ve yeni geliştirilen model sayılarının ise az olduğu tespit edilmiştir.

Bu tez çalışmasının özgünlüğü, bağda yaygın olarak görülen ve ekonomik sorun oluşturan külleme, mildiyö, ölü kol hastalığı ile asma yaprak kıvrılma virüs hastalığı (GLRaV) ve asma kısa boğum virüs (GFLV) hastalık görüntülerinin olduğu özgün yeni bir veri seti oluşturulmuştur. Görüntüler farklı doğal koşullarda sabit bir arka plan kullanılmadan gerçek ortamdan toplanmıştır. Çalışmada hem transfer öğrenme hem de yeni bir model geliştirilerek sınıflandırma işlemi gerçekleştirilmiş ve performans karşılaştırılması yapılmıştır.



3. MATERYAL ve YÖNTEM

3.1. Materyal

3.1.1. Çalışmada değerlendirilen bağ hastalıkları

Bağ hastalıkları fungal, virüs ve bakteriyel olmak üzere üç grupta toplanmaktadır. Çalışmada yaygın olarak görülen ve ekonomik sorun oluşturan fungal hastalıklardan külleme, mildiyö, ölü kol hastalığı ile virüs hastalıklarından asma yaprak kıvrılma virüs hastalığı (GLRaV) ve asma kısa boğum virüs (GFLV) hastalıkları değerlendirilmiştir. Şekil 27’de çalışmada değerlendirilen bağ hastalıklarına örnek görüntüler verilmiştir.




Şekil 27. Çalışmada değerlendirilen bağ hastalıkları

3.1.2. Araştırma alanları

Çalışmada değerlendirilen bağ hastalıkları görüntülerinin elde edilmesi için Tokat ilinde bağ alanları araştırılmıştır. Araştırılan bağ alanlarının bulunduğu ilçeler Şekil 28’da verilmiştir. Bu ilçelere ait aşağıda sıralanan yerlerden hastalık görüntüleri alınmıştır.

- Tokat Orta Karadeniz Geçit Kuşağı Tarımsal Araştırma Enstitüsü Müdürlüğüne ait bağ alanları,
- Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bağ alanları,
- Merkez ilçesine bağlı Güryıldız beldesi bağ alanları,
- Merkez ilçesine bağlı Emirseyit beldesi bağ alanları,
- Merkez ilçesine bağlı Kömeç köyü bağ alanları,
- Merkez ilçesine bağlı Büyükyıldız ve Küçükyıldız köyleri bağ alanları,

- Pazar ilçesine bağlı bazı beldeler ile özellikle Üzümlören beldesi bağ alanları,
- Erbaa ilçesine bağlı bazı belde bağ alanları,
- Niksar ilçesine bağlı bazı belde bağ alanları.



Şekil 28. Araştırma alanları

Şekil 29 ve Şekil 30’da gösterilen Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi’ne ait bağ alanlarında ayrılan 4 sırada ilaçlama yapılmayarak mildiyö, külleme ve ölü kol hastalıklarının görülmesi kontrollü şartlarda sağlanmıştır.



Şekil 29. Tokat Gaziosmanpaşa Üniversitesi Tarımsal Uygulama ve Araştırma Merkezi bağ alanları



Şekil 30. Çalışma için ayrılan sıralar

3.1.3. Çalışmada kullanılan cihazlar

Bağ hastalıklarının görüntülerini elde edebilmek için Şekil 31’de gösterilen GoPro marka Hero 7 Black model kamera ve akıllı telefon kullanılmıştır. Çizelge 3’te kullanılan GoPro Hero 7 Black kameranın ve Çizelge 4’te ise akıllı telefonun özellikleri verilmiştir.



Şekil 31. GoPro Hero 7 Black

Çizelge 3. GoPro Hero 7 Black kameranın teknik özellikleri

Donanım	Teknik Özellik
Görüntü İşlemcisi	GoPro GP1
Sensör Tipi	CMOS
Etkin Piksel	12 MP
Ekran Boyutu	2.0 inç
Azami Çözünürlük	4 000×3 000
Azami Video Çözünürlüğü	3 840x2 160
Video Çözünürlüğü	Ultra HD
Video Kare Hızı	60 fps
Görüntü Oranı	4:3
Sensör Formatı	1/2.3 inç
Sensör Boyutu (Genişlik)	6.17 mm
Sensör Boyutu (Uzunluk)	4.62 mm
En Düşük ISO	100
En Yüksek ISO	6 400
GPS (Konum) özelliği	Mevcut
Optik İmaj Sabitleme	Mevcut

Çizelge 4. Akıllı telefonun teknik özellikleri

Donanım	Teknik Özellik
İşletim Sistemi	Android
İşlemci Türü	Qualcomm Snapdragon 810
İşlemci Hızı	2 GHz
İşlemci Çekirdek Sayısı	8
Ekran Çözünürlüğü	1 920x1 080
Etkin Piksel	23 MP
Video Çözünürlüğü	3 840x2 160
Video Çözünürlüğü	Ultra HD
Video Kare Hızı	60 fps
Sensör Formatı	1/2.3 inç
En Düşük ISO	100
En Yüksek ISO	12 800
Odak Uzaklığı	24 mm

Derin öğrenme işlemleri için iyi bir işlemci ve ekran kartına sahip bilgisayara gereksinim vardır. Yüksek performanslı grafik işleme birimleri (GPU) derin öğrenme işlemleri için verimli bir yapıya sahiptir. Çalışmada da Nvidia grafik kartına (GPU) sahip Asus marka bilgisayar kullanılmıştır. Bilgisayarın teknik özellikleri Çizelge 5’de verilmiştir.

Çizelge 5. Çalışmada kullanılan bilgisayarın teknik özellikleri

Donanım	Teknik Özellikler
Sistem Üreticisi	Asus
İşlemci (CPU)	Intel Core i9
Ekran Kartı (GPU)	Nvidia Quadro RTX 4000 - 8 GB - GDDR6
İşlemci Önbelleği	20 MB
Çekirdek Sayısı	20
İşlemci Tipi	10850K (10.Nesil)
İşlemci Hızı	4.8 GHz
Bellek (RAM)	64 GB-DDR5
Bellek Hızı	3600 Mhz
SSD Kapasitesi	1 TB

3.1.4. MATLAB

MATLAB, kullanıcıların sistemleri hızlı ve verimli bir şekilde analiz etmeleri ve tasarımları için özel olarak hazırlanmış bir programlama platformudur. MATLAB, matematiğin en doğal ifadesine izin veren matris tabanlı bir dil kullanmaktadır. MATLAB, derin öğrenme matrislerini basit ve sezgisel bir şekilde işleyebilme konusunda en iyi programlama platformlarından biri olarak kabul edilmektedir. MATLAB, etiketleme için sinyal verilerini, ses verilerini, görüntüleri ve videoyu içeren etkileşimli derin öğrenme uygulamalarına sahiptir. Etiketleme, derin öğrenmedeki en zor ve zaman alan işlemlerden biridir. MATLAB, bu

işlemleri otomatikleştiren ideal bir uygulamadır. Derin öğrenme işlemleri çok büyük miktarda veri setine ihtiyaç duyduğundan MATLAB, yeterli veriye sahip olunmadığında yapay veri üretilmesine de yardımcı olabilmektedir. Bu sayede modellerin başarı oranının artırılmasını sağlamaktadır. Derin öğrenme işlemleri için MATLAB'ın avantajları;

- ✓ MATLAB, derin öğrenme TensorFlow, PyTorch ve MxNet gibi çerçeveler arasında etkileşim kurmanın ve veri aktarmanın çeşitli yollarına sahiptir.
- ✓ MATLAB, modelleri diğer çerçeveler arasında içe ve dışa aktarmak için ONNX'i destekler. Örneğin, PyTorch'ta tasarlanan bir model MATLAB'a getirilebilmekte ve MATLAB'de eğitilen modeller ONNX çerçevesi kullanılarak dışa aktarılabilir.
- ✓ MATLAB, Python ile birlikte çalışabilirliğini de destekler: Python MATLAB'dan ve MATLAB Python'dan aratılabilir.
- ✓ Deep Learning Toolbox algoritmaları, önceden eğitilmiş modeller ve uygulamalarla derin sinir ağlarını tasarlamak ve uygulamak için bir çerçeve sağlamaktadır.
- ✓ MATLAB ayrıca pekiştirmeli (takviyeli) öğrenme, otonom sürüş, doğal dil işleme, tıbbi görüntü işleme ve bilgisayarla görü için özel araç kutuları ve işlevsellik sağlamaktadır.

3.2. Yöntem

Çalışmada belirlenen amaca ulaşmak için gerçekleştirilen yöntem ve uygulamalar aşağıda sıralanmıştır.

3.2.1. Görüntülerin elde edilmesi

Tokat iklim şartlarında erken ilkbahar ile geç sonbahar (Mart-Kasım) arasında asma yetiştiriciliği yapılmaktadır. Bu süre zarfında çalışılan hastalıkların her biri vejetasyon döneminde ilk semptomların görülmesinden hastalıkların gelişme dönemleri boyunca takip edilerek görüntüler alınmıştır. Çalışmada akıllı telefon kullanılarak 1 920 x 1 080 piksel çözünürlükte 4 892 adet görüntü, GoPro Hero Black 7 kamera kullanılarak 4 000 x 3 000 piksel çözünürlükte 6 108 adet görüntü olmak üzere toplam 11 000 görüntü elde edilmiştir. Görüntüler sağlıklı ve hastalıklı yaprak, sürgün ve salkım görüntüleri içermektedir. Derin öğrenme başarısının artırılmasına katkı sağlamak için görüntüler farklı doğal aydınlanma koşullarında alınmıştır.

3.2.2. Veri setinin oluşturulması

Vejetasyon süresince alınan ham görüntüler bilgisayara aktarılıp, sağlıklı ve her bir hastalık için ayrı ayrı dosyalanmıştır. Çizelge 6’da oluşturulan veri seti gösterilmiştir. Çizelgede gösterildiği gibi veri seti 6 sınıf (ID) içeren toplam 11 000 görüntüden oluşmaktadır. Literatür taramalarında bitki hastalık tespitinin yapıldığı derin öğrenme çalışmalarında (Cruz ve ark., 2019; Guti’errez ve ark., 2021; Ji ve Wu, 2022) veri setleri %70 eğitim, %30 test işlemleri için bölünmektedir. Bu çalışmalardan yola çıkarak veri seti benzer şekilde bölünmüştür. Her bir sınıfta görüntü sayısının %70’i eğitimde %10’u doğrulamada ve %20’si de testte kullanılmıştır. Toplam görüntünün 7 700’ü eğitimde, 1 100’ü ise eğitim doğruluğunu kontrol etmek için doğrulamada kullanılmıştır. Sistemin hiç görmediği kalan 2 200 görüntü ise test olarak kullanılmıştır. Çalışmada sağlıklı görüntüler yaprak, salkım, sürgün üzerinde, külleme hastalığı ise hem yaprak, hem de salkım üzerinde gerçekleştirildiğinden görüntü sayıları diğer sınıflardan daha fazla olmuştur.


Çizelge 6. Çalışmada oluşturulan veri seti

Sınıf (ID)	Hastalık	Görüntü sayısı (adet)	Eğitim (%70)	Doğrulama (%10)	Test (%20)
0	Sağlıklı	2 420	1 694	242	484
1	Külleme	3 215	2 250	322	643
2	Mildiyö	1 375	963	137	275
3	Ölü kol	1 729	1 211	172	346
4	GLRaV	1 136	795	114	227
5	GLFV	1 125	787	113	225
Toplam		11 000	7 700	1 100	2 200


3.2.3. Veri ön işleme ve etiketleme

Çalışma hastalıkların belirlenmesi üzerine olduğu için görüntülerdeki nesnelerin örneklerini bulmak için bir bilgisayarlı görme tekniği olan nesne algılama algoritmaları kullanılmıştır. Nesne algılama algoritmaları, yüksek bir başarı oranında nesneleri tespit edebilmesi için görüntülerin bir ön işlemde geçirilmesi ve özellikle veri setinin etiketleme işlemleri oldukça önemlidir. Bu yüzden çalışmada veri seti işleme tabi tutulmadan önce bazı görüntülerdeki ışık yansıması, bulanıklık ve benek gibi gürültülerin giderilmesi için ön işleme tabi tutulmuştur. Gürültüler giderildikten sonra tüm görüntüler modellere giriş boyutu olarak 512x512 çözünürlükte yeniden boyutlandırılmıştır. Ön işlemlerden sonra MATLAB programında “Image Labeler” uygulaması ile toplam 11 000 görüntü üzerinde etiketleme işlemleri yapılmıştır. Image Labeler uygulamasında ilgili alanı (ROI) etiket olarak işaretlemek için


dikdörtgen etiketleri kullanılmıştır. Çalışmada Image Labeler ile etiketlenen görüntülere örnekler Şekil 32 ile Şekil 37 arasında verilmiştir.



Şekil 32. Tane üzerinde külleme etiketi örneği




Şekil 33. Yaprakta külleme etiketi örneği




Şekil 34. Mildiyo etiketi örneği



Şekil 35. Ölü kol etiketi örneği




Şekil 36. Asma yaprak kıvrılma virüs etiketi (GLRaV) örneği



Şekil 37. Asma kısa boğum virüs etiketi (GFLV) örneği

3.2.4. Modellerin geliştirilmesi

Bağ hastalıkları görüntülerinde hastalıklı bölgelerin tespit edilmesi ve sınıflandırılması için yeni bir model geliştirilmiştir. Geliştirilen modelin mimarisi Şekil 38’de gösterilmiştir. Mimari dört evrişim katmanı ile birlikte dört ReLU katmanı, üç havuzlama katmanı, bir tam bağlantılı katman ve softmax sınıflandırıcısından oluşmaktadır. Giriş görüntüleri 512x512x3 RGB olarak modele verilmiştir. Çıktı sınıfları sağlıklı ve beş hastalık görüntülerinden oluşmaktadır.



Şekil 38. Çalışmada geliştirilen model mimari


Model mimari tasarlanırken aşağıdaki adımlar dikkate alınmıştır;

- Nesne algılama için eğitim verilerinin oluşturulması. Görüntüdeki nesnenin konumunu ve boyutunu tanımlayan dikdörtgen etiketleri kullanarak nesne algılama yer gerçeği (ground truth) etiketlenmiştir.
- Nesne algılama dedektör ağının oluşturulması. Her nesne dedektörü benzersiz bir ağ mimarisi içermektedir. Örneğin, Faster R-CNN dedektörü algılama için iki aşamalı bir ağ kullanırken, SSD Multibox dedektörü tek aşamalı bir ağ kullanmaktadır. Geliştirilen modelde ağ oluşturmak için “layers” işlevleri kullanılmıştır. Ayrıca, Derin Ağ Tasarımcısı (Deep Network Designer) kullanılarak ağ katman katman tasarlanmıştır.
- Dedektörün eğitilmesi. Nesne algılama dedektörünü eğitmek için “trainObjectDetector” işlevi kullanılmıştır.
- Test seti kullanılarak dedektörün değerlendirilmesi. Geliştirilen modelin performansını ölçmek için eğitilmiş nesne dedektörü geniş bir görüntü kümesi üzerinde değerlendirilmiştir. Sonuçları değerlendirmek için “evaluateDetectionPrecision”, “evaluateDetectionRecall” gibi işlevler kullanılmıştır.

- Derin öğrenme dedektörlerini kullanarak nesneleri algılama. Eğitimli dedektör kullanarak bir görüntüdeki nesneler algılanmıştır. Nesne algılama işlevi kullanılarak sınırlayıcı kutular, tahmin puanları ve sınırlayıcı kutulara atanan kategorik etiketler gösterilmiştir.

Teknolojik gelişmelerle birlikte her gün yeni model mimariler ortaya çıkmaktadır. Literatür taramaları incelendiğinde araştırmacılar tarafından nesne tespitte doğruluk ve zaman performansı açısından Faster R-CNN ve SSD Multibox modelleri en yaygın kullanılan modellerdir. Bu nedenle çalışmada yeni geliştirilen model ile karşılaştırma yapmak için Faster R-CNN ve SSD Multibox modelleri kullanılmıştır.


Çalışmada kullanılan derin öğrenme modellerine ilişkin eğitim sırasında oluşturulan parametreler modelin hesaplama karmaşıklığını doğrudan etkilemektedir. Hesaplama karmaşıklığına ek olarak, modelin yüksek sınıflandırma doğruluğu da çok önemlidir. Modellerde kullanılan parametreler deneysel sonuçlar neticesinde elde edilmiştir. Objektif bir değerlendirme yapabilmek için kullanılan derin öğrenme modellerinin eğitimi sırasında parametrelere aynı değerler verilmiştir. Bunlar; CNN modellerinde hastalıklı bölgelerin daha iyi ayırt edilebilmesi için input değeri 512x512x3 olarak alınmıştır. Evrişim katmanlarında 32 adet 4 adım, 2 dolgu'lu 3x3'lük filtre uygulanmıştır. Öğrenme oranı 0.001 olarak belirlenmiştir. Değerin çok düşük seçilme amacı öğrenme hızını düşürmek ve öğrenme süresini artırmaktır. Bu değer yüksek seçilmesi durumunda çok hızlı öğrenmeye çalıştığı için yetersiz öğrenmeye neden olmaktadır. Ağırlık güncelleme aşamasında kullanılan "MiniBatchSize" değeri 32 olarak belirlenmiştir. Eğitim algoritmasının veri seti üzerindeki uygulama sayısını gösteren "MaxEpochs" değeri 100 olarak belirlenmiştir. Hastalıklı bölgeyi aynı verilerle öğrenerek "Shuffle" değeri "ever-epoch" olarak seçilmiştir. Aşırı öğrenmeyi önlemek için "Dropout" değeri 0.1 olarak ayarlanmıştır. Ayrıca daha iyi bir değerlendirme için veri setinden örnekler rastgele seçilmiştir. Çalışmada bağ hastalık görüntülerinde hastalıklı bölgelerin tespiti ve sınıflandırılması için kullanılan modelin işlem basamakları Şekil 39'da gösterilmiştir.



		Gerçek Değer	
		Pozitif (1)	Negatif (0)
Tahmin Edilen Değer	Pozitif (1)	TP	FP
	Negatif (0)	FN	TN

Şekil 40. Karışıklık matrisi (Confusion matrix)

- Doğru pozitif (True Positive-TP); sınıflandırıcı tarafından pozitif sınıfa ait verilerden kaç tanesinin doğru şekilde sınıflandırıldığı temsil edilmektedir.
- Doğru negatif (True Negative-TN); sınıflandırıcı tarafından negatif sınıfa ait verilerden kaç tanesinin doğru şekilde sınıflandırıldığı temsil edilmektedir.
- Yanlış pozitif (False Positive (Tip 1 Hata)-FP); gerçekte negatif sınıfa ait olan bir verinin sınıflandırma sonucunda pozitif sınıf olarak etiketlenmesidir.
- Yanlış negatif (False Negative (Tip 2 Hata)-FN); gerçekte pozitif sınıfa ait olan bir verinin sınıflandırma sonucunda negatif sınıf olarak etiketlenmesidir.



Şekil 41. Karışıklık matrisinden hesaplanan birçok ölçümün gösterilmesi

Şekil 41’de verilen bir karışıklık matrisinden elde edilen performans ölçümleri, Eşitlik 1-7 denklemlerinde gösterildiği gibi temsil edilmektedir;

- Duyarlılık, pozitif olarak tahmin edilmesi gereken işlemlerin ne kadarını pozitif olarak tahmin edildiğini gösteren bir metriktir.

$$\text{Duyarlılık veya Hassasiyet (Recall-Sensitivity)} = \frac{TP}{(TP+FN)} = \frac{TP}{\text{Tüm pozitifler}} \quad (1)$$

- Özgüllük, gerçek değeri negatif olup negatif sınıflandırılan sayının, gerçek değeri negatif olanların tümüne oranıdır.

$$\text{Özgüllük (Specificity)} = \frac{TN}{(TN+FP)} = \frac{TN}{\text{Tüm negatifler}} \quad (2)$$

- Kesinlik, pozitif olarak tahminlenen değerlerin gerçekten kaç adedinin pozitif olduğunu göstermektedir.

$$\text{Kesinlik (Precision)} = \frac{TP}{(TP+FP)} = \frac{TP}{\text{Tahmin edilen pozitifler}} \quad (3)$$

$$\text{Yaygınlık (Prevalence)} = \frac{TP+FN}{\text{Toplam}} = \frac{\text{Tüm pozitifler}}{\text{Toplam}} \quad (4)$$

- Doğruluk, bir modelin başarısını ölçmek için çok kullanılan ancak tek başına yeterli olmadığı görülen bir metriktir. Doğruluk değeri modelde doğru tahmin edilen alanların toplam veri kümesine oranı ile hesaplanmaktadır.

$$\text{Doğruluk (Accuracy)} = \frac{TP+TN}{\text{Toplam}} \quad (5)$$

- F1 Skor, kesinlik ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir. Basit bir ortalama yerine harmonik ortalama olmasının sebebi ise uç durumları da göz ardı edilmemesidir. Basit bir ortalama hesaplaması olması durumunda kesinlik değeri 1 ve duyarlılık değeri 0 olan bir modelin F1 skoru 0.5 olacak ve bu durum yanıltacaktır. F1 skor değerinin kullanılmasının en temel sebebi eşit dağılmayan veri kümelerinde hatalı bir model seçimi yapılmamasıdır.

$$\text{F1 Skor (F1 Score)} = \frac{2 * \text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (6)$$

$$\text{Hata Oranı (Error Rate)} = \frac{FP+FN}{\text{Toplam}} \quad (7)$$

4. BULGULAR ve TARTIŞMA

4.1. Faster R-CNN Sonuçları

Çizelge 7’de Faster R-CNN modelinin performansının değerlendirilmesi için hedef niteliğe ait tahminlerin ve gerçek değerlerin karşılaştırıldığı karışıklık matrisi verilmiştir.

Çizelge 7. Faster R-CNN modelinin karışıklık matrisi (Confusion matrix)


		Tahmin					
		0 Sağlıklı	1 Külleme	2 Mildiyö	3 Ölü kol	4 GLRaV	5 GLFV
Gerçek	0 Sağlıklı	470	8	6	0	0	0
	1 Külleme	18	590	11	11	3	10
	2 Mildiyö	3	11	240	7	5	9
	3 Ölü kol	0	6	5	319	5	11
	4 GLRaV	0	4	5	8	206	4
	5 GLFV	0	6	9	7	4	199

Çizelge 7 incelendiğinde test görüntüleri üzerinde yapılan işlemlerden sonra; sarı ile gösterilen değerler gerçekte olması gereken sınıfın doğru tahmin edildiği sayıyı, kırmızı ile ise gerçekte olması gereken sınıfın yanlış tahmin edildiği sayıları göstermektedir. Faster R-CNN derin öğrenme modelinin test görüntülerine uygulanması sonucunda, 484 sağlıklı görüntünün 470’i, 643 külleme hastalığının 590’ı, 275 mildiyö hastalığının 240’ı, 346 ölü kol hastalığının 319’u, 227 GLRaV hastalığının 206’sı ve 225 GLFV hastalığının 199’u doğru sınıflandırılmıştır. Çizelge 8’de Faster R-CNN modelinin başarısının değerlendirilmesinde kullanılan kesinlik, duyarlılık, F1 skor ve doğruluk değerleri verilmiştir. Toplamda 2 220 test görüntüsünden 2024 görüntü doğru tahmin edilerek genel başarı oranı %92 olarak bulunmuştur.

Çizelge 8. Faster R-CNN modelinin başarısının değerlendirilmesi

Sınıf	Kesinlik	Duyarlılık	F1 Skor	Doğruluk
0 (Sağlıklı)	97.10	95.72	96.40	98.30
1 (Külleme)	91.33	94.4	92.83	95.83
2 (Mildiyö)	87.27	86.95	87.10	96.61
3 (Ölükol)	92.19	90.62	91.39	97.12
4 (GLRaV)	90.74	92.37	91.54	98.15
5 (GLFV)	84.44	85.40	84.91	97.12

Faster R-CNN modelinin doğruluk açısından elde edilen sonuçların daha iyi değerlendirilebilmesi için Kesinlik-Duyarlılık (PR) eğrisi ve ROC eğrisi Şekil 42'de gösterilmiştir.



Şekil 42. Faster R-CNN modelinin PR eğrisi ve ROC eğrisi

Kesinlik-Duyarlılık (PR) eğrisi, dengesiz verilerle işlem yaparken bir modelin performansının daha gerçekçi bir görünümünü sağlamaktadır. Şekil 42'de görüldüğü gibi eğrinin altında kalan oldukça fazladır. Bu alanın yüksek olması çalışmada kullanılan veri setinde sınıflar arasında ayırt etmede bir sorun yaşanmadığını ve tutarlı sonuçlar elde edildiğini göstermektedir. Eğrinin altında kalan arttıkça modelin sınıflar arasında ayırt etme performansı artmaktadır.

4.2. SSD Multibox Sonuçları

Çizelge 9'da SSD Multibox modelinin performansının değerlendirilmesi için hedef niteliğe ait tahminlerin ve gerçek değerlerin karşılaştırıldığı karışıklık matrisi verilmiştir.

Çizelge 9. SSD Multibox modelinin karışıklık matrisi (Confusion matrix)


		Tahmin					
		0 Sağlıklı	1 Külleme	2 Mildiyö	3 Ölü kol	4 GLRaV	5 GLFV
Gerçek	0 Sağlıklı	460	11	9	0	0	4
	1 Külleme	24	591	19	0	0	9
	2 Mildiyö	7	14	251	0	3	0
	3 Ölü kol	0	17	0	324	5	0

	4 GLRaV	0	8	6	0	213	0
	5 GLFV	0	7	10	0	0	208

Çizelge 9 incelendiğinde test görüntüleri üzerinde yapılan işlemlerden sonra; sarı ile gösterilen değerler gerçekte olması gereken sınıfın doğru tahmin edildiği sayıyı, kırmızı ile ise gerçekte olması gereken sınıfın yanlış tahmin edildiği sayıları göstermektedir. SSD Multibox modelinin test görüntülerine uygulanması sonucunda 484 sağlıklı görüntünün 460'i, 643 külleme hastalığının 591'i, 275 mildiyö hastalığının 251'i, 346 ölü kol hastalığının 324'u, 227 GLRaV hastalığının 213'si ve 225 GLFV hastalığının 208'u doğru sınıflandırılmıştır. Çizelge 10'da SSD Multibox modelinin başarısının değerlendirilmesinde kullanılan kesinlik, duyarlılık, F1 skor ve doğruluk değerleri verilmiştir. Toplamda ise 2 220 test görüntüsünden 2 047 görüntü doğru tahmin edilerek genel başarı oranı %92.21 olarak bulunmuştur. SSD Multibox modelinin doğruluk açısından elde edilen sonuçların daha iyi değerlendirilebilmesi için Kesinlik-Duyarlılık (PR) eğrisi ve ROC eğrisi Şekil 43'de gösterilmiştir.

Çizelge 10. SSD Multibox modelinin başarısının değerlendirilmesi

Sınıf	Kesinlik	Duyarlılık	F1 Skor	Doğruluk
0 (Sağlıklı)	95.04	93.69	94.36	97.38
1 (Külleme)	91.91	91.20	91.55	94.94
2 (Mildiyö)	91.27	85.10	88.11	96.78
3 (Ölülük)	93.64	100	96.72	98.94
4 (GLRaV)	93.83	96.38	95.10	98.95
5 (GLFV)	92.44	94.12	93.27	98.56



Şekil 43. SSD Multibox modelinin PR eğrisi ve ROC eğrisi

Şekil 43'de gösterilen SSD Multibox modelinin Kesinlik-Duyarlılık (PR) eğrisi, Faster R-CNN modeline göre eğri altında kalan biraz fazladır. Bu alanın yüksek olması çalışmada kullanılan veri setinde sınıflar arasında ayırt etmede bir sorun yaşanmadığını ve tutarlı sonuçlar elde edildiğini göstermektedir. Eğrinin altında kalan alanın 1'e yaklaşması modelin sınıfları ayırt etme performansının arttığını göstermektedir.

4.3. Geliştirilen Model Sonuçları

Çizelge 11'de, çalışmada geliştirilen modelin performansının değerlendirilmesi için hedef niteliğe ait tahminlerin ve gerçek değerlerin karşılaştırıldığı karışıklık matrisi verilmiştir.

Çizelge 11. Çalışmada geliştirilen modelin karışıklık matrisi (Confusion matrix)


		Tahmin					
		0 Sağlıklı	1 Külleme	2 Mildiyö	3 Ölü kol	4 GLRaV	5 GLFV
Gerçek	0 Sağlıklı	484	0	0	0	0	0
	1 Külleme	20	610	13	0	0	0
	2 Mildiyö	4	10	261	0	0	0
	3 Ölü kol	0	6	0	340	0	0
	4 GLRaV	0	0	5	0	222	0
	5 GLFV	0	0	9	0	0	216

Çizelge 11 incelendiğinde, test görüntüleri üzerinde yapılan işlemlerden sonra; sarı ile gösterilen değerler gerçekte olması gereken sınıfın doğru tahmin edildiği sayıyı, kırmızı ise gerçekte olması gereken sınıfın yanlış tahmin edildiği sayıları göstermektedir. Geliştirilen modelde 484 sağlıklı test görüntüsünden hepsi tespit edilmiştir. 643 külleme hastalığının 610'u, 275 mildiyö hastalığının 261'i, 346 ölü kol hastalığının 340'ı, 227 GLRaV hastalığının 222'si ve 225 GLFV hastalığının 216'sı doğru sınıflandırılmıştır. Her bir sınıf için elde edilen tahmin değerleri diğer modellere göre daha yüksek bulunmuştur. Çizelge 12'de ise çalışmada geliştirilen modelin başarısının değerlendirilmesinde kullanılan kesinlik, duyarlılık, F1 skor ve doğruluk değerleri verilmiştir. Toplamda ise 2 220 test görüntüsünden 2 133 görüntü doğru tahmin edilerek genel başarı oranı %96.95 olarak bulunmuştur.

Çizelge 12. Çalışmada geliştirilen modelin başarısının değerlendirilmesi

Sınıf	Kesinlik	Duyarlılık	F1 Skor	Doğruluk
0 (Sağlıklı)	100	9527	97.58	98.89
1 (Külleme)	94.87	97.44	96.14	97.75
2 (Mildiyö)	94.91	90.63	92.72	98.11
3 (Ölököl)	98.27	100	99.13	99.72
4 (GLRaV)	97.80	100	98.89	99.77
5 (GLFV)	96	100	97.96	99.58

Geliştirilen modelinin doğruluk açısından elde edilen sonuçların daha iyi değerlendirilebilmesi için Kesinlik-Duyarlılık (PR) eğrisi ve ROC eğrisi Şekil 44'de gösterilmiştir.



Şekil 44. Geliştirilen modelinin PR eğrisi ve ROC eğrisi

Geliştirilen modelin Kesinlik-Duyarlılık (PR) eğrisi incelendiğinde, dengesiz verilerle uğraşırken bir modelin performansının daha gerçekçi bir görünümünü sağlamaktadır. Şekil 44’de görüldüğü gibi, eğrinin altında kalan Faster R-CNN ve SSD Multibox modeline göre daha fazladır. Bu alanın çok yüksek olması çalışmada kullanılan veri setinde sınıflar arasında ayırt etmede bir sorun yaşanmadığı ve diğer modellere göre daha tutarlı sonuçlar elde edildiğini göstermektedir. Modelin sınıfları ayırt etme başarı oranı arttıkça eğrinin altında kalan artmaktadır. Eğrinin altında kalan alanın 1 olması modelin mükemmel bir performans gösterdiği anlamına gelmektedir.

4.4. En İyi Sonucun Değerlendirilmesi


Çalışmada geliştirilen modelin yanı sıra transfer öğrenme yapılarak hazır modeller ile de denemeler yapılmıştır. Kullanılan bu modeller SSD Multibox ve Faster R-CNN'dir. Modellerin

test görüntüleri üzerinden elde edilen başarı sonuçlarının karşılaştırılması Çizelge 13’de verilmiştir.


Çizelge 13. CNN modellerinin başarı oranlarının karşılaştırılması

Sınıflar	Doğruluk		
	Geliştirilen Model	Faster R-CNN	SSD Multibox
0 (Sağlıklı)	98.89	98.30	97.38
1 (Külleme)	97.75	95.83	94.94
2 (Mildiyö)	98.11	96.61	96.78
3 (Ölülöl)	99.72	97.12	98.94
4 (GLRaV)	99.77	98.15	98.95
5 (GLFV)	99.58	97.12	98.56


Çizelge 13 incelendiğinde, geliştirilen modelin sağlıklı ve hastalıklı görüntüler üzerinden Faster R-CNN ve SSD Multibox modellerine göre genel olarak daha başarılı bir şekilde çalıştığı görülmektedir. Geliştirilen modelin genel doğruluğu %96.95 elde edilerek Faster R-CNN %92 ve SSD Multibox %92.21 modellerine göre daha başarılı bulunmuştur. Sonuç olarak geliştirilen model halihazırda olan modellere göre başarı oranı daha yüksek bir şekilde hastalıkları tespit edebilmiş ve sınıflandırmıştır. Faster R-CNN ve SSD Multibox modellerinin birbirine göre karşılaştırması incelendiğinde de sağlıklı ve külleme sınıfında Faster R-CNN modelinde daha iyi sonuçlar elde edilirken, virüs hastalıkları ile mildiyö ve ölülöl hastalığında ise SSD Multibox modeli daha iyi sonuçlar vermiştir. Şekil 45-48’de elde edilen performans metriklerin karşılaştırmalı grafikleri verilmiştir.




Şekil 45. Modellerin karşılaştırmalı doğruluk değerleri



Şekil 46. Modellerin karşılaştırmalı kesinlik değlerleri



Şekil 47. Modellerin karşılaştırmalı duyarlılık değlerleri



Şekil 48. Modellerin karşılaştırmalı F1 skor değerleri

Şekil 45 ile Şekil 48 arasında verilen grafikler incelendiğinde, geliştirilen model ile kesinlik, duyarlılık ve F1 skor metriklerinde Faster R-CNN ve SSD Multibox modellerinden daha yüksek değerler bulunmuştur. SSD Multibox modeli kesinlik metriğinde sadece sağlıklı görüntü sınıfında, duyarlılık metriğinde ise sağlıklı, külleme ve mildiyö sınıflarında Faster R-CNN modeline göre düşük değerde kalmıştır. SSD Multibox modeli Faster R-CNN modeline göre özellikle mildiyö, ölü kol ve virüs hastalıklarında daha başarılı sonuçlar elde etmiştir.

Bitkilerde bazı bağ hastalıklarının teşhisi konusunda son yıllarda yapılan akademik çalışmaların ve önerilen yöntemde geliştirilen modelin başarı oranlarının karşılaştırılması Çizelge 14’de verilmiştir.

Çizelge 14. Bağ hastalıklarının tespitine yönelik çalışmaların karşılaştırılması

Yazar	Yıl	Görüntü Sayısı	Model	Nesne	Doğruluk
Ghoury ve ark.	2019	113	Faster R-CNN	GLRaV	93.30
				Mildiyö	95.57
Liu ve ark.	2020	12 740	DICNN	Mildiyö	96.00
Gutierrez ve ark.	2021	275	CNN	Mildiyö	91.00
Guo ve ark.	2022	2 300	Faster R-CNN	Mildiyö	86.91
				Külleme	85.39
Lu ve ark.	2022	12 615	MobilenetV3_large	Mildiyö	96.44
				Külleme	99.31
				GLRaV	98.55
				Külleme	97.75
Önerilen Yöntem	2022	11 000	Geliştirilen Model	Mildiyö	98.11
				Ölü kol	99.72
				GLRaV	99.77
				GLFV	99.58


Önerilen yaklaşım, literatürdeki benzer yöntemlerden daha iyi sonuçlar vermiştir. Literatürde son 5 yılda yapılan çalışmalar incelendiğinde, bitki hastalıklarının teşhisinde derin öğrenme modellerinin yoğun olarak kullanıldığı görülmektedir. Çalışmalarda genellikle derin öğrenme modelleri olarak Faster R-CNN, SSD, VGG16, VGG19 ve GoogLeNet, AlexNet, ResNet modellerinin tercih edildiği görülmektedir. Ayrıca literatürdeki tüm çalışmalarda derin öğrenme modellerinin doğrudan bitki hastalıklarının görüntülerine uygulandığı görülmüştür.

Bu çalışmada, Faster R-CNN derin öğrenme modelinin test veri setine uygulanması sonucunda hastalıkların doğruluk oranları; külleme %95.83, mildiyö %96.61, ölü kol %97.12, GLRaV %98.15, GFLV %97.12 olarak bulunmuştur. Hastalıkların tespiti ve sınıflandırılmasında %92 genel doğruluk elde edilmiştir.


SSD Multibox derin öğrenme modelinin test veri setine uygulanması sonucunda hastalıkların doğruluk oranları; külleme %94.94, mildiyö %96.78, ölü kol %98.94, GLRaV %98.95, GFLV %98.56 olarak bulunmuştur. Hastalıkların tespiti ve sınıflandırılmasında %92.21 genel doğruluk elde edilmiştir.

Geliştirilen derin öğrenme modelinin test veri setine uygulanması sonucunda hastalıkların doğruluk oranları; külleme %97.75, mildiyö %98.11, ölü kol %99.72, GLRaV %99.77, GFLV %99.58 olarak bulunmuştur. Hastalıkların tespiti ve sınıflandırılmasında %96.95 genel doğruluk elde edilmiştir.

Bu sonuçlar neticesinde bağ hastalıklarının tespit edilmesi ve sınıflandırılması için doğru derin öğrenme modelinin belirlenmesinin önemli olduğu sonucuna varılmıştır. Yanlış sınıflandırmalar incelendiğinde, bitki yapraklarının görüntülerinde güneş kaynaklı parıltı ve gölgelerin olduğu görülmektedir. Kılıçarslan (2022), hibrit yöntemlerin daha yüksek performans gösterdiğini bildirmiştir. Hastalık tespitinde de hibrit yöntemler uygulanarak yanlış sınıflandırmaların önüne geçip başarı oranının daha da artacağı düşünülmektedir. Şekil 49'da Faster R-CNN modelinin uygulanmasına, Şekil 50'de ise geliştirilen modelinin uygulanmasına örnek görüntü verilmiştir.



Şekil 49. Faster R-CNN modelinin uygulanmasına örnek görüntüler



Şekil 50. Geliştirilen modelin uygulanmasına örnek görüntüler

5. SONUÇ ve ÖNERİLER

Görüntü işleme ve yapay zeka alanlarındaki hızlı gelişmelere bağlı olarak tarımsal alanlardaki çalışmalar da bu teknolojik gelişmelerden payını almıştır. Son yıllarda, özellikle bitki hastalıklarının otomatik teşhisi için araştırmacılar derin öğrenme yöntemlerinin geliştirilmesine odaklanmıştır. Yapılan çalışmalarda, hastalık semptomlarının daha hızlı saptanması ve hastalık sınıflandırma sonuçlarının doğruluğunun artırılması üzerine çalışılmaktadır. Model performansı arttıkça bitki hastalıklarının tanımlanmasındaki başarı da artacaktır.

Bu çalışmada, bazı bağ hastalıklarının tespiti ve sınıflandırılması için Faster R-CNN, SSD Multibox ve geliştirilen derin öğrenme modeli yöntem olarak önerilmiştir. Deneysel değerlendirmeler sonucunda, hastalıkların tespiti ve sınıflandırılmasında genel doğruluk oranları sırasıyla Faster R-CNN %92, SSD Multibox %92.21 ve geliştirilen model %96.95 olarak bulunmuştur. Bu sonuçlar neticesinde önerilen yöntemin, bağ hastalıklarının tespiti ve sınıflandırılmasında güvenilir bir şekilde kullanılabileceği sonucuna varılmıştır. Ayrıca yapay zeka yöntemleri ile birlikte hastalık tespitinin manuel yaklaşımlara göre çok daha hızlı ve daha başarılı sonuçlar ürettiği görülmektedir. Ek olarak, geliştirilecek yeni model başarılarının daha da artırılması ile görüntüleme ve veri iletimi teknolojilerindeki gelişmeler ile bitki hastalık görüntülerinin gerçek zamanlı olarak değerlendirilmesini de sağlayabilecektir.

Derin öğrenmenin mevcut hesaplama ve verilerin miktarındaki artışlardan kolayca yararlanabilmesi ve elle çok az mühendislik gerektirmesi nedeniyle, yakın gelecekte çok daha fazla başarıya sahip olacağı düşünülmektedir. Gelecekteki çalışmalarda, bağ hastalıkları görüntüleri üzerinden derin öğrenme yöntemleri kullanılarak, hızlı karar verebilecek uzman sistemlerin geliştirilmesi amaçlanmaktadır.

Bağcılık, özel bilgi ve beceri isteyen tarım koludur. Bakım işlerinin zamanında uygulanması çok önemlidir. Hastalık ve zararlılarla mücadele mutlaka yapılmalıdır. Ancak zamansız ve gereksiz ilaç kullanımı doğal dengeyi bozmakta, insan sağlığına zarar vermekte, üründe kalite ve verim kayıplarına yol açmaktadır. Bu nedenle, hastalıkların erken teşhisi ve tanısı çok önemlidir. Yürütülen çalışma bağ hastalıklarının erken dönemde tespit edilmesine imkan sağlayabilecektir. Çalışma sonunda elde edilen çıktılar ve ulaşılan sonuçlar neticesinde, bu çalışmanın bilimsel ve teknik olarak çeşitli iş kollarında faydalı olacağı düşünülmektedir. Bunlar;

- Bilim açısından: Derin öğrenme, hızla görüntü sınıflandırma için standart bir teknik haline gelmektedir. Derin öğrenme kullanarak bitki hastalıklarının otomatik olarak tanımlanmasının önündeki sorun, pratikte bulunan çok çeşitli koşulları ve belirti özelliklerini temsil edebilecek görüntü veri tabanlarının eksikliğidir. Tarımsal alanda hastalık görüntü veri seti bulmak çok zor olmaktadır. Bu çalışmada, bazı bağ hastalıklarının farklı aydınlanma koşullarında alınan görüntüleri ile oluşturulan yeni veri seti bağ hastalıkları alanına önemli katkı sağlayacaktır. Bu veri setlerini kullanacak araştırmacıların yapacağı farklı çalışmalara kolaylık sağlayacak ve gerçekleştirilen bu çalışma, araştırmacıların kendi çalışmalarına yol gösterici olacaktır. Ayrıca çalışmadan elde edilen sonuçlar, yeni çalışmaların yapılmasına öncülük edeceği düşünülmektedir.
- Çiftçi/Üretici açısından: Toprakların birinci derecede faydalanıcıları onu işleyip üzerinde üretim yapan çiftçilerdir. Bitki hastalıkları, üreticinin verimini etkileyeceğinden öncelikle kendileri bu durumdan olumsuz etkilenecektir. Bu olumsuzlukların önlenmesi için erken uyarı veren uzman sistemlerin geliştirilmesi, çiftçilere zaman kaybı olmadan gerekli tedbirlerin alınmasını sağlayacaktır. Böylelikle çiftçilerin hastalıklara erken müdahalesiyle verim kaybı olabildiğince en aza indirilecektir.
- Sanayi açısından: Bitki hastalıkları ile mücadelede en yaygın olarak kimyasal yollardan elde edilen pestisitler kullanılmaktadır. Ancak zamanında ve yerinde uygulanmayan pestisitler bitkiye ve çevreye zarar vererek, doğal dengeyi bozmakta ve insan sağlığına zarar vermektedir. Bu sorunların önüne geçmek için zamanında, doğru miktarda ve doğru pestisitinin uygulaması gerekmektedir. Bu çalışmanın devamında yapılacak çalışmalarla, bitki hastalıklarının otomatik ve gerçek zamanlı olarak belirlendiği uzman sistemler, otonom ilaçlama robotları gibi uygulamaların geliştirilmesine çalışılacaktır.
- Ekonomi açısından: Tarım ürünleri fiyatlarının giderek arttığı günümüz koşullarında, verimli ve kaliteli üretim yapılmasıyla ülke ekonomisine önemli katkılar sağlanacaktır.

6. KAYNAKLAR

- Adem, K., 2018. Exudate detection for diabetic retinopathy with circular hough transformation and convolutional neural networks. *Expert Systems with Applications*, (114):289-295.
- Adem, K. ve Közkurt, C., 2019. Defect detection of seals in multilayer aseptic packages using deep learning. *Turk J Elec Eng & Comp Sci*, 27:4220-4230.
- Adem, K., Ozguven, M.M. ve Altas, Z., 2022. A sugar beet leaf disease classification method based on image processing and deep learning. *Multimedia Tools and Applications*.
- Anonim, 2019a. Bağ entegre mücadele teknik talimatı. Gıda Tarım ve Hayvancılık Bakanlığı, Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü, Türkiye.
- Anonim, 2019b. Westover vineyard advising. <http://www.vineyardadvising.com/frost-or-fungi/> (Erişim Tarihi: 27.10.2019).
- Anonim, 2019c. Zirai mücadele teknik talimatları cilt 4. Gıda Tarım ve Hayvancılık Bakanlığı, Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü, Bitki Sağlığı Araştırma Daire Başkanlığı.
- Akgül, D.S., 2013. Bitki fungal hastalıkları (bağ hastalıkları). Çukurova Üniversitesi, Ziraat Fakültesi Bitki Koruma Bölümü, Ders Notları, Adana.
- Altas, Z., Ozguven, M.M. ve Yanar, Y., 2018. Determination of sugar beet leaf spot disease level (*Cercospora beticola* sacc.) with image processing technique by using drone. *Current Investigations In Agriculture And Current Research*, 5(3):621-631.
- Altas, Z., Özgüven, M.M. ve Yanar, Y., 2019. Bitki hastalık ve zararlı düzeylerinin belirlenmesinde görüntü işleme tekniklerinin kullanımı: şeker pancarı yaprak leke hastalığı örneği. *International Erciyes Agriculture, Animal Food Sciences Conference* 24-27 April 2019 - Erciyes University - Kayseri/Türkiye.
- Altas, Z., Özgüven, M.M. ve Dilmaç, M., 2021. Görüntü işleme teknikleri ile bağ yaprak uyuzu hasarının belirlenmesi. *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, 10(3):77-87.
- Alpaydın, E., 2004. Introduction to machine learning. The MIT Press.
- Atalay, M. ve Çelik, E., 2017. Büyük veri analizinde yapay zeka ve makine öğrenmesi uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22):155-172.
- Ampatzidis, Y., De Bellis, L. ve Luvisi, A., 2017. iPathology: robotic applications and management of plants and plant diseases. *Sustainability*, 9(6):1010.
- Asraf, A., Islam, M. ve Haque, M., 2020. Deep learning applications to combat novel coronavirus (COVID-19) pandemic. *SN Comput Sci*, 1(6):1-7.
- Agarwal, M., Singh, A., Arjariac, S., Sinhad, A. ve Gupta, S., 2020. ToLeD: tomato leaf disease detection using convolution neural network. *Procedia Computer Science* 167:293–301.
- Alruwaili, M., Alanazi, S., El-Ghany, S.A. ve Shehab, A., 2019. An efficient deep learning model for olive diseases detection. *(IJACSA) International Journal of Advanced Computer Science and Applications*, 10:8.
- Ashqar, B.A.M. ve Abu-Naser, S.S., 2018. Image-based tomato leaves diseases detection using deep learning. *International Journal of Academic Engineering Research (IJAER)*, 2(12):10-16.
- Ayon, S.I. ve Islam, M.M., 2019. Diabetes prediction: a deep learning approach. *Int J Inform Eng Electron Bus*, 12(2):21.
- Barbedo, J.G.A., 2018. Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. *Computers and Electronics in Agriculture*, 153:46-53.
- Barbedo, J.G.A., 2019. Plant disease identification from individual lesions and spots using deep learning. *Biosystems Engineering*, 180:96-107.

- Badem, H., 2017. Derin öğrenme yöntemleri kullanarak hiperspektral imgelerin sınıflandırılmasına yönelik yeni yaklaşımlar. Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı (Doktora Tezi), Kayseri.
- Bengio, Y., Goodfellow, I. ve Courville, A., 2015. Deep learning. MIT Press, 2015.
- Bock, C.H., Poole, G.H., Parker, P.E. ve Gottwald, T.R., 2010. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *CRC Crit Rev Plant Sci*, 29(2):59-107.
- Chen, J., Chen, J., Zhang, D., Sun, Y. ve Nanehkaran, Y.A., 2020. Using deep transfer learning for image-based plant disease identification. *Computers and Electronics in Agriculture* 173:05393.
- Clark, D., 2018. Top 16 open source deep learning libraries and platforms. <https://www.kdnuggets.com/2018/04/top-16-open-source-deep-learning-libraries.html>.
- Cruz, A.C., Luvisi, A., De Bellis, L. ve Ampatzidis, Y., 2017. X-FIDO: an effective application for detecting olive quick decline syndrome with deep learning and data fusion. *Front Plant Sci*, 8:1741.
- Cruz, A., Ampatzidis, Y., Pierro, R., Materazzi, A., Panattoni, A., Bellis, L.D. ve Luvisi, A., 2019. Detection of grapevine yellows symptoms in *vitis vinifera* L. with artificial intelligence. *Computers and Electronics in Agriculture*, 157:63-76.
- Darwish, A., Ezzat, D., Hassanien ve A.E., 2020. An optimized model based on convolutional neural networks and orthogonal learning particle swarm optimization algorithm for plant diseases diagnosis. *Swarm and Evolutionary Computation*, 52:100616.
- DeChant, C., Wiesner-Hanks, T., Chen, S., Stewart, E.L., Yosinski, J., Gore, M.A, Nelson, R.J. ve Lipson, H., 2017. Automated identification of northern leaf blight-infected maize plants from field imagery using deep learning. *Phytopathology*, <http://dx.doi.org/10.1094/PHYTO-11-16-0417-R>.
- Deng, L. ve Yu, D., 2013. Deep learning: methods and applications. *Foundations and Trends in Signal Processing*, 7(3-4):197-387.
- Dhakal, A. ve Shakya, S., 2018. Image-based plant disease detection with deep learning. *International Journal of Computer Trends and Technology (IJCTT)*, 61(1):2231-2803.
- Esgario, J.G.M., Krohling R.A. ve Ventura J.A., 2020. Deep learning for classification and severity estimation of coffee leaf biotic stress. *Computers and Electronics in Agriculture*, 169:105162.
- FAO, 2022. Food and agriculture organization of the united nations. FAOSTAT, <https://www.fao.org/faostat/en/#data/QCL> (Erişim Tarihi: 25.10.2022).
- Ferentinos, K.P., 2018. Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145:311-318.
- Fuentes, A., Yoon, S., Kim, S.C. ve Park, D.S., 2017. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*, 17:2022.
- Gavhale, K.R. ve Ujwalla, G., 2014. An overview of the research on crop leaves disease detection using image processing techniques. *IOSR J Comput Eng*, 16(1):10-16.
- Geetharamani, G. ve Arun, P.J., 2019. Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers and Electrical Engineering*, 76:323-338.
- Ghoury, S., Sungur, C. ve Durdu, A., 2019. Real-time diseases detection of grape and grape leaves using Faster R-CNN and SSD MobileNet architectures. *International Conference on Advanced Technologies, Computer Engineering and Science (ICATCES 2019)*, Apr 26-28, 2019 Alanya, Turkey.
- Gutiérrez, S., Hernández, I., Ceballos, S., Barrio, I, Navajas, A.M.D. ve Tardaguila, J., 2021. Deep learning for the differentiation of downy mildew and spider mite in grapevine under field conditions. *Computers and Electronics in Agriculture*, 182:105991.
- Guo, W., Feng, Q., Li, X., Yang, S. ve Yang, J., 2022. Grape leaf disease detection based on attention mechanisms. *Int J Agric & Biol Eng*, 15(5):205-2012.

- Islam, M., Haque, M., Iqbal, H., Hasan, M., Hasan, M. ve Kabir, M.N., 2020. Breast cancer prediction: a comparative study using machine learning techniques. *SN Comput Sci*, 1(5):1-14.
- Islam, M.M., Karray, F., Alhadj, R. ve Zeng, J., 2021. A review on deep learning techniques for the diagnosis of novel coronavirus (COVID-19). *IEEE Access*, 9:30551-30572.
- Janiesch, C., Zschech, P. ve Heinrich, K., 2021. Machine learning and deep learning. *Electronic Markets*, 31:685-695.
- Ji, M. ve Wu, Z., 2022. Automatic detection and severity analysis of grape black measles disease based on deep learning and fuzzy logic. *Computers and Electronics in Agriculture*, 193:106718.
- Jiang, H. ve Learned-Miller, E., 2017. Face detection with the Faster R-CNN. In: 2017 12th IEEE international conference on automatic face & gesture recognition (FG 2017), pp 650-657.
- Karabat, S., 2014. Türkiye ve dünya bağcılığı. *Apelasyon*, ISSN:2149-4908. <http://apelasyon.com/Yazi/33-dunya-ve-turkiye-bagciligi> (Erişim Tarihi: 26.08.2019).
- Kayaalp, K. ve Süzen, A.A., 2018. Derin öğrenme ve Türkiye'deki uygulamaları. *IKSAD Yayınevi*, ISBN 978-605-7510-53-2.
- Karthik, R., Hariharan, M., Anand, S., Mathikshara, P., Johnson, A. ve Menaka, R., 2020. Attention embedded residual CNN for disease detection in tomato leaves. *Applied Soft Computing Journal*, 86:105933.
- Kerkech, M., Hafiane, A. ve Canals, R., 2018. Deep leaning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Computers and Electronics in Agriculture*, 155:237-243.
- Kılıçarslan, S., 2022. Kuru üzüm tanelerinin sınıflandırılması için hibrit bir yaklaşım. *Müh. Bil. ve Araş. Dergisi*, 4(1):62-71.
- Kim, P., 2017. *MATLAB Deep Learning; with machine learning, neural networks and artificial intelligence*. Springer, ISBN-13 (electronic): 978-1-4842-2845-6.
- Li, Z. ve Zhou, F., 2017. FSSD: feature fusion single shot multibox detector. *arXiv preprint arXiv:1712.00960*.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Yang Fu, C. ve Berg, A.C., 2016. SSD: single shot multibox detector. *European Conference on Computer Vision, ECCV 2016: Computer Vision-ECCV 2016*, pp 21–37.
- Liu, F., Wang, Y., Wang, F.C., Zhang, Y.Z. ve Lin, J., 2019. Intelligent and secure content-based image retrieval for mobile users. *IEEE Access*, 7(99):1-1.
- Liu, B., Ding, Z., Tian, L., He, D., Li, S. ve Wang, H., 2020. Grape leaf disease identification using improved deep convolutional neural networks. *Front Plant Sci*, 11:1082.
- Lu, Y., Yi, S., Zeng, N., Liu, Y. ve Zhang, Y., 2017. Identification of rice diseases using deep convolutional neural networks. *Neurocomputing*, 267:378-384.
- Lu, X., Yang, R., Zhou, J., Jiao, J., Liu, F., Liu, Y., Su, B. ve Gu, P., 2022. A hybrid model of ghost-convolution enlightened transformer for effective diagnosis of grape leaf disease and pest. *Journal of King Saud University-Computer and Information Sciences*, 34:1755-1767.
- Ma, J., Du, K., Zheng, F., Zhang, L., Gong, Z. ve Sun, Z., 2018. A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network. *Comput Electron Agric*, 154:18-24.
- Mishra, S., Sachan, R. ve Rajpal, D., 2020. Deep convolutional neural network based detection system for real-time corn plant disease recognition. *Procedia Computer Science*, 167:2003–2010.
- Ning, C., Zhou, H., Song, Y. ve Tang, J., 2017. Inception single shot multibox detector for object detection. *Proceedings of the IEEE International Conference on Multimedia and Expo Workshops (ICMEW) 10–14 July 2017*. IEEE, 978-1-5386-0560-8/17.

- Ozguven, M.M., 2018. The newest agricultural technologies. *Curr Investigations Agric Curr Res*, 5(1):573-580.
- Ozguven, M.M. ve Adem, K., 2019. Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. *Physica A*, 535:122537.
- Ozguven, M.M., 2020. Deep learning algorithms for automatic detection and classification of mildew disease in cucumber. *Fresenius Environmental Bulletin*, 29(08/2020):7081-7087.
- Ozguven, M.M. ve Altas, Z., 2022. A new approach to detect mildew disease on cucumber (*Pseudoperonospora cubensis*) leaves with image processing. *Journal of Plant Pathology*, 104:1397–1406.
- Ozguven, M.M. ve Yanar, Y., 2022. The technology uses in the determination of sugar beet diseases. in: sugar beet cultivation, management and processing. Springer, Editör: Misra, V., Srivastava, S., Mall, A.K. (Eds), Sayfa: 621-642, ISBN: 978-981-19-2729-4.
- Ozguven, M.M., 2023. The digital age in agriculture. Florida: CRC Press Taylor & Francis Group LLC. ISBN 9781032385808.
- Özgüven, M.M., 2018. Hassas tarım. Akfon Yayınları, Sayfa Sayısı: 334, Ankara.
- Özgüven, M.M., 2019. Teknoloji kavramları ve farkları. International Erciyes Agriculture, Animal Food Sciences Conference 24-27 April 2019-Erciyes University-Kayseri/Türkiye.
- Pearson, R.C. ve Goheen, A.C., 1994. Compendium of grape disease. The American Phytopathological Society (APS), ISBN 0-89054-088-8, USA.
- Rangarajan, A.K., Purushothaman, R. ve Ramesh, A., 2018. Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia Computer Science* 133:1040-1047.
- Rossi, V., 1995. Effect of host resistance in decreasing infection rate of cercospora leaf spot epidemics on sugarbeet. *Phytopathol Mediterr*, 34:149-156.
- Savaş, S., 2019. Karotis arter intima media kalınlığının derin öğrenme ile sınıflandırılması. Gazi Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalı, Doktora Tezi, Ankara.
- Saleem, M.H., Potgieter, J. ve Arif, K.M., 2019. Plant disease detection and classification by deep learning. *Plants*, 8:468.
- Sharma, P., Berwal, Y.P.S. ve Ghai, W., 2019. Performance analysis of deep learning CNN models for disease detection in plants using image segmentation. *Information Processing in Agriculture*, 2214-3173.
- Sethy, P.K., Barpanda, N.K., Rath, A.K. ve Behera, S.K., 2020. Deep feature based rice leaf disease identification using support vector machine. *Computers and Electronics in Agriculture*, 175:105527.
- Sorte, L.X.B., Ferraz, C.T., Fambrini, F., Goulart, R.D.R. ve Saito, J.H., 2019. Coffee leaf disease recognition based on deep learning and texture attributes. *Procedia Computer Science*, 159:135-144.
- Song, H.A. ve Lee, S.Y., 2013. Hierarchical representation using NMF. *International conference on neural information processing*, pp 466–473.
- Terzi, İ., Özgüven, M.M., Altaş, Z. ve Uygun T., 2019. Tarımda yapay zeka kullanımı. International Erciyes Agriculture, Animal Food Sciences Conference 24-27 April 2019 - Erciyes University - Kayseri/Turkey.
- TÜİK 2022. Türkiye istatistik kurumu. <https://data.tuik.gov.tr/Kategori/GetKategori?p=tarim-111&dil=1>. (Erişim Tarihi: 21.11.2022).
- Too, E.C., Yujian, L., Njuki, S. ve Yingchun, L., 2019. A comparative study of fine-tuning deep learning models for plant disease identification. *Computers and Electronics in Agriculture*, 161:272-279.
- Türkoğlu, M. ve Hanbay, D., 2018. Derin öğrenme algoritmalarından elde edilen özneteliklere dayalı kayısı hastalık tespiti. *IEEE*, 978-1-5386-6878-8/18.
- Uzun, İ., 2015. Bağcılık. Hasad Yayıncılık, ISBN:9758377336.

- Wang, Q. ve Qi, F., 2019. Tomato diseases recognition based on Faster RCNN. IEEE, 10th International Conference on Information Technology in Medicine and Education (ITME), 78-1-7281-3918-0.
- Zhong, Y. ve Zhao, M., 2020. Research on deep learning in apple leaf disease recognition. Computers and Electronics in Agriculture, 168:105146.



7. ÖZGEÇMİŞ

