

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME TABANLI KİRAZ YAPRAKLARINDA HASAR TESPİTİ

YÜKSEK LİSANS TEZİ

HAZEL BOZCU

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ BURAKHAN ÇUBUKÇU

BİLECİK, 2024
10607349

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME TABANLI KİRAZ YAPRAKLARINDA HASAR TESPİTİ

YÜKSEK LİSANS TEZİ

HAZEL BOZCU

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ BURAKHAN ÇUBUKÇU

BİLECİK, 2024
10607349

BEYAN

Derin Öğrenme Tabanlı Kiraz Yapraklarında Hasar Tespiti adlı yüksek lisans tezinin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.	
DESTEK ALINMIŞTIR	DESTEK ALINMAMIŞTIR
Destek alındı ise;	
Destekleyen kurum;	
Desteğin Türü	Proje Numarası
1- BAP (Bilimsel Araştırma Projesi)	
2- TÜBİTAK	
Diğer;.....	
ETİK KURUL onayı var ise;	
ETİK KURUL karar tarih/sayı:/.....

Öğrenci Adı ve Soyadı

Hazel BOZCU

Tarih

.....

İmza

.....

ÖN SÖZ

Danışmanım Sayın Dr. Öğr. Burakhan ÇUBUKÇU'ya tez çalışmamın oluşumunda ve rehberliğiyle sağlanan değerli katkıları için teşekkür ederim. Yönlendirmeleriyle bu noktaya ulaşabilmek büyük bir fırsat oldu. Savunma sınavında gösterdiğiniz ilgi ve değerli geri bildirimleriniz için ayrıca teşekkür ederim.

Değerli jüri üyelerine de çalışmama kattıkları değerli görüşler için minnettarım.

Bu süreçte yanımda olan sevgili aileme de teşekkür etmek isterim. Onların desteğiyle bu zorlu süreci aşabilmek mümkün oldu.

Hazel BOZCU

2024

ÖZET

DERİN ÖĞRENME TABANLI KIRAZ YAPRAKLARINDA HASAR TESPİTİ

Bu çalışmada tarımsal üretimde verim artışını sağlamak amacıyla kiraz yapraklarındaki hastalıkların tespiti için derin öğrenme yöntemlerinin kullanılması amaçlanmaktadır. Günümüzde yaprak hastalıklarının tespiti uzman personel tarafından yapılabilmekte ancak uzun sürmektedir. Ayrıca, bu uzmanların sayısı yetersiz olabilir, bu da doğru tespitin zorluğuna işaret etmektedir. Bu nedenle, kiraz üretimini artırmak ve hastalıkları erken teşhis etmek için derin öğrenme temelli hastalık tespit uygulamalarının kullanımı bu çalışmanın ana amacıdır.

Çalışmada iki farklı veri seti üzerinde kiraz yaprak hastalığı tespiti için farklı derin öğrenme modellerinin performansı incelenmiştir. Ortalama sonuçlara göre, MobileNet-V2 modeli %98.68 doğruluk ve %98.83 hassasiyet ile yüksek bir performans sergilemiş, Inception-V3 modeli %94.17 F1-Skor ile tatmin edici sonuçlar vermiştir. Önerilen CNN modeli %95.83 F1-Skor ile dikkat çekmiş, önerilen CNN + LSTM modeli %96.33 geri çağırma değeri ile tatmin edici sonuçlar sunmuş ve önerilen CNN + BiLSTM modeli %96.33 F1-Skor ile yüksek bir performans göstermiştir.

En iyi sonuçlar kategorisinde, MobileNet-V2 modeli %99.03 doğruluk oranı ve %99.33 F1-Skor ile en iyi sonuçları vermiş, Inception-V3 modeli %94.00 doğruluk ve %94.33 hassasiyet ile tatmin edici bir performans sergilemiştir. Önerilen CNN modeli %95.66 F1-Skor ile iyi bir performans sergilemiş, önerilen CNN + LSTM modeli %96.67 doğruluk ve %96.67 F1-Skor ile en iyi sonuçları vermiş ve önerilen CNN + BiLSTM modeli %96.66 F1-Skor ile yüksek bir performans göstermiştir.

Bu sonuçlar, kiraz yaprak hastalığı tespiti için derin öğrenme modellerinin umut veren sonuçlar elde ettiğini göstermektedir. Çalışma kapsamında en iyi sonuçlar MobileNet-V2 ve önerilen CNN + LSTM modelleri tarafından elde edilmiştir. Bu çalışmanın, çeşitli veri setleri kullanılarak güvenilirliği artırılabilir, farklı derin öğrenme yöntemleri kullanılarak hastalık tespit başarımları yükseltilebilir ve hastalık tespit süreleri düşürülebilir.

Anahtar Kelimeler: Derin Öğrenme, CNN, LSTM, Transfer Öğrenme, Kiraz Yaprak Hastalıkları

ABSTRACT

DEEP LEARNING-BASED DAMAGE DETECTION ON CHERRY LEAVES

In this study, the use of deep learning methods is aimed at detecting diseases in cherry leaves to increase agricultural productivity. Currently, the detection of leaf diseases is carried out by expert personnel, but it can be time-consuming. Additionally, the number of these experts may be insufficient, indicating the difficulty of accurate detection. Therefore, the main goal of this study is to utilize deep learning-based disease detection applications to increase cherry production and diagnose diseases early.

The performance of different deep learning models for cherry leaf disease detection has been investigated on two different datasets in the study. According to the average results, the MobileNet-V2 model demonstrated high performance with 98.68% accuracy and 98.83% precision, the Inception-V3 model provided satisfactory results with a 94.17% F1-Score. The proposed CNN model attracted attention with a 95.83% F1-Score, the proposed CNN + LSTM model presented satisfactory results with a 96.33% recall, and the proposed CNN + BiLSTM model exhibited high performance with a 96.33% F1-Score.

In the category of best results, the MobileNet-V2 model yielded the highest results with a 99.03% accuracy rate and a 99.33% F1-Score, the Inception-V3 model showed satisfactory performance with 94.00% accuracy and 94.33% precision. The proposed CNN model demonstrated good performance with a 95.66% F1-Score, the proposed CNN + LSTM model provided the best results with 96.67% accuracy and 96.67% F1-Score, and the proposed CNN + BiLSTM model exhibited high performance with a 96.66% F1-Score.

These results indicate promising outcomes for the use of deep learning models in cherry leaf disease detection. The best results in the study were obtained by the MobileNet-V2 and the proposed CNN + LSTM models. The reliability of this study can be enhanced by using various datasets, disease detection success rates can be increased by employing different deep learning methods, and disease detection times can be reduced.

Keywords: Deep Learning, CNN, LSTM, Transfer Learning, Cherry Leaf Diseases

İÇİNDEKİLER

Sayfa No

ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER	iv
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
SİMGELER VE KISALTMALAR LİSTESİ.....	ix
1. GİRİŞ.....	1
2. ÇALIŞMADA KULLANILAN KİRAZ YAPRAKLARINDAKİ HASTALIKLAR .	4
3. YAPAY ZEKA VE GÖRÜNTÜ İŞLEME YÖNTEMLERİ İLE YAPRAKLARDA HASTALIK TESPİTİ	6
3.1 Görüntü İşleme ile Hastalık Tespiti.....	6
3.1.1 Görüntü Edinme	7
3.1.2 Görüntü Ön İşleme	7
3.1.3 Görüntü Segmentasyonu.....	8
3.1.4 Görüntüde Özellik Çıkartma.....	9
3.1.5 Görüntüyü Sınıflandırma	9
3.2 Yapay Sinir Ağları.....	9
3.3 Derin Öğrenme	10
3.4 Evrişimli Sinir Ağları	11
3.4.1 Transfer Öğrenimi	12
3.4.1.1 AlexNet.....	12
3.4.1.2 VGG	13
3.4.1.3 GoogleNet (Inception).....	13
3.4.1.4 Inception-V3	14

3.4.1.5 MobileNet-V2	15
3.4.2 LSTM.....	15
3.4.3 BiLSTM.....	16
4. MATERYAL VE YÖNTEM	17
4.1 Kullanılan Veri Setleri	17
4.1.1. PlantVillage Veri Seti.....	17
4.1.2. Kozlu Veri Seti.....	17
4.2 Kullanılan Derin Öğrenme Yöntemleri.....	18
4.2.1 AlexNet Tabanlı Mimari	18
4.2.2 VGG Tabanlı Mimari.....	19
4.2.3 Inception-V3.....	19
4.2.4 MobileNet-V2	20
4.2.5 CNN.....	20
4.2.6 CNN + LSTM.....	21
4.2.7 BiLSTM	22
4.3 Başarı Metrikleri	22
5. BULGULAR VE DEĞERLENDİRME.....	24
5.1 PlantVillage Veri Seti Sonuçları.....	24
5.2 Kozlu Veri Seti Sonuçları	29
6. SONUÇ VE ÖNERİLER	34
KAYNAKÇA	35

TABLULAR LİSTESİ

	Sayfa No
Tablo 5.1. PlantVillage Veri Seti Alexnet Sınıf Bazlı Sonuçları.....	24
Tablo 5.2. PlantVillage Veri Seti Vgg-16 Sınıf Bazlı Sonuçları.....	25
Tablo 5.3. PlantVillage Veri Seti Inception-V3 Sınıf Bazlı Sonuçları.....	26
Tablo 5.4. PlantVillage Veri Seti Mobilenet-V2 Sınıf Bazlı Sonuçları.....	26
Tablo 5.5. PlantVillage Veri Seti CNN Sınıf Bazlı Sonuçları.....	27
Tablo 5.6. PlantVillage Veri Setinde 3 Tekrarlı Elde Edilen Sonuçlar.....	28
Tablo 5.7. Kozlu Veri Seti Inception-V3 Sınıf Bazlı Sonuçları.....	29
Tablo 5.8. Kozlu Veri Seti Mobilenet-V2 Sınıf Bazlı Sonuçları.....	30
Tablo 5.9. Kozlu Veri Seti CNN Sınıf Bazlı Sonuçları.....	31
Tablo 5.10. Kozlu Veri Seti LSTM Sınıf Bazlı Sonuçları.....	31
Tablo 5.11. Kozlu Veri Seti BILSTM Sınıf Bazlı Sonuçları.....	32
Tablo 5.12. Kozlu Veri Setinde 3 Tekrarlı Elde Edilen Sonuçlar.....	33

ŞEKİLLER LİSTESİ

	Sayfa No
Şekil 2.1. Yaprak Külleme Hastalığından Etkilenmiş Ekin Ve Kabak Bitkisi Yaprığı Örneği...4	4
Şekil 2.2. Yaprak Külleme Hastalığından Etkilenmiş Kiraz Yaprığı Örneği.....5	5
Şekil 2.3. Kozlu Veri Seti Potasyum Eksikliği Hastalığından Etkilenmiş Kiraz Yaprığı.....5	5
Şekil 3.1. Görüntü İşleme Adımlar.....6	6
Şekil 3.2. Temel Görüntü İşleme Adımları.....7	7
Şekil 3.3. K-Means Kümeleme Algoritması Akış Diyagramı.....8	8
Şekil 3.4. İki Sinir Hücreli Tipik Bir Yapay Sinir Ağı Şeması.....10	10
Şekil 3.5. Üç Gizli Katmanlı Sinir Ağı Örneği.....11	11
Şekil 3.6. CNN Mimarisi.....12	12
Şekil 3.7. VGG Mimarisi Katmansal Şeması.....13	13
Şekil 3.8 GoogleNet Boyut Azaltma Modülü.....14	14
Şekil 3.9. Inception-V3 Ağ Mimarisi.....14	14
Şekil 3.10. Uzun Kısa Süreli Hafıza Mimari Yapısı.....15	15
Şekil 3.11. LSTM, BILSTM Farklı Versiyonları.....16	16
Şekil 4.1. Kozlu Veri Seti 3 Sınıflı Örnek Görüntüler.....18	18
Şekil 4.2 Çalışmadaki CNN + LSTM mimarisi.....22	22
Şekil 4.3 Çalışmadaki CNN + BILSTM mimarisi.....22	22
Şekil 4.4. Karışıklık Matrisi (Confusion Matrix).....22	22
Şekil 5.1. PlantVillage Veri Seti Alexnet Tabanlı Mimari Karmaşıklık Matrisi.....24	24
Şekil 5.2. PlantVillage Veri Seti VGG-16 Tabanlı Mimari Karmaşıklık Matrisi.....25	25
Şekil 5.3. PlantVillage Veri Seti Inception-V3 Tabanlı Mimari Karmaşıklık Matrisi.....26	26
Şekil 5.4. PlantVillage Veri Seti Mobilenet-V2 Tabanlı Mimari Karmaşıklık Matrisi.....27	27
Şekil 5.5. PlantVillage Veri Seti CNN Tabanlı Mimari Karmaşıklık Matrisi.....27	27

Şekil 5.6. Kozlu Veri Seti Inception-V3 Tabanlı Mimari Karmaşıklık Matrisi.....	29
Şekil 5.7. Kozlu Veri Seti Mobilenet-V2 Tabanlı Mimari Karmaşıklık Matrisi.....	30
Şekil 5.8. Kozlu Veri Seti CNN Tabanlı Mimari Karmaşıklık Matrisi.....	31
Şekil 5.9. Kozlu Veri Seti LSTM Tabanlı Mimari Karmaşıklık Matrisi.....	32
Şekil 5.10. Kozlu Veri Seti BILSTM Tabanlı Mimari Karmaşıklık Matrisi.....	32

SİMGELER VE KISALTMALAR LİSTESİ

BILSTM Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-term Memory)

CNN: Evrişimsel Sinir Ağları (Convolution Neural Network)

DNN: Derin Sinir Ağları (Deep Neural Network)

HIS: Ton Doygunluğu Yoğunluğu (Hue Saturation Intensity)

KNN: K en yakın komşu Algoritması (K-nearest neighbour)

LSTM Uzun Kısa Süreli Bellek (Long Short-term Memory)

ML: Makine Öğrenmesi (Machine Learning)

ReLU: Doğrutulmuş Doğrusal Birim (Rectified Linear Unit)

ResNet: ResNet Artık Ağlar (Residual Network)

RGB: Red-Green-Blue(Kırmızı-Yeşil-Mavi)

RNN: Yinelemeli Sinir Ağları (Recurrent Neural Network)

ROC: Alıcı İşlem Karakteristikleri

SGD Olasılıksal Dereceli Azaltma (Stochastic Gradient Descent)

SVM: Destek Vektör Makineleri (Support Vector Machine)

VGG: Görsel Geometri Grubu (Visual Geometry Group)

YSA: Yapay Sinir Ağı (Artificial Neural Network)

1. GİRİŞ

Dünyada artan gıda ihtiyacıyla birlikte tarımsal üretimde iyileşme sağlanması, verimliliğin artırılması günümüzde kritik öneme sahip konulardan biri haline gelmektedir. Bu verimliliğin artırılabilmesi için bitki yaprakları, meyvelerde meydana gelen hastalıkların tespit edilmesi önem arz etmektedir. Tarım emekçileri bitki yapraklarındaki ve meyvelerindeki hastalık tespitini çıplak gözle gözlemleyerek yaparlar. Ancak bu işlem uzun zaman almakla birlikte hasta yaprak tespiti konusunda deneyimli personel sayısı yetersiz olup, doğru şekilde tespit edilmesi zor bir yöntemdir. Bunun yanı sıra yüz ölçümü büyük olan çiftliklerde hastalık tespiti daha da zorlaşmakta ve tespit süresi uzamaktadır. Günümüzde uzun zaman alan bu işlem yerine tarımda derin öğrenme tabanlı hastalık tespit uygulamaları kullanılmaya başlanmıştır (Faek ve Al, 2019).

Bitki yapraklarındaki hasarlar bitkinin fotosentez ile yapraklarından besin almasını engelleyerek bitkinin ölümüne neden olabilmektedir (Tarım Bakanlığı,2016). Yaprakları sağlıklı olan kiraz ağaçlarının meyvelerinin irileşmediği bilinmektedir. Yaprığı dökülmüş veya hastalıklı kiraz meyvesi olgunlaşmadan buruşmakta ya da kalitesi düşmektedir. Kiraz yapraklarındaki birçok hastalık meyvenin verimini düşürebilmektedir.

Örneğin, yaprak lekeli hastalığı ileri safhasında bitkinin yapraklarının dökülmesine neden olup bazen kiraz ağacında sadece meyvesini bırakabilmektedir. Bu meyveler tatları kötü, iyi gelişmemiş ve kaliteleri düşük olarak görülmektedir. Külleme hastalığı bitkinin yeşil olan tüm alanlarında görülen pudramsı bir görünüm şeklinde tanımlanabilir. Kiraz yaprak külleme hastalığı genellikle nem oranı yüksek bölgelerdeki bitkilerde görülmektedir. Öncelikle bitkinin yaprağının üst bölgelerinden başlayarak yayılan külleme hastalığı bitkinin yaprak dökmesine ve hatta meyve dökmesine yol açan un gibi beyazlaşarak yaprağı saran bir hastalıktır (Kurt, 2020). Bu hastalıkların ilerlemesini engelleyebilmek için yapraklardaki hastalıkların erken tespiti önem taşımaktadır.

Gelişen teknoloji ile birlikte makine öğrenmesinin alt kategorisi olan derin öğrenme, elle yazılmış metin tanıma, sürücüsüz arabalar, deprem tahmini problemleri, sınıflandırma gibi birçok konu üzerinde son derece önemli ilerlemeler kaydetti. Benzer şekilde yaprak hastalıklarının yapay zeka yöntemleri ile tespit edilerek, erken teşhis sayesinde bitkilerin korunması sağlanabilmektedir. Derin öğrenme yöntemleri kullanarak bitki hastalık tespiti ve sınıflandırması üzerine yapılan bir derleme çalışmasında (Saleem vd., 2019), bitki hastalıklarının tespitinde doğruluk artırılmasında derin öğrenme modellerin önemini

açıklamaktadır.

Örneğin yapılan bir çalışmada mısır hastalık sınıflandırması için evrişimsel sinir ağları (CNN) kullanılarak geliştirilen model mısır yapraklarındaki üç farklı hastalığı tespit edebilmektedir. Bilgisayarlı görme teknikleri yardımıyla bitki yaprak hastalıklarının tanınması için kullanılan tekniklerde biri görüntülerden renk özelliği çıkarımı ile hastalık tespittir (Sibiya vd., 2019). Evrişimsel sinir ağları renk özniteliklerini çıkarma özelliği ile görüntülerin sınıflandırılmasını ve tanınmasını sağlamaktadır.

Bunun dışında destek vektör makineleri (SVM) yaygın kullanılan makine öğrenimi algoritmalarından bir tanesidir (Seyrek, 2021). Sekiz farklı bitki hastalığı içeren bir çalışmada sınıflandırıcı olarak SVM, aşırı öğrenme makineleri (ELM) ve K- en yakın komşu (KNN) kullanılmıştır. Bunlarla birlikte ResNet-50, GoogleNet, ResNet-101, SqueeneNet gibi derin öğrenme (DL) modelleri kullanılmıştır. DL modelleri arasında hassaslık, F1 puanı gibi performans ölçütlerine bakılarak yapılan kıyaslama sonucunu SVM sınıflandırıcılı ResNet-50 en parlak sonucu vermiştir (Saleem vd., 2019). Literatürde birçok araştırmada AlexNet, GoogleNet, VGG-16, Mobilenet gibi transfer öğrenme modellerinin kullanıldığı gözlemlenmektedir. Kullanılan modeller kadar kullanılan veri setlerinin de başarıma etkisi bulunmaktadır.

Veri setinin örneklem sayısının artırılması performansı olumlu yönde arttırmaktadır. Bunun için görüntüyü döndürme, ayna simetrisini (yatay simetri) alma, görüntünün kontrast, keskinlik ve parlaklığını değiştirme gibi veri artırma yöntemleri kullanılabilir. Literatürde yüksek sayıda görüntü ile oluşturulmuş veri setlerinin üzerinde birçok yapay zeka modeli uygulanarak başarımların kıyaslanması yapılan çalışmalar bulunmaktadır.

Gül yaprakları üzerinde yapılan bir çalışmada yapay zeka modellerinin çeşitli türleri ele alınmaktadır. Yapay sinir ağlarının yanı sıra, görüntü işleme için kullanılan CNN ve zaman serileri analizi için yinelemeli sinir ağları (RNN) ve uzun kısa süreli bellek (LSTM) gibi modellerin mevcut olduğunu vurgulamıştır. Özellikle CNN, görüntü verilerinden çıktı üretmek için etkili bir şekilde kullanılmakta ve bu çıktıların nesne tanıma, hastalık teşhisi gibi farklı uygulamalarda kullanabildiği vurgulanmaktadır. Çalışmada ayrıca CNN katmanlarının üç farklı tipinin olduğu açıklanır: evrişimli katmanlar, girdiden özelliklerin çıkarılmasında kullanılan desenler içerir; havuzlama katmanları, verinin boyutunu azaltarak işlemi basitleştirir; tam bağlantılı yapay sinir ağı katmanı ise veriyi düzleştirerek sınıflandırma yapar. Parçada ayrıca RoseNet veri kümesinin kullanıldığı belirtilmekte ve bu verinin üç farklı hastalık türünü içerdiği

ifade edilmektedir. Bu hastalıklara ait örnek resimler kullanılarak yapay zeka sistemlerinin eğitildiği anlatılmaktadır (Gülmez,2023).

Kiraz yaprakları üzerinden yapılan başka bir çalışmada, bitki hastalıklarının tarımsal alanda ekonomik kayıplara neden olduğu vurgulanmıştır. Bu kayıpların %15-25 böcekler tarafından yayılan mantar enfeksiyonlar, bakteriyel enfeksiyonlar ve bitki hastalıklarından oluştuğu belirtilmektedir. Bu bağlamda, bitki hastalıklarının erken teşhisi için bir sistem önerilmektedir. Bu sistemin, bitki hastalıklarından kaynaklanan kayıpları azaltmada önemli bir rol oynayabileceği vurgulanmaktadır. Hastalık teşhisi, önleme ve tedavi, bitki kalitesini artırmak ve ürün güvenliği sağlamak için temel ve kritik bir yaklaşım olarak kabul edilmektedir. Bu çalışmanın ana katkısı, kiraz yaprağı görüntülerindeki külleme hastalığı etkilenen alanını otomatik olarak bölen bir yöntemi vurgulamasıdır. Ayrıca, sağlam alan ile hastalık etkilenen alanın oranını hesaplayarak hastalık teşhisini nicelendirmektedir. Bu yöntem, gerçek zamanlı uygulamalar için külleme hastalığı bölgesini bölümlendirmeyi önermektedir (Sengar vd., 2018).

Literatürde farklı bitki türleri üzerinde evrişimli sinir ağları kullanılarak hastalık tespitleri mevcuttur. Kiraz yaprağı hastalıkları konusunda veri setlerinde çeşitliliği arttırmak amacıyla bu çalışma yapılmıştır. Literatüre transfer öğrenme yöntemleri kullanarak ve transfer öğrenme kullanmadan evrişimli sinir ağı eğitilerek yapılan çalışmalar katkı sunmak amaçlanmıştır. Hindistan'da pirinç yaprakları üzerinde yapılan çalışmaya göre VGG-16 modeliyle başlan çalışmada %58 oranında başarı elde edilmiştir (Tejaswini vd.,2022). Bu çalışmada hem VGG-16 modeli hem de MobileNet-V2, Inception-V3, Uzun Kısa Süreli Bellek yöntemi ve İki Yönlü Uzun Kısa Süreli Bellek yöntemi kullanılmış ve başarı oranı artırılmak istenmiştir. Belirli veri artırma işlemleri ve renk uzayları uygulanarak başarı oranı artırılmıştır. Literatürde bu işlemlerin çeşitli örnekleri de mevcuttur.

Bu tezde, kiraz yaprakları üzerinde derin öğrenme yöntemleri kullanılarak bitki hastalıklarının tespiti üzerine odaklanılmıştır. Geliştirilen teşhis modeli, sağlıklı kiraz bitkilerini, potasyum eksikliği ve külleme gibi yaygın hastalıkları sınıflandırmak amacıyla eğitilmiştir. Ayrıca, veri seti boyutunu artırmak ve modelin genelleme yeteneğini güçlendirmek adına görüntü artırma işlemleri de uygulanmıştır. Tez, sadece bitki hastalıklarını tespit etmekle kalmayıp, aynı zamanda farklı veri setleri üzerinde elde edilen başarımların değerlendirilmesi ile birlikte, ülkemizdeki kiraz üretimini desteklemek adına önemli bir katkı sağlamayı, etkili ve güvenilir bir yöntem sunmayı hedeflemektedir.

2. ÇALIŞMADA KULLANILAN KİRAZ YAPRAKLARINDAKİ HASTALIKLAR

Tez kapsamında derin öğrenme yöntemleri ile kiraz yapraklarında külleme hastalığı ve yaprakta potasyum eksikliği olup olmadığının tahmini amaçlanmıştır. Yaprak küllemesi hastalığı, yapraklardaki yeşil oranını azalttığı için ve yaprakların üzerini beyaz bir örtü ile kaplanmasına sebep olduğundan bitkideki fotosentezi olumsuz etkilemektedir. Fotosentezin olumsuz etkilenmesi ürün miktarını ve meyve kalitesini düşürmektedir. Birçok bitki türünde yaprak küllemesi hastalığına raslanmaktadır.

Yurdumuzda külleme hastalığının sıkça görüldüğü bitkiler; asma yaprağı ve meyvesi, tahıllar, kayısı, şeftali, kiraz ve yonca bitkileridir. Bu bitkilerin yeşil olan kısımlarında sürgünlerinde, konukçunun çiçeğinin sapları, ham yeşil meyvelerinde kül ile kaplanmış bir yapı ile giderek artan şekilde kaplanmaktadır. Kül rengindeki bu yapı içerisinde siyah renkli küçük organizmalar oluşmaya başlamakta ve arılar, rüzgar gibi çevresel faktörlerle hastalık diğer konukçu bitkilere de bulaşabilmektedir (Kurt, 2020). Şekil 2.1.'de yaprak külleme hastalığından etkilenen ekin ve kabak bitkisi yaprağı, Şekil 2.2'de tez kapsamında kullanılan PlantVillage veri setine ait hastalıktan etkilenen kiraz yaprağı örneği verilmektedir.



Şekil 2.1. Yaprak Külleme Hastalığından etkilenmiş ekin ve kabak bitkisi yaprağı örneği

Kaynak: (Yıldız, 2012)



Şekil 2.2. Yaprak külleme hastalığından etkilenmiş kiraz yaprağı örneği

Kaynak: (PlantVillage Veri Seti)

Tez kapsamında tespit edilmesi amaçlanan bir diğer hastalık olan potasyum eksikliği, kiraz ağaçlarının beslenme durumu üzerinde negatif bir etkiye sahiptir. Yapılan çalışmalarda, kiraz ağaçlarının yapraklarında potasyum eksikliği görüldüğü ve optimum değerlerin altında olduğu belirlendiğinde kiraz ağaçlarının verim ve kalitesini olumsuz etkilediği tespit edilmiştir. Bu eksiklik, ağaçların sağlıklı büyümesini ve meyve verimini düşürebilmektedir (Uysal ve Katkat, 2007)

Katkat ve Uysal'ın çalışmasına göre verim ve kaliteyi artırmak için bilinçli bir gübreleme programı gereklidir ve potasyum gibi önemli besin elementlerinin eksikliği bu programın bir parçası olarak ele alınmalıdır. Bu amaçla, toprak ve yaprak analizleri ile kiraz bahçelerinin beslenme durumu belirlenmeli ve sorunlar tespit edilerek gerekli önlemlerin alınması gerekmektedir. Şekil 2.3'de Kozlu veri setine ait potasyum eksikliği bulunan kiraz yaprakları örneği sunulmaktadır.



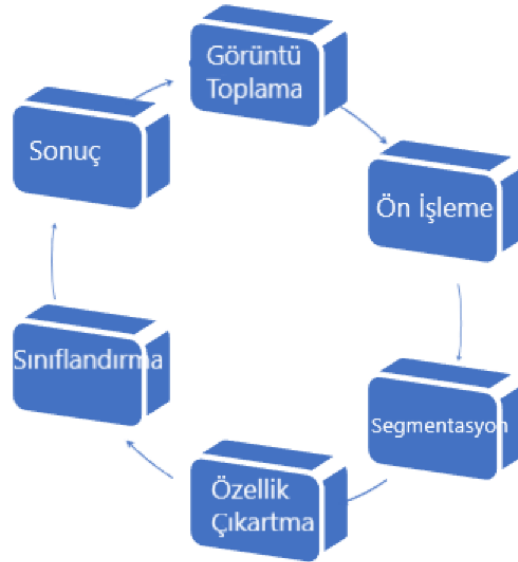
Şekil 2.3. Kozlu Veri Seti Potasyum eksikliği hastalığından etkilenmiş kiraz yaprağı

3. YAPAY ZEKA VE GÖRÜNTÜ İŞLEME YÖNTEMLERİ İLE YAPRAKLARDA HASTALIK TESPİTİ

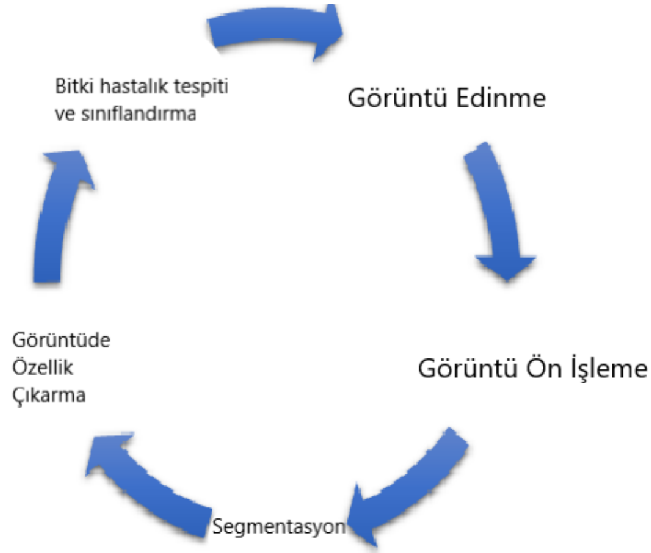
Bu bölümde, tarımsal üretimde yaprak hastalıklarının tespiti için yapay zeka ve görüntü işleme yöntemlerinin kullanımı incelenmektedir. Görüntü işleme süreci genel olarak dış ortamdan toplanan resimlerin bilgisayar ortamına aktarılması, görüntü ön işleme süreci, nesne tespiti, analiz ve gürültülü görsellerin iyileştirilmesi gibi bir dizi işlemi içermektedir. Yapılan çalışmalarda, derin öğrenme modellerinin yaprak hastalık tespitinde yüksek doğruluk elde edebildikleri vurgulanmıştır.

3.1 Görüntü İşleme ile Hastalık Tespiti

Literatürde dış ortamdan özenle toplanmış resimler, belirli bir kalitede bilgisayarlı ortama aktarılır. Bu görsellerin toplanmasında hava şartları, ışık gibi çevresel faktörler fotoğrafın netliği açısından önemlidir. Tarımsal üretimde görüntü işleme yöntemleri kullanılarak yaprak hastalıklarının tespiti üzerine literatür çalışmaları mevcuttur (Altaş ve Yanar, 2019). Amaca uygun görseller toplandıktan sonra ikinci olarak Şekil 3.1'deki gibi ön işleme sürecine girer. Bu süreç nesneyi tespit ve analiz etmek, gürültülü görselleri iyileştirmek, nesnenin sınırlarını belirlemek gibi çok sayıda işlem için kullanılmaktadır (Türkoğlu, 2020). Yapraklardaki hastalık tespiti için temel adımlarda Şekil 3.2'de gösterilmektedir.



Şekil 3.1. Görüntü İşleme Adımları



Şekil 3.2 Temel Görüntü İşleme Adımları

3.1.1 Görüntü Edinme

Bitki yaprak görselleri kamera kullanılarak alınmaktadır. Bu görüntüler kırmızı, yeşil ve mavi (RGB) formatındadır. RGB yaprak görüntüsü için renk dönüşüm yapısı yaratılmakta ve ardından cihazdan bağımsız bir renk uzayı oluşturulan renk dönüşüm yapısı için uygulanmaktadır (Al-Hiary vd., 2011).

3.1.2 Görüntü Ön İşleme

Parazitli görsellerde iyileştirme yapmak, görseldeki diğer nesnelere kaldırmak gibi amaçlarla kullanılan birbirinden farklı ön işleme teknikleri bulunmaktadır. Görüntüyü kırmak, yani istenilen bölgeyi elde etmek için yaprak görüntüsünün kırılması, görüntü yumuşatmak yumuşatma filtresi yardımıyla yapılmaktadır. Görseldeki kontrastı arttırmak için görsel iyileştirme yönteminden yardım alınabilir. Görsellerin sadece gri tonda olması amaçlandığında ise örneğin Eşitlik 1 yardımıyla RGB görseller gri renk görsellere dönüştürülebilir.

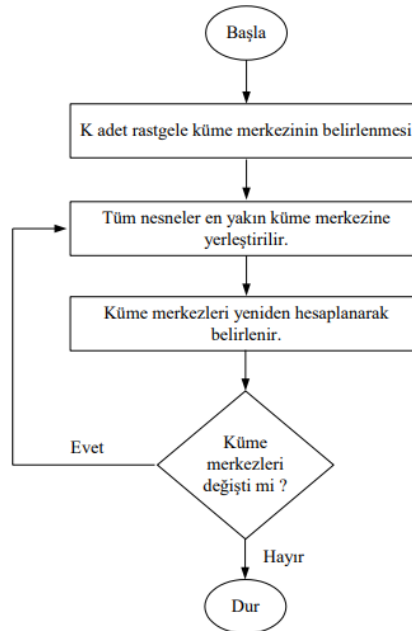
$$\text{Eşitlik 1: } f(x) = 0.2989 x R + 0.5870 x G + 0.114 x B$$

Bu adımlar dışında hastalıklı bitki görüntülerinde iyileştirme yapmak için histogram eşitlemesi uygulanabilir. Bu işlemin amacı ise iyileştirme yapılmak istenen görselin yoğunluklarını dağıtmaktır (Khirade vd., 2015).

3.1.3 Görüntü Segmentasyonu

Görüntü bölütleme olarak da adlandırılan görüntü segmentasyonu görüntü edinme aşamasında elde edilmiş sayısal bir görseli piksellerin değişik özelliklerini baz alarak birden çok bölgeye bölmenin bir yöntemidir. Görüntünün benzer özelliklerinin çeşitli bölümlere ayrılması anlamına da gelir. Pratik analiz işlemi yapmak için anlamlı bilgiler çıkarmak amacıyla segmentasyon yapılabilmektedir. Görüntü pikselleri, bir görüntüdeki her pikselin renk, yoğunluk, doku vb. gibi belirli özellikleri sahip olacak şekilde etiketlenir (Taboada vd., 2013). Temel olarak segmentasyon anlamsal bölütleme ve örnek bölütleme olarak iki tiptir.

Segmentasyon, RGB görüntüsünü ton yoğunluk doygunluğu (HIS) modeline dönüştürme, k-means kümeleme, otsu yöntemi gibi çeşitli yöntemler kullanılarak yapılabilir. RGB görüntüsü, segmentasyon için ton yoğunluk doygunluğu (HIS) modeline dönüştürülür. Sınır tespiti ve nokta tespiti, yaprağın enfekte olan kısmının bulunmasına yardımcı olur. Sınır tespiti için piksellerin 8 bağlanabilirliği göz önünde bulundurulur ve sınır tespit algoritması uygulanır (Khirade vd., 2015). K-means kümeleme yönteminde ise nesnenin bir dizi özelliğe dayalı olarak K sayıda sınıfa gruplandırılması için kullanılır. Nesnenin sınıflandırılması, toplamın en aza indirilmesiyle yapılır, nesne ve karşılık gelen küme arasındaki mesafenin kareleri, K-means için algoritma kümeleme anlamına gelir. K-Means kümeleme algoritması akış diyagramı Şekil 3.3'de verilmektedir.



Şekil 3.3 K-Means Kümeleme Algoritması Akış Diyagramı

Kaynak: (Khirade vd, 2015).

Otsu Eşik Algoritması ise belirli bir eşğin altındaki tüm pikselleri sıfıra ve bu eşğin üzerindeki tüm pikselleri bire ayarlayarak gri seviyeli görüntülerden ikili görüntüler oluşturur (Aravinda, 2017).

3.1.4 Görüntüde Özellik Çıkartma

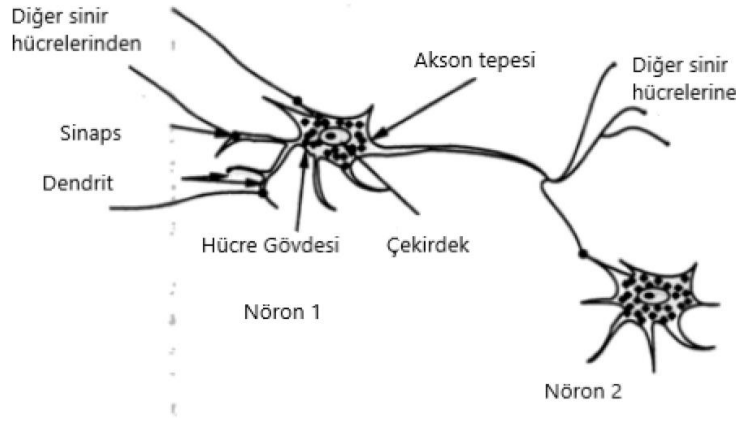
Özellik çıkarma, bir nesnenin tanımlanmasında önemli bir rol oynamaktadır. Görüntü işlemenin birçok uygulamasında öznitelik çıkarımı kullanılmaktadır. Renk, doku, morfoloji, kenarlar vb. özellikler bitki hastalık tespitinde de kullanılabilecek özelliklerdendir. Yapılan bir çalışmada, renk, doku ve morfolojiyi hastalık tespiti için bir özellik olarak değerlendirilmektedir. Çalışmada morfolojik sonucun diğer özelliklerden daha iyi sonuç verdiği vurgulanmaktadır (Jhuria vd., 2013).

3.1.5 Görüntüyü Sınıflandırma

Genellikle segmentasyondan sonraki aşama olarak kullanılan öznitelik çıkarımı doğru sınıflandırmayı kolaylaştırmaktadır. Ko-ilişki, enerji, homojenlik vb. analiz için kullanılan özelliklerdir. Öznitelik çıkarımından sonra görüntü sınıflandırması için kullanılan bulanık mantık, K-en yakın komşu (KNN), destek vektör makinesi (SVM), yapay sinir ağı (YSA), nöro-bulanık girişim sistemi gibi birçok yaklaşım vardır (Solak vd., 2018). Bu veya başka yöntemler kullanılarak yapılan görüntü sınıflama yapraklardaki hastalık teşhisi dahil birçok alanda kullanılabilmektedir.

3.2 Yapay Sinir Ağları

İnsan yüzü tanıma, konuşma tanıma, kanser sınıflandırmadan, gen tahminine varan değişik problemlerde yapay sinir ağları kullanılabilmektedir. YSA temel olarak insan beyninin modellenmesi ile geliştirilmiştir. Beynin hesaplamaları sinapslar(sinir hücreleri arasındaki bağlantı noktaları), aksonlar(sinir hücresinin uzun, ince çıkıntısı) ve dendritlerden oluşan sinirsel nöron ağı tarafından yapılmaktadır. 1943'te McCulloch ve Pitts bir nöronu birbirleri arasında girdi alan ve bu girdinin ağırlığı ile ilişkili olarak aktif yada inaktif kalan bir anahtar modeli olarak tasarlanmıştır (Krogh, 2008).



Şekil 3.4 İki Sinir Hücreli Tipik Bir Yapay Sinir Ağı Şeması

Kaynak: (Yegnanarayana,2009)

Şekil 3.4'de bir nöronun yapısı şematik olarak gösterilmektedir. Dendrit olarak adlandırılan sinir lifleri hücre gövdesi ile bağlantılıdır. Bu dendritler başka nöronlardan sinyal alır. Aksonlar hücre gövdesinden uzanan sinaptin boşluklarda diğer birçok nörona bağlanan ipliklere dallanan tek bir uzun lifdir. Bu bağlantıların diğer hücrelerdeki alıcı ucu hem dendritlerde hem de hücre gövdelerinin kendisinde bulunabilir. Tipik bir nöronun aksonu, diğer nöronlarla ilişkili birkaç bin sinapsa yol açar. Sinapslarda bir hücreden diğerine sinyal iletilir (Yegnanarayana, 2009).


Yapay sinir ağları beynin bu işleyişinden esinlenerek geliştirilmiştir. Günümüzde de popüler olarak kullanılan yapay sinir ağları temel olarak giriş katmanı, gizli katman/lar ve çıkış katmanlarından oluşmaktadır. Bu katmanlar arasında ileri ve geri besleme gibi yöntemler kullanılarak ağlar eğitilmektedir. Eğitimi tamamlandıktan sonra yapay sinir ağları sınıflandırma, tahmin gibi işlemler için kullanılabilir. Günümüzde donanımların gelişmesi ile birlikte yapay sinir ağlarındaki gizli katman sayıları da hızla artmaktadır bu da derin öğrenme çalışmalarının artmasındaki önemli faktörlerden biridir.

3.3 Derin Öğrenme

Derin öğrenme işlenmemiş verilerden önemli özellikleri otomatik olarak öğrenmeye çalışan algoritmalar dizisidir. Temeli yapay sinir ağlarındaki yapay bir sinir hücresi modeline dayanmaktadır. Derin sinir ağları (DNN) temel olarak girdi, gizli ve çıktı katmanları olarak modellenmiş yapay sinir hücreleri adı verilen nöronlardan oluşur. Birden çok gizli katmandan oluşması geleneksel sinir ağlarından ayıran önemli bir farktır (Farman vd., 2019).

Derin sinir ağlarının hiyerarşik yapısı çoklu soyutlama seviyelerinde özellik

öğrenmelerine izin vermektedir. İlk katmanlarda temel özellikler öğrenilerek, daha derin katmanlarda daha üst düzey kavramlar öğrenilebilmektedir. Görüntü, ses, metin özellikleri içeren verilere doğrudan uygulanabilmektedir (Hinton vd., 2015). Şekil 3.5'te girdi katmanı, üç adet gizli katmanları ve çıktı katmanından oluşan bir derin sinir ağı örneği verilmektedir.




Şekil 3.5. Üç gizli katmanlı sinir ağı örneği

Derin öğrenmenin birçok alanda kullanılması ile birlikte bu alanda ImageNet gibi yarışmalar düzenlenmeye başladı. Görüntüler üzerinde yapılan bu yarışmalarda gün geçtikçe hata oranı oldukça azaltan modeller sunulmaktadır. Çok fazla sayıda görüntüden görüntü nitelikleri çıkartmak ve bununla beraber görselleri sınıflandırmak için evrişimli sinir ağı kullanıldı (Krizhevsky vd., 2012).

3.4 Evrişimli Sinir Ağları

Nesne tespiti, sınıflandırılması problemini çözmek üzere özelleşmiş bir derin öğrenme mimarisi olan evrişimli sinir ağları CNN olarak kısaltılmaktadır (Fukushima, 1980). En temel özelliği evrişim katmanları içeren bir model olmasıdır. CNN modeli ihtiyaca göre evrişim katmanı, havuzlama katmanı gibi katmanları içerip bunların sayıları artırılıp azaltılabilir. Şekil 3.6'de evrişim, havuzlama ve tam bağlantı katmanlarını içeren bir CNN mimarisi örneği sunulmaktadır (Bongulwar, 2021).



Şekil 3.6. CNN Mimarisi

Kaynak: (Karaođlan, 2022)

3.4.1 Transfer Öğrenimi

Transfer öğrenme yaklaşımı, makine öğrenmesi algoritmalarında çözülen probleme dair elde edilen bilginin depolanması ve bu bilginin farklı türde uygulamalarda kullanılması üzerine odaklanmaktadır. Transfer öğrenme, öğrenilen bilginin yeni problemlerde etkili bir şekilde kullanılmasını sağlamaktadır (Palakodati vd., 2020).

Bu yöntem, eğitilen bir ağda bilgilerin, farklı bir ağ ve veri kümesinin eğitimi için kullanılmaktadır. Transfer öğrenme, önceki bilgilerden faydalanarak az eğitim verisi ile yüksek başarı ve hızlı öğrenme modeli elde etmeyi amaçlamaktadır. Uygulamalarda genellikle sıfırdan bir CNN modeli eğitmek nadirdir, çünkü bu, yeterli büyüklükte bir veri kümesine sahip olmayı veya eğitimi zorlaştıran diğer zorlukları içerir. Bu nedenle, CNN genellikle büyük boyutlu önceden eğitilmiş veri setleri kullanılarak önceden eğitilir ve daha sonra mevcut veri setinde kullanılır. Eğitim için seçilen veri setinin, eğitilecek veri setiyle uyumlu veya benzer olması başarıyı artırabilir (Çoban, 2023).

3.4.1.1 AlexNet

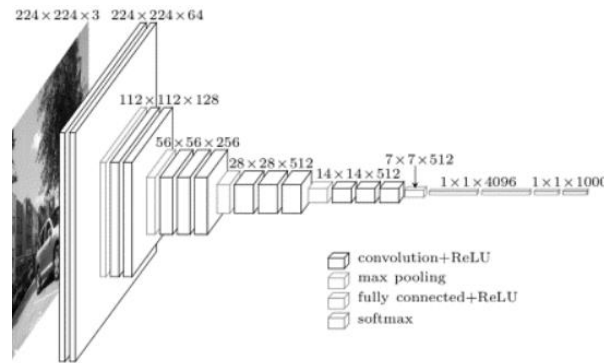
AlexNet, 2012 Büyük Ölçekli Görsel Tanıma Yarışması kazanan (Krizhevsky vd., 2012) bir evrişimli ağ mimarisidir. Bu yarışma, araştırma ekiplerini birbirlerine karşı getirerek birçok görsel tanıma zorluğunda doğruluğu artırmayı hedeflemektedir. Bu bağlamda, modellerini geniş bir etiketli görüntü koleksiyonu olan ImageNet üzerinde test etmişlerdir. ImageNet, yaklaşık 15 milyon yüksek çözünürlüklü etiketli fotoğraf içeren bir görüntü veritabanıdır.

AlexNet'in mimarisinde toplamda sekiz ağırlıklı katman bulunmaktadır; bunların beşi evrişimli katmanlar, üçü ise tam bağlantılı katmanlardan oluşmaktadır. Ardışık her katmanın

sonunda ReLu aktivasyonu kullanılarak, nihai katmana kadar olan süreçte bir softmax dağılımı üretilmekte ve bin sınıflı etiketlere uygulanmaktadır. İlk iki bağlantılı katmanda dropout işlemi uygulanmıştır. Ayrıca, ilk, ikinci evrişimli katmanların yanı sıra beşinci evrişimli katmandan sonra max-pooling işlemi gerçekleştirilmiştir (Al-Mahdi, 2023).

3.4.1.2 VGG

AlexNet prensipleriyle benzer şekilde üretilen bu ağ mimarisi $224 \times 224 \times 3$ boyutlarındaki RGB formatındaki resimleri girdi olarak almaktadır. 3×3 boyutundaki filtreler evrişim katmanında kullanılmaktadır. 2014’de sunulan VGG-16 mimarisi 13 tanesi evrişim, 3 tanesi tam bağlantı olmak üzere toplamda 16 katmandan oluşmaktadır. Mimarinin son katmanında softmax sınıflandırıcısı kullanılmaktadır. VGG-19 mimarisine VGG-16 mimarisinden farklı olarak 3 evrişim katmanı daha eklenerek 16 tanesi evrişim katmanı olmak üzere toplam 19 katman olarak tasarlanmıştır (Simonyan vd., 2014). Şekil 3.7’de VGG mimarisinin katmanları sunulmaktadır.




Şekil 3.7 VGG mimarisi

Kaynak: (Doğan ve Türkoğlu, 2018)

3.4.1.3 GoogleNet (Inception)

Oxford’un sunduğu mimarilerden daha çok katmana sahip olan Inception olarak da adlandırılan GoogleNet’in daha hızlı bir derin öğrenme modeli sunduğu görülmektedir. (Liu, S., & Deng, W., 2015). Toplam 144 katmandan oluşan mimarinin evrişim katmanlarında 1×1 , 3×3 , 5×5 boyutlarında filtreler kullanılmaktadır. Mimari havuzlama, tam bağlantı katmanlarını da barındırmaktadır. Geliştirilme amacı az maliyetle hesaplama ve yüksek performanstır. Diğer mimarilerde filtreleme işlemleri sıralı uygulanırken bu modelde modül adı verilen işlemler aynı anda filtreleme yapılmaktadır. Şekil 3.8’de modüllerin mimarisi verilmektedir.




Şekil 3.8 GoogleNet Boyut Azaltma Modülü

Kaynak: (Doğan ve Türkoğlu, 2019).

3.4.1.4 Inception-V3

Guan vd. (2019), gerçekleştirdiği deneylerde transfer öğrenme yöntemlerinden inception-v3 ağ mimarisini kullanmıştır. InceptionV3 mimarisi 3 tür inception modülü içeren çok katmanlı bir modeldir. Şekil 3.9’de modelin katmanları verilmiştir (Dong vd., 2020). Inception A, inception B, inception C modülleri verinin özelliklerini ayırt edebilirken, bitki sınıflandırma çalışmalarında etkili sonuçlar verdiği gözlemlenmiştir (Xia vd., 2017). Google tarafından geliştirilen transfer öğrenme yöntemlerinin kullanımını sağlayan tensorflow kütüphanesinin (Kumar vd., 2022) esnekliği yüksektir. Derin öğrenme kütüphanelerinden tensorflow görüntü tanıma ve sınıflandırma görevlerinde derin öğrenme tabanlı çalışmalara olanak sağlamıştır (Kumar vd., 2022).

Özellik çıkarmada da kullanılabilen Şekil 3.9’da mimarisi verilen Inception-V3 modelinin katmanlarını evrişim, maksimum havuzlama, birleştirmeler, bırakmalar, tam bağlantı ve ortalama havuzlama katmanları oluşturmaktadır (Chugh vd.,2020). Bu mimarinin özellik çıkartmanın etkinliğini arttırdığı ve görüntünü özelliklerini anlamasına yardımcı olduğu gözlemlenmiştir. (Lee vd., 2017).



Şekil 3.9. Inception-V3 Ağ Mimarisi

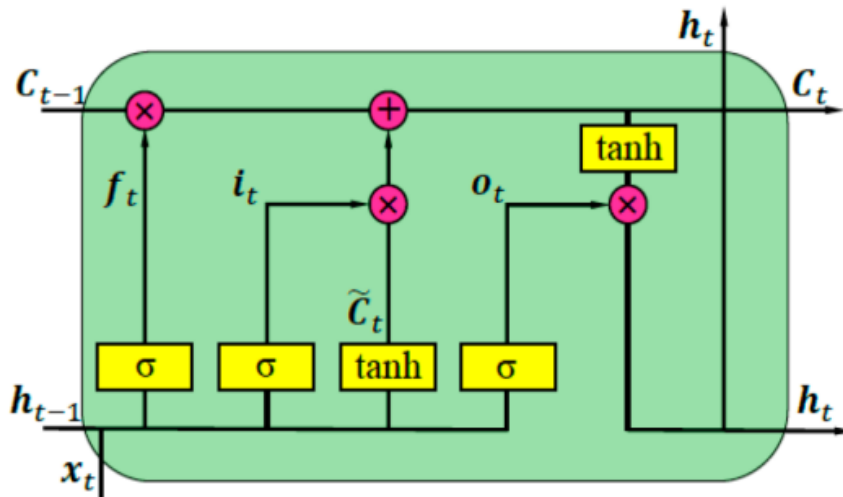
Kaynak: (Dong vd., 2020)

3.4.1.5 MobileNet-V2

Howard vd. (2017) tarafından tanımlanan MobileNet mimarilerinden ilk versiyon, birinci katmanda, bir adet derinlik tabanlı evrişim gerçekleştirilmekte sonrasında ilgili versiyonda bir adet 1×1 boyutlu noktadan noktaya evrişim katmanını eklenmektedir. Noktadan noktaya evrişim katmanını, her görüntü kanalının tek bir filtre çıktısını bir araya getirmektedir. Tüm işlemler tek bir blok içinde tamamlanmakta ve MobileNet-V1 mimarisinde toplamda 13 bu tür blok bulunmaktadır. MobileNet-V2'de ise, tek bir blok, iki evrişim katmanını yerine bir genişletme katmanını (1×1), bir derinlik tabanlı evrişim katmanını (3×3) ve bir projeksiyon katmanını (1×1) içermektedir. MobileNet-V2 yapısı toplamda 17 blok içermektedir. Barman vd. (2020) tarafından yapılan çalışmada narenciye yaprak hastalıklarının sağlıklı narenciye yapraklarından ayırmak için MobileNet-V2 mimarisini kullanılmıştır. MobileNet-V2'nin geleneksel CNN mimarilerine göre çok daha hızlı çalıştığı gözlemlenmiştir (Howard vd., 2017).

3.4.2 LSTM

LSTM, bir RNN türü olup uzun vadeli bağımlılıkları anımsayabilme özelliğine sahiptir. Katmanlar halinde kullanıldığında, LSTM'lerin CNN'in özellik çıkarma kapasitesini artırma yeteneği kanıtlanmıştır (Aditi ve Poovammal, 2019). LSTM, RNN'de eksiklik olarak görülen uzun vadeli bağımlılıkları yakalama konusunda son derece etkilidir (Turkoglu vd., 2019). Şekil 3.12'de unutmaya kapısı içeren bir LSTM mimarisinin yapısı sunulmaktadır.




Şekil 3.10. Uzun kısa süreli hafıza mimari yapısı

Kaynak: (Kara, 2019)

3.4.3 BiLSTM

Yinelemeli Sinir Ağları (RNN), giriş verisini sırayla işlerken, her adımın girdisi olarak bir önceki adımın çıktısını kullanarak bir yapay sinir ağı türüdür. Uzun Kısa Süreli Bellek (LSTM), RNN'nin bir türüdür ve farklı olarak, tek bir nöron katmanı yerine 4 kapı olarak adlandırılan katmanlardan oluşan bir yapıya sahiptir (Hochreiter ve Schmidhuber,1997). BiLSTM ise, çift yönlü bilgi çıkarımını sağlamak amacıyla ileri ve geri yönde her iki yönde ilerleyen iki LSTM yapısından oluşur. Standart LSTM'den farklı olarak, giriş hem ileri hem de geri yönde akar ve her iki yönden gelen bilgiyi etkili bir şekilde kullanabilir. Bu bağlamda, Bidirectional Long Short-Term Memory Networks (BiLSTM) son zamanlarda farklı uygulamalarda büyük bir ilgi görmüştür (Woźniak, vd., 2023). Başka bir ifadeyle, veri giriş dizisi verildiğinde, BiLSTM modeli önce giriş verilerini bir LSTM modeline (geri besleme katmanı-feed backward) besler ve ardından eğitimi giriş verisinin ters sırasındaki başka bir LSTM modeli üzerinden tekrarlar (Siarni-Namini vd., 2019).

LSTM (Şekil 3.11 (a)), uzun giriş verilerini hatırlamak için tanıtılmıştır ve bu nedenle uzun giriş verileri ile çıkış arasındaki ilişki, ek bir boyuta göre (örneğin, zaman veya mekansal konum) açıklanır (Hochreiter ve Schmidhuber,1997). Derin çift yönlü LSTM'ler (BiLSTM) ağları (Schuster ve Paliwal,1997), normal LSTM'lerin bir varyasyonudur (Şekil 3.11 (b)). Bu modellerde istenen yapı, sadece girişlerden çıkışlara değil, aynı zamanda çıkışlardan girişlere doğru eğitilir.



Şekil 3.11. LSTM, BiLSTM Farklı Versiyonları
Kaynak: (Siarni-Namini vd., 2019)

4. MATERYAL VE YÖNTEM

Tez kapsamında iki veri seti üzerinde farklı derin öğrenme yöntemleriyle kiraz yapraklarında hastalık teşhisi yapılmıştır. Tüm yöntemler Google Colab üzerinde 25 GB RAM kapasitesi bulunan, T4 GPU kullanılarak çalıştırılmıştır. Bu tezde, Python 3 programlama dili kullanılarak ve Google Compute Engine altyapısı üzerine inşa edilmiş bir kod geliştirilmiştir. Bu bölümün devamında çalışma sürecinde kullanılan materyal ve yöntemler hakkında detaylar sunulmaktadır.

4.1 Kullanılan Veri Setleri

Bu çalışma kapsamında PlantVillage veri seti kullanılırken bunun yanı sıra Eskişehir Kozlu köyü kiraz bahçelerinden elde edilen kiraz yapraklarından da yeni bir veri seti oluşturulmuştur. Oluşturulan veri setinin çeşitliliğini artırmak ve modellerin genelleme yeteneğine katkı sağlamak için, PlantVillage'den (Mohanty vd, 2016) elde edilen külleme sınıfına ait görüntüler, literatür araştırmaları sonucunda oluşturduğumuz yeni veri setine eklenmiştir.

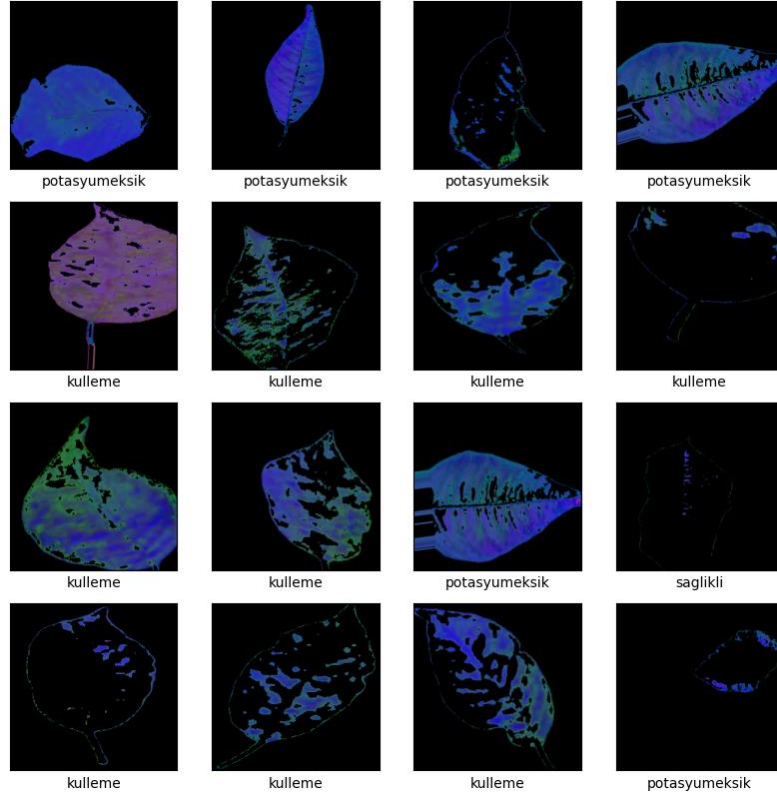
4.1.1. PlantVillage Veri Seti

PlantVillage (Mohanty vd, 2016) 14 farklı tür ve 38 ayrı kategoriye ayrılmış yaklaşık 54,000 sağlıklı yaprak ve hastalık vakası görüntüsünü içeren bir açık kaynak veri setidir. Güvenilir bir görüntü sınıflandırma sistemi oluşturabilmek için doğrulanmış büyük bir veri setine ihtiyacını karşılamak için PlantVillage adında bir proje başlatılmış ve binlerce bitki görüntüsü, sağlıklı ve hasta olanlar dahil olmak üzere toplanmıştır (Mohameth vd., 2020). Bu veri seti üzerinde 2 sınıflı sadece külleme hastalığına sahip yapraklar ve sağlıklı yapraklar üzerinde deneyler yapılmıştır. Eğitim sınıfında 1866 sağlıklı 1683 külleme hastalığına sahip yaprak bulunuyor. Doğrulama sınıfında 456 sağlıklı 421 külleme etiketine sahip yaprak bulunuyor.

4.1.2. Kozlu Veri Seti

Kozlu veri seti, Eskişehir Kozlu Köyü'nde kiraz bahçelerinden toplanan görseller ile elde edilmiştir. Bu çalışma kapsamında birer gün ara ile binlerce kiraz yaprağı fotoğraflanmıştır. Elde edilen fotoğraflar Ziraat mühendisi tarafından etiketlenmiştir. Toplamda 3 sınıftan oluşan bu model için külleme hastalığı PlantVillage veri setinden alınarak veri çeşitliliği artırılmıştır. Potasyum eksikliğine sahip yapraklar, külleme hastalığına sahip yapraklara ek olarak sağlıklı yapraklarda veri setinde bulunmaktadır. Oluşturulan veri setinde

külleme hastalığına ait 478, potasyum eksikliği olan yapraklara ait 480, sağlıklı yapraklara ait 480 görüntü olmak üzere toplam 1438 görüntü bulunmaktadır. Şekil 4.1’de görüntü işleme adımlarından sonra elde edilen Kozlu veri setine ait örnek görüntüler verilmektedir. Çalışmalarda eğitim veri setine veri artırma uygulanmıştır. Artırılmış örnek sayısı 7898’dir. Yüzde 9 oranında test veri setine ayrılmıştır.



Şekil 4.1 Kozlu veri seti 3 sınıflı örnek görüntüler

4.2 Kullanılan Derin Öğrenme Yöntemleri

Bu çalışma kapsamında çeşitli derin öğrenme yöntemleri kullanılarak model geliştirilmiştir. Geliştirilen modeller arasında AlexNet, VGG-16, Inception-V3, MobileNet-V2, CNN + LSTM, ve CNN + BiLSTM yer almaktadır. Her biri, farklı özellikleri ve avantajlarıyla öne çıkan bu derin öğrenme yöntemleri, çalışmanın amacına uygun olarak seçilmiş ve uygulanmıştır. Bu çeşitli derin öğrenme yöntemleri, modelin geniş bir veri yelpazesinde etkili performans sergileme kapasitesini artırmayı hedeflemektedir.

4.2.1 AlexNet Tabanlı Mimari

Bu çalışma, nesne sınıflandırma problemlerini çözmek amacıyla AlexNet benzeri bir derin öğrenme modelinin eğitimi ve değerlendirilmesi üzerine odaklanarak yeni katmanlar

eklenerek deney yapılmıştır. İlk adımda, gerekli Python kütüphaneleri ve modülleri içe aktarılır, veri işleme ve model oluşturma işlemleri için hazırlık yapılır.

Veri kümesi, eğitim, doğrulama ve test verileri olarak ayrılır ve ilgili dizinler belirlenmiştir. Eğitim verilerinin çeşitliliğini artırmak için çeşitli veri artırma işlemleri (örneğin, döndürme, kaydırma, parlaklık ayarı) uygulanmıştır. Eğitim verileri ve etiketleri, bu artırılmış veri setini kullanarak yüklenir ve verinin bir alt kümesi görsel olarak incelenir. Sınıf etiketleri listelenir ve doğrulama verisi için bir veri jeneratörü oluşturulur. Test verileri, ilgili dizinden yüklenir ve boyutlandırılır. Ayrıca, test verileri normalize edilir.

Eğitim sürecini izlemek ve optimize etmek için çeşitli Keras geri çağırma işlevleri (Erken Durdurma, Öğrenme Oranı Azaltma, Model Kontrol Noktası) tanımlanmıştır. Eğitim ve doğrulama süreçleri izlenerek ve sonuçlar görselleştirilmiştir. Modelin performansı, doğrulama veri seti üzerindeki kayıp ve doğruluk değerleri ile değerlendirilmiştir. Elde edilen sonuçlar, modelin sınıflandırma yeteneği hakkında önemli bilgiler sunmakta ve nesne tanıma görevlerinde başarılı bir şekilde kullanılabilinmektedir.

4.2.2 VGG Tabanlı Mimari

Bu çalışmada VGG-16 transfer öğrenme modeli özelleştirilerek kullanılmıştır. Çalışmanın metodolojisi, önceden eğitilmiş bir VGG-16 modelinin transfer öğrenme yöntemi ile kullanılmasını içermektedir. İlk olarak, VGG-16 modeli ImageNet veri kümesi üzerinde önceden eğitilmiş ağırlıklarla içe aktarılmış ve sınıflandırma katmanı hariç tutulmuştur. Giriş verilerinin boyutu belirlendikten sonra öğrenilmiş ağırlıkların değişmeden kalmasını sağlamak amacıyla VGG-16 modelinin eğitilebilirliğini devre dışı bırakılmıştır. Ardından düzleştirme, tam bağlantılı ve sınıflandırma yeni olmak üzere mimariye yeni katmanlar eklenmiştir.

4.2.3 Inception-V3

Bu çalışmada Kozlu veri seti kullanılarak inception-v3 mimarisinin sonuna global ortalama havuzlama katmanı, tam bağlantı katmanları eklenmiştir. Eklenen yeni sınıflandırma katmanları ile inception-v3 mimarisini birleştirilerek yeni bir model oluşturulmuştur. Transfer öğrenmeyi etkinleştirmek için Inception-V3 modelinin katmanlarını dondurarak, bu katmanların öğrenmelerini devre dışı bırakılmıştır. Inception-V3 modelinde, transfer öğrenmeyi başlatmak için kullanılan katmanlar dondurulmakta yani, bu katmanların içindeki ağırlık değerleri eğitim sırasında güncellenmemektedir. Bu sayede, modelin önceden öğrenilmiş bilgileri korunabilmektedir. Eğitim aşamasında modelin tez kapsamında

özelleştirilen versiyonunda eklenen katmanlar güncellenmektedir. Optimizasyon yöntemi olarak Adam kullanılmış ve kayıp fonksiyonu olarak kategorik çapraz entropi seçilmiştir. Eğitim sonunda model, verilen görüntülerin sınıflarını tahmin etmek için kullanılmıştır.

4.2.4 MobileNet-V2

Bu çalışmada Google Colab ortamında Google Drive'a erişim sağlanarak kod çalıştırılmıştır. Kütüphanelerin ve veri yolunun içe aktarımı için Tensorflow (Kumar vd., 2022) kütüphanesi kullanılmıştır. Modelin eğitileceği veri yollarını, görüntülerin boyutunu, veri arttırma (Ramanjot vd., 2023) parametrelerini epoch sayısını ve sınıf sayısı tanımlanmıştır. Veri arttırma ve ön işleme bölümünde eğitim verilerinin veri arttırma işlemleri ile nasıl hazırlandığını gösterilir. Veri arttırma eğitim verisini çeşitlendirmek ve modelin genelleme yeteneğini artırmak amacıyla uygulanmıştır. Önceden eğitilmiş MobileNet-V2 mimarisi kullanılarak model yüklenmiştir. Bu model geniş özellik çıkartma yeteneklerine sahiptir. Modelin ağırlıkları dondurulup, eklenen sınıflandırma katmanları eğitilmiştir. Transfer öğrenme önceden eğitilmiş bir modele yeni son katmanlar eklenerek sınıflandırma içermektedir. Bu çalışmada Mobilenet-V2 modelinin sonuna global ortalama havuzlama katmanı sırayla 128,64 nöron içeren iki tam bağlantı katmanı eklenmiştir. Her tam bağlantı katmanının ardından bir normalleştirme (batch normalizasyon) katmanı ve bırakma (dropout) katmanı eklenmiştir. Yapılan çalışmada optimize edici olarak Adam fonksiyonu kullanılmıştır. Kayıp fonksiyonu olarak "categorical_crossentropy" tercih edilmiştir. Eğitim verisinde belirtilen adımda epoch değerine 30 verilerek eğitim yapılmıştır. Doğrulama verisi ile verinin performansı değerlendirilmiştir.

4.2.5 CNN

Bu bölümde, görüntü sınıflandırma için bir derin öğrenme modeli olan Evrişimli Sinir Ağı (CNN) tasarlandı ve eğitildi. Model, TensorFlow ve Keras kütüphaneleri kullanılarak oluşturuldu. Veri arttırma işlemi için eğitim veri setine her bir orijinal görüntü için 10 farklı arttırılmış görüntü oluşturuldu. Bu arttırma işlemleri görüntüler üzerinde döndürme, kaydırma, eğme, yakınlaştırma, yatay çevirme gibi rastgele dönüşümleri içerir. İlk olarak, modelin yapısı belirlendi. Giriş katmanı olarak bir evrişim katmanı eklenmiştir. Bu katman, 3x3 boyutlu filtrelerle 32 özellik haritası üretiyor ve ReLU aktivasyon fonksiyonu kullanıldı. Ardından, resim boyutlarını küçültmek ve aşırı uyumu önlemek için %20 dropout uygulamak amacıyla MaxPooling2D katmanı ekledik. Benzer şekilde, ikinci ve üçüncü Evrişimli Katmanlar eklenerek, MaxPooling2D ve Dropout katmanları kullanılarak özellik haritaları küçültüldü ve

aşırı uyumu önlemek için işlemler gerçekleştirildi. Bu Evrişimli Katmanlar'dan sonra, Flatten katmanı ile düzleştirme yapıldı ve ardından tam bağlantılı katmanlar eklendi. Bu katmanlar, sırasıyla 64, 128 nöronlarını içeriyor. Aktivasyon fonksiyonları olarak ReLU kullanıldı ve sınıflandırma işlemi için son katmanda softmax aktivasyon fonksiyonu tercih edildi. Modelin eğitim aşamasında, öğrenme oranı (learning_rate) 0.001 olarak belirlendi ve Adam optimizasyon algoritması tercih edildi. Kayıp fonksiyonu olarak kategorik çapraz entropi (categorical_crossentropy) seçilirken, metrik olarak doğruluk (accuracy) oranı kullanılmıştır

4.2.6 CNN + LSTM


Bu çalışmada Python kodu, görüntü işleme ve derin öğrenme yöntemlerini kullanarak bitki yaprakları üzerindeki hastalıkları sınıflandırmak için geliştirilmiştir. Kod, OpenCV, TensorFlow ve diğer ilgili kütüphaneleri içermektedir.

İlk olarak, veri kümesi yüklenir ve veri artırma işlemi uygulanır. Veri artırma, eğitim verilerini çeşitlendirmek için görüntü döndürme, kaydırma, büyütme/küçültme ve yatay yansıtma gibi teknikleri içermektedir. Ardından, veri kümesi sınıflara ayrılır ve renk uzayı dönüşümleri yapılmaktadır. Kahverengi lekeleri vurgulamak için görüntüler üzerinde işlemler gerçekleştirilmiştir.

Veri kümesindeki hastalıkları sınıflandırmak için kullanılmak üzere özelleştirilmiş bir derin öğrenme modeli inşa edilir. Model, bir dizi evrişimli sinir ağı (CNN) ve uzun-kısa süreli hafıza (LSTM) katmanları içerir.

Veriler ilk olarak 32 adet 3x3 boyutunda filtre kullanan ve giriş boyutu [224, 224, 3] olan evrişim katmanına gönderilmektedir. İlk CNN katmanı, olarak belirtilir. CNN katmanları, görüntülerden özellikler çıkarmak için kullanılmaktadır. Ardından, max-pooling katmanı kullanılarak boyut küçültme işlemi yapılmış ve aşırı uyarlamayı önlemek için Dropout katmanı eklenmiştir. Bu katmanların hepsi üçer defa aynı sırayla sıralanmakta ve evrişim katmanları sırasıyla 32, 64 ve 128 adet filtre kullanırken tüm evrişim katmanları relu aktivasyon fonksiyonu kullanmaktadır. Kullanılan tüm max-pooling katmanları 2x2, dropout katmanları sırasıyla 0,2 , 0,2 ve 0,4 olarak ayarlanmıştır.


Buradan çıkan veriler uygun boyutlandırma yapıldıktan sonra 128 hücreli LSTM katmanına iletilmektedir. Modelin sonunda softmax aktivasyon fonksiyonunu içeren tam bağlantı katmanı kullanılarak sınıflandırma işlemi tamamlanmaktadır.



Şekil 4.2 Çalışmadaki CNN + LSTM mimarisi

4.2.7 CNN + BiLSTM

Önerilen bu yöntemde de CNN + LSTM yönteminde kullanılan katmanlar, parametreler, LSTM katmanı yerine BiLSTM katmanı kullanılması dışında aynen kullanılmıştır. BiLSTM katmanı 128 hücreli kullanılmıştır.



Şekil 4.3 Çalışmadaki CNN + BiLSTM mimarisi

4.3 Başarı Metrikleri

Kullanılan derin öğrenme yöntemlerini kıyaslamak için doğruluk, hassasiyet duyarlılık ve F1-puanı metrikleri kullanılmıştır. Bu metriklerin hesaplanabilmesi için öncelikle karmaşıklık matrisinden elde edilen doğru pozitif, yanlış negatif, yanlış pozitif, doğru negatif değerleri çıkarılmıştır. Şekil 4.2’de örnek bir karmaşıklık matrisinde ilgili değerlerin görünümü verilmektedir.

		Tahmin Edilen (Predicted)	
		Doğru Pozitif (DP)	Yanlış Negatif (YN)
Gerçekleşen (Actual)	Doğru Pozitif (DP)		
	Yanlış Pozitif (YP)		

Şekil 4.4 Karışıklık Matrisi (Confusion Matrix)

Kaynak: (Sulistyowati vd., 2023)

Doğru Pozitif (DP): Sınıflandırıcı, sağlıklı bir yaprak örneğini doğru bir şekilde tanımlarsa, bu durum doğru pozitif olarak ifade edilmektedir. Örneğin, sınıflandırıcı, yaprak üzerinde herhangi bir hastalık belirtisi olmadığını doğru bir şekilde tespit ettiğinde, bu bir doğru pozitif durumu temsil eder. (Paymode ve Malode, 2022). Yaprak gerçekten külleme hastalığına sahip.

Doğru Negatif (DN): Sınıflandırıcı, sağlıklı bir yaprak örneğini doğru bir şekilde tanımlarsa, bu durumu doğru negatif olarak nitelendiririz. Örneğin, sınıflandırıcı, yaprak üzerinde herhangi bir hastalık belirtisi olmadığını doğru bir şekilde tespit ettiğinde, bu bir doğru negatif durumu ortaya koyar (Paymode ve Malode, 2022). Yaprak gerçekten külleme hastalığına sahip değil.

Yanlış Pozitif (YP): Gerçekte sağlıklı olan bir yaprak, sınıflandırıcı tarafından hastalıklı olarak yanlış bir şekilde etiketlendiğinde, bu durumu yanlış pozitif olarak adlandırabiliriz. Örneğin, yaprak üzerinde herhangi bir hastalık belirtisi olmadığı halde sınıflandırıcı tarafından hastalıklı olarak yanlış etiketlenen durum, bir yanlış pozitif durumu meydana getirebilir (Paymode ve Malode, 2022). Yaprak külleme hastalığıdır tahmini yapıldığında sağlıklı yaprak çıkması örnek verilebilir.

Yanlış Negatif (YN): Gerçekte hastalıklı olan bir yaprak, sınıflandırıcı tarafından sağlıklı olarak yanlış bir şekilde tahmin edildiğinde, bu durumu yanlış negatif olarak ifade ederiz. Örneğin, yaprak üzerinde belirgin hastalık belirtileri bulunmasına rağmen sınıflandırıcı tarafından sağlıklı olarak yanlış etiketlenen durum, bir yanlış negatif durumu oluşturabilir (Paymode ve Malode, 2022). Yaprak külleme hastalığı değildir diye tahmin edildiğinde gerçekten külleme hastalığı çıkması durumudur.

Elde edilen bu değerler sayesinde doğruluk, hassasiyet, duyarlılık, F1-puanı aşağıdaki eşitliklerde gösterildiği şekilde hesaplanmaktadır.

$$\text{Doğruluk (Accuracy)} = \frac{DP + DN}{DP + DN + YP + YN} \quad (5.1)$$

$$\text{Hassasiyet (Precision)} = \frac{DP}{DP + YP} \quad (5.2)$$

$$\text{Geri Çağırma (Recall)} = \frac{DP}{DP + YN} \quad (5.3)$$

$$\text{F1Puanı (F1Score)} = 2 \times \frac{\text{hassasiyet} \times \text{geri çağırma}}{\text{hassasiyet} + \text{geri çağırma}} \quad (5.4)$$

5. BULGULAR VE DEĞERLENDİRME

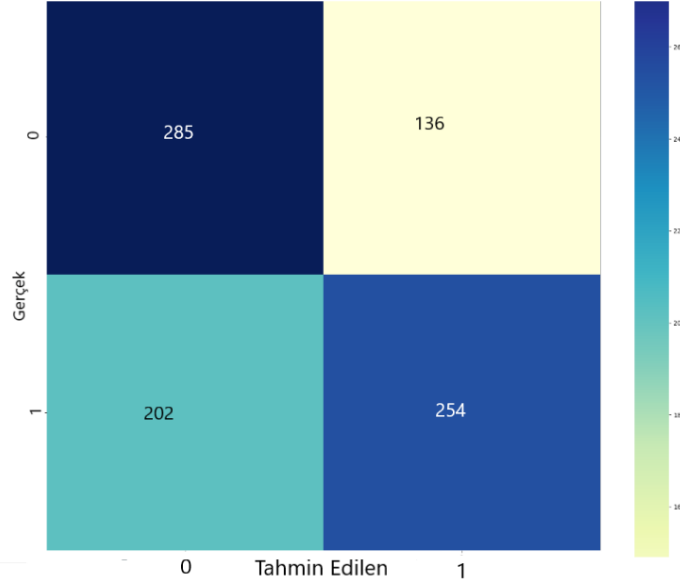
Bu bölümde tez kapsamında kullanılan iki veri seti üzerinde derin öğrenme yöntemleri kıyaslanarak, sonuçları açıklanmıştır. Kiraz bitkisi yapraklarında sağlıklı olanların ve külleme hastalığı olanların tespiti için PlantVillage veri setinde AlexNet, VGG-16, Inception-V3, MobileNet-V2 ve CNN modelleri, Kozlu veri setinde sağlıklı yapraklar, potasyum eksikliği olan ve külleme hastalığı olan yapraklar Inception-V3, MobileNet-V2, CNN, CNN + LSTM, CNN + BiLSTM yöntemleri ile tespit edilmiştir. PlantVillage veri setinde CNN + LSTM ve CNN + BiLSTM yöntemleri kullanılamamıştır çünkü Google colab ortamında kullanılan kaynaklardan RAM birimi yetersiz gelmiştir. Tüm derin öğrenme yöntemleri her iki veri setinde de 30 epoch 3 tekrar olarak çalıştırılmıştır

5.1 PlantVillage Veri Seti Sonuçları

PlantVillage veri seti kullanılarak elde edilen sonuçların sınıf bazlı doğruluk, keskinlik, duyarlılık, F1-puanları AlexNet tabanlı mimari için tablo 5.1’de, VGG-16 tabanlı mimari için tablo 5.2’de, Inception-V3 tabanlı mimari için tablo 5.3’te, MobileNet-V2 modeli için tablo 5.4’de, CNN tabanlı model için tablo 5.5’de verilmektedir. Benzer şekilde elde edilen karmaşıklık matrisleri AlexNet tabanlı mimari için şekil 5.1’de, VGG-16 tabanlı mimari için şekil 5.2’de, Inception-V3 tabanlı mimari için şekil 5.3’te, MobileNet-V2 modeli için şekil 5.4’de, CNN tabanlı model için şekil 5.5’de sunulmaktadır. 3 tekrarın sonucunda en iyi oranlar %99 doğruluk ile MobileNet-V2 modelinde en düşük oranlar %61 doğruluk ile AlexNet olduğu görülmüştür.

Tablo 5.1 PlantVillage veri seti AlexNet sınıf bazlı sonuçları

Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,6100	0,5900	0,6800	0,6300
Sağlıklı yaprak	0,6100	0,6500	0,5600	0,6000




Şekil 5.1. PlantVillage veri seti AlexNet tabanlı mimari karmaşıklık matrisi

AlexNet modeli doğruluk oranı yüzde 61 gibi düşük bir doğruluk oranında kalarak kıyaslanan yöntemler arasında en düşük başarıma sahip yöntem olmuştur.

Tablo 5.2 PlantVillage veri seti VGG-16 sınıf bazlı sonuçları

Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,9800	1,0000	0,9700	0,9850
Sağlıklı yaprak	0,9800	0,9700	1,0000	0,9850




Şekil 5.2. PlantVillage veri seti VGG-16 tabanlı mimari karmaşıklık matrisi

VGG-16 modeli eğitim tamamlanması PlantVillage veri setinde yaklaşık 3 saat boyunca eğitmiş ve oldukça uzun sürmüştür. Başarı oranı yüksek olmasına rağmen öğrenme süresi dolayısı ile Kozlu veri setinde bu model yerine diğer modeller tercih edilmiştir.

Tablo 5.3 PlantVillage veri seti Inception-V3 sınıf bazlı sonuçları

Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,9200	1,0000	0,8400	0,9100
Sağlıklı yaprak	0,9200	0,8700	1,0000	0,9300

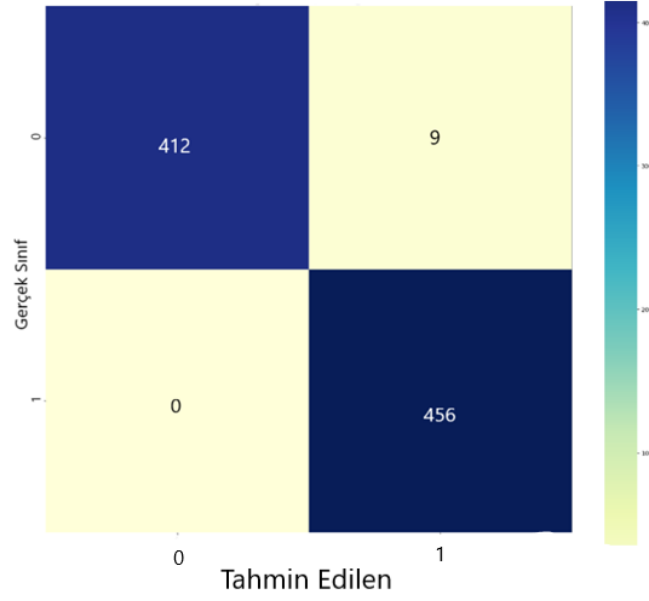


Şekil 5.3. PlantVillage veri seti Inception-V3 tabanlı mimari karmaşıklık matrisi

Tablo 5.3'teki PlantVillage veri setinde Inception-V3 modelinin sınıf bazlı sonuçları incelendiğinde, külleme hastalığı sınıfında %92,00 doğruluk, %100 kesinlik, %84,00 duyarlılık ve %91,00 F1-puanı elde edilirken; sağlıklı yaprak sınıfında ise %92,00 doğruluk, %87,00 kesinlik, %100 duyarlılık ve %93.00 F1-puanı elde edilmiştir.

Tablo 5.4 PlantVillage veri seti MobileNet-V2 sınıf bazlı sonuçları

Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,9900	1,0000	0,9800	0,9900
Sağlıklı yaprak	0,9900	0,9800	1,0000	0,9900

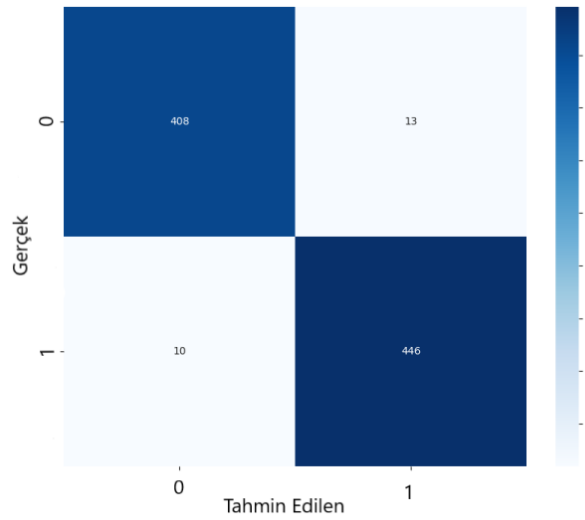


Şekil 5.4. PlantVillage veri seti MobileNet-V2 tabanlı mimari karmaşıklık matrisi

MobileNet yüzde 99 oranıyla yüksek bir doğruluk oranı elde etmiştir. Bu aynı zamanda kıyaslanan modeller arasında elde edilen en yüksek orandır.

Tablo 5.5 PlantVillage veri seti CNN sınıf bazlı sonuçları

Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,9700	0,9800	0,9700	0,9750
Sağlıklı yaprak	0,9700	0,9700	0,9800	0,9750



Şekil 5.5. PlantVillage veri seti CNN tabanlı mimari karmaşıklık matrisi

Kurulan üç evmişim katmanlı CNN modeli 421 hasta yapraktan 408 tanesini doğru tahmin etmiştir. Matristeki 1 sağlıklı yaprakları temsil ederken 0 değerleri hasta yaprakların bulunduğu sınıfı temsil etmektedir. Tablodaki sonuçlara göre, modelin performansı oldukça umut verici görülmektedir. Külleme hastalığı sınıfına ait verilerde doğruluk oranı %97, keskinlik %98, duyarlılık %97 ve F1-puanı ise %97,5 olarak ölçülmüştür. Sağlıklı yaprak sınıfında ise doğruluk oranı %97, keskinlik %97, duyarlılık %98 ve F1-puanı %97,5 olarak belirlenmiştir.

Tablo 5.6. PlantVillage veri setinde 3 tekrarlı elde edilen sonuçlar

Model		Doğruluk	Kayıp		F1-Puanı	Keskinlik	Duyarlılık
AlexNet	En kötü	0,5986	0,6875		0,5882	0,6193	0,5986
	Ortalama	0,6065	0,6883		0,6008	0,6194	0,6065
	En iyi	0,6145	0,6891		0,6135	0,6195	0,6145
VGG-16	En kötü	0,9817	0,2662		0,9817	0,9819	0,9817
	Ortalama	0,9828	0,2619		0,9828	0,9830	0,9828
	En İyi	0,9840	0,2577		0,9840	0,9842	0,9840
MobileNet-V2	En kötü	0,9914	0,0706		0,9874	0,9876	0,9875
	Ortalama	0,9897	0,0787		0,9817	0,9820	0,9818
	En iyi	0,9932	0,0626		0,9932	0,9932	0,9932
Inception-V3	En kötü	0,9247	0,3097		0,9241	0,9343	0,9247
	Ortalama	0,9190	0,3196		0,9182	0,9290	0,919
	En iyi	0,9133	0,3296		0,9124	0,9257	0,9133
CNN	En kötü	0,9738	0,0954		0,9700	0,9700	0,9700
	Ortalama	0,9732	0,0887		0,9700	0,9700	0,9700
	En iyi	0,9738	0,0959		0,9700	0,9700	0,9700

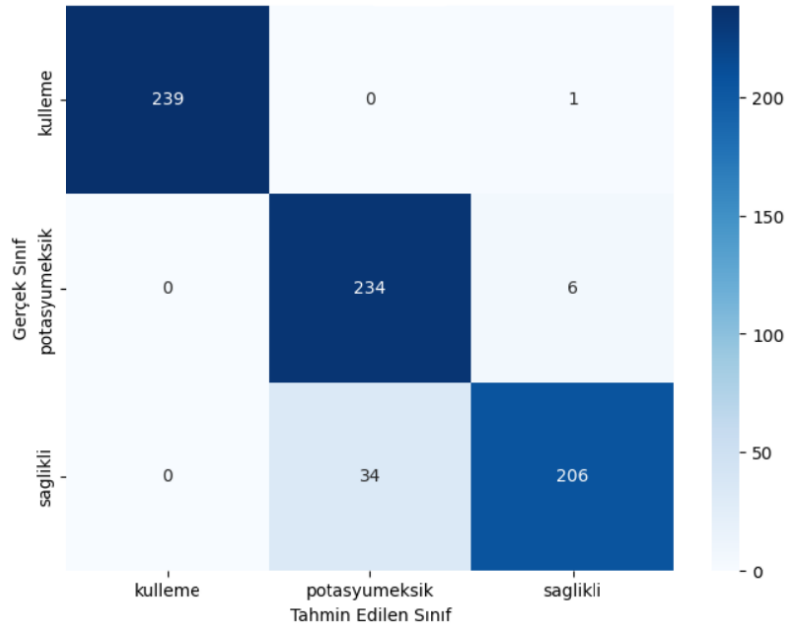
Tablo 5.6'deki PlantVillage veri setinde yapılan üç tekrarın sonuçları incelendiğinde, MobileNet-V2 modelinin en iyi performansı gösterdiği, en düşük doğruluk ve kayıp değerlerinin ortalamalarının yüksek olduğu gözlemlenmiştir. AlexNet modeli en düşük performanslı model olmuştur. Inception-V3 modeli MobileNet-V2'ye göre düşük doğruluk ve yüksek kayıp değerleriyle dikkat çekmiştir. CNN modeli ise genel olarak yüksek doğruluk ve düşük kayıp değerleriyle istikrarlı bir performans sergilemiştir. Bu sonuçlar, MobileNet-V2 modelinin öne çıktığını ve CNN modelinin kararlı bir performans gösterdiğini göstermektedir. Ancak Inception-V3 modelinin performanslarının diğer modellere göre daha geride kaldığı görülmektedir.

5.2 Kozlu Veri Seti Sonuçları

PlantVillage veri setinde elde edilen sonuçlara göre AlexNet doğruluk oranı düşük olduğundan Kozlu veri setinde değerlendirilmemiştir. Aynı zamanda VGG-16 modelinde eğitim süresi uzun sürdüğünden Kozlu veri setinde kıyaslama yapılmamıştır. Kozlu veri seti kullanılarak elde edilen sonuçların sınıf bazlı doğruluk, keskinlik, duyarlılık, F1-puanları Inception-V3 tabanlı mimari için tablo 5.7’te, MobileNet-V2 modeli için tablo 5.8’de, CNN tabanlı model için tablo 5.9’de, CNN + LSTM içeren model 5.10’de, CNN + BiLSTM içeren model tablo 5.11’te verilmektedir. Benzer şekilde elde edilen karmaşıklık matrisleri Inception-V3 tabanlı mimari için şekil 5.6’de, MobileNet-V2 modeli için şekil 5.7’de, CNN tabanlı model için şekil 5.8’de, CNN + LSTM içeren model için şekil 5.9’de, CNN + BiLSTM içeren model için şekil 5.10’te sunulmaktadır.

Tablo 5.7. Kozlu veri seti Inception-V3 sınıf bazlı sonuçları

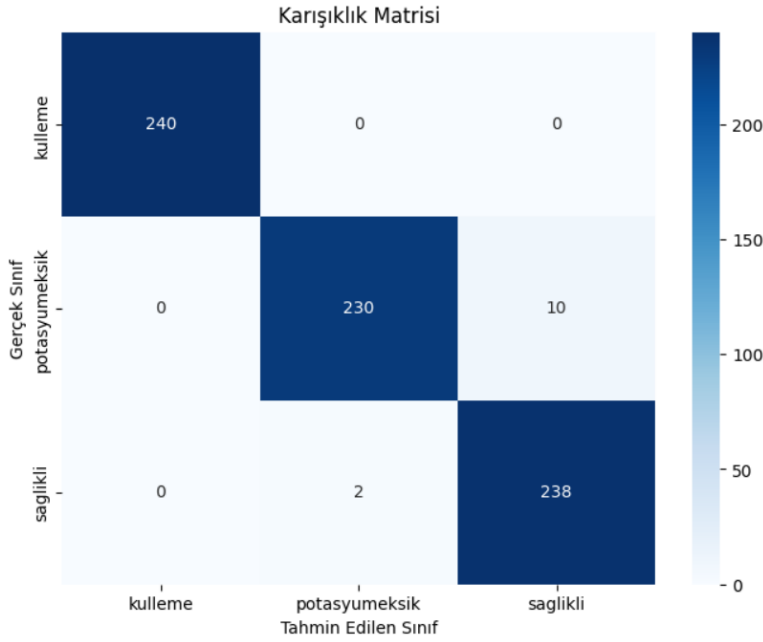
Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,9400	1,0000	0,9700	0,9850
Potasyum eksik hastalığı	0,9400	0,8700	0,9700	0,9200
Sağlıklı yaprak	0,9400	0,9700	0,8600	0,9100



Şekil 5.6. Kozlu veri seti Inception-V3 tabanlı mimari karmaşıklık matrisi

Tablo 5.8. Kozlu veri seti MobileNet-V2 sınıf bazlı sonuçları

Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,9800	1,0000	1,0000	1,0000
Potasyum eksik hastalığı	0,9800	0,9900	0,9600	0,9700
Sağlıklı yaprak	0,9800	0,9600	0,9900	0,9800



Şekil 5.7. Kozlu veri seti MobileNet-V2 tabanlı mimari karmaşıklık matrisi


Kozlu veri seti üzerinde gerçekleştirilen derin öğrenme yöntemlerinin performansını değerlendiren Tablo 5.6 ve Tablo 5.7, iki farklı mimari olan Inception-V3 ve MobileNet-V2 modellerinin sınıf bazlı sonuçlarını karşılaştırmaktadır. Her iki tablo da külleme hastalığı, potasyum eksik hastalığı ve sağlıklı yaprak sınıflarında doğruluk, keskinlik, duyarlılık ve F1-puanı metriklerini sunmaktadır.

MobileNet-V2 modeli, külleme hastalığı sınıfında mükemmel bir başarı elde ederek %100 doğruluk, keskinlik, duyarlılık ve F1-puanı elde etmiştir. Potasyum eksik hastalığı sınıfında yüksek doğruluk ve keskinlikle başarılı bir performans gösterirken, sağlıklı yaprak sınıfında da oldukça iyi bir performans sergilemiştir. Diğer yandan, Inception-V3 modeli de külleme hastalığı sınıfında %100 keskinlik elde etmiş ancak diğer metriklerde MobileNet-V2'nin gerisinde kalmıştır. Potasyum eksik hastalığı ve sağlıklı yaprak sınıflarında da

MobileNet-V2'ye göre daha düşük performans göstermiştir.

Tablo 5.9. Kozlu veri seti CNN sınıf bazlı sonuçları

Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,9600	0,9700	0,9900	0,9800
Potasyum eksik hastalığı	0,9600	0,9500	0,9400	0,9400
Sağlıklı yaprak	0,9600	0,9700	0,9500	0,9600




Şekil 5.8. Kozlu veri seti CNN tabanlı mimari karmaşıklık matrisi

Bu değerlendirmeler, modelin genel olarak yüksek doğruluk ve sınıflandırma başarısı gösterdiğini, özellikle külleme hastalığı sınıfında yüksek hassasiyet ve duyarlılık oranlarına sahip olduğunu göstermektedir.

Tablo 5.10. Kozlu veri seti LSTM sınıf bazlı sonuçları


Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,9600	0,9700	0,9900	0,9800
Potasyum eksik hastalığı	0,9600	0,9500	0,9400	0,9400
Sağlıklı yaprak	0,9600	0,9700	0,9500	0,9600



Şekil 5.9. Kozlu veri seti CNN+LSTM tabanlı mimari karmaşıklık matrisi

Tablo 5.11. Kozlu veri seti BiLSTM sınıf bazlı sonuçları

Sınıflar	Doğruluk	Keskinlik	Duyarlılık	F1-puanı
Külleme hastalığı	0,9700	0,9800	0,9200	0,9500
Potasyum eksik hastalığı	0,9700	0,9200	0,9800	0,9500
Sağlıklı yaprak	0,9700	1,0000	1,0000	1,0000



Şekil 5.10. Kozlu veri seti CNN+BiLSTM tabanlı mimari karmaşıklık matrisi

Tablo 5.10 ve 5.11 sonuçlarına göre, BiLSTM modeli genel olarak daha yüksek doğruluk, keskinlik, duyarlılık ve F1-puanı elde etmiştir. Özellikle, BiLSTM modelinin

külleme hastalığı sınıfındaki duyarlılık oranının daha düşük olduğu ancak diğer metriklerde üstün olduğu gözlemlenmektedir. Potasyum eksik hastalığı ve sağlıklı yaprak sınıflarında ise BiLSTM modeli daha dengeli bir performans sergilemiştir.

Tablo 5.12. Kozlu veri setinde 3 tekrarlı edilen sonuçlar

Model		Doğruluk	Kayıp	F1-Puanı	Kesinlik	Duyarlılık
MobileNet-V2	En kötü	0,9833	0,0453	0,9833	0,9833	0,9833
	Ortalama	0,9868	0,04315	0,9883	0,9883	0,9867
	En iyi	0,9903	0,0410	0,9933	0,9933	0,9900
Inception-V3	En kötü	0,9431	0,1951	0,9433	0,9466	0,9433
	Ortalama	0,9431	0,1832	0,9417	0,9450	0,9433
	En iyi	0,9431	0,1714	0,9400	0,9433	0,9433
CNN	En kötü	0,9597	0,1201	0,9600	0,9633	0,9600
	Ortalama	0,9597	0,1106	0,9583	0,9633	0,9600
	En iyi	0,9597	0,1012	0,9566	0,9633	0,9600
CNN + LSTM	En kötü	0,9625	0,1152	0,9600	0,9633	0,9633
	Ortalama	0,9646	0,1026	0,9634	0,9633	0,9650
	En iyi	0,9667	0,0901	0,9667	0,9633	0,9667
CNN + BiLSTM	En kötü	0,9611	0,1280	0,9600	0,9633	0,9600
	Ortalama	0,9632	0,1094	0,9633	0,9650	0,9633
	En iyi	0,9653	0,0907	0,9666	0,9666	0,9667

Tablo 5.12'te sunulan sonuçlar, farklı derin öğrenme modellerinin performansını değerlendirirken çeşitli metrikler kullanarak elde edilen bilgileri içermektedir. Bu metrikler arasında doğruluk, kayıp, F1-puanı, kesinlik ve duyarlılık yer almaktadır. İncelenen modeller arasında MobileNet-V2, en üst düzeyde performans gösteren model olarak öne çıkmaktadır. En iyi durumda, MobileNet-V2 modelinin doğruluğu %99,03, kayıp %0,0410, F1-puanı %99,33, kesinlik %99,33 ve duyarlılık %99,00 olarak ölçülmüştür.

Diğer modellerin en iyi durumda elde ettikleri sonuçlar da dikkate değerdir. Inception-V3 modeli %94,31 doğruluk, %0,1714 kayıp, %94,00 F1-puanı, %94,33 kesinlik ve %94,33 duyarlılık ile başarılı bir performans sergilemiştir.

Ayrıca, CNN, CNN + LSTM ve CNN + BiLSTM modelleri de benzer şekilde yüksek performans göstermiştir. Ancak, değerlendirme kriterlerine göre MobileNet-V2 modelinin en üst düzeyde başarı elde ettiği söylenebilir.

6. SONUÇ VE ÖNERİLER

Bu tez çalışması, kiraz yapraklarındaki hastalıkların tespit ederek tarımsal üretimde erken teşhis gerçekleştirerek üretimdeki verimi arttırmak amacıyla gerçekleştirilmiştir. Çalışmada PlantVillage ve Eskişehir Kozlu Köyü'ndeki kiraz tarlalarından elde edilen görüntülerle oluşturulan Kozlu veri setleri kullanılmıştır. PlantVillage veri setinde AlexNet, VGG-16, Inception-V3, MobileNet-V2 ve CNN modelleri, Kozlu veri setinde ise Inception-V3, MobileNet-V2, CNN, CNN + LSTM ve CNN + BiLSTM modelleri kullanılarak yapraklarda hastalık teşhisi gerçekleştirilmiş ve yöntemlerin başarımları birbirleri ile karşılaştırılmıştır.

PlantVillage veri setinde AlexNet modeli %61 doğruluk oranı ile en kötü sonucu verdiğinden, VGG-16 modeli yüksek başarı elde etmesine rağmen eğitim süresi uzun olduğundan dolayı Kozlu veri seti üzerinde uygulaması yapılmamıştır. Inception-V3 modeli yüksek doğruluk oranına sahip olup, MobileNet-V2 en yüksek doğruluk oranına ulaşarak diğer modelleri geride bırakmıştır. Çalışmada önerilen modellerden biri olan CNN modeli hem külleme hastalığı hem de sağlıklı yaprakları yüksek doğruluk oranlarıyla sınıflandırmıştır.

Kozlu veri setinde ise Inception-V3, MobileNet-V2, CNN, LSTM ve BiLSTM modelleri incelenmiştir. MobileNet-V2 ve CNN modelleri yüksek doğruluk oranlarına ulaşarak başarılı sonuçlar elde etmiştir. Özellikle MobileNet-V2 modeli tüm sınıflarda en yüksek başarıyı göstermiştir. CNN + LSTM ve CNN + BiLSTM modelleri de iyi sonuçlar elde etmiş ancak bazı sınıflarda diğer modellere göre daha düşük performans sergilemiştir. CNN katmanlarının sonuna LSTM veya BiLSTM katmanının eklenmesinin başarımları arttırdığı gözlemlenmiştir.

CNN + LSTM ve CNN + BiLSTM modellerinin yüksek RAM kaynağı gerektirmesinden PlantVillage veri setinde Google Colab ortamındaki sınırlı RAM kaynakları nedeniyle kullanılamamış olması çalışmanın bir limitasyonu olmuştur. Kozlu veri setini oluştururken kullanılacak bahçe sayısının azlığı da çalışmanın bir diğer kısıtı olmuştur. Gelecekteki çalışmalarda, daha büyük ve çeşitli veri setleri kullanılarak modellerin güvenilirliği artırılabilir. Ayrıca, başka derin öğrenme mimarileri ile çalışmalar yapılarak, sonuç kıyaslamaları yapılabilir. Modellerin eğitim süreleri ve bellek kullanımı üzerine daha detaylı analizler yapılabilir, bu da daha etkili ve hızlı modellerin geliştirilmesine katkı sağlayabilir.

KAYNAKÇA

Aditi, M. K., & Poovammal, E. (2019). Image Classification Using A Hybrid LSTM-CNN Deep Neural Network, *Int. J. Eng. Adv. Technol*, 8(6), 1342-1348.

Al-Hiary, H., Bani-Ahmad, S., Reyalat, M., Braik, M., & Alrahamneh, Z. (2011). Fast And Accurate Detection And Classification Of Plant Diseases, *International Journal Of Computer Applications*, 17(1), 31-38.

Al-Mahdi, I. N. O. (2023). Cnn Googlenet And Alexnet Architecture Deep Learning For Diabetic Retinopathy Image Processing And Classification, July, 1–23.

Altaş, Z., Özgüven, M. M., & Yanar, Y. (2019). Bitki Hastalık Ve Zararlı Düzeylerinin Belirlenmesinde Görüntü İşleme Tekniklerinin Kullanımı: Şeker Pancarı Yaprak Leke Hastalığı Örneği, s. 24-27 April

Aravinda, C. V. (2017). Classification And Clustering Of Infected Leaf Plant Using K-Means Algorithm In *International Conference On Cognitive Computing And Information Processing* (pp. 468-474). December, Springer, Singapore.

Barman, U., Choudhury, R. D., Sahu, D., & Barman, G. G. (2020). Comparison of convolution neural networks for smartphone image based real time classification of citrus leaf disease. *Computers and Electronics in Agriculture*, 177, 105661.

Bongulwar, D. M. (2021). Identification of Fruits Using Deep Learning Approach. *IOP Conference Series: Materials Science and Engineering*, 1049(1), 012004.

Chugh, G., Sharma, A., Choudhary, P., & Khanna, R. (2020). Potato leaf disease detection using inception V3. *Int. Res. J. Eng. Technol*, 7(11), 1363-1366.

Faek, G., & Al, S. (2019). Electrical And Computer Engineering Plant Disease Detection Using Svm Classification. *Ghassan Faek Shakir Al Daban Master Thesis Supervisor*

Doğan, F., & Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.

Doğan, F., & Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.

Dong, N., Zhao, L., Wu, C. H., & Chang, J. F. (2020). Inception v3 based cervical cell classification combined with artificially extracted features. *Applied Soft Computing*, 93,

106311.

Emirali, E., & Karşılıgil, M. E. (2022). Using word embeddings in detection of temporal expressions in turkish texts. *In 2022 30th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.,May

Fukushima, K. (1980). A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol, Cybern*, 36, 193-202.

Guan, Q., Wan, X., Lu, H., Ping, B., Li, D., Wang, L., ... & Xiang, J. (2019). Deep convolutional neural network Inception-v3 model for differential diagnosing of lymph node in cytological images: a pilot study. *Annals of translational medicine*, 7(14).

Gülmez, B. (2023). Parçacık sürü optimizasyonu destekli derin öğrenme ile gül yaprağı hastalık tespiti. 348–352.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.

Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.

Hinton, G., LeCun, Y., & Bengio, Y. (2015). Deep learning. *Nature*, 521(7553), 436-444.

Jhuria, M., Kumar, A., & Borse, R. (2013). Image processing for smart farming: Detection of disease and fruit grading. *In 2013 IEEE second international conference on image information processing (ICIIP-2013)* (pp. 521-526). IEEE ,December

Uysal, E., & Katkat, A. V. (2007). Bursa Yöresinde Yetiştirilen Kiraz Ağaçlarının Azot, Fosfor, Potasyum, Kalsiyum Ve Magnezyum İle Beslenme Durumları. *Anadolu Ege Tarımsal Araştırma Enstitüsü Dergisi*, 17(1), 71-84.

Kara, A. (2019). Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7(4), 882–892.

Karaoğlan, B. (2022). Görüntü İşlemenin Convolutional Neural Network (Cnn) Modeli Kullanılarak Tarımsal Alanda Uygulanması: Hastalıklı Yaprak Tespiti (Doctoral Dissertation).

- Khirade, S. D., & Patil, A. B.** (2015) Plant disease detection using image processing. *In 2015 International conference on computing communication control and automation* (pp. 768-771). IEEE., February.
- Korzniakov, K. A., Kislov, D. E., Altman, J., Doležal, J., Vozmishcheva, A. S., & Krestov, P. V.** (2021). Using U-Net-like deep convolutional neural networks for precise tree recognition in very high resolution RGB (red, green, blue) satellite images. *Forests*, 12(1), 66.
- Krogh, A.** (2008). What are artificial neural networks?. *Nature biotechnology*, 26(2), 195-197
- Kumar, S., Ratan, R., & Desai, J. V.** (2022). Cotton Disease Detection Using TensorFlow Machine Learning Technique. *Advances in Multimedia*, 2022
- Kurt, Ş.** (2020). Bitki Fungal Hastalıkları. Bitki Fungal Hastalıkları. *Akademisyen Kitap Evi*.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Lee, S. H., Chan, C. S., Mayo, S. J., & Remagnino, P.** (2017). How deep learning extracts and learns leaf features for plant classification. *Pattern Recognition*, 71, 1–13.
- Liu, S., & Deng, W.** (2015). Very deep convolutional neural network based image classification using small training sample size. *In 2015 3rd IAPR Asian conference on pattern recognition (ACPR)* (pp. 730-734). IEEE.
- Mohameth, F., Bingcai, C., & Sada, K. A.** (2020). Plant disease detection with deep learning and feature extraction using plant village. *Journal of Computer and Communications*, 8(6), 10-22.
- Palakodati, S. S. S., Chirra, V. R. R., Dasari, Y., & Bulla, S.** (2020). Fresh and rotten fruits classification using CNN and transfer learning. *Revue d'Intelligence Artificielle*, 34(5), 617–622.
- Ramanjot, Mittal, U., Wadhawan, A., Singla, J., Jhanjhi, N. Z., Ghoniem, R. M., Ray, S. K., & Abdelmaboud, A.** (2023). Plant Disease Detection and Classification: A Systematic Literature Review. *Sensors*, 23(10).
- Saleem, M. H., Potgieter, J., & Arif, K. M.** (2019). Plant disease detection and classification by deep learning. *Plants*, 8(11), 468.
- Schuster, M., & Paliwal, K. K.** (1997). Bidirectional recurrent neural networks. *IEEE*

transactions on Signal Processing, 45(11), 2673-2681.

Sengar, N., Dutta, M. K., & Travieso, C. M. (2018). Computer vision based technique for identification and quantification of powdery mildew disease in cherry leaves. *Computing*, 100(11), 1189–1201.

Seyrek, E. C. (2021). Hiperspektral görüntü sınıflandırma uygulamalarında makine ve derin öğrenme kullanımı (Master's thesis).

Siame-Namini, S., Tavakoli, N., & Namin, A. S. (2019). A comparative analysis of forecasting financial time series using arima, lstm, and bilstm. arXiv preprint arXiv:1911.09512.

Sibiya, M., & Sumbwanyambe, M. (2019). A computational procedure for the recognition and classification of maize leaf diseases out of healthy leaves using convolutional neural networks. *AgriEngineering*, 1(1), 119-131.

Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.

Solak, S., & Altınışik, U. (2018). Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması. *Sakarya University Journal of Science*, 22(1), 56-65.

Sulistyowati, T., Purwanto, P., Alzami, F., & Pramunendar, R. A. (2023). VGG16 Deep Learning Architecture Using Imbalance Data Methods For The Detection Of Apple Leaf Diseases. *Moneter: Jurnal Keuangan Dan Perbankan*, 11(1), 41–53.

Srivastava, P. (2020). Corn Leaf Disease Identification with Improved Accuracy.

Tejaswini, P., Singh, P., Ramchandani, M., Rathore, Y. K., & Janghel, R. R. (2022). Rice leaf disease classification using CNN. In *IOP Conference Series: Earth and Environmental Science* (Vol. 1032, No. 1, p. 012017). IOP Publishing. ,June

Taboada, M., Cabrera, E., Epelde, F., Iglesias, M. L., & Luque, E. (2013). Using an agent-based simulation for predicting the effects of patients derivation policies in emergency departments. *Procedia Computer Science*, 18, 641-650.

Tarım Bakanlığı (2016). Kiraz-Vişne Hastalık ve Zararlıları ile Mücadele Kitapçığı, 34-58

Turkoglu, M., Hanbay, D., & Sengur, A. (2019). Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests. *Journal of Ambient Intelligence and*

Humanized Computing, 1-11.

Türkoğlu, M. (2020). Görüntü işleme tabanlı bitki türleri ve hastalıkları tanıma

Yegnanarayana, B. (2009). Artificial neural networks. PHI Learning Pvt. Ltd,16-40

Yıldız, F. (2012) Bitki Fungal Hastalıkları (2012), 21-26

Woźniak, M., Wiczorek, M., & Silka, J. (2023). BiLSTM deep neural network model for imbalanced medical data of IoT systems. *Future Generation Computer Systems*, 141, 489-499.

Xia, X., Xu, C., & Nan, B. (2017). Inception-v3 for flower classification. *2017 2nd International Conference on Image, Vision and Computing, ICIVC 2017*, 783–787.