



**T.C.
AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DERİN ÖZNİTELİKLER KULLANILARAK KİRAZ
YAPRAKLARINDA KÜLLEME HASTALIK SEVİYESİNİN
SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Hatice KAYHAN

HAZİRAN

HATİCE KAYHAN

**TEKNOLOJİ VE İNOVASYON
YÖNETİMİ ANABİLİM DALI**

HAZİRAN 2022

**DERİN ÖZNİTELİKLER KULLANILARAK KİRAZ YAPRAKLARINDA
KÜLLEME HASTALIK SEVİYESİNİN SINIFLANDIRILMASI**

Hatice KAYHAN

**YÜKSEK LİSANS TEZİ
TEKNOLOJİ VE İNOVASYON YÖNETİMİ ANABİLİM DALI**

Danışman

Dr. Öğr. Üyesi Yavuz ÜNAL

İkinci Danışman

Dr. Öğr. Üyesi Emrah DÖNMEZ

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2022

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Hatice KAYHAN tarafından hazırlanan “Derin Öznitelikler Kullanılarak Kiraz Yapraklarında Külleme Hastalık Seviyesinin Sınıflandırılması” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Teknoloji ve İnovasyon Yönetimi Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Yavuz ÜNAL

Teknoloji ve İnovasyon Yönetimi Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Başkan: Dr. Öğr. Üyesi Fahrettin Burak DEMİR

Yazılım Mühendisliği Anabilim Dalı, Bandırma On Yedi Eylül Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Üye: Dr. Öğr. Üyesi Mehmet EKİCİ

Elektrik- Elektronik Mühendisliği Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Tez Savunma Tarihi: 27/06/2022

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Amasya Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Hatice KAYHAN

27/06/2022

DERİN ÖZNİTELİKLER KULLANILARAK KİRAZ YAPRAKLARINDA KÜLLEME HASTALIK SEVİYESİNİN SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Hatice KAYHAN

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2022

ÖZET

Kiraz meyvesi, *Prunus avium* familyasına ait etli ve sert çekirdekli bir meyve çeşididir. Tüm dünyada tüketilen ve ticari değeri yüksek olan kiraz meyvesinin, ülkemizde de önemli ölçüde üretimi ve ihracatı yapılmaktadır. Kiraz bitkisi, yetiştirilmesi zor olan meyve türlerinden biridir. Yaygın olarak yetiştirilen bu bitki türünün büyütülmesi ve yaşatılması sürecinde çeşitli pestisit hastalıklarla karşılaşmaktadır. Bu hastalıkların tespitinde uzman görüşlerinden ve çitçi deneyimlerinden yararlanılsa da bitkilerin sağlıklı bir şekilde yetiştirilmesinde yeterli olmamaktadır. Bu nedenle, günümüzde bitkilerin ekiminden hasatına kadar ki tüm süreçlerin izlenmesinde bilgisayar teknolojilerinden faydalanılmaktadır. Tarımda kullanılan görüntü işleme ve makine öğrenmesine dayalı yapay zekâ uygulamaları daha güvenli, daha hızlı ve daha uygun maliyetli operasyonlara olanak sağlamaktadır. Bilgisayar destekli tarım analiz sistemleri bitki hastalıklarının tespit edilmesi, tanımlanması ve izlenmesinde yaygın olarak kullanılmaktadır. Geliştirilen bu sistemler tarımsal verimliliği arttırmak ve sağlıklı mahsuller yetiştirmek noktasında yenilikçi çözümler sunmaktadır. Özellikle bitki hastalıklarının tespit edilmesi ve izlenmesi süresinde doğru kararlar alınmasına yardımcı olmaktadır. Bu çalışmada kiraz bitkisinin yapraklarında görülen bakteriye dayalı hastalıkların tespit edilmesi amaçlanmıştır. Bu hastalıkların tespitinde ön-eğitilmiş konvolüsyonel sinir ağları kullanılarak (Convolutional Neural Network- CNN) hastalığa ait öznitelikler belirlenmiştir. Elde edilen bu öznitelikler ise CNN ağının son katmanında yer alan varsayılan sınıflandırıcı yerine LDA (Linear Discriminant Analysis), KNN (K-Nearest Neighbor), SVM (Support Vector Machine) sınıflandırıcılarının aracılığıyla; sağlıklı, az veya çok hastalıklı bitki tespitini yapmak amacıyla kullanılmıştır. Genel deney sonuçlarına göre çok sınıflı bu problemde en iyi başarımlar %88.1 ile Doğrusal SVM (Linear SVM) sınıflandırıcısı ile elde edilmiştir.

Sayfa Adedi	: 59
Anahtar Kelimeler	: Kiraz bitkisi, Bitki hastalıkları, Yapay öğrenme, Evrimsel sinir ağı
Danışman	: Dr. Öğr. Üyesi Yavuz ÜNAL
İkinci Danışman	: Dr. Öğr. Üyesi Emrah DÖNMEZ

CLASSIFICATION OF LEVEL OF POWDERY MILDEW DISEASE ON CHERRY LEAVES USING DEEP ATTRIBUTES

(M.Sc. Thesis)

Hatice KAYHAN

AMASYA UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2022

ABSTRACT

Cherry fruit is a fleshy and stone fruit variety belonging to the *Prunus avium* family. Cherry fruit, which is consumed all over the world and has a high commercial value, is also produced and exported in our country. The cherry plant is one of the fruit types that is difficult to grow. Various pesticide diseases are encountered in the process of growing and maintaining this widely grown plant species. Although expert opinions and farmers' experience are used in the detection of these diseases, it is not enough for the healthy growth of plants. For this reason, computer technology is used to monitor all processes from planting to harvesting. Artificial intelligence applications based on image processing and machine learning used in agriculture enable safer, faster, and more cost-effective operations. Computer-aided agricultural analysis systems are widely used in the detection, identification, and monitoring of plant diseases. These developed systems offer innovative solutions to increase agricultural productivity and grow healthy crops. It helps to make the right decisions, especially during the detection and monitoring of plant diseases. In the study, it was aimed to determine the bacterial diseases seen on the leaves of the cherry plant. In the detection of these diseases, the features of the disease were determined by using pre-trained convolutional neural networks (Convolutional Neural Network - CNN). These obtained features were used to detect healthy, more or less diseased plants through LDA (Linear Discriminant Analysis), KNN (K-Nearest Neighbor), SVM (Support Vector Machine) classifiers instead of the default classifier in the last layer of the CNN network. According to the general test results, the best performance in this multi-class problem has been achieved with the Linear SVM classifier with 88.1%.

Page Number	: 59
Key-Words	: Cherry plant, Plant diseases, Machine learning, Convolutional neural network
Supervisor	: Assist. Prof. Dr. Üyesi Yavuz ÜNAL
Co-Supervisor	: Assist. Prof. Dr. Üyesi Emrah DÖNMEZ

ÖN SÖZ ve TEŞEKKÜR

Yüksek Lisans Tezi olarak sunduğum “Derin Öznelikler Kullanılarak Kiraz Bitkisinde Bakteriye Dayalı Hastalık Tespiti” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Akademik gelişimime büyük katkı sağlayan, nezaketleri ve sonsuz sabırları ile beni her zaman destekleyen, bu araştırmanın gerçekleştirilmesinde çok büyük emekleri olan, birlikte çalışmaktan mutlu olduğum çok değerli hocalarım Dr. Öğr. Üyesi Yavuz ÜNAL’ a ve Dr. Öğr. Üyesi Emrah DÖNMEZ’ e en içten teşekkürlerimi sunarım.

Tüm süreci benimle yaşayan, her durumda bana inanan ve destekleyen sevgili eşim Osman KAYHAN’ a sabrı, desteği ve sevgisi için; hayatımdaki en değerli varlıklarım biricik yavrularım Azra KAYHAN, Asya KAYHAN ve Abdullah Uras KAYHAN’ a varlıkları ve yaşattıkları her an için minnettarım. İyi ki varsınız.

İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT	v
ÖN SÖZ ve TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ.....	ix
ŞEKİLLER DİZİNİ	xi
RESİMLER DİZİNİ	xii
KISALTMALAR DİZİNİ.....	xiii
1. GİRİŞ	1
2. İLİŞKİLİ ÇALIŞMALAR.....	3
2.1. Bitki Hastalıkları ile İlgili Yapay Öğrenme Çalışmaları.....	4
2.2. Bitki Hastalıkları ile İlgili Derin Öğrenme Çalışmaları	9
3. PROBLEM TANIMI VE ÖN-BİLGİ.....	15
3.1. Problemin Durumu.....	15
3.2. Araştırmanın Amacı	15
4. MATERYAL VE YÖNTEM.....	16
4.1. Veri Seti	16
4.2. Derin Öznitelikler.....	16
4.3. Ön-eğitilmiş Evrimsel Sinir Ağı Modelleri	17
4.3.1. GoogleNet (Inception V1).....	18
4.3.2. ResNet.....	21
4.3.3. DarkNet.....	22
4.3.4. NASNet.....	22

	Sayfa
4.4. Sınıflandırıcı Yöntemleri	24
4.4.1. LDA	25
4.4.2. En yakın komşu (KNN)	27
4.4.3. Destek vektör makineleri (SVM)	29
4.4.4. Bayes sınıflandırma algoritması.....	33
4.5. Öznitelik Seçici	34
5. DENEYLER VE GÖZLEMLER.....	36
5.1. Deney Konfigürasyonu	36
5.2. Deney Sonuçları	37
6. TARTIŞMA VE SONUÇ	50
KAYNAKLAR.....	51
ÖZGEÇMİŞ.....	59

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 4.1. Darknet-19 yapısı (Redmon ve Farhadi, 2016: 6)	22
Çizelge 5.1. Karmaşıklık matrisi (Sağlıklı)	38
Çizelge 5.2. Sınıflandırma performans metrikleri (Sağlıklı)	38
Çizelge 5.3. Karmaşıklık matrisi (Az hastalıklı)	38
Çizelge 5.4. Sınıflandırma performans metrikleri (Az hastalıklı)	39
Çizelge 5.5. Karmaşıklık matrisi (Çok hastalıklı)	39
Çizelge 5.6. Sınıflandırma performans metrikleri (Çok hastalıklı)	39
Çizelge 5.7. Tahmin edici sınıflandırma performansları	40
Çizelge 5.8. Karmaşıklık matrisi ve performans metrikleri – 50 öznitelik (Sağlıklı).....	40
Çizelge 5.9. Karmaşıklık matrisi ve performans metrikleri – 50 öznitelik (Az hastalıklı).....	41
Çizelge 5.10. Karmaşıklık matrisi ve performans metrikleri – 50 öznitelik.....	41
Çizelge 5.11. Karmaşıklık matrisi ve performans metrikleri – 100 öznitelik (Sağlıklı).....	422
Çizelge 5.12. Karmaşıklık matrisi ve performans metrikleri – 100 Öznitelik (Az Hastalıklı).....	42
Çizelge 5.13. Karmaşıklık matrisi ve performans metrikleri – 100 Öznitelik.....	42
Çizelge 5.14. Karmaşıklık matrisi ve performans metrikleri – 250 Öznitelik (Sağlıklı).	43
Çizelge 5.15. Karmaşıklık matrisi ve performans metrikleri – 250 Öznitelik (Az hastalıklı).....	43
Çizelge 5.16. Karmaşıklık matrisi ve Performans metrikleri – 250 Öznitelik (Çok hastalıklı).....	43
Çizelge 5.17. Karmaşıklık matrisi ve Performans metrikleri – 500 Öznitelik (Sağlıklı)	44
Çizelge 5.18. Karmaşıklık matrisi ve Performans metrikleri – 500 Öznitelik (Az hastalıklı).....	44
Çizelge 5.19. Karmaşıklık matrisi ve performans metrikleri – 500 öznitelik (Çok hastalıklı).....	44

Çizelge	Sayfa
Çizelge 5.20. Genel çok sınıflı performans parametreleri (3 sınıfın tümü) – 50 öznitelik.....	45
Çizelge 5.21. Genel çok sınıflı performans parametreleri (3 sınıfın tümü) – 100 öznitelik.....	46
Çizelge 5.22 Genel çok sınıflı performans parametreleri (3 sınıfın tümü) – 250 öznitelik	47
Çizelge 5.23. Genel çok sınıflı performans parametreleri (3 sınıfın tümü) – 500 öznitelik	48
Çizelge 5.24. Öznitelik sayısına karşılık sınıflandırıcı başarımı	49

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 4.1. DarkNet-19 (YoloV2) architecture.....	17
Şekil 4.2. Evrimsel sinir ağı mimarisi (CNN) (Kang, Song ve Sun, 2019)	18
Şekil 4.3. Boyut azaltmalı başlangıç modülü (Szegedy ve diğerleri, 2015: 4)	19
Şekil 4.4. GoogleNet ağ mimarisi (Szegedy ve diğerleri, 2015)	20
Şekil 4.5. Normal ve artık blok yapısı (Zhang ve diğerleri, 2021: 289)	21
Şekil 4.6. CIFAR-10 ve ImageNet için model mimarisi (Zoph, Vasudevan, Shlens ve Le, 2018)	23
Şekil 4.7. NASNet arama alanının şematik diyagramı (Zoph ve diğerleri, 2018)	24
Şekil 4.8. Genel bir karar ağacı yapısı (Safavian; ve Landgrebe, 1991: 661)	26
Şekil 4.9. KNN algoritması çalışma prensibi (Raj, 2021)	27
Şekil 4.10. DVM ağ mimarisi (S. Chen ve Yu, 2007)	29
Şekil 4.11. Optimum hiper düzlem ve DVM.....	31
Şekil 4.12. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi ...	32
Şekil 4.13. (a) Doğrusal olarak ayrılamayan veri seti ve (b) Doğrusal ayrılamayan veri setleri için hiper-düzlemin belirlenmesi	33
Şekil 5.1. Temsili CNN mimarisi modeli	36
Şekil 5.2. QSVM algoritması için ROC eğrisi- 50 öznitelik	45
Şekil 5.3. QSVM algoritması için ROC eğrisi- 100 öznitelik	46
Şekil 5.4. QSVM algoritması için ROC eğrisi- 250 öznitelik	47
Şekil 5.5. LSVM algoritması için ROC eğrisi- 500 öznitelik.....	48

RESİMLER DİZİNİ

Resim	Sayfa
Resim 4.1. Veri-setinden örnek yaprak görüntüleri.....	16



KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı kısaltmalar açıklamalarıyla birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
ANN	Artificial Neural Networks
BPNN	Back-Propagation Neural Network
CFS	Correlation Based Feature Selection
CNN	Convolutional Neural Network
ESA	Evrışimli Sinir Ağı
GAN	Generative Adversarial Network
GLCM	Gray-Level Co-Occurrence Matrix
KNN	K-Nearest Neighbours
LVQ	Learning Vector Quantization
M-bCNN	Matrix-Based Convolutional Neural Network
MRMR	Minimum Redundancy Maximum Relevance
SVM	Support Vector Machine
VGG	Visual Geometry Group
YSA	Yapay Sinir Ağı

1. GİRİŞ

Bitki hastalıklarının önceden tespiti bitki verimini etkileyen önemli faktörler arasında yer almaktadır. Bitki hastalıkları tüm bir bitkiyi etkileyebileceği gibi bitkiyi bölgesel olarak da etkileyebilir. Bitkiler türlerine göre farklı farklı hastalıklara yakalanabilmekte bu hastalıklar bakteri, mantar, pestisit, zararlı böcekler ve diğer bitkilerden taşınabilmektedir. Zirai uzmanlar genellikle gözlem yoluyla hastalık tespitini gerçekleştirmektedir. Uzmanlar bitkinin hastalığını tespit ederken bitkinin yaprak, kök, gövde ve çekirdek barındıran kısımlarını incelerler ve tetkiklerini yaparlar. Hastalıklar bitki verimini etkileyebileceği gibi bitkilere kısmi veya kalıcı hasarlar da verebilmektedirler. Bu nedenle tespitlerinin doğru şekilde yapılması doğru müdahale için kritik bir husustur. Diğer taraftan, uzmanların yanı sıra tetkik yapılması amacıyla bilgisayar destekli uygulamalar da geliştirilmektedir.

Son yıllarda bilgisayar destekli tarım uygulamalarına yönelik kayda değer bir gelişim yaşandığı görülmektedir. Bu uygulamaların kullanılması ile tarımsal işlemlerin ve süreçlerin daha verimli bir şekilde yürütülmesi amaçlanmaktadır. Tohum ekiminden arazi sulamasına, bitki ilaçlamadan rekolte tespitine, hastalık tespitinden hasat işlemine kadar birçok tarım uygulamasında bilgisayar destekli uygulamalar geliştirilmektedir. Bu tarımsal işlemler arasında bitki verimliliğinde önemli bir rol oynayan hastalık tespiti için de bu uygulamaların geliştirilmesi oldukça önemli bir sacayağıdır. Hastalıkların tespitinde uzmanların etiketlediği verilere dayalı olarak bilgisayar destekli hastalık tespit sistemleri geliştirilmektedir. Bu sistemlerde temel olarak yapay öğrenme tabanlı yaklaşımlar kullanılmaktadır.

Yapay öğrenme biyolojik canlılarının sinir sistemlerindeki öğrenme, hafızada tutma ve güncelleme modelini bilgisayar ortamında modellemeye yönelik bir yaklaşım/yöntemdir. Yapay öğrenmeye dayalı olarak çok sayıda sınıflandırma ve regresyon problemlerinin çözümü mümkündür. Hizmetten endüstriye, ulaşımdan eğitime, sağlıktan tarıma vb. birçok sektörde yapay öğrenme sistemlerinin geliştirildiği görülmektedir. Bu sistemler sağlamış oldukları yüksek karar verme becerisi ile hem karar destek sistemi olarak hem de doğrudan karar verici olarak kullanılabilmektedirler. Günümüzde, tarım ürünlerinde verimliliğin artırılması, hastalık ve zararlılara erkenden müdahale edilmesi amacıyla yapay öğrenme uygulamaları geliştirilmektedir. Bu uygulamaların geliştirilmesinde temel kaynak zirai

uzman kararlarına dayanmaktadır. Son yıllarda geleneksel yapay öğrenme yaklaşımlarının yerini derin öğrenme yöntemleri olarak ta bilinen evrişimsel sinir ağı modelleri almıştır.

Evrişimsel sinir ağı (Convolutional Neural Network), piksel verilerini işlemek için özel olarak tasarlanmış görüntü tanıma ve işlemede kullanılan bir tür yapay sinir ağıdır. CNN'ler, hem üretici hem de tanımlayıcı görevleri gerçekleştirmek için derin öğrenmeyi kullanan, genellikle öneri sistemleri ve doğal dil işleme (NLP) ile birlikte görüntü ve video tanımayı içeren makine görüşünü kullanan güçlü görüntü işleme, yapay zekâ uygulamaları geliştirilmesini sağlar. Evrişimsel sinir ağı modelleri, geleneksel yöntemlerde uygulanan görüntü üzerinde öznitelik çıkarımı yöntemleri ile öznitelik elde edilmesi ve bu özniteliklerin sınıflandırılması sürecini daha verimli bir hale getirmiştir. Evrişimsel sinir ağları, öznitelikleri üçüncü parti bir yöntemle ihtiyaç duymadan çok katmanlı bir mimari içindeki konvolüsyon vb. aritmetik işlemler kullanarak belirlemektedir. Bir CNN'nin katmanları, bir giriş katmanı, bir çıkış katmanı ve çoklu evrişim katmanlarını, havuz katmanlarını, tam bağlantılı katmanları ve normalleştirme katmanlarını içeren bir gizli katmandan oluşur. Elde edilen öznitelikler ağın son katmanındaki SoftMax sınıflandırıcı yönteminin eğitilmesinde veya doğrudan bir başka sınıflandırıcı yöntemi eğitimi için kullanılabilir. Bu ağların kullanılmasıyla birlikte elde edilen öznitelikler veri setinin belirgin özelliklerinin çıkarımında temsil düzeyini de artırmaktadır.

2. İLİŞKİLİ ÇALIŞMALAR

Ekonomik kalkınmanın önemli bir kaynağı olan tarım endüstrisinde bitkilerin korunması ve verimliliğin arttırılabilmesi oldukça önemlidir. Günümüzde tarımda gıda üretimini arttırabilmek ve mahsul verimliliği sağlayabilmek için sadece uzman görüşlerinden ve çiftçi deneyimlerinden yararlanmak yeterli olmamaktadır. Çünkü bitkilerin sadece çıplak gözle izlenmesi ve manuel yorumlamalar zaman, maliyet ve verimlilik kayıplarına neden olabilmektedir. Bu durum, tarımda gıda güvenirliliği ve sürdürülebilirliği açısından ciddi bir tehdit oluşturmaktadır. Bu nedenle, tüm tarımsal süreçlerin izlenebilmesi ve önlemlerin alınabilmesi için tarım alanlarında gerekli alt yapının oluşturulması son derece önem arz etmektedir. Geliştirilen modern sistemler tarımsal verimliliği arttırmak ve sağlıklı ürünler yetiştirmek hususunda yenilikçi çözümler sunmaktadır. Mahsullere ilişkin semptomların otomatik tespiti, geniş ekin tarlalarının daha hızlı izlenmesi ve hastalıkların erken teşhis edilmesine katkı sağlamaktadır. Bu nedenle, özellikle son yıllarda sürdürülebilir bir tarım için görüntü tabanlı fenotipleme ve dijital görüntü işlemeye dayalı yöntemlerden sıklıkla yararlanılmaktadır. Tarımda; haşere tespiti, bitki hastalıklarının tespiti, mahsullerden yüksek verim alınabilmesi vb. birçok alanda kullanılan bilgisayar destekli sistemler, tarım endüstrisindeki düşük verim ve ekonomik kayıpların önüne geçmektedir.

Günümüzde tarımda uzmanlar tarafından yapılan muayeneler ve biyolojik incelemeler gibi geleneksel yöntemlerin yerini bilgisayar destekli tarım analiz sistemleri almaya başlamıştır. Özellikle bitki fizyolojisinin incelenmesinde ve hastalıkların tespit edilmesinde kullanılan bu sistemler, büyük miktardaki verinin kısa sürede işlenmesini ve anlamlı sonuçlar elde edilmesini sağlamaktadır. Dolayısıyla yapılan araştırmalarda, farklı türdeki birçok bitki hastalığının önceden tespit etmek, bitkilerin yaprak ve gövdelerindeki semptomları otomatik olarak algılayabilmek için dijital görüntü işlemeye ve yapay öğrenmeye dayalı metotlar sıklıkla kullanılmaktadır. Bilgisayar destekli tespit sistemlerinde en kritik husus bitkinin kök, gövde, çiçek ve yaprak gibi bileşenleri üzerinde hastalık belirtilerini ifade eden özelliklerin çıkarılmasıdır. Bu özellikler analiz sistemlerinde öznitelik olarak bilinirler. Literatürde özniteliklerin görüntü işleme yöntemleriyle elde edilerek sınıflandırıcı yöntemlerine girdi oluşturması söz konusudur. Bu yaklaşım geleneksel sınıflandırma yaklaşımı olarak bilinir. Son zamanlarda ise yaygın olarak, evrimsel sinir ağlarından doğrudan elde edilebilen derin öznitelikler kullanılarak sınıflandırma yapılmaktadır. Bu

yöntem ise günümüzde de sıklıkla kullanılan daha modern sınıflandırma yaklaşımı sağlamaktadır.

Araştırmanın bu bölümünde bitkilerde hastalık tespitine ilişkin yerli ve yabancı literatürde yapay öğrenme ve derin öğrenme yöntemlerine dayalı çalışmalar ifade edilmiştir.

2.1. Bitki Hastalıkları ile İlgili Yapay Öğrenme Çalışmaları

Bashish, Braik ve Bani-Ahmad (2011) çalışmalarında, bitkilerdeki yaprak hastalıklarını teşhis etmek ve sınıflandırmak için görüntü işleme tabanlı bir yaklaşım önermişlerdir. Sunulan yöntem; bir renk dönüşüm yapısı, K-ortalama kümeleme tekniği ile görüntü bölütleme, doku özelliklerinin hesaplanması ve çıkarılan özneliliklerin önceden eğitilmiş bir sinir ağı ile test edilmesi olmak üzere dört aşamada ele alınmıştır. Sonuç olarak, önerilen yöntemin %93 hassasiyetle incelenen yaprak hastalıklarını saptayıp, sınıflandırabildiği görülmüştür.

Waghmare, Kokare ve Dandawate (2016), bitki hastalıklarının tespit edilmesinde yaprak doku analizi ve örüntü tanıma yöntemlerine dayalı bir çalışma gerçekleştirmişlerdir. Üzüm bitkisine ait yaprak görüntülerinin kullanıldığı çalışmada, sistemden girdi olarak alınan görüntüler segmentasyon işlemine tabi tutulmuş ve ardından yaprağın hastalıklı kısmını tespit etmek için yüksek geçirgen bir filtre kullanılarak analiz işlemi gerçekleştirilmiştir. Çalışmada, üzüm bitkisinde en sık görülen tüylü küf, küllenme, kara çürük ve diğer hastalıkları sistematik olarak sınıflandırılmak için SVM modeli kullanılmış ve %96,6'lık bir başarıma ulaşılmıştır.

Arivazhagan, Shebiah, Ananthi ve Vishnu Varthini (2013) çalışmalarında, bitki yaprak hastalıklarını otomatik olarak tespit etmek ve doku özelliklerine göre sınıflandırmak için bir algoritma önermişlerdir. Çalışmada önerilen sistem dört ana adımda ele alınmıştır. İlk olarak, işleme şemasında görüntüler RGB görüntüleri için bir renk dönüşüm yapısına ve ardından bir segmentasyon işlemine tabi tutulmuştur. Son aşamada, çıkarılan öznelilikler bir destek vektörü makine sınıflandırıcısından geçirilerek test edilmiştir. Önerilen yöntemin, incelenen hastalıkları %94 doğrulukla başarılı bir şekilde tespit edip sınıflandırabildiği görülmüştür.

Islam, Dinh, Wahid ve Bhowmik (2017) ‘Plant Village’ görüntü veri tabanından elde etikleri 300 patates yaprağı görüntü verisini, görüntü işleme ve makine öğrenmenin entegre kullanımı ile test etmişlerdir. Segmentasyon yaklaşımı ve SVM analizleri ile patates bitkisindeki hastalıkların sınıflandırıldığı çalışmada %95’lik bir başarıma ulaşılmıştır.

Liu ve Zhou (2009), pirinç yapraklarındaki hastalıklı kısımları tespit etmek geri yayımlı yapay sinir ağına dayalı bir çalışma gerçekleştirmişlerdir. Çalışmada Ningxia Hui Özerk Bölgesi’nden elde edilen görüntü verileri kullanılmıştır. Önerilen yöntemin pirinç kahverengi lekelerini tanımlama kabiliyetine sahip olduğunu ifade edilmiştir.

Jhuria, Kumar ve Borse (2013), makalelerinde yapay sinir ağı ile meyve hastalıklarını tespit etmeye çalışmışlardır. Çalışmada oluşturulan görüntü veri seti; renk, doku ve morfoloji olmak üzere üç özellik vektörü dikkate alınarak hastalık kategorilerine göre sınıflandırılmıştır. Hastalık görüntülerinin eğitimi ve sorgu görüntülerinin uygulanması için iki ayrı veri tabanından yararlanılmıştır. Çalışma sonucunda geliştirilen sinir ağının, incelenen hastalıkları tespit etmede ve sınıflandırmada başarılı olduğu ve morfolojinin %90 oranla diğer iki öznelikten daha iyi sonuç verdiği gözlenmiştir.

Bauer, Korč ve Förstner (2011), şeker pancarı yapraklarında görülen yaprak benek patojeni ‘Cercospora beticola’ ve pas patojeni ‘Uromyces betae’ isimli iki farklı hastalığın tespitine ilişkin bir çalışma gerçekleştirmişlerdir. Önerilen yöntemde hastalıkların sınıflandırılması için k-en yakın komşu, Bayes sınıflandırma ve koşullu rastgele alan olmak üzere üç farklı model kullanılmıştır. Çalışmada sonucunda sınıflandırma oranları; Cercospora beticola hastalığı için %91 ve Uromyces betae hastalığı için %86 olarak elde edilmiştir.

Naikwadi ve Amoda (2013), bitki yaprak hastalıklarının otomatik olarak tespit edilmesi ve sınıflandırılmasına ilişkin bir çalışma gerçekleştirmişlerdir. Yapılan çalışmada renk özelliğine ve kenar algılama tekniğine dayalı olan histogram eşleştirme tekniği ile hastalıklar tespit edilmeye çalışılmıştır. Örneklerin eğitimi için RGB görüntü katmanlarını kırmızı, yeşil ve mavi katmanlara ayıran katman ayırma tekniği ve katmanlı görüntülerin kenarlarını tespit eden bir kenar algılama tekniğinden yararlanılmıştır. Deneysel sonuçlar, önerilen algoritmanın bitki yaprak hastalıklarını tespit etmede güçlü bir yöntem olduğunu göstermiştir.

Hassan ve Abdulazeez (2021) yaptıkları çalışmada, bitkilerde yaprak hastalıklarını tespit etmek ve tanımlamak için Naive Bayes, Karar ağaçları, SVM ve Random Forest olmak üzere dört farklı sınıflandırma algoritması kullanmışlardır ve yöntemlerin sınıflandırma performanslarını karşılaştırmışlardır. Çalışma sonucunda SVM ile en iyi doğrulama sonucuna ulaşılmıştır.

Francis, Anto ve Anoop (2016) çalışmalarında, bitki yaprak görüntüleri ile bitki hastalıklarını otomatik olarak tespit etmeyi amaçlamışlardır. Araştırmada görüntü analiz tekniği ile biber bitkisinin yapraklarındaki görsel semptomlar kullanılarak sağlıklı ve sağlıklı bitkiler tespit edilmiş ve hastalıkların varlığı belirlenmeye çalışılmıştır.

Özerdem ve Acar (2011), Gri Seviyeli Eş-Oluşum (GLCM) tabanlı sınıflandırma yöntemlerini kullanarak, zambak çiçeği yaprağında pas hastalığı olup olmadığını tespit etmeyi amaçlayan bir çalışma gerçekleştirmişlerdir. Çalışmada sınıflandırıcı olarak çok katmanlı algılayıcı, k-En Yakın Komşu (k-NN) ve en küçük kareler destek vektör makinesi (LS-SVM) yöntemleri kullanılmış ve 32'si sağlıklı, 21'i hastalıklı olmak üzere toplam 53 örnek, sağlıklı ve hastalıklı olarak sınıflandırılmıştır. Araştırmada k-NN ve çok katmanlı yapay sinir ağı sınıflandırıcılarının %88,9 oranla en iyi tespit performansına sahip modeller olduğu sonucuna ulaşılmıştır.

Shruthi, Nagaveni ve Raghavendra (2019) çalışmalarında bitki hastalıklarının teşhisi için SVM, ANN, KNN, CNN ve Fuzzy olmak üzere beş farklı makine öğrenimi sınıflandırma tekniği kullanmışlardır. Araştırmada, CNN sınıflandırıcısının daha fazla sayıda hastalığı, yüksek doğruluk oranıyla tespit edebildiği sonucuna ulaşılmıştır.

Ilic, Ilic, Jovic ve Panic (2018), çalışmalarında meyve hastalıklarındaki enfeksiyon tahmini için “monilinia laxa” ve “coccoomyces hiemalis” olarak ifade edilen spesifik iki kiraz meyvesi enfeksiyon hastalığını farklı matematiksel teknikler kullanarak analiz etmişlerdir. Altı önemli hava durumu değişkeni ve yılın ayı temsil eden bir değişken, yordayıcı değişkenler olarak seçilmiştir. Araştırmada kullanılan veri setleri, sekiz yıllık bir zaman dilimine ait verileri içermektedir. Çalışmada tahmin doğruluğunun %95,8 olduğu ifade edilmiştir.

Singh, Varsha ve Misra (2015) tarafından yapılan çalışmada, bitki hastalıklarının sınıflandırılması ve otomatik olarak tespit edilmesinde görüntü bölütleme tekniği için genetik algoritma kullanılmıştır. Önerilen yöntemin daha az hesaplama adımları ile erken evrede bitki hastalıklarını teşhis edilebilme avantajı sunduğu ifade edilmiştir.

Khirade ve Patil (2015), makalelerinde çok sayıda bitki hastalığının izlenmesi ve tespit edilmesinde manuel yöntemlerin zorluğunu göz önünde bulundurarak görüntü işleme metoduna dayalı bir çalışma gerçekleştirmişlerdir. Bitki hastalıklarının tespiti için ilk aşamada sisteme girdi olarak verilen yaprak görüntüleri; kırpma, görüntü yumuşatma, görüntü iyileştirme ve histogram eşitleme gibi ön işlemlere tabi tutulmuştur. Çalışmada yaprak görüntüleri ile bitki hastalıklarının tespitine ilişkin bazı segmentasyon ve YSA' ya dayalı sınıflandırma algoritmaları tartışılmıştır.

Chanda ve Biswas (2019) çalışmalarında, bitki hastalıklarının daha verimli bir şekilde tanımlamak ve sınıflandırmak için BPNN dayalı bir yaklaşım önermişlerdir. Çalışmada ağırlıkları elde etmek için geri yayılım algoritmasından, yerel optimizasyon ve aşırı uyum gibi sorunlar için ise Parçacık Sürü Optimizasyonundan (PSO) yararlanılmıştır. Beş farklı bakteri ve mantar hastalığı içeren yaprak görüntülerinin kullanılmıştır. Görüntüler ilk olarak yeniden boyutlandırma, kontrast geliştirme, yeşil piksel maskeleme ve renk modeli dönüşümü gibi ön işlemlere tabi tutulmuş ve ardından bitkinin hastalıklı kısımlarını sınıflandırabilmek için görüntü bölütleme işlemi uygulanmıştır. Sonuç olarak, önerilen yöntem ile %96,2'lik bir başarıma ulaşılmıştır.

Dhakate ve Ingole (2015) tarafından nar bitkisindeki hastalıkların tespit edilmesine ilişkin bir çalışma gerçekleştirilmiştir. Önerilen yöntemde, nar bitkisinde sıklıkla görülen dört hastalık türü; bakteriyel yanıklık, meyve lekesi, meyve çürüğü ve yaprak lekesi olarak sınıflandırılmış ve ardından sayısal görüntü işleme ve sinir ağı yöntemleri test edilmiştir. Çalışma sonucunda hastalıkların tespit edilmesinde %90 oranında yüksek bir sınıflandırma başarısına ulaşılmıştır.

Chuanlei, Shanwen, Jucheng, Yancui ve Jia (2017) elma yaprağı hastalıklarının teşhis edilmesinde görüntü işleme tekniklerine ve örüntü tanıma yöntemlerine dayalı bir çalışma önermişlerdir. Çalışmada genetik algoritma ve korelasyona dayalı öznetelik seçimi (CFS)

yöntemleri birleştirilerek öznitelikler seçilmiş ve son aşamada hastalıkların sınıflandırılmasında SVM algoritması kullanılmıştır. Önerilen yöntemde %90 oranında hastalıkları doğru tanımlama başarısına ulaşılmıştır.

Karadağ ve Taşaltın (2016), biber yapraklarından Spektrometre cihazıyla topladıkları spektral yansıma verilerini kullanarak hastalık tespitine ilişkin bir çalışma önermişlerdir. Çalışmada, veri seti hastalıklı ve sağlıklı olmak üzere iki gruba ayrılarak yapay sinir ağı ile sınıflandırılmış ve yüksek tahmin sonuçlarına ulaşılmıştır.

Mo (2010), buğday bitkilerindeki sarı pas hastalığının ortaya çıkmasına sebep olan bakterilerin sayılarını tahmin etmek için üç ayrı geri yayımlı yapay sinir ağı modeline dayalı bir çalışma gerçekleştirmiştir.

Sabrol ve Satish (2016), hastalıklı domates yapraklarının sınıflandırılmasına ilişkin bir çalışma gerçekleştirmişlerdir. Domates yaprakları; domates geç yanıklığı, septoria lekesi, bakteriyel leke, bakteriyel kanser, domates yaprağı kıvrılması ve sağlıklı olmak üzere altı türde sınıflandırılmıştır. Çalışmada kamera ile çekilmiş 383 görüntüden oluşan veri setine Otsu 'nun görüntü bölütleme metodu uygulanmış ve karar ağacı sınıflandırıcısı ile eğitilerek sınıflandırma için denetimli öğrenme tekniklerinden yararlanılmıştır. Çalışma sonucunda genel olarak %97,3'lük bir sınıflandırma başarısına ulaşılmıştır.

Bashir ve Sharma (2012), çeşitli bitki hastalıklarının tespitinde K-ortalama kümeleme ve renk ve doku analizine dayanan bir yaklaşım önermişlerdir. Çalışmada Malus Domestica yaprak hastalığını tespit etmek için gri tonlamalı görüntülerin yoğunluk değerleri histogram eşitleme yöntemi kullanılarak elde edilmiştir. Görüntü bölütleme doku analizi için Co-occurrence matrix (CCM) yöntemi ve renk analizi için K-ortalama kümeleme algoritması kullanılmıştır.

Liu, Wu ve Huang (2010), makalelerinde sinir ağı ve temel bileşenler analiz tekniklerini kullanarak pirinç salkımlarındaki farklı mantar enfeksiyon seviyelerini ayırt etmeye ve sınıflandırmaya yönelik bir çalışma gerçekleştirmişlerdir.

2.2. Bitki Hastalıkları ile İlgili Derin Öğrenme Çalışmaları

Yuwana ve diğerleri (2019) çalışmalarında, bitki görüntülerinin tüm olası koşullar altında toplanmasının zor ve maliyetli olması durumunu göz önünde bulundurarak, daha güçlü bir derin evrişimli sinir ağı eğitmek için Çok koşullu eğitim (MCT) modelini önermişlerdir. Çalışmada 5,632 adet çay yaprağı görüntüsü içeren bir veri seti kullanılmıştır. Eğitim verileri farklı yönde ve çözünürlükte ideal olmayan çevresel koşullar altında test edilerek yöntemin sağlamlığı tartışılmıştır.

Aslan (2021), şeftali ağacı hastalıklarının tespiti için evrişimli sinir ağı yöntemine dayalı bir çalışma gerçekleştirmiştir. Çalışmada, hastalıkların tespiti için daha önceden eğitilmiş AlexNet modeli kullanılmıştır. Önerilen yöntem, 427 adet şeftali koşnili ve 327 adet şeftali monilya hastalıklarına ait renkli görüntüler içeren bir veri seti üzerinde test edilmiştir. Deneysel sonuçlar, önerilen yöntemin %99,30 yüksek doğruluk oranıyla hastalık tespiti yapabildiğini göstermiştir.

Türkoğlu, Hanbay, Sivrikaya ve Hanbay (2020), kayısı hastalıklarının tespit etmek için evrişim, relu, normalizasyon, havuzlama ve tam bağlı katmanlardan oluşan Derin Evrişimsel Sinir Ağlarına (DESA) dayalı bir model önerilmişlerdir. Kayısı hastalıklarına ait görüntüler içeren bir veri tabanı üzerinde yapılan test sonucunda %98,20 oranında sınıflandırma başarısına ulaşılmıştır. Ayrıca önerilen yöntem geleneksel özellik çıkarma yöntemleri ile karşılaştırılmış ve geliştirilen derin öğrenme modelinin daha yüksek sınıflandırma başarısına sahip olduğu da ifade edilmiştir.

Chen, Chen, Zhang, Nanekaran ve Sun (2020) tarafından yapılan çalışmada, bitki hastalıklarının tespit edilmesinde önceden eğitilmiş VGGNet modülü ile transfer öğrenmeyi kullanan INC-VGGN adlı bir derin evrişimli sinir ağı mimarisi önerilmiştir. Çalışmada hem halka açık PlantVillage veri seti hem de çalışma için oluşturulan görüntü veri seti kullanarak mısır ve pirinç bitkilerine ait hastalıklar test edilmiştir. Araştırmada, PlantVillage veri seti ile %91,83, oluşturulan veri setinde ise %92,00'lik bir doğruluğa ulaşılmıştır.

Militante, Gerardo ve Dionisio (2019), derin öğrenme metodunu ile bitki çeşitlerini ve hastalık türlerini tespit etmeyi amaçlayan bir çalışma gerçekleştirmişlerdir. Araştırmada, 32

adet farklı bitki çeşidi evrişimli sinir ağı (CNN) ile test edilmiş ve hastalık tespitinde %96,5'lik bir doğruluğa ulaşılmıştır.

Toğaçar (2021), dikkat modüllerinden oluşan derin öğrenme modeli ile pamuk bitkisindeki hastalıkların tespitine ilişkin bir çalışma önermiştir. Çalışmada, pamuk bitkisine ait görüntü veri kümesinde dikkat modülü kullanılarak bitkide odaklanması istenen hastalıklı bölgelerin tespit edilmesi ve modelin eğitim başarımının artırılması amaçlanmıştır. Deneysel sonuçlar incelediğinde, hastalıkların sınıflandırılmasında olasılıksal dereceli azalma yönteminde %95,70 ve uyarlanabilir moment tahmini yönteminde ise %96,56 oranında genel bir başarıya ulaşılmıştır.

Karthik ve diğerleri (2020) domates yapraklarındaki üç tür (erken yanıklık, geç yanıklık ve yaprak küfü) enfeksiyon tipini tespit etmek için iki derin öğrenme mimarisi içeren bir çalışma önermişlerdir. İlk olarak, kalıntı öğrenme ile birlikte ileri beslemeli CNN kullanılmış ve ardından kalıntı derin ağına üstüne dikkat mekanizması uygulanarak test edilmiştir. Deneysel sonuçlar, dikkat temelli kalıntı CNN mimarisinin enfeksiyon türünü %98 doğrulukla tespit edebildiğini göstermiştir.

Jiang, Li ve Safara (2021), elma meyvesindeki enfeksiyonların tespit edilmesinde ve önlenmesinde derin öğrenme metoduna dayalı bir çalışma gerçekleştirmişlerdir. Çalışmada, elma hastalık görüntülerini sınıflandırmak için derin evrişimli sinir ağı kullanılmıştır. Önerilen yöntem SVM ile karşılaştırıldığında, hastalıkları doğru teşhis etme noktasında daha iyi performans gösterdiği sonucuna ulaşılmıştır.

Çetiner (2021), çalışmasında elma ağacı yapraklarındaki hastalıkları tespit etmek ve sınıflandırmak için Konvolüsyonel Sinir Ağı (CNN) tabanlı bir derin öğrenme modeli kullanmıştır. Önerilen yöntem, farklı aydınlatma seviyesi, gürültü, arka planın homojen olmaması durumlarını içeren zorluk seviyesi yüksek bir veri seti üzerinde test edilmiştir. Çalışmada bir sağlıklı sınıf ve üç farklı hastalıklı sınıf olmak üzere toplam 3642 adet yaprak görüntüsü kullanılmıştır. Deneysel sonuçlar, transfer öğrenme tekniği olan DenseNet201 ağının, eğitim doğruluk ve doğrulama doğruluk sonuçlarının diğer ağ modellerinden daha yüksek olduğunu göstermiştir.

Geetharamani ve Pandian (2019) çalışmalarında derin evrişimsel sinir ağına dayalı bir bitki yaprağı hastalığını tespit etme modeli önermişlerdir. Önerilen model, 39 farklı bitki yaprağı sınıfı ve arka plan görüntüsü içeren açık bir veri seti kullanılarak eğitilmiş ve çalışma sonucunda %96,46 oranında sınıflandırma doğruluğuna ulaşılmıştır.

Too, Li, Sam ve Liu (2019) tarafından yapılan çalışmada, görüntü tabanlı bitki hastalıklarının tanımlanmasında ve sınıflandırılmasında kullanılan derin evrişimli sinir ağların ince ayarı ve değerlendirilmesi amaçlanmıştır. PlantVillage veri seti kullanılarak Visual Geometry Group (VGG) net, Inception V4, ResNet ve DenseNet gibi farklı derin ağ mimarilerinin performansları değerlendirilmiştir. Önerilen yaklaşımda; karpuz, portakal, mısır, üzüm, kiraz ve yaban mersini yapraklarının görüntü verileri kullanılmıştır. Çalışma sonucunda DenseNet, %99,75 test doğruluğu ile en iyi performans gösteren model olmuştur.

Mohanty, Hughes ve Salathé (2016) halka açık bir veri seti kümesi kullanarak, derin evrişimsel sinir ağı ile 14 mahsul türünü ve 26 hastalığı tanımlayan bir çalışma önermişlerdir. Çalışma sonucunda eğitilen model %99,35 oranında yüksek bir doğruluk göstermiştir. Ayrıca önerilen model, çevrimiçi kaynaklardan alınan (Bing Image Search and IPM Images) bir dizi görüntü üzerinde de test edilmiş ve %31,4'lük bir başarı sağlanmıştır.

Sardogan, Tuncer ve Ozen (2018) çalışmalarında bitki hastalıklarını otomatik olarak sınıflandırmak ve hastalık belirtilerini tespit edebilmek için Evrişimli Sinir Ağı (CNN) tabanlı bir model ve Öğrenme Vektörü Nicelme (LVQ) algoritması tabanlı bir yöntem sunmuşlardır. Çalışmada, 500 adet domates yaprağı görüntüsü içeren veri seti ile testler yapılmıştır. Çalışma sonucunda önerilen yöntemin dört farklı domates yaprağı hastalığını başarılı bir şekilde tespit edebildiği görülmüştür.

Lin ve diğerleri (2019), matris tabanlı evrişimli sinir ağı (M-bCNN) ile birlikte birleşik evrişimli sinir ağı kullanarak buğday yaprağı üzerinde yaprak hastalıklarının sınıflandırmasına ilişkin bir çalışma gerçekleştirmişlerdir. Önerilen yaklaşımda, M-bCNN ile %90,'lik test doğruluğuna ulaşılmıştır.

Kılıç, Ecemiş ve İlhan (2021), narenciye ağaçlarındaki yaprak görüntüleri üzerinden hastalıkların tespit edip, sınıflandırılmak için evrişimli sinir ağına dayalı bir çalışma önermişlerdir. Hastalıkların sınıflandırılması için öğrenme aktarımı kapsamında test edilen AlexNet ve VGG16 ağ mimarileri, oluşturulan özel bir ESA model ile karşılaştırılmıştır. Çalışmada tasarlanan ESA modeli ile %82 doğruluk oranı elde edilirken, öğrenme aktarımı sonucunda %92'in üzerinde bir sonuca ulaşılarak, öğrenme aktarımı yöntemiyle eğitilen ağlardan daha yüksek başarımlar elde edildiği görülmüştür.

Pardede, Suryawati, Sustika ve Zilvan (2018), çalışmalarında el yapımı özellikler ve veri etiketlemesi gerektirmeyen evrişimli otomatik kodlayıcı kullanarak denetimsiz bir öznetelik öğrenme algoritması ile bitki hastalıklarını tespit etmeye çalışmışlardır. Çalışma Plantvillage veri setindeki mısır ve patates bitkilerinden elde edilen veriler ile gerçekleştirilmiş ve önerilen yöntemin geleneksel otomatik kodlayıcılara göre daha iyi performans gösterdiği sonucuna ulaşılmıştır.

Durmus, Gunes ve Kirci (2017), derin öğrenme algoritmalarını kullanarak tarlalarda ve seralarda yetişen domates bitkisindeki hastalıkları tespit etmeyi amaçlayan bir çalışma gerçekleştirmişlerdir. Çalışmada PlantVillage veri setindeki domates yaprak görüntüleri AlexNet ve SqueezeNet derin öğrenme yöntemleri ile test edilmiştir. AlexNet' in %95,65 doğruluk oranıyla, SqueezeNet' ten (%94,3) daha iyi başarımlar elde ettiği görülmüştür.

Gandhi, Nimbalkar, Yelamanchili ve Ponkshe (2018), mobil bir uygulama ile bitki yaprağı görüntülerinden hastalıkların tanımlanmasına yönelik bir çalışma gerçekleştirmişlerdir. Çalışmada, mevcut sınırlı sayıda ki görüntü verisini arttırmak için GAN, sınıflandırma işlemi için ise CNN modelinden yararlanılmıştır.

Atila, Uçar, Akyol ve Uçar (2021) çalışmalarında, bitki hastalıklarının tespiti için derin öğrenme modellerini kullanmışlardır. Çalışmada PlantVillage veri setindeki 39 sınıf bitkinin yaprak görüntüleri EfficientNet derin öğrenme mimarisi ile sınıflandırılmıştır. Çalışmada önerilen model diğer derin öğrenme modelleri ile karşılaştırıldığında EfficientNet mimarisinin, AlexNet, ResNet, VGG16 ve Inception V3 ağlarından daha iyi sonuç verdiği gözlenmiştir.

Joshi, Kaushik, Dutta, Srivastava ve Choudhary (2021), derin öğrenme algoritmalarını kullanarak bitkilerde viral enfeksiyon hastalıklarının tespiti yönelik bir çalışmada gerçekleştirmişlerdir. Vigna mungo isimli baklagil bitkisine ait yaprak görüntü veri seti Evrişimli Sinir Ağı (CNN), VirLeafNet modeli ile eğitilmiş ve önerilen yöntemle %97,4 sınıflandırma doğruluğuna ulaşılmıştır.

Luna, Dadios ve Bandala (2018), domates bitkisi hastalıklarının tespiti için yenilikçi bir çözüm geliştirdiklerini iddia etmektedirler. Domates bitkisi yapraklarının 4.923 görüntüsünden oluşan bir veri kümesini kullanarak, “Phoma Rot”, “Leaf Miner” ve “Target Spot” türü üç hastalığı belirlemek için derin bir evrişimli sinir ağı eğittiler. Transfer öğrenme ile eğitilen ağdan elde edilen öznitelikler domates hastalıklarından hangisinin olduğunu belirlemek için kullanılmış ve modelin %95,75 doğruluk sağladığı ifade edilmiştir.

Jiang, Chen, Liu, He ve Liang (2019) GoogLeNet Inception yapısı ve Rainbow birleştirme modellerini tanıtarak derin CNN'leri kullanan yeni bir elma yaprağı hastalığı tespit modeli önermiştir. Çalışmada önerilen yeni INAR-SSD adlı derin evrişim sinir ağı modeli, 26.377 adet hastalıklı yaprak görüntüsünden oluşan veri setine uygulanmıştır. Deneysel sonuçlar %78.80 hastalık algılama performansı gerçekleştirdiğini göstermektedir.

Fujita, Kawasaki, Uga, Kagiwada ve Iyatomi (2016), salatalık yapraklarındaki sağlıklı ve viral hastalık tarafından enfekte olmuş yedi tür hastalık görüntüsü içeren veri seti ile bitki hastalıklarını tespit etmeyi amaçlayan bir çalışma önermişlerdir. Çalışmada, dört katlı çapraz doğrulama stratejisi altında evrişimli sinir ağı sınıflandırma sistemi ile %82,3'lük bir başarımla elde edilmiştir.

Hernández ve López (2020), bitki hastalıklarının tespitinde bayes derin öğrenme tekniğine dayalı olasılıksal bir programlama metodolojisi önermişlerdir. Çalışma sonuçları, yöntemin bitki hastalıklarını tespit etmede tipik optimizasyon yaklaşımlarıyla karşılaştırılabilir sınıflandırma performansına sahip olduğunu göstermiştir.

Ferentinos (2018), bitki hastalıklarının teşhis edilmesinde derin öğrenme metodolojisi olan evrişimli sinir ağı modeline dayalı bir çalışma gerçekleştirmiştir. Çalışmada sağlıklı ve

hastalıklı 25 farklı bitki görüntüsü içeren açık bir veri tabanı kullanılmıştır. Sınıflandırmada en başarılı model mimarisi %99.53'lük başarı oranı ile VGG evrişimli sinir ağı modeli olmuştur. Bu yüksek başarı oranı ile evrişimli sinir ağı modellerinin basit yaprak görüntülerindeki bitki hatalıklarını tespit etmede kullanışlı metotlar olduğu ifade edilmiştir.

Özcan ve Dönmez (2021), biber bitkisi yaprak görüntüleri üzerinde derin öznitelik çıkarımı yaparak bakteri tabanlı hastalık tespit yöntemi önermişlerdir. Çalışmalarında PilantVillage veri-seti olarak toplamda 2475 adet olmak üzere, 1478 adet sağlıklı ve 997 adet bakteri hastalıklı yaprak görüntüleri kullanılmıştır. Derin öznitelik çıkarımı için DarkNet-19 CNN modeli kullanmıştır. Dört farklı sınıflandırıcıda öznitelikleri hem varsayılan haliyle hem de PCA ile boyut indirgemek suretiyle kullanmak üzere test ettiler. Sınıflandırma başarımları ise %98.8 olarak ifade edilmiştir

Bansal, Kumar ve Kumar (2021) tarafından yapılan çalışmada, elma ağaçlarındaki yaprak hastalıklarının tespit edilebilmesi amaçlanmış ve çalışmada önceden eğitilmiş DenseNet121, EfficientNetB7 ve EfficientNet NoisyStudent derin öğrenme modelleri kullanılmıştır. Önerilen yöntemde elma meyvesine ait yaprak görüntüleri; sağlıklı, elma kara leke hastalığı, sedir elma pası hastalığı ve çoklu hastalıklar olmak üzere dört kategoride sınıflandırılmıştır. Çalışma sonucunda %96,25'lik bir doğruluk oranına ulaşılmıştır.

3. PROBLEM TANIMI VE ÖN-BİLGİ

3.1. Problemin Durumu

Bu çalışmanın kapsamı, bilgisayar destekli tarım analizi sistemleri ile bitki hastalıkları tespitinin yapılmasına dayanmaktadır. Tarımsal analizde öne çıkan bir sac ayağı olarak bitkilerde hastalık tespiti genellikle bir zirai uzmanın gözlemlemesi yoluyla yapılmaktadır. Bilgisayar destekli sistemlerle bu hastalık tespiti işlemi yapay öğrenme yöntemleriyle daha hızlı ve verimli bir şekilde gerçekleştirilebilmektedir.


3.2. Araştırmanın Amacı

Bu çalışmada amaç, ülkemizde üretimi de yoğun bir şekilde gerçekleştirilen kiraz bitkisine ait bakteriyel hastalığın yaprak görüntülerinden elde edilen derin öznitelikleri kullanarak yapay öğrenme yaklaşımlarıyla tespitini gerçekleştirmektir. Bu amaç doğrultusunda bitkiye erken müdahale ile üretim verimliliğinin de geliştirileceği öngörülmektedir.

4. MATERİYAL VE YÖNTEM

4.1. Veri Seti

Toplamda 1906 farklı kiraz yaprağı imgesini içeren veri-setinde veriler zirai uzman tarafından üç grup olarak etiketlenmiştir. Bu etiketler “sağlıklı”, “az hastalıklı” ve “çok hastalıklı” şeklindedir. Sağlıklı veriler 854 adet, az hastalıklılar 537 adet ve hastalıklılar ise 515 adettir. Verilerle ilgili az ve çok hastalıklı yaprak imgelerini etiketlemede zirai bir uzmandan yardım alınmıştır. Veri-setinden örnek bir kesit aşağıda Resim 4.1’de verilmiştir.




Resim 4.1. Veri-setinden örnek yaprak görüntüleri

4.2. Derin Öznitelikler

Geleneksel yöntemlerde eldeki veri üzerinde veriyi en iyi biçimde betimleyen ve temsil eden vektörel büyüklüklerin (bir görüntüdeki köşe noktaları, renk, doku vb. temsil edebilen bir grup sayısal değer) hesaplanması gerçekleştirilir. Bu hesaplama işleminde üçüncü parti SURF, SIFT, FAST vb. yöntemler kullanılmaktadır. Derin öznitelikler ise evrimsel sinir ağ modellerinin tam bağlı katmanlarından elde edilmektedirler. Bu öznitelikler ise analiz edilen verileri en iyi temsil eden vektörel büyüklüklere karşılık gelmektedir. Bu öznitelikler girdi verilerinin derin öğrenme ağının hiyerarşik her bir katmanında farklı

konvolüsyon vb. işlemlere tabi tutularak çıktı katmanlara tutarlı değerler sağlarlar. Çalışma kapsamında DarkNet-19 evrişimsel sinir ağı modeli (Redmon ve Farhadi, 2016) kullanılmıştır. Aşağıdaki Şekil 4.1’de DarkNet-19 mimarisi gösterilmektedir.



Şekil 4.1. DarkNet-19 (YoloV2) Architecture


4.3. Ön-eğitilmiş Evrişimsel Sinir Ağı Modelleri

Derin öğrenme, yüksek-boyutlu (high-dimensional) verilerden özellikler çıkaran ve girdiler ile çıktılar arasında bu özellikler vasıtasıyla ilişki kuran makine öğrenmesinin bir alt dalıdır (Dandıl ve Serin, 2020: 455). Derin öğrenme içerisinde çok sayıda sınıflandırma modeli bulunmaktadır ve farklı birçok alanda uygulanmaktadır. Evrişimsel Sinir Ağları (ESA) ise derin öğrenme modelleri arasında en yaygın kullanılan ağ modellerinden biridir.

Evrişimsel sinir ağları (CNN-Convolutional Neural Network) bilgisayarlı görü, video ve ses uygulamalarında veri kümeleri üzerinden özellik çıkarma ve sınıflandırma amacıyla geliştirilmiş çok katmanlı yapay sinir ağı modelleri olarak ifade edilmektedir. (Girshick, Donahue, Darrell ve Malik, 2014). ESA, yüksek doğruluk ile çalışması ve biyolojik temellere dayanması sebebiyle gelişmiş mimariye sahip birçok ESA modeli ortaya çıkmış ve son 10 yılda görüntü tanıma, ses tanıma, tıbbi tanı, doğal dil işleme ve sınıflandırma gibi alanlarda yaygın bir şekilde kullanılmıştır. İlk başarılı ESA modeli 1989 yılında LeCun ve ekibi (1989) tarafından geliştirilmiştir. Evrişimsel sinir ağı modeli Le-Net 5 ile ilk kez el yazısıyla posta kodu tanıma ve banka çekleri üzerindeki sayıların okunması üzerine çalışmalar yapılmıştır (LeCun ve diğerleri, 1989). ESA, ilgili özellikleri herhangi

bir insan denetimi olmaksızın tespit edebilen ve büyük miktarda veri ile çalışabilen güçlü bir ağıdır.

ESA, klasik sinir ağlarından farklı olarak evrişim özellik çıkarma ve sınıflandırma katmanları içeren bir yapıdan oluşmaktadır. Bir ESA mimarisi; evrişim, aktivasyon, havuzlama ve tam bağlı olmak üzere dört katmandan oluşmaktadır ve yüksek boyuttaki verilerden düşük boyutlu öznitelikler çıkarmaktadır. Bu katmanlardan elde edilen öznitelikler ile herhangi bir sınıflandırıcı kullanılarak sınıflandırma işlemi gerçekleştirilmektedir (Anthimopoulos, Christodoulidis, Ebner, Christe ve Mougiakakou, 2016: 1209). Bir ESA mimarisinin genel yapısı Şekil 4.2’de gösterilmektedir.



Şekil 4.2. Evrişimsel Sinir Ağı Mimarisi (CNN) (Kang, Song ve Sun, 2019)


Sistem üzerinde ön-eğitilmiş ESA modelleri farklı veri kümelerine uygulanarak sınıflandırma başarısı artırılabilir. Ön-eğitilmiş bazı ESA mimarileri aşağıda ifade edilmiştir.

4.3.1. GoogleNet (Inception V1)

GoogLeNet, derin evrişimli sinir ağı Inception Network’ün bir türevi olarak geliştirilmiş, 22 katmanlı yüksek doğruluk oranı ile sınıflandırma yapabilen bir evrişimsel sinir ağı mimarisidir (Alake, 2020). Hebbian ilkesine dayalı boyut azaltma katmanları ve çok ölçekli işlemenin sezgisine dayandırılmış bir başlangıç mimarisi (Inception modules) olarak tanımlanmaktadır (Szegedy ve diğerleri, 2015). Model 2014 yılında Szegedy ve arkadaşları

tarafından önerilmiştir ve ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ILSVRC14), görüntü sınıflandırma ve nesne algılama gibi bilgisayarla görme görevlerini çözerek 5,7 hata oranı ile birincilik ödülü almıştır (Szegedy ve diğerleri, 2015).

GoogleNet ağının her bloğu Inception bloğu olarak adlandırılmaktadır. GoogleNet ağ mimarisi içerisindeki havuzlama katmanından önce ekstra bir doğrusal katman kullanılmaktadır. Yani modeldeki 3×3 evrişim katmanlarından önce 1×1 evrişimli filtre ile girdi yığınınındaki özellik haritalarının sayısı azaltılmak istenmiştir. Böylece filtrelerin genişliği ve derinliği artırılmıştır. Boyut azaltma işlemi gerçekleştirilerek daha hızlı bir eğitim sağlanmış ve aynı zamanda hesaplama maliyetine neden olan toplam parametre sayısı arttırılmadan bellek yükü önemli ölçüde azaltılmıştır. Hesaplama yükünü azaltmak amacıyla 3×3 ve 5×5 evrişim katmanlarından önce fazladan 1×1 evrişim katmanı eklenerek oluşturulan boyut küçültmeli başlangıç modülü Şekil 4.3'de gösterilmektedir.



Şekil 4.3. Boyut azaltmalı başlangıç modülü (Szegedy ve diğerleri, 2015: 4)

GoogleNet mimarisinde; dokuz başlangıç modülü, iki evrişim katmanı, boyut küçültme için bir evrişim katmanı, iki normalleştirme katmanı, dört maksimum havuzlama katmanı, bir ortalama havuzlama, bir tam bağlantılı olmak üzere yaklaşık 6,8 milyon parametre bulunmaktadır (Mehdipour Ghazi, Yanikoglu ve Aptoula, 2017: 239). Her başlangıç modülü sırayla iki evrişim katmanı, boyut küçültme için dört evrişim katmanı ve bir maksimum havuzlama katmanına sahiptir ve tüm evrişim katmanlarında ReLU

etkinleştirme işlevi uygulanmaktadır (Mehdipour Ghazi, Yanikoglu ve Aptoula, 2017: 239).

Bu mimaride genel olarak, konvolüsyon ve havuzlama katmanlarını üst üste istiflemekten uzaklaşmak için paralel olarak birbirine bağlı modüller kullanılmıştır. Bu sayede katmanların hepsini yığınlamak ve çok sayıda filtre kullanmanın neden olduğu hesaplama ve bellek maliyetlerinin ve modelin ezberleme olasılığının önüne geçilmiştir. GoogleNet ağ mimarisinin yapısı Şekil 4.4’de gösterilmektedir.




Şekil 4.4. GoogleNet Ağ Mimarisi (Szegedy ve diğerleri, 2015)

4.3.2. ResNet

ResNet (Residual Networks), 2015 yılında He ve arkadaşları (2015) tarafından, “Deep Residual Learning for Image Recognition” makalesinde önerilmiş atlamalı blok yapısına sahip bir evrimsel sinir ağı modelidir. ResNet bir veya daha fazla katmanı atlayan "kimlik kısayolu bağlantısı" adı verilen bir bağlantı yapısına sahiptir (Feng, 2017). Modelin ana fikri, çok derin ağların eğitimini kolaylaştırmak için artık öğrenme çerçevesine dayanmaktadır (Tai, Yang ve Liu, 2017: 2791).

ResNet mimarisi, 2015 yılında 3,6 hata oranı ile ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında birinci olmuştur. Diğer ESA'lara nispeten daha derin olsa da düşük karmaşıklığa sahip basit ve düz yapıda bir modeldir. 152 katmandan oluşan model, derin sinir ağların başarılı bir şekilde eğitilmesini sağlamaktadır.

ResNet modelinde giriş değeri olan x , $F(x)$ fonksiyonuna aritmetik ekleme işlemi uygulanarak haritalanmakta ve katman girişini x 'i toplama operatörüne taşıyan çizgi artık bağlantı (veya kısayol bağlantısı) olarak ifade edilmektedir (Zhang, Lipton, Li ve Smola, 2021). Bu sayede artık bloklar girdiler, katmanlar arasında kalan bağlantılar aracılığıyla daha hızlı yayılmakta ve geçmiş katman bilgileri ileri katmanlara etkin bir şekilde iletilebilmektedir. Şekil 4.5'teki görselde ResNet artık bloğu sunulmuştur.



Şekil 4.5. Normal ve artık blok yapısı (Zhang ve diğerleri, 2021: 289)

4.3.3. DarkNet

DarkNet, C ve CUDA ile yazılmış derin öğrenme modellerinde kapsamlı şekilde kullanılabilen açık kaynaklı bir sinir ağıdır. DarkNet mimarisi, YOLOv2 temelinde geliştirilmiş, gerçek zamanlı nesne tespitinde iyi bir performans gösteren bir modeldir.

Bu çalışma kapsamında, derin özniteliklerin çıkarılmasında DarkNet-19 ön-eğitilmiş evrişimsel sinir ağı modeli (Redmon ve Farhadi, 2016) kullanılmıştır. DarkNet-19 mimarisi, 19 evrişim katmanı ve 5 maksimum havuzlama (maxpool) katmanı olan, GoogleNet ile benzer ağ yapısına sahip evrişimli bir sinir ağı modelidir (Yang, Li ve Li, 2018: 180). Modelde, ağa girdi olarak 256x256 boyutlu görüntüler verilmektedir ve VGG modeli ile benzer şekilde 3x3 filtre ile çalışmaktadır. Aynı zamanda Darknet, ResNet'e benzer bir şekilde daha ince özellikler eklemek için yüksek çözünürlüklü özellikleri düşük çözünürlüklü özelliklerle birleştiren bir geçiş katmanı kullanmaktadır (Yang ve diğerleri, 2018: 181). DarkNet-19 modelinin iç katman yapısı Çizelge 4.1'de gösterilmektedir.


Çizelge 4.1. DarkNet-19 Yapısı (Redmon ve Farhadi, 2016: 6)

Type	Filters	Size/Stride	Output
Convolutional	32	3 × 3	224 × 224
Maxpool		2 × 2/2	112 × 112
Convolutional	64	3 × 3	112 × 112
Maxpool		2 × 2/2	56 × 56
Convolutional	128	3 × 3	56 × 56
Convolutional	64	1 × 1	56 × 56
Convolutional	128	3 × 3	56 × 56
Maxpool		2 × 2/2	28 × 28
Convolutional	256	3 × 3	28 × 28
Convolutional	128	1 × 1	28 × 28
Convolutional	256	3 × 3	28 × 28
Maxpool		2 × 2/2	14 × 14
Convolutional	512	3 × 3	14 × 14
Convolutional	256	1 × 1	14 × 14
Convolutional	512	3 × 3	14 × 14
Convolutional	256	1 × 1	14 × 14
Convolutional	512	3 × 3	14 × 14
Maxpool		2 × 2/2	7 × 7
Convolutional	1024	3 × 3	7 × 7
Convolutional	512	1 × 1	7 × 7
Convolutional	1024	3 × 3	7 × 7
Convolutional	512	1 × 1	7 × 7
Convolutional	1024	3 × 3	7 × 7
Convolutional	1000	1 × 1	7 × 7
Avgpool		Global	1000
Softmax			

4.3.4. NASNet

Neural Architecture Search Network (NASNet), 2018 yılında ilk olarak küçük bir görüntü veri setini (CIFAR-10) kategorize etmek için yüksek performansa sahip bir yapı taşı olarak


Google ekibi tarafından geliştirilmiştir (Martínez, Martínez ve Jacinto, 2020: 664). Daha sonrasında model daha kapsamlı veri seti olan ImageNet için genişletilmiştir. Böylelikle yüksek sınıflandırma kapasitesine ve azaltılmış parametreye sayısına sahip bir model ortaya çıkmıştır (Martínez ve diğerleri, 2020:664). CIFAR-10 ve ImageNet için oluşturulan model mimarileri Şekil 4.6’da sunulmuştur.



Şekil 4.6. CIFAR-10 ve ImageNet için Model Mimarisi (Zoph, Vasudevan, Shlens ve Le, 2018)

Bu model, mimari yapıları optimize etmek için yeniden güçlendirme ve öğrenme arama yöntemlerinden yararlanan nöral ağ mimarisi olarak tanımlanmaktadır (Zoph, Vasudevan, Shlens ve Le, 2018: 8697). Modelde, mimari yapılandırmaları optimize etmek için pekiştirmeli öğrenme yaklaşımı ve optimal sinir mimarisini bulmak için ise Tekrarlayan

Sinir Ağı (RNN) kullanılmaktadır (Osajima, 2019: 22). RNN bunun için, ilk olarak farklı mimarilere sahip ağlar örneklemekte, ardından bu alt ağları yakınsama için eğilmekte ve doğrulama veri kümesinden doğrulukları elde edilerek model parametrelerini oluşturmaktadır (Osajima, 2019: 22). NASNet arama alanının şematik diyagramı Şekil 4.7’de gösterilmektedir.



Şekil 4.7. NASNet arama alanının şematik diyagramı (Zoph ve diğerleri, 2018)

4.4. Sınıflandırıcı Yöntemleri

Bu amaçla söz konusu uygulamaların tespit işlemlerinde kullanılan sınıflandırma algoritmaları etiketli verilerle eğitilirler. Eğitim aşamasında bu sınıflandırıcılarda her bir veri işleme iterasyonunda verilerden üzerinde belirli ağırlıklara sahip vektör (öznitelik) parametreleri hesaplanmaktadır ve önceki değerler güncellenmektedir. Daha sonra sistemde yeni gelen verinin veri özniteliklerini çıkartılmaktadır. Eğitimli sınıflandırıcı algoritması kendi güncel parametreleriyle yeni gelen verinin öznitelik parametrelerini karşılaştırarak bu yeni verinin ilgili sınıf bilgisini belirlemektedir. Çalışma kapsamında LDA, KNN ve SVM sınıflandırıcı yöntemleri kullanılmıştır.

Sınıflandırma performanslarını ölçmek amacıyla kullanılan performans metrikleri eşitlik (4.1), (4.2) ve (4.3)’ te verilmiştir.

$$Doğruluk = \frac{DP + DN}{(DP + YP + YN + DN)} \quad (4.1)$$

$$Duyarlılık = \frac{DP}{DP + YN} \quad (4.2)$$


$$Özgünlük = \frac{DN}{DN + YP} \quad (4.3)$$

4.4.1. LDA sınıflandırıcı

Lineer Ayırıklık Analizi (LDA) (atıf), sınıflandırma ve boyut indirgeme için kullanılan doğrusal bir modeldir. En yaygın olarak örüntü sınıflandırma problemlerinde öznitelik çıkarımı için kullanılır. LDA, sınıflar arasındaki değişkenliği en üst düzeye çıkaracak ve sınıflar içindeki değişkenliği azaltacak şekilde verileri D boyutlu bir özellik alanından bir D' (D>D') boyutlu uzaya yansıtır.

LDA, veriler hakkında bazı basitleştirici varsayımlarda bulunur. İlk varsayım, verilerin Gauss olduğu, her değişkenin çizildiğinde bir çan eğrisi gibi şekillendirildiğidir. İkincisi ise, her özelliğin aynı varyansa sahip olması, her değişkenin değerlerinin ortalama etrafında ortalama olarak aynı miktarda değişmesidir. Bu varsayımlarla, LDA modeli her sınıf için verilerinden ortalama ve varyansı tahmin eder. Bunu iki sınıflı tek değişkenli (tek girişli değişken) durumuna göre tasarlamak basittir. Çalışma kapsamında LDA sınıflandırıcısı için 'Doğrusal' kernel fonksiyonu kullanılmıştır. (Witten, 2001: 236).

LDA: Sınıf ayrımı için bileşen eksenlerini maksimize eder.



Şekil 4.8. Genel bir LDA yapısı

Şekil 4.8’de de görüldüğü üzere LDA ile maksimum bileşenin elde edilmesi amaçlanır. Minimum bileşen şekilden de anlaşılabacağı üzere kötü projeksiyon (izdüşüm) yaptığından sınıfların ayrıştırılması çok zor bir hal alır. Bileşenin maksimize edilmesiyle birlikte iyi bir projeksiyon elde edilir ve sınıflar çok rahat biçimde ayrılabilir.

Lojistik regresyon, basit ve güçlü bir doğrusal sınıflandırma algoritmasıdır. Ayrıca alternatif doğrusal sınıflandırma algoritmalarına ihtiyaç olduğunu gösteren sınırlamaları vardır.


- İki Sınıflı Problemler. Lojistik regresyon, iki sınıflı veya ikili sınıflandırma problemlerine yöneliktir. Çok sınıflı sınıflandırma için genişletilebilir, ancak bu amaç için nadiren kullanılır.
- İyi Ayrılmış Sınıflarla Kararsız. Sınıflar iyi ayrıldığında lojistik regresyon kararsız hale gelebilir.
- Birkaç Örnekle Kararsız. Parametreleri tahmin etmek için birkaç örnek olduğunda lojistik regresyon kararsız hale gelebilir.

Lineer Diskriminant Analizi, bu noktaların her birini ele alır ve çok sınıflı sınıflandırma problemleri için doğrusal bir yöntemdir. İkili sınıflandırma problemlerinde bile hem lojistik regresyon hem de doğrusal diskriminant analizini denemek iyi bir yoldur.

4.4.2. En yakın komşu (KNN)

K-En Yakın Komşu (K-Nearest Neighbor - KNN) yöntemi (Guo, 2003) sınıflandırma ve regresyon için kullanılan en temel gözetimli ve parametrik olmayan yöntemlerden biridir. Veri dağılımı ile ilgili az ya da hiçbir ön bilginin olmadığı durumlarda kullanılmaktadır. En yakın komşu yöntemi ortama gelen yeni bir verinin eğitim vektörleri aracılığı ile mevcut sınıflardan hangisine girdiğini tespit etmede kullanılmaktadır.

KNN, bir gözlemin en yakın komşularına bakarak gözlemin en büyük oranda hangi sınıfa ait olduğunu tahmin eden denetimli öğrenme algoritmasıdır. KNN algoritması, yeni bir veri noktasının sınıfını tahmin etmek için o noktanın mevcut veri noktalarına olan uzaklığını hesaplamaktadır. Temelde yeni noktaya en yakın noktalar aranmakta ve örnek veri noktasının bulunduğu sınıf ve en yakın komşu, k değerine göre belirlenmektedir. KNN algoritmasının örnek çalışma şekli Şekil 4.9'da gösterilmektedir.



Şekil 4.9. KNN algoritması çalışma prensibi (Raj, 2021)

Modelin performansını; k en yakın komşu sayısı, eşik değeri, benzerlik ölçütü etkilemektedir (Köktürk, 2009). Eğitim setindeki örnekler n boyutlu sayısal nitelikler ile ifade edilmektedir ve her örnek n boyutlu uzayda bir noktayı temsil edecek şekilde tüm eğitim örnekleri n boyutlu bir örnek uzayda tutulmaktadır (Taşcı ve Onan, 2016: 2).

Sonradan belirlenen bir örnek, eğitim setindeki kendisine en benzer komşuların k sayısına göre sınıflandırılmaktadır (Kermani, Barani ve Ghaeini-Hessaroeeyeh, 2015: 348). Tahmin edilmek istenen veri için k parametresi ile kaç komşu noktaya bakılması gerektiği belirlenmektedir. Burada, $k=1$ olduğunda sınıflandırmaya çalıştığımız örnek en yakın komşusunun bulunduğu sınıfa dahil edilmektedir (Köktürk, 2009: 15). k değeri 1'den büyük ve genelde tek sayı olarak seçilen bir tam sayıdır ve modelde sadece bir tane en büyük benzerlik değerine değil, k tane en büyük benzerlik değerine bakılmaktadır (Köktürk, 2009: 16). Modelde seçilen k en yakın komşu sayısı küçük bir değer seçilmiş ise benzerlikleri yüksek olan örnekler aynı sınıfta yer almakta, eğer k değeri büyük seçilmiş ise birbirine benzemeyen örneklerin aynı sınıfta olması hatası ortaya çıkabilmektedir (Köktürk, 2009: 16).

Modelde ilk olarak eğitim ve test verileri arasındaki mesafe hesaplanmaktadır (Kermani, Barani ve Ghaeini-Hessaroeeyeh, 2015: 348). Bunun için uygun mesafe ölçüsü seçimi oldukça önemlidir. Burada tahmin edilecek örnekler arası yakınlıklar için çeşitli uzaklık ölçütleri kullanılabilir. KNN algoritmasında mesafeleri hesaplamak için kullanılan bazı farklı mesafe ölçütleri aşağıda ifade edilmiştir (Albon, 2018).

- **Öklid Mesafesi:** Öklid uzayında iki nokta arasındaki doğrusal uzaklığın hesaplanmasıdır.

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.4)$$

- **Manhattan mesafesi:** İki nokta arasındaki mesafenin 90 derecelik açı ile ölçüldüğü mesafedir.

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (4.5)$$


- **Minkowski mesafesi:** normalleştirilmiş bir vektör uzayında tanımlı iki nokta arasındaki uzaklığı ölçmektedir.

$$d(x, y) = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (4.6)$$

4.4.3. Destek vektör makineleri (SVM)

Destek vektör makinasının temelleri Cortes ve Vapnik'in yapmış olduğu çalışmalara dayanmaktadır. Yıllar içerisinde geliştirilerek istatistiksel öğrenme algoritması ile asıl başarıları uygulamaları 1990'lı yıllarda ortaya çıkmıştır. İlk olarak 1992 yılında Vladimir Vapnik ve çalışma arkadaşları tarafından COLT (Computational Learning Theory) konferansında önerilmiştir. Bugünkü şekline en yakın hali ise Cortes ve Vapnik'in (1995) 1995 yılında yaptığı çalışma ile ortaya konmuştur. İlerleyen yıllarda Cortes ve Vapnik çalışmalarını genişleterek bu algoritmayı regresyon problemleri için de uygulamışlardır.

Destek Vektör Makineleri (DVM) (Zanaty, 2012) iki sınıflı sınıflandırıcılardır. SVM'ler ile çok sınıflı sınıflandırma yapmak için en yaygın teknik, $|C|$ bire karşı-hepsi sınıflandırıcıları (genellikle "hepsine karşı bir" veya OVA sınıflandırması olarak adlandırılır) oluşturmak ve test verilerini en büyük marj (margin) ile sınıflandıran sınıfı seçmektir. Diğer bir strateji, bire bir sınıflandırıcılar kümesi oluşturmak ve en çok sınıflandırıcı tarafından seçilen sınıfı seçmektir.




Şekil 4.10. DVM ağ mimarisi (S. Chen ve Yu, 2007)

DVM, sınıflar arasındaki optimal sınırları belirleyebilmek için optimizasyon algoritmalarını kullanmakta ve sınıfların ayrıldığı tüm olası sınırlar arasındaki hataları en aza indirerek sınıflar arasındaki karışıklığın azaltılmasını sağlamaktadır (Huang, Davis ve Townshend, 2002: 726). İlk olarak iki sınıflı doğrusal verilerin sınıflandırılması problemlerinde kullanılan metot, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir (Kavzoğlu ve Çölkesen, 2010: 75). Genel olarak

DVM metodu, verileri optimal olarak iki sınıfa ayıran n boyutlu bir hiper-düzlemin oluşturulması esasına dayanmaktadır (Yakut, Elmas ve Yavuz, 2014: 143). DVM ağ mimarisi Şekil 4.10'da gösterilmektedir.

DVM, “istatistiksel öğrenme teorisine” diğer bir deyişle Vapnik-Chervonenkis (VC) teorisine dayanan, örnek verileri daha yüksek boyutlu bir uzayda optimal bir hiper düzlem belirleyerek sınıflandıran bir metottur. Burada amaç, sınıfları birbirinden ayıran optimum hiper düzlemi bulmak ve sınıflar arasındaki sınırın maksimum olduğu bir hiper düzlem belirlemektir. DVM, hata oranı üst sınırının en küçük olmasını için Vapnik'in duyarsız kayıp fonksiyonu kullanılarak risk minimizasyonu ile regresyon tahmini yapmaktadır (Tay ve Cao, 2001). Ayrıca deneysel hatadan ve yapısal risk minimizasyonundan (YRM) türetilen düzenleme teriminden oluşan bir risk fonksiyonu kullanılmaktadır (Tay ve Cao, 2001). YRM makine öğrenmesinde oldukça sık kullanılan bir tümevarım yöntemidir ve bu metot aşırı uyum sorununu önlemek için kullanılmaktadır.

Optimal hiper düzlemde iki örnek sınıfa ayrılan basit bir sınıflandırma örneği Şekil 4.11'de (Nguyen Duc, Kamwa, Dessaint ve Cao-Duc, 2017: 8) gösterilmiştir. Şekil 4.11'de ki kare ve daireler iki örnek sınıfı, iki boyalı örnekler ise destek vektörleri temsil etmektedir.



Şekil 4.11. Optimum hiper düzlem ve DVM

DVM yöntemi hem doğrusal yapıda hem de doğrusal yapıda olmayan verilerin sınıflandırılmasında kullanılabilmektedir. Doğrusal olarak ayrılabilen bir sınıflandırma probleminde, karar fonksiyonu kullanılarak eğitim verisini en uygun şekilde ayırabilecek bir hiper düzlem elde edilmektedir (Kavzoğlu ve Çölkesen, 2010: 75). Doğrusal bir DVM, eşitlik (4.7)'deki gibi tanımlanmaktadır (Nguyen Duc ve diğerleri, 2017: 7)

$$f(x) = \text{sign}(w^T x + b) \quad (4.7)$$

Burada elde edilen optimal hiper düzlem giriş alanını olabildiğince maksimum marjla ayırmaktadır. Optimum hiper düzleme ait eşitlikler ise eşitlik (4.8) ve eşitlik (4.9)'da ki gibi ifade edilmektedir (Nguyen Duc ve diğerleri, 2017: 7).


$$w^T x + b > 1 \quad (4.8)$$

$$w^T x + b < -1 \quad (4.9)$$

Burada, “-1” ve “+1” sınıf etiketlerini, w ağırlık ve b eğilim değerini göstermektedir (Nguyen Duc ve diğerleri, 2017: 7). Hiper-düzlemleri oluşturan destek vektörleri ise eşitlik (4.10)'da gösterilmektedir.

$$w^T x + b = \pm 1 \quad (4.10)$$


Doğrusal olarak ayrılabilen temsili kümeye ait gösterim ise Şekil 4.12’de sunulmuştur (Kavzoğlu ve Çölkesen, 2010: 76).



Şekil 4.12. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi

Doğrusal olarak verilerin sınıflandırılmadığı durumda ise giriş uzayı doğrusal olarak ayrıştırılabilecek bir forma dönüştürülmektedir. Bunun için eğitim verilerinin optimum hiper düzlemin diğer tarafında kalmasından kaynaklanan problem için pozitif bir yapay değişken (ξ_i) tanımlanmakta ve sınırın maksimum ve yanlış sınıflandırma hatalarının minimum hale getirilmesi için pozitif değerler alan ve C ile gösterilen bir düzenleme parametresi tanımlanmaktadır (Tayyar ve Tekin, 2013: 198). Doğrusal olarak ayırım yapılamayan optimizasyon problemi için eşitlik (4.11)'deki formül kullanılmaktadır ve temsili örnek kümeye ait gösterim Şekil 4.13'de sunulmuştur (Kavzoğlu ve Çölkesen, 2010: 77).

$$\min \left[\frac{\|w\|^2}{2} + C \sum_{i=1}^r \xi_j \right] \quad (4.11)$$



Şekil 4.13. (a) Doğrusal olarak ayırlamayan veri seti ve (b) Doğrusal ayırlamayan veri setleri için hiper-düzlemin belirlenmesi.

4.4.4. Bayes sınıflandırma algoritması

Bayes sınıflandırıcısı, Thomas Bayes tarafından 1763 yılında geliştirilmiş, bayes teoremine dayanan basit olasılıksal bir sınıflandırma algoritmasıdır. Bu sınıflandırma, istatistiksel sınıflandırma teknikleri arasında hızlı ve yüksek performansı nedeniyle sıklıkla kullanılmaktadır.

Bayes teoremi, rassal bir değişkenin olasılık dağılımı içerisinde koşullu olasılıklar ile marjinal olasılıklar arasındaki ilişkiyi gösteren bir teoremdir. Bu sınıflandırma yöntemindeki amaç, veri sınıfının olasılığını tespit etmek için verilen veri sınıfının koşullu olasılıklarından yararlanmak ve eğitim kümesi içerisindeki olasılık dağılımlarından her bir sınıfın olasılığını hesaplamaktır (Erten, 2012: 59)

Bayes teoremi, n boyutlu bir uzayda tanımlı X vektörü $(x_1, \dots, x_n)$, m adet sınıfı bulunan C_k ($C_1, \dots, C_n$) veri kümesinde son olasılığı maksimize eden bir sınıf etiketi olan C ile indirgenmiş formülü eşitlik (4.12)'deki gibi ifade edilmektedir (Nizam ve Akın, 2014).

$$P(C_i|X) = P(X|C_i)P(C_i) \quad (4.12)$$

LDA modeli sınıflandırıcıda (Jia, Deng, Xin ve Liu, 2019), olasılıkları tahmin etmek için Bayes Teoremini kullanılmıştır. Her sınıfa yeni bir girdi veri kümesinin ait olma olasılığını temel alarak tahminlerde bulunurlar. En yüksek olasılığa sahip sınıf, çıktı sınıfı olarak

kabul edilir ve ardından LDA bir tahminde bulunur. Tahmin, girdi verilen çıktı sınıfının olasılığını tahmin eden Bayes Teoremi kullanılarak yapılmaktadır. Ayrıca her sınıfın olasılığı ve her sınıfa ait verilerin olasılığı kullanılmaktadır.

4.5. Öznitelik Seçici

Öznitelik seçimi, veri setindeki ilgisiz niteliklerin çıkarılması veya verilerin gürültüden temizlenmesi olarak tanımlanabilir (Bektaş ve Babur, 2016). Sınıflandırma işlemlerinde kullanılan öznitelikler sınıflandırma başarısında önemli bir etkiye sahiptir. Veri seti içerisindeki en iyi özniteliklerin seçilmesi ve bulunması modelin performansını ve eğitim süresi gibi unsurlar üzerinde önemli etkiye sahiptir. Bir modelde öznitelik sayısının az olması durumunda sınıfların düzgün olarak ayrışamaması sorunu ortaya çıkmakta ya da öznitelik sayısının fazla olması durumunda eğitim zamanının artması, gürültüsü çok olan özniteliklerin doğruluk oranını düşürmesi gibi problemler ile karşılaşmaktadır (Kaynar, Arslan, Görmez ve Işık, 2018: 177). Bu nedenle iyi seçilmiş öznitelikler sınıflandırma doğruluğunun artmasına ve istenen bir performans düzeyini elde etmek için gereken eğitim verisi miktarının azaltılmasına katkı sağlamaktadır (Forman, 2003: 1290).

Sınıflandırma başarısını arttırmak için farklı öznitelik seçme yöntemleri kullanılmaktadır. Bu çalışmada, Ding ve Peng (2005) tarafından önerilen MRMR (Minimum Redundancy Maximum Relevance) yöntemi kullanılmıştır. MRMR, sınıf ile yüksek korelasyona ve kendi aralarında düşük korelasyona sahip özellikleri seçme eğiliminde olan bir özellik seçim yaklaşımı olarak tanımlanmaktadır (Radovic, Ghalwash, Filipovic ve Obradovic, 2017: 2). MRMR, sınıf etiketiyle olan ilişkisine dayanarak en uygun özellikleri bulmaya ve özelliklerin fazlalığını en aza indirmeye çalışmaktadır (Peng, Long ve Ding, 2005). Bu filtreleme işlemi, maksimum alaka düzeyine ve minimum fazlalığa sahip özellikleri ortaya çıkarmaktadır (Alomari, Khader, Al-Betar ve Awadallah, 2018).

MRMR (Peng, Long ve Ding, 2005), genlerin ve fenotiplerin özelliklerini doğru bir şekilde tanımlamak ve alaka düzeyini daraltmak için kullanılan bir yöntemdir. Bu daraltılmış alt küme, genellikle ilgili ancak gereksiz değerler içermektedir. MRMR, alt kümelerden gereksiz parçaları kaldırarak veri temsili azaltmaktadır. MRMR yinelemeli olarak çalışmaktadır. Her yinelemede (bir kurala göre) en iyi özelliği tanımlar ve onu seçili

özellikler sepetine eklemektedir. Bir özellik, bir daha asla görünmemek üzere kümeye bir kez girmektedir MRMR, her yinelemede seçim yapılmasına izin vermektedir. Hedef değişkene göre maksimum alaka düzeyine ve önceki yinelemelerde seçilen özelliklere göre minimum fazlalığa sahip olan özellik seçim yaklaşımıdır. Uygulamada, her i yinelemesinde, değerlendirilecek her özellik (f) için bir puan hesaplanmaktadır ve eşitlik (4.13)'te ki gibi ifade edilmektedir.

$$score_i(f) = \frac{F(f, target)}{\sum_{s \in sf, i-1} \frac{|corr(f, s)|}{i-1}} \quad (4.13)$$


Bir f özelliğinin i . Yinelemedeki (veya döngüdeki) alaka düzeyi, özellik ile hedef değişken arasındaki F istatistiği olarak hesaplanmaktadır. Burada i yineleme parametresidir, f değerlendirilmekte olan özelliktir, F parametresi F istatistiğidir ve parametre düzeltmesi Pearson korelasyonudur. Denklemden de görüleceği gibi korelasyon mutlak değerde alınmalıdır.

5. DENEYLER VE GÖZLEMLER

5.1. Deney Konfigürasyonu

Deneyler 6. Nesil i7 2.6 GHz işlemci, 8GB RAM, 2GB GTX950 GPU, SSD HDD ve Windows 10 Pro konfigürasyonuna sahip bilgisayar üzerinde gerçekleştirilmiştir. Derin özniteliklerin çıkarılması amacıyla DarkNet-19 ön-eğitilmiş evrimsel sinir ağı modeli kullanılmıştır. Özniteliklerin çıkarımı ve sınıflandırma işleminin programlanması amacıyla MATLAB 2020b versiyonu kullanılmıştır. Uygulama için herhangi bir ek ayar ve optimizasyon yapılmamıştır. Benzer şekilde kullanılan veri-seti üzerinde herhangi bir ön-işlem ve iyileştirme yapılmadan doğrudan kullanım söz konusudur.

Öznitelik çıkarımı DarkNet-19 CNN modelinin tam bağlı katmanından (Fully Connected Layer) elde edilmiştir. Tam bağlı katmandan toplamda 1000 adet öznitelik elde edilmiştir. Elde edilen öznitelikler sınıflandırıcının eğitim ve test süreçlerine girdi olmak üzere 10 kat çapraz doğrulamaya göre analiz edilmiştir. Ön eğitilmiş DarkNet-19 CNN modelinde sınıflandırıcı katmanında bulunan SoftMax sınıflandırıcı kaldırılarak yerine LDA, KNN ve SVM sınıflandırıcıları kullanılmıştır, Şekil 5.1.



Şekil 5.1. Temsili CNN mimarisi modeli

LDA, KNN ve SVM sınıflandırıcıları öznitelikler ile eğitilmiş ve çapraz doğrulama ile test edilmiştir. LDA sınıflandırıcısında kovaryans yapısı tam bağlı olarak kullanılmıştır. KNN sınıflandırıcısında K komşuluk değeri 5 olarak seçilirken, uzaklık metriği 'Euclidean' ve uzaklık ağırlığı eşit olarak seçilmiştir. Bu konfigürasyon KNN-1 olarak adlandırılmıştır.

KNN sınıflandırıcısı için ikinci konfigürasyon (KNN-2) olarak komşu sayısı 10 seçilirken, uzaklık metriği yine ‘Euclidean’ seçilmiş ve uzaklık ağırlığı olarak karesel tersleme tekniği kullanılmıştır. SVM sınıflandırıcısında ise kernel fonksiyonu olarak, doğrusal (LSVM), kübik (CSVM) ve karesel (QSVM) fonksiyonlar kullanılmıştır.

Sınıflandırma başarımının değerlendirilmesi için doğruluk (ACC), duyarlılık (Precision) ve özgünlük (Recall) performans metrikleri hesaplanmıştır. Bu metriklerin hesabında karmaşıklık matrisi verileri kullanılır. Karmaşıklık matrisi, modelin başarımını ölçmek amacıyla geliştirilen modelin test seti üzerinde yapmış olduğu doğru ve yanlış tahmin sayılarını karşılaştırmamızı sağlar. Tez araştırmasında amaç, sağlıklılara göre daha yüksek bir frekansta bulunan az veya çok hastalıklı örnekleri seçmek olduğundan sağlıklı sınıflar yanında az veya çok hastalıklı sınıflarda ayrı sonuçlarda pozitif sınıf olarak ele alınmıştır. Veri setinde örneğin az hastalıklı olarak etiketli örneklerden modelin az hastalıklı olarak tahmin ettikleri doğru pozitif (TP-True Positive), modelin sağlıklı veya çok hastalıklı olarak tahmin ettikleri yanlış negatif (FN-False Negative); veri setinde sağlıklı veya çok hastalıklı olarak etiketli örneklerden modelin sağlıklı veya çok hastalıklı olarak tahmin ettikleri doğru negatif (TN-True Negative), modelin az hastalıklı olarak tahmin ettikleri yanlış pozitif (FP-False Positive) olarak isimlendirilir. Performans metriklerine ait matematiksel formüller aşağıda verilmiştir:

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + FN + TN} \quad (5.1)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (5.2)$$

$$\text{Özgünlük} = \frac{TN}{TN + FP} \quad (5.3)$$

5.2. Deney Sonuçları

Deney sonuçlarına göre, “sağlıklı”, “az hastalıklı” ve “çok hastalıklı” sınıf etiketleri için karmaşıklık matrisleri aşağıda verilen Çizelge 5.1, Çizelge 5.2 ve Çizelge 5.3 gibi elde edilmiştir. Veri-setinde her bir sınıf için ayrı karmaşık matrisleri ile çoklu sınıf problemlerinde bire karşı hepsi çalışma biçimine uygun olarak sonuçların verilmesi

amaçlanmıştır. Böylece her bir sınıfta elde edilen genel başarımlar sonuçları ortaya çıkarılmıştır.

Çizelge 5.1. Karmaşıklık matrisi (Sağlıklı)

	TP	FN	FP	TN
LDA	829	25	58	994
WKNN	841	13	43	1009
FKNN	843	11	24	1028
QSVM	839	15	6	1046
CSVM	843	11	3	1049
LSVM	835	19	2	1050

Sağlıklı olan yaprakların sınıflandırılmasında çok yüksek başarımlar elde edilmiştir. Bu yüksek başarımdaki en temel faktör sağlıklı ve hastalıklı ayrımı için CNN modelinden elde edilen özneliliklerin ayırt edicilik oranlarının yüksek olmasından kaynaklanmaktadır. Sağlıklı sınıf için genel başarımlar durumunu karakterize eden performans metrikleri aşağıdaki Çizelge 5.2’te verilmiştir.

Çizelge 5.2. Sınıflandırma performans metrikleri (Sağlıklı)

	Doğruluk (%)	Duyarlılık	Özgünlük
LDA	95,6%	0,94	0,97
WKNN	97,1%	0,96	0,98
FKNN	98,2%	0,98	0,99
QSVM	98,9%	0,99	0,98
CSVM	99,3%	1,00	0,99
LSVM	98,9%	1,00	0,98

Az hastalıklı kiraz yaprakları için karmaşıklık matrisi değerleri aşağıdaki Çizelge 5.3’te verilmiştir. Benzer biçimde karmaşıklık matrisi bir sınıfa karşı diğer kalanlar biçiminde oluşturulmuştur.

Çizelge 5.3. Karmaşıklık matrisi (Az Hastalıklı)

	TP	FN	FP	TN
LDA	345	192	151	1218
WKNN	389	148	140	1229
FKNN	389	148	144	1225

QSVM	413	124	115	1254
CSVM	419	118	123	1246
LSVM	424	113	109	1260

Yukarıdaki az hastalıklı sınıfına bağlı olarak elde edilen performans metrikleri aşağıda Çizelge 5.4’ te verilmiştir.

Çizelge 5.4. Sınıflandırma performans metrikleri (Az Hastalıklı)

	Doğruluk (%)	Duyarlılık	Özgünlük
LDA	82,0%	0,89	0,64
WKNN	84,9%	0,90	0,72
FKNN	84,7%	0,89	0,72
QSVM	87,5%	0,92	0,77
CSVM	87,4%	0,91	0,78
LSVM	88,4%	0,92	0,79

Çok hastalıklı kiraz yaprakları için karmaşıklık matrisi değerleri aşağıdaki Çizelge 5.5’ te verilmiştir. Benzer biçimde karmaşıklık matrisi bir sınıfa karşı diğer kalanlar biçiminde oluşturulmuştur.

Çizelge 5.5. Karmaşıklık matrisi (Çok Hastalıklı)

	TP	FN	FP	TN
LDA	354	161	169	1222
WKNN	367	148	126	1265
FKNN	366	149	140	1251
QSVM	411	104	122	1046
CSVM	402	113	116	1275
LSVM	421	94	115	1050

Yukarıdaki az hastalıklı sınıfına bağlı olarak elde edilen performans metrikleri aşağıda Çizelge 5.6’da verilmiştir.

Çizelge 5.6. Sınıflandırma performans metrikleri (Çok Hastalıklı)

	Doğruluk (%)	Duyarlılık	Özgünlük
LDA	82,7%	0,88	0,69
WKNN	85,6%	0,91	0,71
FKNN	84,8%	0,90	0,71

QSVM	86,6%	0,90	0,80
CSVM	88,0%	0,92	0,78
LSVM	87,6%	0,90	0,82

Deney sonuçlarına göre DarkNet-19 CNN modeli ile sağlıklı ve hastalıklı kiraz yaprağı görüntülerinden çıkarılan öznitelikler ile tatmin edici sınıflandırma başarımları yakalanmıştır. Özellikle sağlıklı bitki yaprağını tanımada başarımlar %99,3 doğruluk oranı ile kernel fonksiyonu olarak kübik fonksiyon kullanılan SVM sınıflandırıcısı tarafından sağlanmıştır. Az hastalıklı yaprakların tespitinde genel başarımlar %88,4 ile doğrusal SVM ile elde edilirken, çok hastalıklı tespitinde başarımlar %88,0 ile kübik kernel kullanan SVM sınıflandırıcısına aittir. Deneylerde herhangi bir imge ön işleme, parametre ve fonksiyon optimizasyonları yapılmamıştır. Nihai çoklu sınıf başarımları (Acc), sınıflandırma maliyetleri (Cost), tahmin hızı – obs/s (PS) ve eğitim zamanı – s (TT) parametreleri Çizelge 5.7’ de verilmiştir.

Çizelge 5.7. Tahmin edici sınıflandırma performansları

	Acc.	Cost	PS	TT
LDA	80,2%	378	2000	17,186
WKNN	83,8%	309	350	25,643
FKNN	83,8%	308	350	25,335
QSVM	87,3%	243	1700	32,169
CSVM	87,3%	242	1700	26,055
LSVM	88,1%	226	3200	14,508

Öznitelik seçimi aşamasında MRMR öznitelik seçimi yöntemi ile çeşitli öznitelik boyutlarında LDA, KNN ve SVM sınıflandırıcılarının tahmin başarımları analiz edilmiştir. Burada her öznitelik boyutu için sınıflandırma yöntemlerinin performanslarının istatistiksel olarak ölçülmesi amaçlanmıştır. 50 öznitelik için sağlıklı bitki yaprağı tespitinde elde edilen karmaşıklık matrisi ve performans metrikleri aşağıda Çizelge 5.8’de verilmiştir. 50 öznitelikle sağlıklı bitki yaprağını tanımada kübik kernel kullanan SVM sınıflandırıcısı ile %99,1’lik bir başarımlar sağlanmıştır.

Çizelge 5.8. Karmaşıklık matrisi ve Performans metrikleri – 50 Öznitelik (Sağlıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	810	44	14	1038	97,0%	0,98	0,95

WKNN	843	11	26	1026	98,1%	0,97	0,99
FKNN	836	18	25	1027	97,7%	0,97	0,98
QSVM	836	18	7	1045	98,7%	0,99	0,98
CSVM	840	14	4	1048	99,1%	1,00	0,98
LSVM	833	21	8	1044	98,5%	0,99	0,98

Benzer biçiminde 50 öznitelik için az hastalıklı sınıfına bağlı olarak elde edilen karmaşıklık matrisi değerleri ve performans metrikleri aşağıda Çizelge 5.9’da verilmiştir.

Çizelge 5.9. Karmaşıklık matrisi ve Performans metrikleri – 50 Öznitelik (Az Hastalıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	395	142	198	1171	82,2%	0,67	0,74
WKNN	397	140	163	1206	84,1%	0,71	0,74
FKNN	361	176	189	1180	80,8%	0,66	0,67
QSVM	429	108	164	1205	85,7%	0,72	0,80
CSVM	407	130	154	1215	85,1%	0,73	0,76
LSVM	371	166	133	1236	84,3%	0,74	0,69

Çok hastalıklı sınıf etiketine sahip kiraz yaprakları için 50 öznitelikli karmaşıklık matrisi değerleri ve performans metrikleri aşağıda Çizelge 5.10’da verilmiştir.

Çizelge 5.10. Karmaşıklık matrisi ve Performans metrikleri – 50 Öznitelik (Çok Hastalıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	354	161	135	1256	84,5%	0,72	0,69
WKNN	351	164	126	1265	84,8%	0,74	0,68
FKNN	331	184	164	1227	81,7%	0,67	0,64
QSVM	365	150	105	1286	86,6%	0,78	0,71
CSVM	369	146	132	1259	85,4%	0,74	0,72
LSVM	393	122	168	1223	84,8%	0,70	0,76

Sağlıklı yaprak görüntülerinin sınıflandırılmasında 100 öznitelik sayısı ile elde edilen karmaşıklık matrisi değerleri ve performans metrikleri Çizelge 5.11’de verilmiştir. Sağlıklı sınıf için genel başarımlarını karakterize eden performans metrikleri incelendiğinde kübik karnel kullanan SVM sınıflandırıcısı ile %99,0 bir başarımlar elde edildiği görülmektedir.

Çizelge 5.11. Karmaşıklık matrisi ve Performans metrikleri – 100 Öznitelik (Sağlıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	816	38	11	1041	97,4%	0,99	0,96
WKNN	842	12	24	1028	98,1%	0,97	0,99
FKNN	839	15	17	1035	98,3%	0,98	0,98
QSVM	839	15	9	1043	98,7%	0,99	0,98
CSVM	843	11	8	1044	99,0%	0,99	0,99
LSVM	827	27	9	1043	98,1%	0,99	0,97

100 öznitelik sayısı için az hastalıklı sınıfına bağlı olarak elde edilen karmaşıklık matrisi değerleri ve performans metrikleri aşağıda Çizelge 5.12’de verilmiştir.

Çizelge 5.12. Karmaşıklık matrisi ve Performans metrikleri – 100 Öznitelik (Az Hastalıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	403	134	185	1184	83,3%	0,69	0,75
WKNN	402	135	178	1191	83,6%	0,69	0,75
FKNN	377	160	175	1194	82,4%	0,68	0,70
QSVM	422	115	144	1225	86,4%	0,75	0,79
CSVM	417	120	151	1218	85,8%	0,73	0,78
LSVM	400	137	161	1208	84,4%	0,71	0,74

Benzer şekilde 100 öznitelik sayısı için çok hastalıklı sınıfa bağlı olarak elde edilen karmaşıklık matrisi değerleri ve performans metrikleri aşağıda Çizelge 5.13’de verilmiştir.

Çizelge 5.13. Karmaşıklık matrisi ve Performans metrikleri – 100 Öznitelik (Çok Hastalıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	359	156	132	1259	84,9%	0,73	0,70
WKNN	339	176	121	1270	84,4%	0,74	0,66
FKNN	342	173	156	1235	82,7%	0,69	0,66
QSVM	380	135	112	1279	87,0%	0,77	0,74
CSVM	371	144	116	1275	86,4%	0,76	0,72
LSVM	373	142	136	1255	85,4%	0,73	0,72

250 öznitelik sayısı için “sağlıklı”, “az hastalıklı” ve “çok hastalıklı” sınıf etiketleri için elde edilen karmaşıklık matrisi değerleri ve performans metrikleri Çizelge 5.14, Çizelge 5.15 ve Çizelge 5.16’da ki gibi elde edilmiştir. Sağlıklı yaprak tespitinde başarıım %99,4 ile kübik kernel kullanan SVM sınıflandırıcısına ait olduğu görülmektedir.

Çizelge 5.14 Karmaşıklık matrisi ve Performans metrikleri – 250 Öznitelik (Sağlıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	832	22	4	1048	98,6%	1,00	0,97
WKNN	848	6	28	1024	98,2%	0,97	0,99
FKNN	848	6	17	1035	98,8%	0,98	0,99
QSVM	840	14	5	1047	99,0%	0,99	0,98
CSVM	845	9	2	1050	99,4%	1,00	0,99
LSVM	833	21	4	1048	98,7%	1,00	0,98

Benzer biçimde az hastalıklı sınıfa bağlı olarak elde edilen karmaşıklık matrisi değerleri ve performans metrikleri aşağıda Çizelge 5.15’te verilmiştir.

Çizelge 5.15. Karmaşıklık matrisi ve Performans metrikleri – 250 Öznitelik (Az Hastalıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	427	110	158	1211	85,9%	0,73	0,80
WKNN	408	129	160	1209	84,8%	0,72	0,76
FKNN	394	143	143	1226	85,0%	0,73	0,73
QSVM	420	117	134	1235	86,8%	0,76	0,78
CSVM	413	124	134	1235	86,5%	0,76	0,77
LSVM	409	128	126	1243	86,7%	0,76	0,76

Çok hastalıklı sınıf için elde edilen karmaşıklık matrisi değerleri ve performans metrikleri ise aşağıda Çizelge 5.16’da verilmiştir.

Çizelge 5.16. Karmaşıklık matrisi ve Performans metrikleri–250 Öznitelik (Çok Hastalıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	373	142	112	1279	86,7%	0,77	0,72
WKNN	349	166	113	1278	85,4%	0,76	0,68
FKNN	368	147	136	1255	85,2%	0,73	0,71
QSVM	391	124	116	1275	87,4%	0,77	0,76
CSVM	390	125	122	1269	87,0%	0,76	0,76
LSVM	402	113	132	1259	87,1%	0,75	0,78

500 öznitelik sayısı ile sağlıklı yaprak görüntülerinin sınıflandırılmasında elde edilen karmaşıklık matrisi değerleri ve performans metrikleri Çizelge 5.17’de verilmiştir.

Çizelge 5.17. Karmaşıklık matrisi ve Performans metrikleri – 500 Öznitelik (Sağlıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	833	21	9	1043	98,4%	0,99	0,98
WKNN	843	11	52	1000	96,7%	0,94	0,99
FKNN	848	6	26	1026	98,3%	0,97	0,99
QSVM	837	17	3	1049	99,0%	1,00	0,98
CSVM	842	12	4	1048	99,2%	1,00	0,99
LSVM	831	23	1	1051	98,7%	1,00	0,97

500 öznitelik sayısı ile az hastalıklı yaprak görüntülerinin sınıflandırılmasında elde edilen karmaşıklık matrisi değerleri ve performans metrikleri Çizelge 5.18’de verilmiştir.

Çizelge 5.18. Karmaşıklık matrisi ve Performans metrikleri – 500 Öznitelik (Az Hastalıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	407	130	124	1245	86,7%	0,77	0,76
WKNN	390	147	128	1241	85,6%	0,75	0,73
FKNN	385	152	150	1219	84,2%	0,72	0,72
QSVM	421	116	121	1248	87,6%	0,78	0,78
CSVM	408	129	129	1240	86,5%	0,76	0,76
LSVM	425	112	114	1255	88,1%	0,79	0,79

500 öznitelik sayısı ile çok hastalıklı sınıf için genel başarımlarını karakterize eden karmaşıklık matrisi değerleri ve performans metrikleri Çizelge 5.19’da verilmiştir.

Çizelge 5.19. Karmaşıklık matrisi ve Performans metrikleri–500 Öznitelik (Çok Hastalıklı)

	TP	FN	FP	TN	ACC (%)	Precision	Recall
LDA	398	117	135	1256	86,8%	0,75	0,77
WKNN	370	145	123	1268	85,9%	0,75	0,72
FKNN	361	154	136	1255	84,8%	0,73	0,70
QSVM	405	110	119	1272	88,0%	0,77	0,79
CSVM	396	119	127	1264	87,1%	0,76	0,77
LSVM	417	98	118	1273	88,7%	0,78	0,81


Çalışmanın son kısmında öznitelik sayılarına göre elde edilen genel çok sınıflı performans parametrelerinin nihai çoklu sınıf başarımları (Acc), sınıflandırma maliyetleri (Cost), tahmin hızı – obs/s (PS) ve eğitim zamanı – s (TT) parametreleri gösterilmiştir.

Çizelge 5.20’de 50 öznitelik sayısı için genel çok sınıflı performans parametreleri verilmiştir ve kübik karesel SVM sınıflandırıcısı ile %85,5 oranla en iyi sınıflandırma başarımına ulaşılmıştır.

Çizelge 5.20. Genel çok sınıflı performans parametreleri (3 sınıfın tümü) – 50 Öznitelik

	Acc.	Cost	PS	TT
LDA	81,8%	347	42000	0,877
WKNN	83,5%	315	18000	1,054
FKNN	80,2%	378	19000	1,049
QSVM	85,5%	276	24000	1,677
CSVM	84,8%	290	24000	1,735
LSVM	83,8%	226	3200	14,508

50 öznitelik ile daha iyi sınıflandırma performansı gösteren QSVM algoritmasının ROC eğrisi Şekil 5.2’ de gösterilmiştir. ROC alanı değeri incelendiğinde 0,98 oranla ile yüksek sınıflandırma başarımına ulaşıldığı söylenebilir.




Şekil 5.2. QSVM algoritması için ROC eğrisi- 50 Öznitelik

100 öznitelik için elde edilen genel çok sınıflı performans parametreleri Çizelge 5.21’de verilmiştir. Kübik karesel SVM sınıflandırıcısı ile %86,1 oranla en iyi sınıflandırma başarımına ulaşılmıştır.

Çizelge 5.21. Genel çok sınıflı performans parametreleri (3 sınıfın tümü) – 100 Öznitelik

	Acc.	Cost	PS	TT
LDA	82,8%	328	30000	0,891
WKNN	83,1%	323	11000	1,234
FKNN	81,7%	348	12000	1,254
QSVM	86,1%	265	18000	1,750
CSVM	85,6%	275	18000	1,750
LSVM	83,9%	306	22000	1,696

100 öznitelik ile daha iyi sınıflandırma performansı gösteren QSVM algoritmasının ROC eğrisi Şekil 5.3’ de gösterilmiştir. ROC alanı değeri incelendiğinde 0,98 oranla ile yüksek sınıflandırma başarımına ulaşılmıştır.




Şekil 5.3. QSVM algoritması için ROC eğrisi- 100 Öznitelik

250 öznitelik için elde edilen genel çok sınıflı performans parametreleri Çizelge 5.22’de verilmiştir. Kübik karesel SVM sınıflandırıcısı ile %86,6 oranla en iyi sınıflandırma başarımına ulaşılmıştır.

Çizelge 5.22 Genel çok sınıflı performans parametreleri (3 sınıfın tümü) – 250 Öznitelik

	Acc.	Cost	PS	TT
LDA	85,6%	274	16000	1,342
WKNN	84,2%	301	5400	1,965
FKNN	84,5%	296	5400	1,987
QSVM	86,6%	255	10000	2,413
CSVM	86,5%	258	10000	2,428
LSVM	86,3%	262	14000	2,291

250 öznitelik ile daha iyi sınıflandırma performansı gösteren QSVM algoritmasının ROC eğrisi Şekil 5.4’te verilmiştir. ROC alanı değeri incelendiğinde 0,98 oranla ile yüksek sınıflandırma başarımına ulaşıldığı söylenebilir.




Şekil 5.4. QSVM algoritması için ROC eğrisi- 250 Öznitelik

500 öznitelik için elde edilen genel çok sınıflı performans parametreleri Çizelge 5.23'te verilmiştir. Kübik doğrusal SVM sınıflandırıcısı ile %87,8 oranla en iyi sınıflandırma başarımına ulaşılmıştır.

Çizelge 5.23. Genel çok sınıflı performans parametreleri (3 sınıfın tümü) – 500 Öznitelik

	Acc.	Cost	PS	TT
LDA	85,9%	268	7300	3,230
WKNN	84,1%	303	2700	3,689
FKNN	83,6%	312	2800	3,299
QSVM	87,3%	243	6200	4,054
CSVM	86,4%	260	6400	3,253
LSVM	87,8%	233	8800	3,579

250 öznitelik ile daha iyi sınıflandırma performansı gösteren LSVM algoritmasının ROC eğrisi Şekil 5.5' te verilmiştir. ROC alanı değeri incelendiğinde 0,97 oranla ile yüksek sınıflandırma başarımına ulaşıldığı söylenebilir.



Şekil 5.5. LSVM algoritması için ROC eğrisi- 500 Öznitelik

Çizelge 5.24'te çeşitli öznitelik sayılarıyla elde edilen genel sınıflandırıcı başarımları verilmiştir. Öznitelik sayısındaki artışa karşılık SVM tabanlı sınıflandırıcılarda sınıflandırıcı başarımları artarken LDA sınıflandırıcısında %85,9 ile en iyi başarımları 500 öznitelikle elde edilmiştir. Diğer taraftan, KNN tabanlı sınıflandırıcılarda ise en iyi başarımları 250 öznitelikle elde edilmiştir. Bu sınıflandırıcılardan WKNN ile %84,2 ve FKNN ile %84,5 oranında başarımları elde edilmiştir.

Çizelge 5.24. Öznitelik sayısına karşılık sınıflandırıcı başarımları

Öznitelik Sayısı	LDA	WKNN	FKNN	QSVM	CSVM	LSVM
50	81,8%	83,5%	80,2%	85,5%	84,8%	83,8%
100	82,8%	83,1%	81,7%	86,1%	85,6%	83,9%
250	85,6%	84,2%	84,5%	86,6%	86,5%	86,3%
500	85,9%	84,1%	83,6%	87,3%	86,4%	87,8%
1000	80,2%	83,8%	83,8%	87,3%	87,3%	88,1%

6. TARTIŞMA VE SONUÇ

Bu çalışmada hastalıklı (az, çok) ve sağlıklı bitki yapraklarını tespit etmek amacıyla kiraz bitkisi yaprak imgeleri ön-eğitilmiş DarkNet-19 CNN modeline girdi olarak verilmiş ve modelin tam bağlı katmanından imgelere ait öznitelikler elde edilmiştir. Elde edilen bu öznitelikler modelin son katmanı olan SoftMax katmanı yerine LDA, KNN ve SVM sınıflandırıcılarına verilmiştir. Yürütülen deneyler neticesinde hastalık tespitinde %88 civarında bir başarımla elde edilmiştir.

Çalışmada, çeşitli öznitelik boyutları için sınıflandırma yöntemlerinin performansları istatistiksel olarak analiz edilmiştir. Elde edilen performans metrikleri ile öznitelik sayısı arttıkça sınıflandırıcı başarımlarında aşağı veya yukarı yönlü değişim olduğu tespit edilmiştir. Bu noktada kullanılacak sınıflandırıcının ve üzerinde çalışılan veri setinin büyük önemi olduğu söylenebilir. Sınıflandırıcı başarımları öznitelik sayısındaki artışa paralel yukarı yönlü iyileşme gösterse de kabul edilebilir bir başarımla seçilmesi enerji tüketimi üzerinde pozitif bir etkiye sahiptir. Çünkü analiz edilen öznitelik sayısı ne kadar az olursa sınıflandırıcı eğitimi ve testinde harcanan enerji tüketimi de daha az olacaktır.

Geliştirilen bu sistemle hem ülkemizde hem de dünyada katma değeri yüksek bir meyve olarak yetiştirilen kiraz bitkisinde bakteriyel hastalık tespitinin yapay öğrenme yaklaşımlarıyla tespiti önerilmektedir. Bu tespit hızı ve erken yapılmasıyla önlemlerin alınması ve bu yolla kiraz yetiştiriciliğinde verimliliğin artırılmasına katkı sağlanacağı öngörülmektedir.

Dijitalleşmenin giderek yaygınlaştığı bu dönemde bu ve benzer çalışmalar ile tarımda bilgisayar destekli uygulamalar daha yaygın bir biçimde kullanılacaktır. Gelecek çalışmalarda bitki hastalıklarının birden fazla çeşidinin tanınması ve hastalık miktarının daha belirgin bir biçimde belirlenmesi planlanmaktadır. Bir sonraki aşamada ise hastalıklara karşı uygulanması önerilen iyileştirici işlemleri öneren bir sistemin geliştirilmesi amaçlanmaktadır.

KAYNAKLAR

- Alake, R. (2020). Deep Learning: GoogLeNet Explained. *Towards Data Science*. 29 Ocak 2022 tarihinde <https://towardsdatascience.com/deep-learning-googlenet-explained-de8861c82765> adresinden erişildi.
- Albayrak, A. S. ve Yılmaz, Ş. K. (2009). Veri Madenciliği: Karar Ağacı Algoritmaları ve İMKB Verileri Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 31–52.
- Albon, C. (2018). *Python Machine Learning CookBook*. O'Reilly Media. <http://proquest.safaribooksonline.com.ezproxy.lib.vt.edu/9781786464477> adresinden erişildi.
- Alomari, O. A., Khader, A. T., Al-Betar, M. A. ve Awadallah, M. A. (2018). A novel gene selection method using modified MRMR and hybrid bat-inspired algorithm with β -hill climbing. *Applied Intelligence*, 48(11), 4429–4447. doi:10.1007/s10489-018-1207-1
- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A. ve Mougiakakou, S. (2016). Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network. *IEEE Transactions on Medical Imaging*, 35(5), 1207–1216. doi:10.1109/TMI.2016.2535865
- Arivazhagan, S., Shebiah, R. N., Ananthi, S. ve Vishnu Varthini, S. (2013). Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. *Agricultural Engineering International: CIGR Journal*, 15(1), 211–217.
- Aslan, M. (2021). Derin Öğrenme ile Şeftali Hastalıklarının Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (23), 540–546. doi:10.31590/ejosat.883787
- Atila, Ü., Uçar, M., Akyol, K. ve Uçar, E. (2021). Plant leaf disease classification using EfficientNet deep learning model. *Ecological Informatics*, 61, 1–13. doi:10.1016/j.ecoinf.2020.101182
- Bansal, P., Kumar, R. ve Kumar, S. (2021). Disease detection in apple leaves using deep convolutional neural network. *Agriculture*, 11(7), 617. doi:10.3390/agriculture11070617
- Bashir, S. ve Sharma, N. (2012). Remote Area Plant Disease Detection Using Image Processing. *IOSR Journal of Electronics and Communication Engineering*, 2(6), 31–34. doi:10.9790/2834-0263134
- Bashish, D. Al, Braik, M. ve Bani-Ahmad, S. (2011). Detection and Classification of Leaf Diseases using K-means-based Segmentation and Neural-networks-based Classification. *10(2)*, 267–275.
- Bauer, S. D., Korč, F. ve Förstner, W. (2011). The potential of automatic methods of classification to identify leaf diseases from multispectral images. *Precision Agriculture*, 12(3), 361–377. doi:10.1007/s11119-011-9217-6

- Bektaş, B. ve Babur, S. (2016). Makine öğrenmesi teknikleri kullanılarak meme kanseri teşhisinin performans değerlendirilmesi. *TıpTekno"16 Tıp Teknolojileri Kongresi*, 27-29 Ekim, İstanbul, Türkiye.
- Çetiner, H. (2021). Yaprak Hastalıklarının Sınıflandırılabilmesi İçin Önceden Eğitilmiş Ağ Tabanlı Sinir Geliştirimi. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 15, 442–456. doi:10.54365/adyumbd.988049
- Chanda, M. ve Biswas, M. (2019). Plant disease identification and classification using back-propagation neural network with particle swarm optimization. *Proceedings of the International Conference on Trends in Electronics and Informatics (ICOEI)*, 1029–1036. doi:10.1109/icoei.2019.8862552
- 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, 1–11. doi:10.1016/j.compag.2020.105393
- Chen, S. ve Yu, P. (2007). Support vector networks pruning on flood forecasting and data mining. *Journal of Hydrology*, 347, 67–78.
- Chuanlei, Z., Shanwen, Z., Jucheng, Y., Yancui, S. ve Jia, C. (2017). Apple leaf disease identification using genetic algorithm and correlation based feature selection method. *International Journal of Agricultural and Biological Engineering*, 10(2), 74–83. doi:10.3965/j.ijabe.20171002.2166
- Cortes, C. ve Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20, 273–297.
- Dandıl, E. ve Serin, Z. (2020). Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 451–463. doi:10.31590/ejosat.780705
- Dhakate, M. ve Ingole, A. B. (2015). Diagnosis of pomegranate plant diseases using neural network. In *2015 fifth national conference on computer vision, pattern recognition, image processing and graphics (NCVPRIPG)*, 1–4.
- Ding, C. ve Peng, H. (2005). Minimum redundancy feature selection from microarray gene expression data. *Journal of Bioinformatics and Computational Biology*, 3(2), 185–205. doi:10.1109/CSB.2003.1227396
- Durmus, H., Gunes, E. O. ve Kirci, M. (2017). Disease detection on the leaves of the tomato plants by using deep learning. *2017 6th International Conference on Agro-Geoinformatics, Agro-Geoinformatics. IEEE*, 1–5. doi:10.1109/Agro-Geoinformatics.2017.8047016
- Erten, M. (2012). *Sınıflandırma yöntemleri kullanılarak imza biyometriğine dayalı kişi tanıma*. Selçuk Üniversitesi.
- Fadaei Kermani, E., Barani, G. A. ve Ghaeini-Hessaroeiyeh, M. (2015). Prediction of

- cavitation damage on spillway using K-nearest neighbor modeling. *Water Science and Technology*, 71(3), 347–352. doi:10.2166/wst.2014.495
- Feng, V. (2017). An Overview of ResNet and its Variants. *Towards Data Science*. 30 Ocak 2022 tarihinde <https://towardsdatascience.com/an-overview-of-resnet-and-its-variants-5281e2f56035> adresinden erişildi.
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. doi:10.1016/j.compag.2018.01.009
- Forman, G. (2003). An Extensive Empirical Study of Feature Selection Metrics for Text Classification George. *Journal of Machine Learning Research*, 3, 1289–1305. doi:10.1162/153244303322753670
- Francis, J., Anto, S. D. ve Anoop, B. K. (2016). Identification of leaf diseases in pepper plants using soft computing techniques. In *2016 conference on emerging devices and smart systems (ICEDSS)*, 168–173.
- Fujita, E., Kawasaki, Y., Uga, H., Kagiwada, S. ve Iyatomi, H. (2016). Basic investigation on a robust and practical plant diagnostic system. *Proceedings - 2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA)*, 989–992. doi:10.1109/ICMLA.2016.56
- Gandhi, R., Nimbalkar, S., Yelamanchili, N. ve Ponkshe, S. (2018). Plant disease detection using CNNs and GANs as an augmentative approach. In *2018 IEEE International Conference on Innovative Research and Development (ICIRD)*, 1–5.
- Geetharamani, G. ve Pandian, A. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers and Electrical Engineering*, 76, 323–338. doi:10.1016/j.compeleceng.2019.04.011
- Girshick, R., Donahue, J., Darrell, T. ve Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 580–587. doi:10.1109/CVPR.2014.81
- Guo, G., Wang, H., Bell, D., Bi, Y. ve Greer, K. (2003). KNN model-based approach in classification. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 986–996. doi:10.1007/978-3-540-39964-3_62
- Hassan, R. J. ve Abdulazeez, A. M. (2021). Plant Leaf Disease Detection by Using Different Classification Techniques: Comparative. *Asian Journal of Research in Computer Science*, 8(4), 1–11. doi:10.9734/ajrcos/2021/v8i430205
- Hernández, S. ve López, J. L. (2020). Uncertainty quantification for plant disease detection using Bayesian deep learning. *Applied Soft Computing Journal*, 96, 1–9. doi:10.1016/j.asoc.2020.106597

- Huang, C., Davis, L. S. ve Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725–749. doi:10.1080/01431160110040323
- Ilic, M., Ilic, S., Jovic, S. ve Panic, S. (2018). Early cherry fruit pathogen disease detection based on data mining prediction. *Computers and Electronics in Agriculture*, 150, 418–425. doi:10.1016/j.compag.2018.05.008
- Islam, M., Dinh, A., Wahid, K. ve Bhowmik, P. (2017). Detection of potato diseases using image segmentation and multiclass support vector machine. *Canadian Conference on Electrical and Computer Engineering*, 8–11. doi:10.1109/CCECE.2017.7946594
- Jhuria, M., Kumar, A. ve Borse, R. (2013). Image processing for smart farming: Detection of disease and fruit grading. *2013 IEEE 2nd International Conference on Image Information Processing (ICIIP-2013)*, 521–526.
- Jia, W., Deng, Y., Xin, C. ve Liu, X. (2019). A classification algorithm with Linear Discriminant Analysis and Axiomatic Fuzzy Sets. *Mathematical Foundations of Computing*, 2(1), 73–81. doi:10.3934/mfc.2019006
- Jiang, H., Li, X. ve Safara, F. (2021). IoT-based Agriculture: Deep Learning in Detecting Apple Fruit Diseases. *Microprocessors and Microsystems*, 104321. doi:10.1016/j.micpro.2021.104321
- Jiang, P., Chen, Y., Liu, B., He, D. ve Liang, C. (2019). Real-Time Detection of Apple Leaf Diseases Using Deep Learning Approach Based on Improved Convolutional Neural Networks. *IEEE Access*, 7, 59069–59080. doi:10.1109/ACCESS.2019.2914929
- Joshi, R. C., Kaushik, M., Dutta, M. K., Srivastava, A. ve Choudhary, N. (2021). VirLeafNet: Automatic analysis and viral disease diagnosis using deep-learning in Vigna mungo plant. *Ecological Informatics*, 61, 1–15. doi:10.1016/j.ecoinf.2020.101197
- Kang, X., Song, B. ve Sun, F. (2019). A deep similarity metric method based on incomplete data for traffic anomaly detection in IoT. *Applied Sciences*, 9(1), 135. doi:10.3390/app9010135
- Karadağ, K. ve Taştaltın, R. (2016). Biber Bitkisinden Alınan Spektral Yansımaların Yapay Sinir Ağları Kullanarak Hastalık Tespiti. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 5, 50–59.
- 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, 1–12. doi:10.1016/j.asoc.2019.105933
- Kavzoğlu, T. ve Çölkesen, İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi*, 144, 73–82. <https://www.researchgate.net/publication/275037555> adresinden erişildi.

- Kaynar, O., Arslan, H., Görmez, Y. ve Işık, Y. E. (2018). Makine Öğrenmesi ve Öznitelik Seçim Yöntemleriyle Saldırı Tespiti. *Bilişim Teknolojileri Dergisi*, 11(2), 175–185. doi:10.17671/gazibtd.368583
- Khirade, S. D. ve Patil, A. B. (2015). Plant disease detection using image processing. *Proceedings - 1st International Conference on Computing, Communication, Control and Automation*, 768–771. doi:10.1109/ICCUBEA.2015.153
- Kılıç, E., Ecemiş, İ. N. ve İlhan, H. O. (2021). Narenciye Ağaç Yaprak Hastalıklarının Evrişimli Sinir Ağları ile Sınıflandırılması. In *2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, 452–456.
- Köktürk, F. (2009). *K-En Yakın Komşuluk, Yapay Sinir Ağları Ve Karar Ağaçları Yöntemlerinin Sınıflandırma Başarılarının Karşılaştırılması*. Bülent Ecevit Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik Anabilim Dalı, Doktora Tezi.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. ve Jackel, D., L. (1989). Metabolism OutFOXes circadian rhythm. *Neural Computation*, 1(4), 541–551.
- Lin, Z., Mu, S., Huang, F., Mateen, K. A., Wang, M., Gao, W. ve Jia, J. (2019). A unified matrix-based convolutional neural network for fine-grained image classification of wheat leaf diseases. *IEEE Access*, 7, 11570–11590. doi:10.1109/ACCESS.2019.2891739
- Liu, L. ve Zhou, G. (2009). Extraction of the rice leaf disease image based on BP neural network. In *2009 International Conference on Computational Intelligence and Software Engineering*, 1–3. doi:10.1109/CISE.2009.5363225
- Liu, Z. Y., Wu, H. F. ve Huang, J. F. (2010). Application of neural networks to discriminate fungal infection levels in rice panicles using hyperspectral reflectance and principal components analysis. *Computers and Electronics in Agriculture*, 72(2), 99–106. doi:10.1016/j.compag.2010.03.003
- Luna, R. G. De, Dadios, E. P. ve Bandala, A. A. (2018). Automated Image Capturing System for Deep Learning-based Tomato Plant Leaf Disease Detection and Recognition. *TENCON 2018 IEEE Region 10 Conference*, 1414–1419. doi:10.1109/TENCON.2018.8650088
- Martínez, F., Martínez, F. ve Jacinto, E. (2020). Performance evaluation of the NASnet convolutional network in the automatic identification of COVID-19. *International Journal on Advanced Science, Engineering and Information Technology*, 10(2), 662–667. doi:10.18517/ijaseit.10.2.11446
- Mehdipour Ghazi, M., Yanikoglu, B. ve Aptoula, E. (2017). Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing*, 235(August 2016), 228–235. doi:10.1016/j.neucom.2017.01.018
- Militante, S. V., Gerardo, B. D. ve Dionisio, N. V. (2019). Plant Leaf Detection and

- Disease Recognition using Deep Learning. *2019 IEEE Eurasia Conference on IOT, Communication and Engineering, ECICE*, 579–582. doi:10.1109/ECICE47484.2019.8942686
- Mo, L. (2010). Prediction of wheat stripe rust using neural network. *Proceedings - 2010 IEEE International Conference on Intelligent Computing and Intelligent Systems*, 3, 475–479. doi:10.1109/ICICISYS.2010.5658476
- Mohanty, S. P., Hughes, D. P. ve Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1–10. doi:10.3389/fpls.2016.01419
- Naikwadi, S. ve Amoda, N. (2013). Advances in Image Processing for Detection of Plant Diseases. *International Journal of Application or Innovation in Engineering & Management*, 2(11), 168–175.
- Nguyen Duc, H., Kamwa, I., Dessaint, L. A. ve Cao-Duc, H. (2017). A novel approach for early detection of impending voltage collapse events based on the support vector machine. *International Transactions on Electrical Energy Systems*, 27(9), 1–18. doi:10.1002/etep.2375
- Nizam, H. ve Akın, S. S. (2014). Sosyal Medyada Makine Öğrenmesi ile Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması. *XIX. Türkiye’de İnternet Konferansı*, 1(6). <https://docplayer.biz.tr/39581631-Sosyal-medyada-makine-ogrenmesi-ile-duygu-analizinde-dengeli-ve-dengesiz-veri-setlerinin-performanslarinin-karsilastirilmasi.html> adresinden erişildi.
- Osajima, J. S. (2019). Scaling Down: Efficient Inference for Convolutional Neural Networks. *Doctoral dissertation, UCLA*. <https://escholarship.org/uc/item/0th2s0ss> adresinden erişildi.
- Özcan, A. ve Dönmez, E. (2021). Bacterial Disease Detection for Pepper Plant by Utilizing Deep Features Acquired from DarkNet-19 CNN Model. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(4), 573–579. doi:10.24012/dumf.1001901
- Özerdem, M. S. ve Acar, E. (2011). Zambak yaprağı imgelerinde pas hastalıklarının GLCM tabanlı sınıflandırma yöntemleri ile tespiti. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 2(2), 95–105.
- Pardede, H. F., Suryawati, E., Sustika, R. ve Zilvan, V. (2018). Unsupervised Convolutional Autoencoder-Based Feature Learning for Automatic Detection of Plant Diseases. In *2018 International Conference on Computer, Control, Informatics and its Applications (IC3INA)*, 158–162. doi:10.1109/IC3INA.2018.8629518
- Peng, H., Long, F. ve Ding, C. (2005). Feature selection based on mutual information. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(8), 1226–1238. doi:10.1109/cita.2015.7349827
- Radovic, M., Ghalwash, M., Filipovic, N. ve Obradovic, Z. (2017). Minimum redundancy

- maximum relevance feature selection approach for temporal gene expression data. *BMC Bioinformatics*, 18(9), 1–14. doi:10.1186/s12859-016-1423-9
- Raj, A. (2021). Introduction to Classification Using K Nearest Neighbours. *Towards Data Science*. 8 Şubat 2022 tarihinde <https://towardsdatascience.com/getting-acquainted-with-k-nearest-neighbors-ba0a9ecf354f> adresinden erişildi.
- Redmon, J. ve Farhadi, A. (2016). YOLO9000: Better, faster, stronger. *arXiv:1612.08242*. eprint: 1612.08242. Cornell University.
- Sabrol, H. ve Satish, K. (2016). Tomato plant disease classification in digital images using classification tree. *International Conference on Communication and Signal Processing (ICCSP)*, 1242–1246. doi:10.1109/ICCSP.2016.7754351
- Safavian, S. R. ve Landgrebe, D. (1991). A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics*, 21(3), 660–674. doi:10.1109/21.97458
- Salzberg, S. L. (1994). C4.5: Programs for Machine Learning. *Machine Learning*, 16, 235–240. doi:<https://doi.org/10.1007/BF00993309>
- Sardogan, M., Tuncer, A. ve Ozen, Y. (2018). Plant Leaf Disease Detection and Classification Based on CNN with LVQ Algorithm. *UBMK 2018 - 3rd International Conference on Computer Science and Engineering*, 382–385. doi:10.1109/UBMK.2018.8566635
- Shruthi, U., Nagaveni, V. ve Raghavendra, B. K. (2019). A Review on Machine Learning Classification Techniques for Plant Disease Detection. *2019 5th International Conference on Advanced Computing and Communication Systems, ICACCS*, 281–284. doi:10.1109/ICACCS.2019.8728415
- Singh, V., Varsha ve Misra, A. K. (2015). Detection of unhealthy region of plant leaves using image processing and genetic algorithm. *Conference Proceeding - 2015 International Conference on Advances in Computer Engineering and Applications, ICACEA 2015*, 1028–1032. doi:10.1109/ICACEA.2015.7164858
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... Rabinovich, A. (2015). Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (Cvpr)*, 1–9.
- Tai, Y., Yang, J. ve Liu, X. (2017). Image super-resolution via deep recursive residual network. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2790–2798. doi:10.1109/CVPR.2017.298
- Taşcı, E. ve Onan, A. (2016). K- En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi. *Akademik Bilişim*, 1–8.
- Tay, F. E. H. ve Cao, L. (2001). Application of support vector machines in financial time series forecasting. *Omega*, 29(4), 309–317. doi:10.1016/S0305-0483(01)00026-3

- Tayyar, N. ve Tekin, S. (2013). İMKB-100 Endeksinin Destek Vektör Makineleri ile Günlük, Haftalık ve Aylık Veriler Kullanılarak Tamin Edilmesi. *AİBÜ Sosyal Bilimler Enstitüsü Dergisi*, 13(1), 189–217.
- Toğaçar, M. (2021). Dikkat Modülleri ile Oluşturulmuş Derin Öğrenme Modelini Kullanarak Pamuk Hastalığının Tespiti. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 36(3), 659–668.
- 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. doi:10.1016/j.compag.2018.03.032
- Türkoğlu, M., Hanbay, K., Sivrikaya, I. S. ve Hanbay, D. (2020). Derin Evrışimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması Classification of Apricot Diseases by using Deep Convolution Neural Network. *BEÜ Fen Bilimleri Dergisi*, 9(1), 334–345.
- Waghmare, H., Kokare, R. ve Dandawate, Y. (2016). Detection and Classification of Diseases of Grape Plant Using Opposite Colour Local Binary Pattern Feature and Machine Learning for Automated Decision Support System. *2016 3rd International Conference on Signal Processing and Integrated Networks (SPIN)*, 513–518.
- Witten D. M. and Tibshirani R., “Penalized classification using Fisher’s linear discriminant,” 2011.
- Yakut, E., Elmas, B. ve Yavuz, S. (2014). Yapay Sinir Ağları Ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(1), 139–157.
- Yang, Z., Li, J. ve Li, H. (2018). Real-time Pedestrian and Vehicle Detection for Autonomous Driving. *2018 IEEE Intelligent Vehicles Symposium (IV)*, 179–184. doi:10.1109/IVS.2018.8500642
- Yuwana, R. S., Suryawati, E., Zilvan, V., Ramdan, A., Pardede, H. F. ve Fauziah, F. (2019). Multi-Condition Training on Deep Convolutional Neural Networks for Robust Plant Diseases Detection. In *2019 International Conference on Computer, Control, Informatics and its Applications(IC3INA)*, 30–35. doi:10.1109/IC3INA48034.2019.8949580
- Zanaty, E. A. (2012). Support Vector Machines (SVMs) versus Multilayer Perception (MLP) in data classification. *Egyptian Informatics Journal*, 13(3), 177–183. doi:10.1016/j.eij.2012.08.002
- Zhang, A., Lipton, Z. C., Li, M. ve Smola, A. J. (2021). Dive Into Deep Learning. *arXiv preprint arXiv:2106.11342*. doi:10.1016/j.jacr.2020.02.005
- Zoph, B., Vasudevan, V., Shlens, J. ve Le, Q. V. (2018). Learning Transferable Architectures for Scalable Image Recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 8697–8710. doi:10.1109/CVPR.2018.00907

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı: Hatice KAYHAN

Eğitim Derecesi

Lise: Kılıçarslan Anadolu Lisesi (2000-2004)

Lisans: Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Maliye (2004 - 2008)

Lisans: Amasya Üniversitesi, Eğitim Fakültesi, Bilgisayar ve Öğretim Teknolojileri Öğretmenliği (2016- 2022)

Çalıştığı Kurumlar

Amasya Çalışma ve İş Kurumu İl Müdürlüğü (2009-)

Yabancı Dili: İngilizce

Yayınlar

Kayhan, H. , Ünal, Y. ve Dönmez, E. (2022). Detection of cherry plant bacterial disease with deep features, *3.rd International Congress of Engineering Sciences and Multidisciplinary Approaches*, 717-726.